



Universidad  
Carlos III de Madrid

Trabajo de Fin de Grado

Doble Grado en Ingeniería Informática y Administración de Empresas

# **Predicción de Quiebras Empresariales Mediante Inteligencia Artificial**

Autor: Álvaro Montero Casarejos

Tutor de Informática: David Quintana Montero

Tutor de ADE: Miguel Ángel López Gómez

Colmenarejo, febrero 2016





# Abstract

El estudio de la predicción de quiebras empresariales ha incrementado su interés e importancia durante los últimos años, especialmente desde comienzo de la crisis de 2008, diferentes actores de la economía mundial, han requerido de sistemas capaces de identificar señales de insolvencia, con objeto de evitar los conocidos escenarios adversos asociados a las quiebras.

A partir de los años 90, el campo de la Inteligencia Artificial se adentra en el estudio de la quiebra empresarial, consiguiendo una mejora de tasas predictivas, frente a las obtenida por parte de los modelos teóricos y estadísticos.

La presente investigación se lleva a cabo con el propósito de establecer una génesis en el desarrollo de nuevos modelos de predicción, facilitando una comparación de las diferentes técnicas predictivas empleadas a lo largo de los últimos 50 años, basada tanto en investigaciones de terceros, como en el estudio empírico propio.

Utilizando de manera independiente las máquinas de soporte vectorial y los árboles de decisión sobre la muestra estudiada, se alcanzan las mejores tasas de acierto. No obstante, el estudio empírico revela una mejora generalizada de las tasas de acierto al realizar una optimización previa de la muestra mediante el uso de técnicas de selección de atributos.

Por otro lado, el trabajo justifica la tendencia actual de emplear modelos híbridos en la predicción de quiebras, al lograr la tasa de acierto más alta de la investigación (93.47%) mediante la combinación de cinco técnicas clasificatorias a través del clasificador combinatorio por votación.

**Palabras clave:** Quiebra, predicción, empresas, inteligencia artificial, solvencia, modelos, análisis, híbridos, ratios financieros.



# Agradecimientos

La finalización de este trabajo de fin de estudios no hubiese sido posible sin la orientación y dedicación manifiesta de mis tutores de TFG, David Quintana Montero y Miguel Ángel López Gómez. Sus inmediatos consejos y réplicas ante las dudas suscitadas, han motivado mi interés y entusiasmo en la investigación sobre el uso de inteligencia artificial aplicado a las ciencias empresariales.

Quiero agradecer a mis mentores profesionales y compañeros, Kike, Javi y Rubén, por permitirme trabajar en este proyecto durante los últimos meses, así como por ser los ejemplos más cercanos de perseverancia, conocimiento y liderazgo que he tenido durante mi etapa formativa.

Deseo dar las gracias también, a mi hermano Gonzalo, por amenizar los peores días. Así como agradecer a mi novia Lucía, su cariño, comprensión y paciencia.

Mi más especial dedicación a mi familia y amigos, por todo el apoyo recibido a lo largo de estos cinco años y medio. Especialmente a mis padres y a mi abuela, por los valores que me han inculcado y por el esfuerzo continuo que han realizado siempre.

Por último, quisiera hacer extensiva mi gratitud a la Universidad Carlos III, institución que ha construido los pilares de mi conocimiento y me ha permitido abrir la mente en otras latitudes gracias a sus convenios internacionales.

A todos ellos, mi más sincero agradecimiento.

Álvaro Montero Casarejos

Colmenarejo, a 24 de Febrero de 2016.





# Índice General

<b>1. Introducción .....</b>	<b>0</b>
1.1    Preámbulo .....	1
1.2    Objetivos .....	2
1.3    Estructura de la Memoria.....	2
1.4    Medios para el Desarrollo del Proyecto .....	5
<b>2. Marco Teórico de la Quiebra Empresarial .....</b>	<b>6</b>
2.1    Quiebra.....	7
2.2    Tipos de Quiebra .....	8
2.3    Regulación .....	8
2.4    Procedimiento concursal.....	10
2.5    Predicción de quiebras .....	10
2.6    Eficiencia de los Modelos de Predicción de Quiebras.....	11
<b>3. Revisión de la Literatura - Modelos de Predicción de Quiebras.....</b>	<b>13</b>
3.1    Clasificación de los Modelos de Predicción de Quiebras .....	14
3.2    Modelos Teóricos de Predicción .....	15
3.2.1    Medidas de Descomposición del Balance (BSDM) .....	15
3.2.2    Teoría de la Ruina del Jugador .....	15
3.2.3    Teoría de Gestión de Tesorería .....	16
3.2.4    Teorías de Riesgo de Crédito.....	16
3.2.4.1    Modelo de Black-Scholes-Merton (BSM – Prob) .....	17
3.2.4.2    Modelo de CreditMetrics.....	18
3.2.4.3    Modelo de Moody’s KMV .....	19
3.2.4.4    Modelo de CSFB’s CreditRisk+ .....	21



3.2.4.5	Modelo de McKinsey's CreditPortfolio View .....	21
3.3	Modelos Estadísticos de Predicción .....	23
3.3.1	Análisis Univariante .....	24
3.3.2	Análisis Discriminante .....	24
3.3.3	Modelos de Regresión Logística .....	26
3.3.3.1	Modelo Logit .....	27
3.3.3.2	Modelo Probit .....	27
3.3.4	Modelo de Probabilidad Lineal .....	28
3.3.5	Gráficos de Control de Suma Acumulada (CUSUM) .....	29
3.3.6	Modelos de Ajuste Parcial .....	30
3.3.7	Técnica de Escalado Multidimensional (MDS) .....	31
3.4	Técnicas de Inteligencia Artificial Aplicadas .....	33
3.4.1	Razonamiento Basado en Casos (CBR) .....	33
3.4.2	Modelos de redes neuronales .....	36
3.4.2.1	Perceptrón Multicapa (MLP) .....	39
3.4.2.2	Red Neuronal Probabilística (PNN) .....	39
3.4.2.3	Red de Neuronas de Base Radial (RBFN) .....	41
3.4.2.4	Mapas Autoorganizados (SOM) .....	41
3.4.3	Conjuntos aproximados .....	42
3.4.4	Algoritmos genéticos .....	45
3.4.5	Máquinas de soporte vectorial .....	46
3.4.6	Árboles de decisión (Particionamiento Recursivo) .....	47
3.4.7	K-Vecinos más Cercanos .....	48
3.5	Modelos Híbridos .....	49
3.6	Análisis de los modelos de predicción .....	52
3.6.1	Comparativa de modelos .....	52



3.6.1.1	Comparativa de Modelos Teóricos .....	58
3.6.1.2	Comparativa de Modelos Estadísticos .....	60
3.6.1.3	Comparativa de Técnicas de Predicción Basadas en IA .....	63
3.7	Ratios empleados en modelos de IA .....	67
3.8	Conclusiones del Capítulo .....	71
<b>4.</b>	<b>Estudio Empírico.....</b>	<b>73</b>
4.1	Introducción .....	74
4.2	Muestra estudiada .....	74
4.2.1	Variables Estudiadas.....	76
4.2.2	Distribución de Variables .....	78
4.3	Selección de Atributos.....	79
4.3.1	Correlación Atributo - Quiebra.....	79
4.3.2	Ratio de Ganancia de Información .....	80
4.3.3	Clasificador OneR .....	80
4.3.4	ReliefF.....	80
4.3.5	Incertidumbre Simétrica.....	81
4.3.6	Resultado global de la selección de atributos.....	81
4.4	Experimentos planteados.....	83
4.5	Resultados .....	87
4.5.1	Experimento 1 .....	87
4.5.2	Experimento 2 .....	88
4.5.3	Experimento 3 .....	90
4.5.4	Experimento 4 .....	91
4.6	Conclusiones del Capítulo .....	92
<b>5.</b>	<b>Conclusiones, Limitaciones y Trabajo Futuro .....</b>	<b>95</b>





5.1	Conclusiones.....	96
5.2	Limitaciones.....	97
5.3	Trabajo Futuro.....	98
<b>6.</b>	<b>Planificación y Presupuesto .....</b>	<b>101</b>
6.1	Planificación .....	102
6.1.1	Planificación Inicial .....	102
6.1.2	Planificación Real.....	104
6.2	Presupuesto.....	106
<b>7.</b>	<b>Referencias .....</b>	<b>107</b>
<b>8.</b>	<b>Anexo 1.....</b>	<b>113</b>
<b>9.</b>	<b>Anexo 2.....</b>	<b>120</b>
<b>10.</b>	<b>Anexo 3.....</b>	<b>128</b>



# Índice de Figuras

Figura 1. Representación de las funciones Logit, Probit y Modelo de Probabilidad Lineal (LPM).....	29
Figura 2. Mapa perceptual de empresas quebradas y solventes.....	32
Figura 3. Ciclo Básico de un Sistema CBR [23] .....	36
Figura 4. Arquitectura de una red neuronal [63] .....	37
Figura 5. Arquitectura de redes probabilísticas [64].....	40
Figura 6. Redes neuronales de base radial [26] .....	41
Figura 7. Ejemplo de transformación de datos [29].....	47
Figura 8. Ejemplo de creación de árbol binario de decisión para la predicción de quiebras [68] .....	48
Figura 9. Ejemplo de K-vecinos cercanos [66].....	49
Figura 10. Diagrama de porcentajes de modelos de predicción empleados por categoría .....	52
Figura 11. Diagrama de porcentajes de modelos teóricos empleados.....	53
Figura 12. Diagrama de porcentajes de modelos estadísticos empleados .....	53
Figura 13. Diagrama de porcentajes de modelos basados en IA empleados .....	54
Figura 14. Diagrama de tasas de precisión predictiva por categoría .....	55
Figura 15. Diagrama de porcentajes de errores tipo I por categoría .....	55
Figura 16. Diagrama de porcentajes de errores tipo II por categoría .....	56
Figura 17. Diagrama de tasas de precisión predictiva de modelos estadísticos.....	57
Figura 18. Diagrama de tasas de precisión predictiva de modelos basados en IA .....	57
Figura 19. Diagrama de porcentajes de errores tipo I de modelos estadísticos.....	57
Figura 20. Diagrama de porcentajes de errores tipo I de modelos basados en IA .....	57
Figura 21. Diagrama de porcentajes de errores tipo II de modelos estadísticos.....	57
Figura 22. Diagrama de porcentajes de errores tipo II de modelos basados en IA .....	57
Figura 23. Representación gráfica: Pasivo circulante > Activo Circulante [65] .....	69
Figura 24. Diagrama Completo del Experimento 4 .....	86
Figura 25. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 1) .....	87
Figura 26. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 2) .....	88
Figura 27. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 3) .....	90
Figura 28. Diagrama de tasas medias de error generadas por los clasificadores combinatorios (Experimento 4).....	91



Figura 29. Diseño Inicial del Sistema Híbrido Propuesto .....	100
Figura 30. Diagrama de la planificación presupuestada .....	103
Figura 31. Diagrama de la planificación real .....	105



# Índice de Tablas

Tabla 1. Categorías de modelos de predicción .....	14
Tabla 2. Medición del Riesgo de Crédito [8] .....	19
Tabla 3. Ratios componentes del Z-Score .....	26
Tabla 4. Histórico de modelos híbridos de predicción de quiebras .....	51
Tabla 5. Rendimiento Modelos Estadísticos vs Modelos Basados en IA.....	57
Tabla 6. Ventajas y limitaciones de los modelos de predicción teóricos.....	59
Tabla 7. Comparativa de modelos de crédito .....	60
Tabla 8. Ventajas y limitaciones de los modelos estadísticos.....	63
Tabla 9. Ventajas y limitaciones de las técnicas basadas en IA.....	67
Tabla 10. Recuento de ratios más empleados .....	68
Tabla 11. Variables incluidas en la muestra estudiada .....	77
Tabla 12. Variables menos significativas según técnicas de selección .....	82
Tabla 13. Matriz de Confusión .....	84
Tabla 14. Especificidad y Sensibilidad de clasificadores (Experimento 1) .....	88
Tabla 15. Tasas de error, precisión, especificidad y sensibilidad de clasificadores (Experimento 2) .....	89
Tabla 16. Comparativa de tasas de error en experimentos 1 y 2 .....	89
Tabla 17. Tasas de error y precisión medias de clasificadores combinados (Experimento 2).....	90
Tabla 18. Comparativa de tasas de error en experimentos 3 y 4 .....	91
Tabla 19. Histórico de Metodologías .....	117
Tabla 20. Ratios seleccionados para los estudios escogidos [46] .....	119
Tabla 21. Comparativa de selección de atributos .....	120
Tabla 22. Matrices de confusión medias de los clasificadores .....	122
Tabla 23. Matrices de confusión medias de los clasificadores .....	124
Tabla 24. Errores obtenidos por clasificador e iteración (Experimento 3) .....	125
Tabla 25. Errores obtenidos por clasificador e iteración (Experimento 4) .....	126
Tabla 26. Parametrización en técnicas empleadas .....	127

## Capítulo 1.

# Introducción

En este primer capítulo se proporciona una visión general del proyecto, explicando la distribución de los contenidos recogidos en la memoria, así como aspectos estructurales y terminología utilizada a lo largo de la memoria.



## 1.1 Preámbulo

Entre las consecuencias derivadas de la crisis económica y financiera iniciada en 2008, se encuentra la quiebra de numerosas empresas en todo el mundo. Concretamente en España, 45.232 sociedades mercantiles se declararon en concurso de acreedores desde el comienzo de la depresión, según los datos de la agencia de rating española Axesor [62].

A pesar de que la predicción de quiebras ha sido un tema ampliamente tratado durante los últimos cincuenta años, la crisis ha devuelto el interés por la investigación sobre el fracaso empresarial. Su objetivo principal, no es otro que detectar si una empresa no será capaz de pagar sus deudas, con objeto de anteponerse a esta situación y establecer las acciones correspondientes para evitar o disminuir las consecuencias adversas.

La consumación de este objetivo entraña numerosas dificultades, teniendo en cuenta que cada empresa guarda unas características concretas que la hacen única y diferente con respecto del resto (sector económico, actividad realizada, estructura financiera, situación del mercado, regulación existente, número de empleados, deudas contraídas, gastos, etc.). Al mismo tiempo que los imprevisibles giros del mercado acentúan aún más el problema.

Sin embargo, existen ciertos modelos y técnicas de predicción, científicamente estudiadas y evolucionadas, que pueden ser empleadas en el entorno empresarial con la intención de que inversores, empresarios y otros interesados, mejoren la toma de sus decisiones y eviten las consecuencias finales de la quiebra.

La Inteligencia Artificial es un campo que ha evolucionado considerablemente en los últimos treinta años, debido en gran medida, a los avances tecnológicos de los equipos informáticos. Esto ha permitido que actualmente se utilicen nuevas técnicas capaces de lograr mejores resultados y mayor precisión en la predicción de quiebras.



## 1.2 Objetivos

Este trabajo persigue cumplir las siguientes metas:

- Definir el marco teórico de la predicción de quiebras mediante la puntualización de los conceptos principales. La ejecución de este objetivo implicará en primer lugar la explicación del término “quiebra”, desde los puntos de vista económico y regulatorio, así como esclarecer la tipología y problemática del tema en cuestión.
- Estableciendo como punto de partida la publicación de M. Adnan Aziz y Humayon A. Dar que resume el funcionamiento y la utilidad de las herramientas principales en la predicción de quiebras en 2006 [4], se realizará una revisión de los modelos de predicción citados, para posteriormente actualizar y ampliar esta investigación, añadiendo nuevas técnicas empleadas en el área de estudio con objeto de situar la investigación en el momento actual.
- Realizar una comparación de las capacidades y hándicaps de los modelos estudiados.
- Medir en términos cuantitativos la utilización de los diferentes modelos y resumir el rendimiento producido por cada uno de ellos.
- Identificar las variables que mejor explican la quiebra de una empresa.
- Confeccionar un estudio empírico de corte científico propio e independiente en el que se ponga a prueba el rendimiento de las diferentes técnicas soportadas por el software disponible.
- Proponer indicaciones para la elaboración de un sistema de predicción presumiblemente útil a partir de las conclusiones obtenidas.

## 1.3 Estructura de la Memoria

La configuración seleccionada para organizar los contenidos de esta memoria comprende dos bloques diferenciados: el primer bloque, formado por el segundo y el tercer capítulo, se corresponde con la memoria de Administración y Dirección de Empresas; mientras que el segundo bloque, abarca la memoria de Informática, comprendiendo los capítulos 4 y 5.

Con el objetivo de crear una base de conocimiento para desarrollar nuestro trabajo y poder amparar el posterior estudio empírico, el primer bloque de la memoria se enmarca dentro de la quiebra empresarial y su predicción, tomando como punto de partida los conceptos básicos de la



quiebra empresarial y evolucionando hacia la predicción de quiebras. Este bloque se estructura de la siguiente forma:

- El segundo capítulo describe el marco teórico de la quiebra empresarial, introduciendo conceptos como las características, tipologías, regulación y procedimientos jurídicos relacionados con la quiebra empresarial y con la predicción de la misma.
- El tercer capítulo elabora una revisión de la literatura de los modelos de predicción de quiebras empleados hasta el momento, describiendo el funcionamiento y contrastando la efectividad de los modelos teóricos, estadísticos y basados en inteligencia artificial. Inicialmente este capítulo trata de manera general las diferentes teorías y métodos empleados en la predicción de quiebras, para posteriormente centrar su atención en las técnicas de predicción basadas en inteligencia artificial.

El segundo bloque de la memoria, correspondiente a la parte de Informática, cuenta con la siguiente estructura:

- El capítulo cuatro, se corresponde con la elaboración del estudio empírico independiente sobre la predicción de quiebras mediante el uso de diferentes técnicas predictivas basadas en Inteligencia Artificial. En primer lugar se lleva a cabo una fase de selección de atributos mediante diferentes procedimientos y posteriormente, son elaborados cuatro experimentos en los que se pone a prueba el rendimiento de las técnicas de clasificación utilizadas resolver el problema de la predicción de quiebras. El primer experimento probará 16 técnicas de clasificación sobre una muestra original, el segundo experimento volverá a realizarse con las técnicas anteriores sobre la muestra modificada en base a los resultados obtenidos en la fase de selección de atributos. El tercer experimento realiza una combinación de los mejores clasificadores y comprueba su rendimiento con la muestra original. Finalmente, el cuarto y último experimento comprueba el rendimiento de esta combinación de clasificadores sobre la muestra modificado empleado en el experimento 2. Tras analizar los resultados obtenidos en los experimentos, el capítulo finaliza con las conclusiones específicas extraídas del estudio empírico en su totalidad.





- El quinto capítulo, se organiza en tres secciones. En primer lugar se comentan las conclusiones finales del trabajo en su conjunto. Para lograr una resolución satisfactoria sobre el problema de la predicción de quiebras, se interrelaciona la información procesada en la revisión de la literatura con las conclusiones extraídas en el estudio empírico, indicando las características y componentes recomendables, para desarrollar a partir de este trabajo, un sistema de predicción de quiebras en futuros proyectos. Este último aspecto es desglosado en el último apartado “Trabajo Futuro”, donde de forma adicional a la propuesta de recomendaciones para el desarrollo de un sistema predictor de quiebras, también sugeriremos una serie de investigaciones o variaciones a nuestro trabajo, cuya realización podría aportar valor en la creación de soluciones para predecir la quiebra de manera exitosa.
- El capítulo seis informa acerca de la planificación inicial proyectada y la planificación finalmente ejecutada, así como del presupuesto estimado que conlleva la realización de este trabajo.

Para facilitar la comprensión de los contenidos, la memoria dispone de tres anexos al final del documento:

- En el anexo 1 se incluye un listado histórico acerca de la evolución de los modelos empedados en la predicción de quiebras, así como una tabla en la que son señalados los ratios empleados en una muestra de estudios.
- El anexo 2 contiene los resultados generados a partir del estudio empírico.
- Por último, el anexo 3 se corresponde con el resumen en inglés del trabajo.

Debido a la naturaleza interdisciplinar de este trabajo, al finalizar los capítulos tres y cuatro, se exponen conclusiones específicas de cada capítulo. El motivo no es otro que facilitar la extracción de información útil ante el desarrollo del trabajo, para finalmente, realizar una conclusión global contraponiendo las nociones de la sección teórica frente a los resultados obtenidos en la parte empírica.



Por su parte, este capítulo de introducción se constituye de: texto introductorio, determinación de objetivos del estudio, definición de la estructura de la memoria y desglose de medios necesarios para la realización del proyecto.

## **1.4 Medios para el Desarrollo del Proyecto**

Para la realización de este proyecto y para poder alcanzar los objetivos propuestos, se necesita disponer de los siguientes medios:

- Ordenador personal TOSHIBA Portegé R700
- Microsoft Office Professional Plus 2013
- Acceso a internet (Navegador Google Chrome).
- Matlab 2013a
- Librería PRTools 4.2.5
- WEKA
- CSVed 2.3.4



## Capítulo 2.

# Marco Teórico de la Quiebra Empresarial

El segundo capítulo del trabajo trata las nociones básicas que atañen a la quiebra empresarial y a su predicción, haciendo referencia a los significados jurídicos y económicos del concepto quiebra, así como introduce en el trabajo los modelos predictivos.



## 2.1 Quiebra

La Real Academia Española atribuye el término “quiebra”, al juicio por el que se incapacita patrimonialmente a alguien por su situación de insolvencia y se procede a ejecutar todos sus bienes en favor de la totalidad de sus acreedores.

Económicamente, se denomina quiebra a la situación patrimonial perjudicial para la empresa, generada al encontrarse un valor del activo en libros inferior al valor de las deudas contraídas con terceros, dando lugar a un patrimonio neto negativo causado por las pérdidas prolongadas en el tiempo durante varios ejercicios financieros. Técnicamente, la situación de quiebra ocurre cuando el ratio de solvencia (Activo Total/Pasivo Total) es menor que 1.

En conclusión, la quiebra es la coyuntura en la que una empresa es incapaz de hacer frente a sus obligaciones de pago<sup>1</sup>. Caracterizada principalmente por su carácter permanente, siendo conocida como bancarrota.

Frecuentemente, el término quiebra es relacionado con el concepto de suspensión de pagos, no obstante, existen matices que diferencian ambas ideas. En primer lugar, el término suspensión de pagos hace referencia a una circunstancia contable por la que una empresa declara su incapacidad temporal de hacer frente a sus obligaciones en el corto plazo, debido a su incapacidad de liquidar sus activos, es decir, la empresa tiene activos suficientes para hacer frente a las deudas existentes, sin embargo no puede convertirlos en dinero para hacer frente a las obligaciones más inmediatas. Por el contrario, una empresa en quiebra, no tiene capacidad para hacer frente a las deudas.

Al declararse una empresa en suspensión de pagos, comienza un procedimiento legal cuyo objetivo reside en alcanzar un acuerdo entre deudor y acreedor, siendo posible la resolución de dicha circunstancia, mediante un aplazamiento, una refinanciación o una renegociación de las condiciones de pago.

---

<sup>1</sup> Busconómico. Diferencia entre suspensión de pagos y quiebra técnica. <http://www.busconómico.com/>



Este trabajo responde a una investigación de naturaleza económica, por esta razón, utilizaremos la expresión “quiebra”, haciendo alusión a la problemática condición en la que una empresa cesa su actividad al no tener suficiente liquidez para pagar sus deudas.

## 2.2 Tipos de Quiebra

Las quiebras pueden ser clasificadas en tres categorías dependiendo de las condiciones causantes:

1. **Fraudulenta:** Existe una intención manifiesta de quebrar la empresa con el fin de defraudar a terceros (principalmente acreedores). Tiene como objetivo la obtención de un lucro en perjuicio de otras personas.
2. **Culpable:** La quiebra sucede como consecuencia de negligencias por parte de uno o varios empresarios que incumplen sus obligaciones.
3. **Fortuita:** Se origina la situación de quiebra debido a situaciones de infortunio que reducen el capital de la empresa disminuyendo la capacidad de hacer frente a las obligaciones existentes. Es posible exculpar legalmente al empresario. Son las más comunes y para las que se suelen enfocar los modelos de predicción.

## 2.3 Regulación

En España la situación jurídica de quiebra y suspensión de pagos estaba regulada por el Código de Comercio de 1885 y por la Ley de suspensión de pagos 26 de julio de 1922, sin embargo, esta Ley y los artículos referentes a la quiebra incluidos en el Código de Comercio, fueron derogados por la actual legislación concursal (Ley 22/2003 del 9 julio, posteriormente reformada por la Ley 38/2011 de 10 de Octubre) cuyos artículos 2 y 5 de dicha Ley *dicen*:

*“Artículo 2.- Presupuesto Objetivo*

1. *La declaración de concurso procederá en caso de insolvencia del deudor común.*
2. *Se encuentra en estado de insolvencia el deudor que no puede cumplir regularmente sus obligaciones exigibles.*



3. Si la solicitud de declaración de concurso la presenta el deudor, deberá justificar su endeudamiento, su estado de insolvencia, que podrá ser actual o inminente. Se encuentra en estado de insolvencia inminente el deudor que prevea que no podrá cumplir regular o puntualmente sus obligaciones.

4. Si la solicitud de declaración de concurso la presenta un acreedor, deberá fundarla en título por el cual se haya despachado ejecución o apremio sin que el embargo resultasen vienen libres bastantes para el pago, o en la existencia de alguno de los siguientes hechos:

1. El sobreseimiento general en el pago corriente de las obligaciones del deudor.
2. La existencia de embargos por ejecuciones pendientes que afecten de una manera general al patrimonio del deudor.
3. El alzamiento o la liquidación apresurada o ruinosa de sus bienes por el deudor.
4. El incumplimiento generalizado de obligaciones de alguna de las clases siguientes: las de pago de obligaciones tributarias exigibles durante los tres meses anteriores a la solicitud de concursos; las de pago de cuotas de la Seguridad social, y demás conceptos de recaudación conjunta durante el mismo periodo; las de pago de salarios e indemnizaciones y demás retribuciones derivadas de las relaciones de trabajo correspondientes a las tres últimas mensualidades.

#### *Artículo 5.-Deber de solicitar la declaración de concurso*

1. El deudor deberá solicitar la declaración de concurso dentro de los meses siguientes a la fecha en que se hubiera conocido o debido conocer su estado de insolvencia.

2. Salvo prueba, en contrario, se presumirá que el deudor ha conocido su estado de insolvencia cuando haya acaecido alguno de los hechos que puedan servir de fundamento de concurso necesario conforme al apartado 4 del artículo 2 y, si se trata de alguno de los previstos en su párrafo 4., Haya transcurrido el plazo correspondiente. [···]”

Existen otras referencias legales de regulación ante problemas de cumplimiento de obligaciones como la ley de sociedades de Capital (LSC) (Real Decreto Legislativo 1/2010 de 2 de julio) contempla:

*“Artículo 363.- Causas de disolución*

*1. La sociedad de capital deberá disolverse:*

*a. Por el cese en el ejercicio de la actividad o actividades que constituyan al objeto social en particular, se entenderá que se ha producido el cese tras un periodo de inactividad superior a un año.*

*b. Por la conclusión de la empresa que constituya su objeto.*

*c. Por la imposibilidad manifiesta de conseguir el fin social.*

*d. Por la paralización de los órganos sociales de modo que resulta imposible su funcionamiento.*

*e. Por pérdidas que dejen reducido el patrimonio neto a una cantidad inferior a la mitad del capital social, a no ser que éste se aumente o se reduzca en la medida suficiente, y siempre que no sea procedente solicitar la declaración de concurso.*

*f. Por reducción del capital social por debajo del mínimo legal, que no sea consecuencia del cumplimiento de una ley.*

*g. Porque el valor nominal de las participaciones sociales sin voto o de las acciones sin voto excediera de la mitad del capital social desembolsado y no se restableciera la proporción en el plazo de dos años.*

*h. Por cualquier otra causa establecida en los estatutos. [...]”*

## **2.4 Procedimiento concursal**

Cuando una empresa se declara legalmente en quiebra, la empresa puede acudir a un procedimiento concursal donde se examina su patrimonio y se comprueba la posibilidad de liquidar los activos presentes, con objeto de saldar las deudas contraídas, respondiendo así a los acreedores.

## **2.5 Predicción de quiebras**

Denominamos “predicción de quiebra” a la acción o capacidad de prever o conocer de antemano si una empresa entrará en situación de quiebra en un futuro cercano, a partir de cualquier tipo de información disponible en el momento actual.

La predicción de quiebra responde a un problema clasificatorio, donde dado unos datos sobre una empresa y/o sobre su entorno, es necesario clasificar dicha empresa en dos o más clases. Habitualmente el resultado de la predicción responde a dos grupos diferenciados: empresas que

futuramente se encontrarán en situación de quiebra y empresas que no se encontraran en esta situación.

Entre las dificultades que entraña la predicción de quiebras financieras, encontramos la invalidez metodológica existente para determinar modelos temporalmente estables. La quiebra empresarial se corresponde con la última etapa de una serie de situaciones negativas ocurridas a lo largo de un periodo de tiempo para una empresa determinada. Por otro lado, los parámetros que definen a una empresa son muy característicos: el número de empleados, el sector al que pertenece, el mercado en el que opera, el momento económico mundial en el que transcurra su actividad, el producto que vende, etc. Por tanto, cualquier variación en estos parámetros, impacta directamente en la precisión de un modelo de predicción de quiebras. Incluso desarrollándose un modelo personalizado para los parámetros que definen a una empresa determinada, existe la posibilidad de que las características que definen a la economía del momento varíen (i.e. se origina una nueva crisis financiera), terminado por inutilizar dicho modelo.

Además, existen restricciones para obtener datos de empresas quebradas, bien porque la información contable de la empresa desaparece con ella, o bien porque los directivos de las empresas son reacios a facilitar información de la compañía declarada como insolvente.

Otra de las dificultades encontradas en el campo de estudio, es la selección de variables explicativas para la quiebra empresarial, puesto que muchos de los datos son irrelevantes y pueden ser desechados, otros son importantes y deben ser incluidos, incluso es posible que con el transcurso del tiempo, algunos de los datos redundantes pasen a ser cruciales y viceversa. Como conclusión, cada empresa y cada momento histórico pueden suponer estudios independientes.

## **2.6 Eficiencia de los Modelos de Predicción de Quiebras**

Decimos que un modelo es eficiente, fundamentalmente, si es capaz de diferenciar con precisión las empresas que están en situación de bancarrota de las que no lo están, es decir si obtiene una tasa de acierto alta (precisión) y, por tanto, minimiza la tasa de error. El número de errores se desglosa en número de errores de tipo I y errores de tipo II:

- A) El modelo clasifica como no insolvente (sana) a una empresa que quiebra. (Error de tipo I o falso positivo).





- B) El modelo predice que una empresa quiebra, sin embargo es solvente. (Error de tipo II o falso negativo).

La determinación de un error de tipo I, de tipo II o de la suma de ambos, viene dada por diferentes puntos de corte (indicios para determinar si un resultado representa a una empresa sana o a una fracasada) que terminan por diagnosticar la fortaleza del modelo. El punto de corte minimiza el número total de errores de clasificación de las firmas.

En cualquier caso, pese a que la eficiencia total es la magnitud más importante de un modelo, en el mundo real se otorga tanta importancia a la precisión del modelo como al coste de los errores.



## Capítulo 3.

# Revisión de la Literatura - Modelos de Predicción de Quiebras

Con objeto de conocer los recursos disponibles para resolver el problema de la predicción de quiebras, realizamos una revisión de la literatura para comprender el funcionamiento de los modelos de predicción utilizados, considerando aquellos más empleados y efectivos, así como distinguiendo las variables evaluadas más explicativas.

### 3.1 Clasificación de los Modelos de Predicción de Quiebras

Los modelos de predicción de quiebras pueden clasificarse en dos categorías en función del origen de la información que utilizan como input para realizar el análisis de insolvencia económica:

1. Aproximación en base contable:

Utilizan métodos cuantitativos y cualitativos aplicados a la solvencia de una empresa, tomando como fuente de información los estados contables.

2. Estimación a partir de fuentes alternativas y superiores:

Aquellos que usan la información dinámica de mercado y su variabilidad para estimar probabilidades de quiebra, de tal manera que las fuentes de datos quedan abiertas a cualquier información relacionada con la probabilidad de quiebra además de los estados contables. Por ejemplo: información bursátil, particularidades del sector en el que se realiza la actividad, regulación, facilidades de acceso al crédito, etc.

También es posible categorizar los modelos de predicción atendiendo a su propósito investigativo tal y como se refleja en la tabla 1:

Categoría	Características Principales
Modelos Teóricos	<ul style="list-style-type: none"><li>• Orientados a causas cualitativas de insolvencia.</li><li>• Utilización de información que satisfaga el argumento teórico.</li><li>• Multivariante.</li><li>• Suelen usar técnicas estadísticas para facilitar un soporte cuantitativo al argumento teórico.</li></ul>
Modelos Estadísticos	<ul style="list-style-type: none"><li>• Centrados en síntomas de insolvencia.</li><li>• Datos extraídos de cuentas contables de compañías.</li><li>• Univariantes o multivariantes (más común).</li><li>• Siguen procedimientos de modelos clásicos.</li></ul>
Modelos Basados en Inteligencia Artificial (AIES)	<ul style="list-style-type: none"><li>• Centrados en síntomas de insolvencia.</li><li>• Información extraída cuentas contables de las compañías.</li><li>• Normalmente multivariante.</li><li>• Resultantes de avances tecnológicos y del desarrollo de la información.</li><li>• Fuerte dependencia de tecnología computacional.</li></ul>

Tabla 1. Categorías de modelos de predicción

## 3.2 Modelos Teóricos de Predicción

### 3.2.1 Medidas de Descomposición del Balance (BSDM)

BSDM es una de las teorías básicas centradas en la descomposición del balance que persigue el objetivo de prever y evitar insolvencias. El procedimiento consiste en la observación de los cambios sucedidos en las cuentas que conforman el balance, siguiendo el argumento principal de que “las empresas tienden a mantener un estado de equilibrio que asegura el mantenimiento de la estructura de las empresas existentes”.

Existe una mayor probabilidad de que una empresa sea incapaz de mantener el estado de equilibrio cuando en un período razonable de tiempo, los estados financieros de la empresa indican cambios relevantes en la composición del balance de los activos y los pasivos.

Esta teoría no tiene mayor complejidad que la de entender que todas las empresas tratan de mantener un equilibrio en su estructura financiera. El acontecimiento de cambios significativos en el balance revela una incapacidad de mantener el equilibrio por parte de la empresa, pudiendo ser cualquiera de estos cambios el detonante de la insolvencia económica en la empresa.

Autores como Lev [1] o Booth [3] aplican esta lógica económica de quiebra probable de empresas.

### 3.2.2 Teoría de la Ruina del Jugador

Dentro del contexto de la insolvencia empresarial, la empresa interpreta el papel de un jugador de apuestas. La empresa continuará llevando a cabo su actividad hasta que su patrimonio neto sea igual a 0, momento en el que quebraría.

Esta teoría asume que la empresa ha obtenido cierta cantidad de capital en efectivo (caja), cuyo uso podría suponer el fin o continuidad de la empresa de forma aleatoria en función de las operaciones existentes.

La empresa obtiene en todo momento un flujo de caja, que bien puede ser positivo o negativo, por tanto existe una probabilidad de que el flujo de caja sea negativo durante varios periodos consecutivos. Dado que la empresa ya no tiene el capital en efectivo, la empresa se declararía en quiebra, aunque seguiría siendo solvente siempre y cuando su patrimonio neto sea

positivo. El valor del patrimonio neto de la empresa será obtenido a partir del valor de liquidación del capital contable.

En el artículo publicado en 1973 por Wilcox [3] fue estimado el “margen de quiebra” en función de los flujos de efectivo, tanto positivos como negativos y asignando, como si se tratase de una reserva, el valor de la equidad en los libros contables, mediante la fórmula:

$$\text{Margen de Quiebra} = \frac{(\text{Equidad en libros} + \text{Flujo de Caja Esperado})}{\text{Volatilidad del Flujo de Caja}}$$

Los flujos de caja suman o restan a la reserva, sin embargo si la reserva se agota la empresa se considera en quiebra.

### 3.2.3 Teoría de Gestión de Tesorería

La gestión de los balances de tesorería es uno de los aspectos con mayor importancia para las empresas a corto plazo. El desequilibrio continuado entre entradas y salidas de efectivo, puede originar dificultades financieras para la empresa.

La gestión de tesorería comprende la gestión de dinero en efectivo desde que comienza su tránsito a la empresa hasta que la abandona en los pagos y su error puede ser concretado como el desequilibrio entre las entradas y las salidas de efectivo, pudiendo conducir a la empresa a un estado de incapacidad para hacer frente a sus obligaciones financieras a medida que maduran [4].

Popularmente, el modelo de demanda de dinero que describe el comportamiento de la gestión de tesorería es el que sigue el enfoque de la gestión de tesorería de inventario, donde la demanda de dinero por parte de una empresa depende del volumen de las transacciones [5].

### 3.2.4 Teorías de Riesgo de Crédito

El riesgo de crédito se corresponde a la exposición que afronta una empresa de que una contraparte no cumpla con sus obligaciones de pago. Las teorías de riesgo están vinculadas a los acuerdos de Basilea I y Basilea II, en lo que refiere a firmas financieras. Parte de estos acuerdos hacían hincapié en el desarrollo de modelos de evaluación interna de riesgo de crédito. Estos modelos y sus predicciones de riesgo, se basan en teorías económicas de finanzas corporativas y son denominados colectivamente como teorías de riesgo de crédito.

### 3.2.4.1 Modelo de Black-Scholes-Merton (BSM - Prob)

En 1974 Merton planteó un modelo, basado en el modelo matemático desarrollado por Fisher Black y Myron Scholes, para evaluar el riesgo de crédito de una empresa caracterizando la equidad de una empresa como una opción de compra sobre sus activos [6]. La paridad Put/Call<sup>2</sup> sirve para fijar el precio de una opción de venta y utilizándose como una representación análoga del riesgo de crédito de la empresa. El modelo asume que una empresa tiene una cierta cantidad de deuda de cupón cero con vencimiento futuro.

Para este modelo, la probabilidad de quiebra de una compañía es la probabilidad de que el valor de mercado de los activos ( $V_A$ ) sea menor que el valor exigible de la deuda ( $X$ ) en un momento determinado ( $T$ ).

Siendo la probabilidad de que  $V_A(T) < X$  la siguiente:

$$N\left(-\frac{\ln\frac{V_A}{X} + \left(\mu - \delta - \frac{\sigma_A^2}{2}\right)T}{\sigma_A\sqrt{T}}\right) = BSM-Prob$$

Esta ecuación determina que la probabilidad de quiebra es una función de la distancia entre el valor corriente de los activos de la firma y el valor exigible de sus obligaciones  $\left(\frac{V_A}{X}\right)$ , ajustado por el crecimiento esperado del valor de los activos  $\left(\mu - \delta - \frac{\sigma_A^2}{2}\right)$  relativo a la volatilidad de estos ( $\sigma_A$ ) [7].

Para evaluar de manera empírica el BSM-Prob a partir de la ecuación anterior, es necesario calcular:

- Valor de mercado de los activos:  $V_A$
- Volatilidad de los activos:  $\sigma_A$
- Retorno esperado de los activos:  $\mu$

---

<sup>2</sup> Definición Rankia (usuario Sharkopciones): “La paridad Put/Call es una relación entre las opciones call, las opciones put y el propio precio del subyacente, de forma que en todo momento debe existir un equilibrio entre los precios, y cuando esta paridad se desajusta, es cuando aparecen oportunidades de arbitraje”

### 3.2.4.2 Modelo de CreditMetrics

En 1997, JP Morgan desarrolla CreditMetrics, una herramienta cuyo objetivo es obtener la medición del riesgo de portafolios como consecuencia de los cambios en el valor de la deuda causados por variaciones en la calificación crediticia de la contraparte, de esta manera, no sólo tiene en cuenta el incumplimiento en sí mismo, sino también los aumentos o disminuciones en la calidad crediticia del emisor. El procedimiento para determinar los riesgos de crédito se lleva a cabo en tres etapas:

1. **Definición de la matriz de probabilidades de transición:** se elabora una tabla que resume las probabilidades de que un emisor con calificación  $i$  pase a tener una calificación  $j$ <sup>3</sup>.
2. **Valuación del precio forward del bono:** se utiliza la curva de tasas correspondiente a cada nivel de calificación para calcular el precio forward de cada bono<sup>4</sup>, obteniendo un valor para cada calificación.
3. **Medición del riesgo de crédito (credit VaR):** el cálculo del valor del riesgo (VaR) se obtiene a partir de los cambios en el valor del bono, es decir, las pérdidas y/o ganancias que se obtendrían en las diferentes calificaciones. Asumiendo normalidad en los cambios en la distribución de pérdidas y/o ganancias, la media y la volatilidad del portafolios, como medida de riesgo, se calcula de la siguiente forma:

$$\mu_{TOTAL} = \sum_{i=1}^n P_i \Delta V_i \quad \sigma_p = \sqrt{\sum_{i=1}^n P_i (\Delta V_i - \mu)^2}$$

Donde:

$P_i$  = Probabilidad de tener calificación  $i$ .

$\mu_{TOTAL}$  = Probabilidad de tener calificación  $i$ .

$\Delta V_i$  = Probabilidad de tener calificación  $i$ .

---

<sup>3</sup> Las probabilidades de transición pueden calcularse internamente o utilizar las otorgadas por las empresas calificadoras (Standard & Poor's, Fitch y Moody's).

<sup>4</sup> Valor presente del bono a un año, teniendo en cuenta las tasas de descuento de la curva que representan la calificación del bono y cupones del bono a partir de un año hasta el vencimiento del bono.

Cálculo del VaR para un crédito de calificación BBB:

	Probabilidad de transición	Valor del bono	Cambio de valor $\Delta V$	$P_i(\Delta V_i - \mu)^2$
AAA	0.02%	\$109.35	1.82	0.0010
AA	0.33%	\$109.17	1.64	0.0146
A	5.95%	\$108.64	1.11	0.1473
BBB	86.93%	\$107.53	0.00	0.1852
BB	5.30%	\$102.01	(5.52)	1.3586
B	1.17%	\$98.09	(9.45)	0.9442
CCC	0.12%	\$83.63	(23.91)	0.6595
Incumplimiento	0.18%	\$51.13	(56.40)	5.6326
	media =	\$107.07	media = (0.46)	Varianza = 8.9431 Desv. est. = 2.9905

Asumiendo distribución normal:

Credit VaR (95%) = \$ (5.40)

Credit VaR (99%) = \$ (7.43)

$$\mu - 1.65\sigma = -0.46 - 1.65 \times 2.99 = -5.40$$

$$\mu - 2.33\sigma = -0.46 - 2.33 \times 2.99 = -7.43$$

Tabla 2. Medición del Riesgo de Crédito [8]

### 3.2.4.3 Modelo de Moody's KMV

En 2002, Moody's Analytics adquiere KMV, una herramienta de análisis crediticio cuyo funcionamiento se basa en la estimación estructural para calcular el *expected default frequency* (EDF) o frecuencia de quiebra esperada. Esta medida permite calcular la probabilidad de que una contraparte no cumpla con sus obligaciones de pago. Tres fases son necesarias para calcular las probabilidades de insolvencia actuales:

#### 1. Estimación del valor de mercado y de la volatilidad de los activos de la empresa:

$$\text{Valor de la equidad } (E) = f(V, \sigma_v, K, c, r)$$

$$\text{Volatilidad de la equidad } (E) = g(V, \sigma_v, K, c, r)$$



Donde:

$K$  = Ratio de apalancamiento<sup>5</sup>

$c$  = Pago medio del cupón en el L/P

$r$  = Tasa de cero riesgo<sup>6</sup>

$V$  = Valor de la empresa

$\sigma_v$  = Volatilidad de valor de la empresa

$V_0$  = Valor actual de la empresa

$\mu$  = Retorno del valor esperado

## 2. Cálculo de la distancia de insolvencia ( $d_f$ )

$$\text{Punto de insolvencia } (d^*) = \text{deuda } c/p + \frac{\text{deuda } l/p}{2}$$

$$d_f = \frac{E(V_T) - d^*}{\sigma_v} = \frac{\ln \frac{V_0}{d^*} + \left( \mu - \frac{\hat{\sigma}_V^2}{2} \right) T}{\hat{\sigma}_V \sqrt{T}}$$

## 3. Escalado de la distancia de insolvencia acorde a las probabilidades actuales de insolvencia

Las distancias de insolvencia de cada empresa son almacenadas en bases de datos con el fin de poder estimar la proporción de empresas quebradas para una distancia de insolvencia dada. Es decir, en base a la información histórica de una gran muestra de empresas, es posible determinar cuántas empresas han quebrado.

---

<sup>5</sup> Mide la variación del resultado después de impuestos ante cambios en el resultado antes de intereses. Permite observar el efecto palanca que tienen los costes fijos financieros sobre el resultado empresarial. Se calcula de la siguiente forma:  $\text{Apalancamiento Financiero} = \frac{\text{Activo}}{\text{Fondos propios}} \times \frac{\text{BAT}}{\text{BAII}}$

<sup>6</sup> "Concepto teórico que asume que en la economía existe una alternativa de inversión que no tiene riesgo para el inversionista" - Wikipedia

### 3.2.4.4 Modelo de CSFB's CreditRisk+

Este modelo basado en el marco de las ciencias actuariales, deriva la distribución de pérdidas de una cartera de bonos o préstamos donde se asume la insolvencia. El modelo extrae las características principales de los eventos de incumplimiento crediticio y permite el cálculo explícito de una distribución de la pérdida total de una cartera de crédito.

CreditRisk+ modela el riesgo de incumplimiento, el cual no está relacionado con la estructura de capital de la empresa, sino que se mantiene la suposición sobre las causas del incumplimiento. El deudor insolvente tendrá una probabilidad  $P_a$  y uno no insolvente  $1 - P_a$ .

El modelo utilizará para cada calificación de crédito sus correspondientes tasas de insolvencia así como la volatilidad de las mismas para calcular la frecuencia de aparición de insolvencia. La herramienta asume que la tasa de insolvencia sigue una distribución Gamma, aunque no existan evidencias de que el factor de riesgo tenga una incidencia de este tipo sobre las probabilidades de incumplimiento y solamente se utiliza porque permita la aplicación del método de recurrencia [9].

Para calcular el impacto de las pérdidas utiliza la exposición de pérdidas y las tasas de recuperación. La exposición de la pérdida para cada deudor es ajustada por la anticipación de la tasa de recuperación con el fin de producir una pérdida en caso de impago. Posteriormente las pérdidas son clasificadas en diferentes grupos, siendo aproximado a un mismo número el nivel de exposición en cada grupo, con el fin de facilitar los cálculos.

Por último, para derivar la distribución de las pérdidas donde cada crédito tiene su propio importe y probabilidad de cumplimiento, se utiliza la función generadora del *proceso de Poisson*<sup>7</sup>: Gracias a este proceso es posible conocer la distribución de una variable compuesta por la suma de variables aleatorias individuales.

### 3.2.4.5 Modelo de McKinsey's CreditPortfolio View

El modelo de CreditPortfolio View (CPV) aplica un enfoque macroeconómico para la medición del riesgo. Frecuentemente, los ciclos de crédito se coordinan con los ciclos de negocio, siendo la

---

<sup>7</sup> También conocido como ley de los sucesos raros, es un proceso estocástico de tiempo continuo que consiste en "contar" eventos raros (de ahí el nombre "sucesos raros") que ocurren a lo largo del tiempo. (Wikipedia).



probabilidad de insolvencia una función de variables macroeconómicas tales como la tasa de desempleo, las tasas de interés, la tasa de crecimiento, el gasto público, los tipos de cambio y el ahorro agregado.

Aunque se trata de un modelo teórico, también emplea modelos de regresión logística, en concreto Logit, para estimar la relación entre la probabilidad de insolvencia y las variables macroeconómicas explicativas.

El funcionamiento del modelo es el siguiente:

1. Simulación del estado de la economía.
2. Ajuste de la tasa de incumplimiento con el estado de la simulación de la economía.
3. Atribución de una probabilidad de insolvencia por cada deudor sobre la base de las simulaciones del estado de la economía.
4. El valor de las transacciones individuales atribuido a los deudores de acuerdo con la probabilidad de defecto se determina sobre la base de las simulaciones del estado de la economía.
5. Se calcula la pérdida de la cartera mediante la adición de los resultados para todas las transacciones.
6. Elaboración de un mapa de distribución de pérdidas a partir de los resultados obtenidos tras repetir los puntos anteriores n veces.

### 3.3 Modelos Estadísticos de Predicción

Gracias a las capacidades para extraer información relevante de muestras de datos aparentemente indescifrables, las técnicas estadísticas han sido empleadas en investigaciones de todo tipo, por supuesto, también en el estudio de la predicción de quiebras, donde se han aplicado diversas técnicas, en ocasiones, de manera directa y en muchas otras, complementando a modelos teóricos o basados en inteligencia artificial.

Existe un modelo estadístico distinguido entre los diversos métodos utilizados durante los últimos cincuenta años en la predicción de quiebras: el análisis discriminante múltiple (ADM). A pesar de que numerosos autores utilizaron este método para comparar los resultados relativos a la eficiencia empresarial, si bien es cierto, que no existe unanimidad respecto al liderazgo de este método en precisión. Altman elaboró en 1968 un diseño experimental basado en ADM, que testeado con diferentes sectores, países y etapas, utilizando técnicas estadísticas, horizontes de tiempo y diseños muestrales sin obtener resultados relevantes acerca de cuáles eran los instrumentos clave para un mejor resultado [10]. Desde entonces se generalizó la idea de que no existían herramientas milagrosas, sino que dependiendo del problema a analizar, de la información disponible, del sector al que pertenece la empresa, de la etapa en la que se sitúe la actividad de la empresa, las técnicas óptimas podían ser unas u otras.

Debido a la problemática existente para encontrar una técnica líder en precisión y efectividad, los análisis financieros en predicción comenzaron a incorporar a la utilización de ratios financieros, la aplicación de modelos dinámicos e indicadores combinados, como la gestión de recursos humanos, oportunidades del mercado, etc., facilitando de esta manera información acerca de la situación general de la empresa con el fin de mejorar la predicción de la solvencia económica de la empresa.

En las décadas de los 80's y 90's se introdujeron técnicas más complejas y precisas tras cumplirse con los supuestos requeridos para la estimación de máxima verosimilitud, destacando los Modelos de Probabilidad Condicional<sup>8</sup>.

---

<sup>8</sup> Modelos que permiten estimar la probabilidad de que una empresa fracase con base en una determinada distribución de probabilidades.

### 3.3.1 Análisis Univariante

La característica principal de estos modelos de predicción es la confianza total en una única variable económica, es decir, tratan de determinar la significatividad de cada ratio para explicar la insolvencia económica. La mayor parte de estudios estadísticos, emplea en su fase inicial alguna técnica fundamental de análisis univariante como el análisis de la varianza y el test de clasificación dicotómica [11].

En los diferentes estudios sobre insolvencia empresarial llevados a cabo, el objetivo principal consistía en localizar diferencias sistemáticas que favoreciesen la quiebra empresarial comparando ratios financieros de empresas que quiebran con ratios de empresas que son solventes.

Este modelo, fue utilizado en la predicción de quiebras en 1966 por Beaver, determinando así el primer trabajo de referencia, fiable y contrastable realizado con técnicas estadísticas [12].

### 3.3.2 Análisis Discriminante

El objetivo de esta técnica estadística es obtener la combinación lineal de dos o más variables independientes que mejor discrimina entre los grupos inicialmente definidos (las compañías solventes y las compañías en quiebra).

Esto se logra mediante la regla estadística de maximizar la varianza relativa de la intersección de ambos grupos en función del grupo de estudio (compañía solvente o compañía en quiebra). Esta relación es interpretada mediante el ratio varianza de intersección/varianza del grupo (Z).

El análisis discriminante obtiene las combinaciones lineales de la siguiente forma:

$$Z = w_1x_1 + w_2x_2 + \dots + w_nx_n$$

Donde:

$Z$  = Puntuación discriminante.

$w_i$  = Pesos discriminantes

$x_i$  = Ratios financieros

$i$  = Número de ratios

De esta manera, cada empresa obtiene una puntuación discriminante compuesta concreta que posteriormente es comparada con un valor de corte, lo que determina si la empresa pertenece al grupo de las empresas solventes o al grupo de las empresas en quiebra.

Este tipo de análisis funciona adecuadamente siempre y cuando se cumplan las siguientes condiciones:

1. Las variables pertenecientes a cada grupo sigan una distribución normal.
2. Las matrices de covarianza son iguales para cada grupo.
3. Lo grupos son discretos, identificables y no se superponen.

Además de la dificultad existente de encontrar el cumplimiento de tales condiciones en el mundo real [13], otro de los problemas más graves es la existencia de multicolinealidad entre variables independientes, especialmente con procedimientos escalonados. Los estudios confirman que la aparición de estos problemas bajo supuestos de normalidad, no debilitan la capacidad de clasificación, pero sí la capacidad predictiva.

Los análisis discriminantes pueden ser clasificados en del número de grupos previamente definidos objetos de estudio de sus diferencias:

- Análisis discriminante simple (ADS): dos grupos.
- Análisis discriminante múltiple (ADM): más de dos grupos.

Dos métodos comúnmente utilizados para obtener los modelos discriminantes son:

- Método simultáneo (Directo): basado en el modelo de construcción, por lo que el modelo se define ex ante y después se utiliza el análisis discriminante.
- Método escalonado: el procedimiento selecciona un subconjunto de variables para generar un modelo de discriminación utilizando selección hacia adelante, eliminación hacia atrás o selección por pasos. Este método comienza sin incluir variables en el modelo. En cada iteración, si la variable seleccionada contribuye menos a la capacidad de discriminación del modelo no cumple con el criterio para quedarse, es eliminada. Cuando todas las variables cumplen con el criterio para no ser eliminadas el procedimiento finaliza, quedando identificadas las variables más relevantes.

Sin embargo, el método únicamente destaca las variables en base a motivos estadísticos, sin tener en cuenta la importancia económica de las variables.

En 1968, E.Altman aplicó el modelo estadístico de análisis discriminante para diseñar el modelo Z-Score de predicción de quiebras [10]. Originalmente, se incluían cinco ratios financieros:

Ratios	
$X_1$	Fondo de maniobra / Activos Totales
$X_2$	Ganancias retenidas /Activos Totales
$X_3$	BAlI/Activos totales / Activos Totales
$X_4$	Valor de Mercado del Equity / Valor en libros de Obligaciones Totales
$X_5$	Ventas / Activos Totales

Tabla 3. Ratios componentes del Z-Score

Que conformaban el modelo Z-Score de la siguiente forma:

$$Z = 1.2 * X_1 + 1.4 * X_2 + 3.3 * X_3 + 0.6 * X_4 + 0.99 * X_5$$

Una variación del modelo de análisis discriminante lineal es el análisis discriminante cuadrático. Ambos asumen que las variables independientes siguen una distribución normal, sin embargo el análisis discriminante cuadrático no asume que las matrices de covarianza de la muestra sean idénticas.

### 3.3.3 Modelos de Regresión Logística

Este tipo de análisis puede predecir el resultado de la quiebra empresarial utilizando una función logística (como función de variables explicativas), que modela las probabilidades que potencialmente describen el resultado de determinados datos.

El modelo tiene una formulación equivalente dada por:

$$\text{Probabilidad de Quiebra} = \frac{1}{1 + e^{(-Z)}} = \frac{1}{1 + e^{-(W_0 + W_1 X_1 + \dots + W_n X_n)}}$$

A diferencia del modelo anterior, este modelo no especifica un valor de corte para realizar la evaluación de la empresa, sino que cada empresa es asignada con una probabilidad de quiebra según el nivel de confianza deseado. Esta técnica pondera mediante pesos  $W_i$  el impacto de las

variables explicativas  $X_i$  y asigna un valor  $Z$  que determina la probabilidad de quiebra de cada empresa incluida en la muestra.

Existen diferentes modelos, dependiendo de la función logística empleada:

### 3.3.3.1 Modelo Logit

Este modelo de regresión logística emplea una función inversa del sigmoide.

$$\text{logit}(p) = \log\left(\frac{p}{1-p}\right) = \log(p) - \log(1-p)$$

En el estudio realizado por Ohlson [14], especificando un nivel de confianza del 1%, el error del tipo I era del 0% (inexistente) y el error de tipo II era del 47%. Aumentando el nivel de confianza, ambos tipos de error incrementan.

A partir de esta técnica, se desarrollaron modelos con el fin de predecir el fracaso empresarial, uno de ellos fue el modelo Hazard [15]. Este modelo, en lugar de incluir los valores de las variables independientes correspondientes a una empresa en un determinado año, incluye todos los valores de las variables obtenidos en años anteriores para una empresa concreta:

$$P_{i,t} = (1 + e^{-y_{i,t}})^{-1}$$

$$y_{i,t} = a + \beta' X_{i,t-1} = \beta' \begin{bmatrix} X_{1,t-1} & \cdots & X_{1,t-j} \\ \vdots & \ddots & \vdots \\ X_{n,t-1} & \cdots & X_{n,t-j} \end{bmatrix}$$

$n$  es el número de variables incluidas,  $j$  el número de años anteriores a  $t$  para los que existen datos. La función Logit asigna el valor de  $\beta' X$  a una probabilidad entre 0 (quiebra) y 1 (no quiebra).

Este modelo no asume normalidad multivariante, ni igualdad de matrices de covarianza como se daba en el análisis discriminante, sino que incorpora efectos no lineales y usa una función acumulativa lógica para predecir una quiebra económica. Gracias a ello evita el problema de agrupar empresas en función de criterios como el sector o la actividad.

### 3.3.3.2 Modelo Probit

El modelo Probit difiere en pocos aspectos respecto del modelo Logit. Ambos tienen como objetivo obtener la probabilidad de que los datos estudiados pertenezcan a un conjunto determinado



previamente. Sin embargo, el modelo Probit utiliza una función de distribución normal en  $W_j$ , obteniendo un comportamiento muy similar al de la función Logit.

Frente al análisis Logit, este modelo ha sido utilizado en un menor número de ocasiones, debido a la restricción de trabajar con parámetros cuya función de distribución debe ser normal.

Entre los estudios que aplicaron el análisis Probit para la predicción de quiebras se encuentra el de Zmijewski [16], el cual utilizó los datos publicados de unas 2100 empresas en la Bolsa de Valores de Nueva York entre 1972 y 1978.

Zmijewski únicamente consideró tres ratios financieros: ROA (Beneficios Netos/Activo Total), FINL (Pasivo Exigible/Activo Total) y LIQ (Activo Circulante/Pasivo a Corto). Una vez diseñado el modelo Probit ( $W^* = a_0 + a_1ROA + a_2FINL + a_3LIQ + e$ ), formó seis grupos diferentes entre empresas solventes e insolventes, asignando para cada grupo una función  $W^*$ . La función  $W^*$  con menor sesgo fue la asignada al último grupo, el cual estaba configurado mediante 40 empresas quebradas y 800 solventes, obteniendo como resultado:

$$W^* = -4,803 - 3,599 ROA + 5,406 FINL - 0,100 LIQ + e$$

Las conclusiones del estudio indican que el coeficiente de la rotación de activos (ROA) mantiene signo negativo, mientras que el endeudamiento (FINL) siempre posee signo positivo. Por otro lado la liquidez (LIQ) varía entre positivo y negativo. Deduciendo que la probabilidad de quiebra se ve reducida en función de la rotación de los activos y aumenta al incrementar el endeudamiento, no siendo estadísticamente significativo el valor de la liquidez.

### 3.3.4 Modelo de Probabilidad Lineal

El funcionamiento de este método consiste en relacionar un conjunto de observaciones de determinadas variables, en el caso de la predicción: los ratios financieros, denotados con  $x_i$ , con el comportamiento de la variable dicotómica  $Y$ , que representa la quiebra. Para ello, emplean parámetros  $\beta_i$  con el fin de hallar una relación de respuesta con las variables del tipo:

$$Y = \beta_0 + \beta_1 x_1 + \dots + \beta_n x_n + \varepsilon$$

$\beta_0, \beta_1, \dots, \beta_n$  son los parámetros de la relación lineal buscada, mientras que  $\varepsilon$  es el error asociado al modelo, el cual incluye todos los factores residuales, inexactitudes de medición.

En la ilustración 1, podemos observar el comportamiento de este modelo en comparación con los modelos de regresión logística.




Figura 1. Representación de las funciones Logit, Probit y Modelo de Probabilidad Lineal (LPM)

### 3.3.5 Gráficos de Control de Suma Acumulada (CUSUM)

Una de las herramientas más efectivas para detectar cambios de una distribución de buena calidad a una de mala calidad son los procedimientos CUSUM (Cumulative Sum). La gráfica CUSUM es una gráfica de control de tiempo ponderado, la cual representa las sumas acumuladas de las desviaciones de cada valor de una muestra dada con respecto a la variable Y.

Gracias a esta suma acumulada, cualquier mínima desviación en la media del proceso implica valores de desviación acumulados que aumentan o disminuyen constantemente, de tal manera que pueden determinar el inicio de un cambio de tendencia económica e informar del deterioro solvente de una empresa de manera inmediata.

Este modelo tiene gran utilidad cuando se trabaja con procesos de bajo control, ya que detectan cambios con respecto a un objetivo debido a que los gráficos escenifican información procedente de la secuencia de valores muestrales.

### 3.3.6 Modelos de Ajuste Parcial

En 1969 Lev [58] advirtió que los ratios financieros de la empresa seguían un proceso de ajuste, por ello, realizó un estudio empleando por primera vez un modelo de ajuste parcial para caracterizar el proceso dinámico de ajuste de ratios iniciado por cualquier gestión activa de la empresa.

El modelo de ajuste parcial comprende dos partes: una parte estática describe como se alcanza un determinado resultado y una parte dinámica que incluye el proceso de ajuste parcial; esta parte dinámica se explica mejor usando el comportamiento de la gestión de tesorería de una firma (comentado anteriormente) como ejemplo:

Tal y cómo comentamos en la descripción del modelo teórico, la quiebra de la gestión de tesorería puede ser definida como un desequilibrio entre las entradas y las salidas de efectivo. Asumiendo que la demanda de dinero sigue el enfoque de la gestión de activos de inventario, donde la demanda de dinero dependerá del volumen de las transacciones, el proceso continúa de la siguiente manera:

$$\ln M(t) = \ln D + e_s \ln S(t) + e_i \ln i(t) + u(t) \quad (3)$$

Donde:

$M(t)$ : Balance de efectivo actual (Periodo  $t$ ).

$D$ : Constante Escala.

$S(t)$ : Volumen de las transacciones.

$i(t)$ : Coste de oportunidad.

$e_s$ : Elasticidad del balance de efectivo respect a  $S$ .

$e_i$ : Elasticidad del balance de efectivo respect a  $i$ .

$u(t)$ : Variable aleatoria de error.

La ecuación (3) adaptada a la versión dinámica mediante el ajuste parcial sería:

$$\ln M(t) = y\{\ln D + e_s \ln S(t) + e_i \ln i(t) + u(t)\} + (1 - y)M(t - 1) + yu(t) \quad (3)$$

Donde  $y$  y  $(1 - y)$  son los pesos que representan la tasa de ajuste.

En este ejemplo concreto de modelo de ajuste parcial, el proceso de clasificación y predicción de quiebras sigue el siguiente criterio:

- Para una empresa en quiebra, los valores absolutos de las elasticidades del balance de efectivo respecto del volumen de transacciones  $S$  y el coste de oportunidad  $i$ , será menor en comparación a una empresa solvente.
- Para una empresa en quiebra, la tasa de ajuste  $y$  puede ser mayor que 1 y superará la tasa de ajuste de una empresa solvente.

Si los ratios financieros de una empresa, sufren importantes desviaciones con respecto de los ratios medios de las empresas pertenecientes al mismo sector, los inversores y otros usuarios podrían suponer que no está operando óptimamente, con la posible consecuencia de tener que exponerse a toma de decisiones por parte de los directivos de la empresa con el fin de restablecer la estructura adecuada del ratio [17], suponiendo una amenaza [18].

### 3.3.7 Técnica de Escalado Multidimensional (MDS)

El procedimiento de este conjunto de técnicas estadísticas tiene como objetivo tomar preferencias y percepciones de los datos facilitados para su representación en un diagrama visual, llamado mapa perceptual, de dos o más dimensiones.

Para conformar el mapa perceptual, toma como entrada una matriz de proximidades donde se relacionan la proximidad existente entre una empresa y otra. Posteriormente, genera una matriz que relaciona a cada empresa con una dimensión, utilizándose esta matriz y gracias a la fórmula general de la distancia de Minkowski, se obtiene finalmente la matriz de distancias con la que representar el mapa [19].

Podemos observar en la ilustración 2 un ejemplo de mapa perceptual obtenido al aplicar las escalas multidimensionales a los datos de empresas quebradas y solventes. En este caso el programa estadístico SPSS generaba este resultado al introducir datos de empresas numeradas quebradas (1 – 29) y solventes (30 – 66). Observamos a la izquierda del mapa una agrupación de las empresas solventes y otra menos notoria de las empresas insolventes a la derecha.




Figura 2. Mapa perceptual de empresas quebradas y solventes<sup>9</sup>

<sup>9</sup> Ciberconta.unizar.es, (2016). *Análisis financiero con escalas multidimensionales*. [25 enero 2016].

### 3.4 Técnicas de Inteligencia Artificial Aplicadas

A partir de los años 90 del siglo XX, las técnicas de inteligencia artificial comienzan a ser empleadas en el estudio de la quiebra empresarial mediante redes de neuronas artificiales y árboles de decisión. Los estudios revelaron que estos modelos poseían un mayor potencial de aplicación en la predicción de quiebras al integrar técnicas y procedimientos más innovadores.

La inteligencia artificial es eficaz en la solución de problemas gracias a la implantación o creación de sistemas capaces de adquirir conocimiento mediante información bien de base contable (ej. ratios financieros) o de fuentes externas (ej. Cotización de empresas del sector), empleando dicho conocimiento en la elaboración de conclusiones sobre nuevos datos.

En 1990 se utiliza por primera vez una técnica de inteligencia artificial [20], en concreto redes neuronales, en su estudio de predicción de quiebras. Entre los años 1990 y 2005, los métodos de inteligencia artificial amplían su influencia en el ámbito de la predicción de quiebras mediante el uso de nuevas técnicas como el razonamiento basado en casos, la teoría de los conjuntos aproximados, las máquinas de vectores de apoyo, la teoría de los conjuntos borrosos e incluso la integración de algunas de estas técnicas en un único sistema de decisión.

A continuación, indagamos en el funcionamiento de las técnicas anteriormente enumeradas:

#### 3.4.1 Razonamiento Basado en Casos (CBR)

La técnica de Razonamiento Basado en Casos (Case-Based Reasoning o CBR) es un proceso cuyo objetivo es la resolución de nuevos problemas a través de analogías, es decir, tomando como base soluciones de problemas anteriormente resueltos [21]. Este modelo intenta simular el comportamiento ocasional de un ser humano de resolver un problema recurriendo a la solución de otro problema anterior con características similares al que tenemos actualmente, aceptando la teoría de que si una resolución fue satisfactoria para un ejercicio previo, existen motivos para creer que puede ser ventajoso aplicar el mismo remedio.

El proceso de CBR se integra en sistemas dotados de una memoria donde se almacenan experiencias, ejemplos o casos, esta memoria es conocida como base de conocimiento y su función es la de proporcionar al usuario referencias sobre circunstancias anteriores con características

similares a la situación actual, de tal forma, que a través de estos casos relevantes sea posible predecir el comportamiento de los nuevos.

Al ser una técnica perteneciente en continuo desarrollo e innovación, podemos encontrar diferentes sistemas CBR centrados en resolver determinados tipos de problemas, tales como CHEF, JULIA, CASEY, HYPO o PROTOS [22]. Sin embargo, todos ellos siguen un proceso de cuatro etapas:

1. **Recuperación:** se retoma la experiencia/as de un problema/as problemas con características similar/es al problema de entrada desde la base de conocimiento. El inicio de esta etapa se establece con la elaboración de una descripción del problema y una descripción de todos los elementos relevantes del contexto como base para realizar la búsqueda de similitudes con casos existentes en la memoria.

Con el fin de encontrar una buena asociación entre un caso almacenado en la base de conocimiento y el problema planteado, primero se lleva a cabo un proceso provisional de búsqueda de problemas potencialmente aptos y después un proceso de selección definitiva de los problemas encontrados en la etapa anterior.

La recuperación de un problema o conjunto de problemas, puede realizarse siguiendo la indexación directa indicada por los punteros hacia las características del problema, realizando una búsqueda en la estructura indexada o buscando modelos de casos.

Aparentemente, los mejores problemas serán aquellos que tengan un número superior de características en común con el problema a resolver (más parecidos), sin embargo es posible encontrar casos con un menor número de características en común que proporcionen buenos resultados, únicamente depende de la estrategia que llevemos a cabo.

Tras haber realizado la búsqueda, se efectúa una selección concluyente de los casos más propensos a ser una solución eficaz para el problema. Normalmente, se seleccionan aquellos casos con más características en común, no obstante existen situaciones en las que los motivos aportados no son lo suficientemente sólidos como para emplear el caso en cuestión y se utilizan otros criterios como la discriminación de casos con características no deseadas.

2. **Reutilización:** se asigna la solución del problema seleccionado previamente al problema actual. Con el fin de minimizar las diferencias entre el caso recuperado y el problema a



resolver, se realiza una abstracción de las características del caso a reutilizar, ignorando la información no relevante, para posteriormente copiar estas características al nuevo caso en construcción. A veces, no es posible copiar ciertas características en bloque de manera directa, por tanto es necesario transformar las características mediante operaciones de adaptación.

- 3. Revisión:** se realizan simulaciones para determinar si la solución construida es realmente correcta y tiene capacidad para resolver el problema actual. Tanto las soluciones correctas como las incorrectas proporcionadas por el sistema, se introducen en la base de conocimiento como ejemplo de errores, es decir, el sistema también se “nutre” de sus propios errores a fin de no volver a generar soluciones con ese error y proporcionar una mejora en la calidad de las soluciones. Esta fase se ejecuta en primer lugar mediante una fase de evaluación de la solución generada, aplicando la propia solución en el contexto proporcionado en el problema o en una simulación aproximada del contexto. El resultado obtenido determinará si la elección de esta solución ha sido correcta o no, comprobando si los valores resultantes son los esperados (correcto funcionamiento del sistema, correcta solución de un problema, etc.). Tras haber realizado la evaluación del caso, se realiza una reparación de los posibles errores que incluye la solución del problema. Esta etapa no pretende corregir los errores que presenta la solución únicamente sino que su objetivo principal es el de añadir nuevos casos etiquetados como “fallos” a la base de conocimiento y así contribuir a mejorar la toma de decisiones en futuros problemas.
- 4. Retención o evaluación:** se procede con el almacenamiento del nuevo caso en la base de conocimiento, constituyendo información que posibilitará al sistema para continuar con su crecimiento y evolución, evitando así la reducción de la vida útil del sistema, ya que en caso de que los problemas a resolver sufriesen cambios fuera de su conocimiento, el sistema dejaría de resolver los problemas convenientemente.

Debido al gran tamaño que puede llegar a tener la base de conocimiento, es necesario elaborar un modo de organizar los casos de tal manera que, dado un caso a resolver, sea posible recuperar los casos más útiles. Para ello es necesario realizar un proceso de



clasificación de casos y características mediante etiquetas. Este proceso es conocido como “indexación” y es uno de los componentes más importantes y problemáticos en el proceso CBR.

A la hora de construir un sistema CBR existen dos problemas en relación al proceso de indexación. En primer lugar, el diseño de un vocabulario de índices entraña la dificultad de determinar el tipo de etiquetas para indexar los casos, es necesario precisar qué campos deben tener así como los valores que pueden tomar.

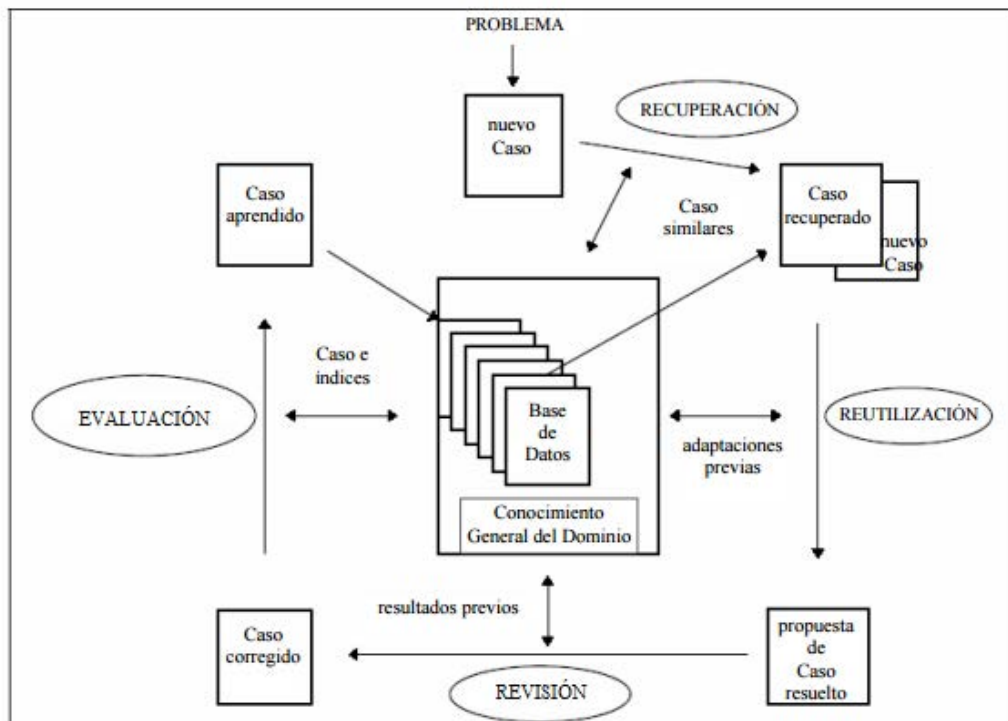


Figura 3. Ciclo Básico de un Sistema CBR [23]

### 3.4.2 Modelos de redes neuronales

Las redes de neuronas artificiales (RNA) son un sistema de unidades de procesamiento interconectadas que cooperan entre sí con el fin de generar una única señal.

Una neurona artificial hereda los principios neuro-biológicos que describen el comportamiento de las neuronas en el cerebro. Es un elemento simple que recibe entradas de fuentes externas sobre las que se aplica una función de activación  $f$  de las sumas ponderadas en

función de pesos  $w$  ponderados, cuyo valor sufre modificaciones durante el proceso de aprendizaje. El aprendizaje de conocimientos se consiste en determinar un valor para estos pesos.

$$y_i = \sum w_{ij}y_j$$

La interconexión de neuronas está estructurada en tres niveles:

1. Neuronas de entrada - Capa de entrada: capa que recibe directamente la información de origen externo a la red.
2. Neuronas ocultas - Capa oculta: conjunto de neuronas que no tienen contacto con el entorno exterior. En función de cómo se configuren las interconexiones de estas neuronas y de su número, se determina una tipología de redes u otra.
3. Neuronas de salida - Capa de salida: transmiten la información generada por la red al exterior.




Figura 4. Arquitectura de una red neuronal [63]

Las redes de neuronas pueden ser clasificadas en función de la arquitectura y disposición de las neuronas:

- A. Redes de propagación hacia delante o acíclicas:** las señales transcurren desde la capa de entrada hacia la capa de salida sin presentar ciclos ni conexiones entre neuronas de una misma capa. Dentro de este grupo podemos diferenciar entre redes monocapa (ej. Adaline) y redes multicapa (ej. Perceptrón multicapa).
- B. Redes recurrentes:** existen uno o más ciclos cerrados de activación neuronal (ej. Elman).

Otra clasificación se rige de acuerdo al tipo de aprendizaje<sup>10</sup> que utiliza.

- 1. Aprendizaje supervisado:** la red neuronal necesita un conjunto de datos de entrada de los cuales ya se conoce su respuesta objetivo o ha sido previamente clasificado. El objetivo principal de este aprendizaje es la creación de una función capaz de predecir el valor correspondiente a un objeto de entrada tras haber “aprendido” de los datos de entrenamiento facilitados, es decir, generaliza el resultado de problemas desconocidos a partir de ejemplos. (ej. Perceptrón simple)
- 2. Aprendizaje no supervisado o autoorganizado:** tal y como revela su nombre, no necesitan un conjunto de datos con conocimiento previo, sino que trata los objetos de entrada como un conjunto de variables aleatorias construyendo un modelo de densidad<sup>11</sup> para el conjunto de datos (ej. Redes de Kohonen).
- 3. Redes híbridas:** modelo mixto que combina características de ambos tipos de aprendizaje (supervisado y no supervisado) facilitando la convergencia con la ayuda de funciones de mejora. (ej. Redes de base radial).
- 4. Aprendizaje reforzado:** similar al aprendizaje supervisado con la limitación de únicamente facilitar a la red escasa información acerca de si la respuesta generada es acertada o errónea. Este tipo de aprendizaje está basado en el principio de condicionamiento por refuerzo, es decir, Se aprenden las conductas reforzadas positivamente y se castigan las

---

<sup>10</sup> El aprendizaje hace referencia a la posible necesidad o no, de emplear un conjunto de entrenamiento supervisado.

<sup>11</sup> Modelo soportado mediante una función de densidad de probabilidad de una variable aleatoria continua que describe la probabilidad relativa según la cual dicha variable aleatoria tomará determinado valor.

conductas reforzadas negativamente mediante la asignación positiva o negativa de pesos sinápticos.

Introducida la noción de aprendizaje, así como su clasificación, es importante explicar el funcionamiento del **algoritmo de retroalimentación (*backpropagation* o *BPNN*)**, dado su frecuente utilización en el estudio de las predicciones. El nombre de este algoritmo hace referencia a la forma en que se propagan los errores a través de la red con el objetivo de actualizar el valor de los pesos en cada iteración (aprendizaje). Para el correcto funcionamiento de este algoritmo, es necesario trabajar bajo aprendizaje supervisado para comparar la salida correcta facilitada y la salida propuesta por la red a partir de los conjuntos de prueba, calculando el error y retropropagándolo para reajustar el valor de los pesos. Este proceso se repite un número determinado de ocasiones por cada par de entradas-salidas de prueba.

Aunque existen diferentes arquitecturas, las más empleadas en el ámbito de la predicción de quiebras son el perceptrón multicapa (MLP), la red neural probabilística (PNN), la red de funciones de base radial (RBFN) y el mapa de rasgos auto-organizados (SOM). A continuación, comentamos cada arquitectura:

### 3.4.2.1 Perceptrón Multicapa (MLP)

El modelo perceptrón multicapa (Multilayer Perceptron – MLP) es el más utilizado como aproximador universal de funciones en asociación al algoritmo de retroalimentación, explicado anteriormente. A diferencia su modelo predecesor (perceptrón simple), esta red neuronal formada por diversas capas, permite la resolución de problemas no lineales.

Debido a su gran robustez ante los errores que puedan aparecer en los ejemplos de entrenamiento y a su capacidad de aceptar como entrada largos tiempos de entrenamiento [24], este modelo supone una gran herramienta en predicción de quiebras en empresas.

### 3.4.2.2 Red Neuronal Probabilística (PNN)

Con el objetivo de desarrollar un modelo de red de neuronas con la capacidad de realizar un entrenamiento rápido con información proveniente del mundo real (200 veces más rápido en comparación con Perceptron Multicapa [25]), nacieron las redes de neuronas probabilísticas (Probabilistic Neural Networks - PNN).

Una red neuronal probabilística es una red neuronal unidireccional derivada de un algoritmo estadístico basado en el Análisis Discriminante Lineal y del método de ventanas Parzen.

Las ventanas Parzen es un procedimiento no paramétrico que genera una estimación de la función probabilística de densidad mediante la superposición de un número determinado de ventanas o réplicas de una función (normalmente Gaussiana). A partir del cálculo de la función probabilística de densidad de cada clase de la muestra entrenada, el método clasifica los datos.

Las redes de neuronas probabilísticas, organizan sus operaciones en cuatro capas:

1. **Capa de entrada:** recibe e introduce en la capa patrón los valores de las variables.
2. **Capa patrón:** contiene una neurona por cada caso de entrenamiento, se calcula la distancia entre el problema a resolver y el correspondiente problema de entrenamiento ya resuelto, para cada una de las neuronas que conforman la capa.
3. **Capa de suma:** calcula la probabilidad de pertenecer a una clase determinada para cada caso.
4. **Capa de salida:** clasifica en función de las probabilidades obtenidas anteriormente.




Figura 5. Arquitectura de redes probabilísticas [64]

### 3.4.2.3 Red de Neuronas de Base Radial (RBFN)

Las redes de neuronas de base radial (Radial Basis Function Network – RBFN) usan como funciones de activación funciones de base radial<sup>12</sup>. La salida proporcionada por la red es calculada en función de la distancia a un punto denominado centro, donde la función posee un extremo.

A diferencia del perceptrón multicapa, realizan una transformación local y no lineal sobre las señales recibidas por parte de la capa de entrada. El carácter local de las funciones de base radial se debe a que alcanzan un nivel cercano al máximo de su recorrido cuando el patrón de entrada  $X(n)$  se encuentra cerca del centro de la neurona. Si por el contrario, el patrón de entrada se aleja del centro de la neurona, el valor de la se inclina a alcanzar el valor mínimo de su recorrido.




Figura 6. Redes neuronales de base radial [26]

El entrenamiento de las RBFN determina tanto los parámetros de la capa de salida (pesos  $W$ ) optimizando el espacio de entradas, como los parámetros de la capa oculta (centros  $C$  y desviaciones asociadas  $d$ ), optimizando en base a las salidas deseadas.

### 3.4.2.4 Mapas Autoorganizados (SOM)

Un mapa auto-organizado (Self-organizing Map – SOM) es un tipo de red neuronal artificial cuyo entrenamiento se lleva a cabo mediante aprendizaje no supervisado, generando una representación discreta del espacio de los datos de entrada.

Consiste en un conjunto de neuronas normalmente distribuidas en forma de malla bidimensional (disposición ortogonal o hexagonal). Cada neurona que conforma esta malla, tiene

<sup>12</sup> Wikipedia: función real cuyo valor depende sólo de la distancia del origen, de forma tal que  $\phi(r) = \Phi(\|x\|)$ , o de forma alternativa de la distancia a algún centro  $x_k$ , tal que  $\phi(r) = \Phi_k(x) = \Phi(\|x - x_k\|)$ .

ligado un vector de iguales dimensiones al espacio de entrada, llamado vector de pesos de la neurona. En la fase de aprendizaje, cada vez que se presenta un dato de entrada  $x$  a la red, la neurona con el vector de pesos más próximo y sus neuronas colindantes, corrigen sus pesos para parecerse más a la entrada  $x$ . Tras un número determinado de iteraciones, la red se adapta a la distribución de los datos.

La función  $f$  asociada a un mapa auto-organizado es la función que relaciona cualquier valor de la entrada  $x$  con la neurona de la malla con el vector de pesos más cercano a dicha entrada.

Al llevarse a cabo un aprendizaje no supervisado, no existe una referencia fiable para comprobar la veracidad del resultado, por tanto, es necesario incluir una función de coste asociada que el mapa tratará de minimizar a lo largo del aprendizaje.

De manera genérica, podemos enumerar el funcionamiento de un SOM en tres etapas:

1. Inicialización de los vectores de peso de las neuronas.
2. Aprendizaje de la red.
3. Evaluación de una función de coste.

### 3.4.3 Conjuntos aproximados

Dentro de los sistemas de Inducción de Reglas, pertenecientes al área de la inteligencia artificial encontramos el método de Conjuntos aproximados (Rough set). Su misión consiste en clasificar objetos a partir de información imprecisa o desconocida.

Un rough set es una colección de objetos que habitualmente contiene casos fronterizos, es decir, casos que no pueden ser clasificados como miembros de una clase, ni de otra. Partiendo de la base de que a cada objeto del universo de estudio es posible ligarle algún tipo de información, se elabora un sistema de información que codifica las variables independientes, transformando los valores continuos de las estas variables en términos cualitativos en función del criterio de expertos en la materia.

Sea el sistema de información  $(U, A)$ , ( $U = \text{Universo}$  y  $A = \text{Atributos}$ ) y los conjuntos  $B$  y  $A$ , donde  $B$  es un subconjunto de atributos de  $A$  ( $B \subseteq A$ ) y  $X$  es un subconjunto de elementos de  $U$  ( $X \subseteq U$ ). Este conjunto de datos imprecisos puede ser reemplazado o representado por dos conjuntos precisos:

$$\underline{B}X = \cup \{Y \in U \setminus IND(B) : Y \subseteq X\} \quad (1)$$

$$\overline{B}X = \cup \{Y \in U \setminus IND(B) : Y \cap X \neq \emptyset\} \quad (2)$$

(1). Aproximación por debajo  $\underline{B}X$ : unión de todos los objetos incluidos en  $X$ . (Seguramente pertenecen a  $X$ )

(2). Aproximación por encima  $\overline{B}X$ : unión de todos los objetos que tienen una intersección no vacía con  $X$ . (Posiblemente pertenecen a  $X$ ).

De tal manera que en  $\overline{B}X - \underline{B}X$  encontramos todos aquellos objetos que no pueden identificarse como no pertenecientes, ni tampoco como pertenecientes a  $X$ .

Calculando el coeficiente precisión  $p$  como:

$$p = \frac{\underline{B}X}{\overline{B}X}$$

Si  $p = 1$  el conjunto será duro o exacto con respecto a la relación de equivalencia  $B$ , si es  $p < 1$  el conjunto es vago con respecto a  $B$ , midiendo así el grado de imperfección o integridad del conocimiento sobre el conjunto  $X$  considerando los atributos incluidos en la relación de equivalencia.

En caso de tener una clasificación en dos clases: empresas que quebrarán y empresas que no quebrarán, es posible calcular para cada grupo las aproximaciones por encima y por debajo.

Entre las funciones realizadas en el proceso de razonamiento de conjuntos aproximados, se encuentra la identificación de las dependencias entre atributos durante el análisis de la tabla de información, reduciendo los atributos redundantes.

La reducción del sistema de información permite obtener reglas de decisión, es decir, reglas que determinan si un objeto pertenece a una clase de decisión<sup>13</sup> concreta. Una regla de decisión es una sentencia lógica de la siguiente forma:

IF *< se cumplen condiciones >* THEN *<*  
*el objeto pertenece a clase de decisión X >*

---

<sup>13</sup> La clase de decisión se define previamente por un usuario.



Una regla de decisión puede ser:

- **Determinística:** el cumplimiento de una condición conlleva una consecuencia exacta y concisa.
- **No determinística:** la consumación de una condición desencadena consecuencias inconsistentes o aproximadas. (ej. Conduce a varias posibles decisiones).

El aprendizaje inductivo permite hacer funcionar los procedimientos capaces de generar conjuntos de reglas de decisión que incluyen todas las clases de decisión, conjuntos denominados algoritmos de decisión. Existen diferentes estrategias de inducción de reglas:

- Generación de un conjunto mínimo de reglas que cubren todos los objetos de la tabla.
- Generación de un conjunto exhaustivo de reglas consistentes en todas las reglas posibles de la tabla.
- Generación de un conjunto de reglas de decisión fuertes que cubran relativamente un gran número de objetos (no todos necesariamente).

Un posible resultado de este método tendría la forma:

- *Regla 1.  $(R1 = 2) \& (R2 = 4) \Rightarrow (Q = 0)$ ; empresas [2, 14, 18, 23]*
- *Regla 2.  $(R4 = 3) \& (R3 = 2) \Rightarrow (Q = 1)$ ; empresas: [17, 21, 25, 26]*
- *Regla 3.  $(R2 = 1) \& (R4 = 4) \Rightarrow (Q = 1)$ ; empresas: [7, 10, 22]*
- *Regla 4.  $(R4 = 1) \& (R1 = 4) \Rightarrow (Q = 0)$ ; empresas: [13, 19, 24]*
- *Regla 5.  $(R3 = 3) \& (R2 = 3) \Rightarrow (Q = 1)$ ; empresas: [1, 4]*

Donde:

<b>Ratios</b>	<b>Definición</b>
<b>R1</b>	<i>BAlI/Fondos de los accionistas</i>
<b>R2</b>	<i>Ingresos netos/Fondos de los accionistas</i>
<b>R3</b>	<i>Resultado Operativo/Activos Totales</i>
<b>R4</b>	<i>Resultado Operativo/Activos Permanentes</i>

Teniendo en cuenta que existen  $n$  empresas (instancias) y pudiendo tomar  $Q$  los valores 0 o 1 en función de si se predice la solvencia de la empresa o bien su quiebra. De tal manera que la regla 2  $[(R4 = 3) \& (R3 = 2) \Rightarrow (Q = 1)]$ ; empresas: [17, 21, 25, 26] significaría:

*Cuando los ratios  $R4$  y  $R3$  de las empresas número 17, 21, 25 y 26 toman los valores 3 y 2, respectivamente, estas empresas quiebran.*

### 3.4.4 Algoritmos genéticos

La técnica de algoritmos genéticos está basada en los principios de la evolución biológica y herencia genética, persiguiendo el objetivo de dar solución a problemas específicos. Funcionan evolucionando una población de individuos al tiempo que se aplica sobre ella operaciones de inicialización, selección, cruzamiento y mutación, operaciones que se explican a continuación:

1. **Inicialización:** en esta etapa una población de estructuras genéticas llamadas cromosomas, son distribuidas aleatoriamente en el espacio de búsqueda, seleccionándose el punto inicial de la búsqueda.
2. **Selección:** tras la etapa de inicialización, cada cromosoma es evaluado mediante una función de evaluación definida por el usuario con el fin de codificar numéricamente el comportamiento del cromosoma, señalizando con puntuaciones superiores a los individuos más fuertes. La selección de la función de evaluación es una de las mayores complejidades, debido a que esta función debe imitar el comportamiento de los individuos en el mundo real de manera aproximada. Por tanto, gran parte del rendimiento del modelo irá condicionado por la fidelidad de la función de valuación.
3. **Cruzamiento o recombinación:** los individuos señalizados con las puntuaciones más altas, sobrevivirán y propagarán sus características a la siguiente generación, contribuyendo a continuar la búsqueda de una solución óptima. Los cromosomas de alto rendimiento son propensos a ser replicados sucesivamente, mientras que las estructuras de bajo rendimiento tenderán no ser escogidas y a desaparecer. La fase de cruzamiento crea nuevos individuos a partir de dos individuos escogidos aleatoriamente, esto se lleva a cabo combinando segmentos de ambas partes en un nuevo individuo. No todos los individuos seleccionados participan en la fase de cruzamiento, dependiendo de la probabilidad dada por la tasa de cruzamiento podrán propagar sus características o bien finalizar su utilidad.

Es importante comentar la existencia de diferentes tipos de cruzamiento, según el número de segmentos del cromosoma que se heredarán al nuevo individuo.

- 4. Mutación:** la etapa de mutación es un mecanismo donde aleatoriamente se selecciona parte de la población y se modifica una parte del cromosoma aleatoriamente. Si el individuo mutante es factible, reemplaza su anterior disposición. La presencia de mutaciones asegura que la probabilidad de alcanzar un punto en el espacio de búsqueda nunca será 0.

Con el fin de incluir información cualitativa para predecir el modo en el que ciertas variables económicas evolucionan debido a consideraciones económicas (crisis del sector, crisis financieras, crecimiento del mercado,..), se utiliza una matriz de transición para dirigir la dinámica de transformación de la muestra, permitiendo introducir consideraciones económicas u otras circunstancias externas para otorgar mayores probabilidades a determinadas transformaciones o bien reducir la probabilidad de otras que generan valores sin sentido o poco útiles. Esta matriz indica la probabilidad de que un individuo  $i$  se transforme en  $j$

Por tanto, el algoritmo se compone de dos etapas: en la primera, se generan los individuos de la población intermedia y en la segunda se generan los individuos de la población final teniendo en cuenta las probabilidades registradas en la matriz de transición.

Gracias a este procedimiento, es posible transformar conjuntos de datos originales, que poseen características propias, en un conjunto de datos final, con características similares a los conjuntos de datos más adaptados o válidos. Es decir, es posible obtener una muestra artificial futura basada en los mejores valores de la muestra original.

En 2002 Shin y Lee, utilizaron un algoritmo genético para optimizar los coeficientes de un sistema de reglas.

### 3.4.5 Máquinas de soporte vectorial

La técnica de las máquinas de soporte vectorial es una técnica de clasificación cuyo objetivo consiste en calcular hiperplanos de separación en un espacio compuesto por características de una dimensión mayor, que logren la máxima separación entre clases [27].

El funcionamiento se lleva a cabo transformando los datos originales cuya representación se realiza en el espacio de entrada, en una representación dentro del espacio de características.

Para ello, realiza un aprendizaje de la superficie de decisión de dos clases distintas de los puntos de entrada y mapea esos puntos a un espacio de características de una dimensión mayor, encontrando un hiperplano que separe de forma óptima a los puntos de una y otra clase [28].

La forma más sencilla de separar dos clases es mediante una recta, un plano o un hiperplano N-dimensional, no obstante, a pesar de que la predicción de quiebras busca clasificar empresas en dos clases (empresa solvente o empresa en quiebra), el campo de estudio implica el tratamiento de numerosas variables independientes, curvas no lineales y casos donde los conjuntos de datos no pueden ser separados en su totalidad.

Con la intención de solucionar estos problemas, se utilizan las funciones Kernel, las cuales describen el problema en un espacio de características de mayor dimensión, donde es posible emplear separadores lineales. En resumen, permiten aplicar algoritmos lineales sobre problemas no lineales.

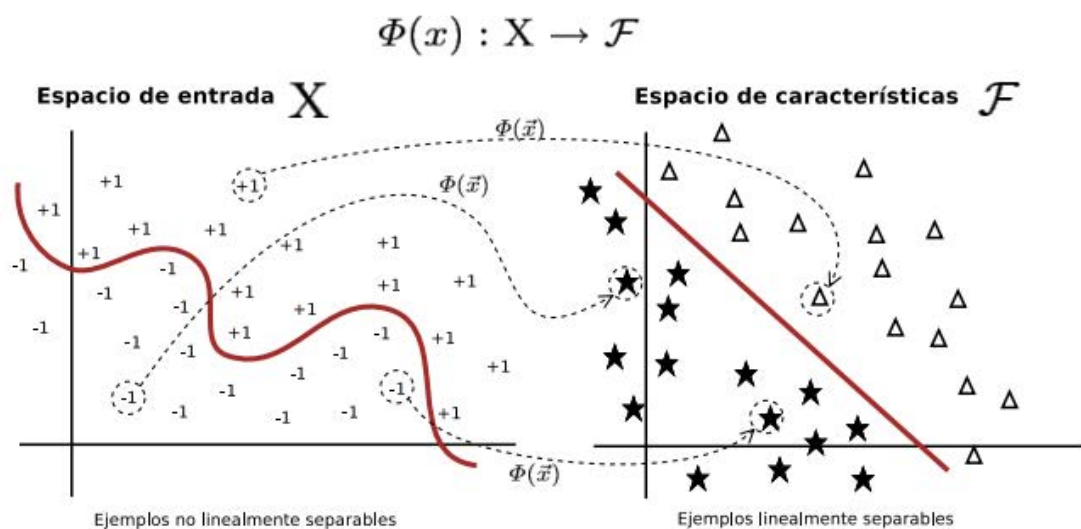


Figura 7. Ejemplo de transformación de datos [29]

### 3.4.6 Árboles de decisión (Particionamiento Recursivo)

Mediante el uso de esta técnica es posible construir árboles de decisión que configuren la influencia de determinadas variables explicativas, en nuestro caso los ratios financieros, sobre la variable objetivo del estudio, es decir, la solvencia o quiebra de la empresa.

El aprendizaje basado en árboles de decisión estructura la información a partir de listas ordenadas de datos de entrenamiento, de manera similar a los sistemas de predicción basados en

reglas. Los árboles de decisión poseen hojas que representan etiquetas de clase y ramas que representan conjuntos de características que caracterizan a estas etiquetas. Esta organización de los datos, permite representar y categorizar un número determinado de condiciones que ocurren de forma reiterada, con la finalidad de resolver un problema.

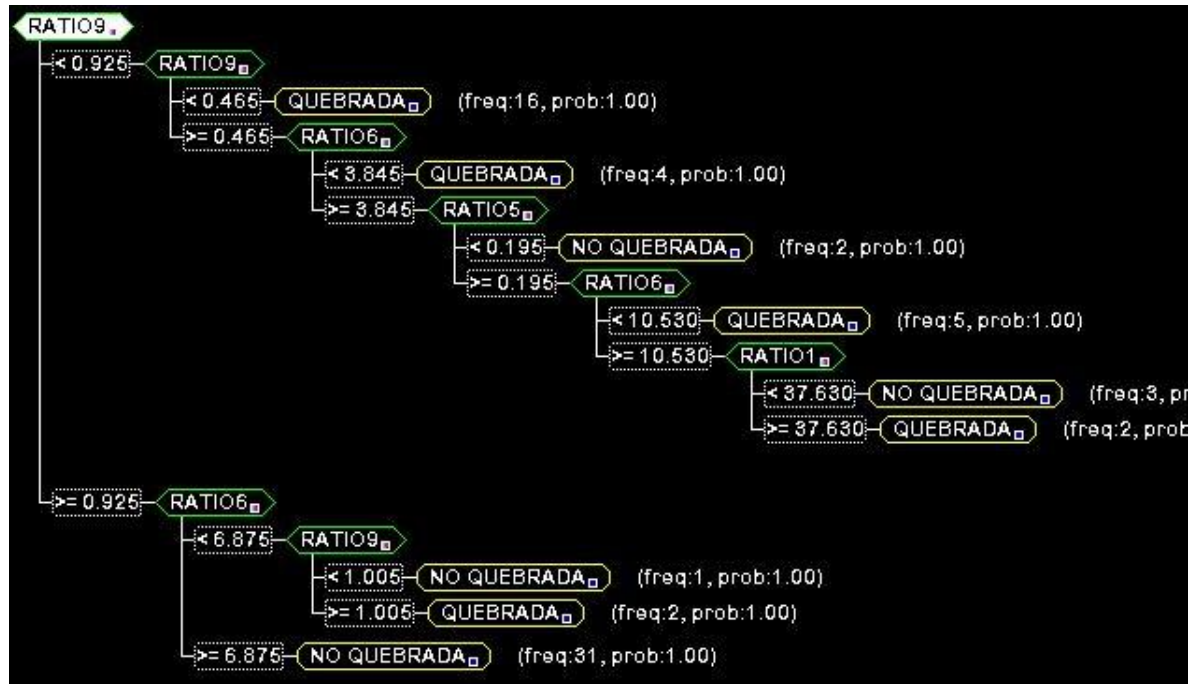


Figura 8. Ejemplo de creación de árbol binario de decisión para la predicción de quiebras [68]

Esta técnica puede ser utilizada como una herramienta de decisión complementaria a otras técnicas como el análisis discriminante, tal y como plantearon Frydman, Altman y Kao en su estudio [30]. Adicionalmente, estos autores afirmaron la existencia de una mayor precisión clasificatoria del algoritmo de particionamiento recursivo frente al análisis discriminante.

### 3.4.7 K-Vecinos más Cercanos

Este método clasificatorio no paramétrico, calcula el valor de la función probabilística de densidad de que un elemento a pertenezca a una clase C, basándose en los datos de entrenamiento. Para ello, divide el espacio en regiones por localización y etiqueta en función de esta información, Si la clase C es la más repetida entre los K prototipos más cercanos en el espacio para un elemento nuevo, este elemento será asignado a la clase C.




Figura 9. Ejemplo de K-vecinos cercanos [66]

Para determinar la distancia existente entre los prototipos y el elemento a clasificar, se utiliza la distancia euclídea:

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^p (x_{ri} - x_{rj})^2}$$

Este método ha sido utilizado anteriormente en el estudio de la predicción de quiebras. Algunas investigaciones plantean sistemas combinados de modelos K-vecinos, cuyos resultados eran obtenidos a partir de una ponderación de los modelos, minimizando de esta manera el error global [67]. Otros estudios alcanzan tasas de acierto superiores al 87%, aplicando una variación del modelo, conocida como *Fuzzy K-Vecinos más cercanos* [67].

### 3.5 Modelos Híbridos

Tal y como indica su nombre, los modelos híbridos son modelos que integran paralela o secuencialmente modelos predictivos, explotando de ellos sus habilidades y/o mitigando con la ayuda de otros modelos los efectos negativos que puedan tener algunos modelos.

Los modelos híbridos no pertenecen a un grupo acotado que guarde características comunes, sino que más bien es un campo de desarrollo abierto, donde cada investigador configura diferentes modelos teóricos, estadísticos y/o basados en inteligencia artificial para hacer frente a un tipo de problemas. Suelen caracterizarse por una mayor robustez con respecto a los sistemas más tradicionales.

Algunos modelos híbridos empleados en la predicción de quiebras son:

Año	Autor/es	Modelos integrados	Información adicional
1992	Marose [31]	Redes neuronales (Perceptrón multicapa) y técnicas estadísticas	Chase Manhattan Bank desarrolló el sistema bajo el nombre de PCML (Public Company Loan Model), con el fin de ayudar a decidir la concesión de créditos a través del suministro de informes, gráficos, puntos fuertes y débiles, así como una clasificación de las empresas según el crédito que merecen.
1996	Back et al. [32]	Algoritmos genéticos y Redes de neuronas	Emplean algoritmos genéticos para proporcionar datos de entrada a redes de neuronas, estableciendo un modelo híbrido para mejorar el rendimiento.
1998	Shin et al. [33]	Logit y Redes de Neuronas (Perceptron multicapa)	Plantearon un sistema híbrido con capacidad de determinar un determinado nivel de riesgo de crédito para cada empresa a partir de la puntuación basada en los resultados de los modelos Logit y perceptrón multicapa. En la actualidad, este modelo se utiliza en la práctica en el banco Boram Bank de Corea.
2000	Ahn et al. [34]	Conjuntos aproximados y Redes de Neuronas	Utilizaron la técnica de conjuntos aproximados para reducir el número de ratios financieros y variables cualitativas sin pérdida de información, para posteriormente, desarrollar reglas de clasificación y entrenar redes de neuronas.

2009	McKee y Lensberg [35]	Algoritmos genéticos y razonamiento basado en casos	El algoritmo genético optimiza la ponderación de características y selecciona ejemplos de forma simultánea.
2010	Ravisankar et al. [36]	Redes de neuronas, conjuntos aproximados y algoritmos genéticos	Construyeron diferentes modelos híbridos con redes de neuronas multicapa, redes de neuronas probabilísticas, conjuntos aproximados y algoritmos genéticos.
2010	Yeh et al. [37]	Conjuntos aproximados y máquinas de soporte vectorial	Los atributos redundantes eran reducidos mediante los conjuntos aproximados para luego predecir la quiebra empresarial con máquinas de soporte vectorial.
2013	Lin et al. [38]	Máquinas de soporte vectorial y LLE	El algoritmo LLE reduce la dimensión de la muestra para extraer características y se realiza la predicción mediante máquinas de soporte vectorial.
2014	Zhang et al. [39]	Conjuntos aproximados y algoritmos genéticos	La ejecución del proceso incluye cuatro etapas:  Selección secuencial de las características relevantes, generación de reglas mediante conjuntos aproximados, utilización del algoritmo genético de colonia de hormigas, y uso de técnica de validación cruzada estratificada para mejorar la generalización del modelo.

*Tabla 4. Histórico de modelos híbridos de predicción de quiebras*



### 3.6 Análisis de los modelos de predicción

Con el fin de esclarecer toda la información aportada en la explicación de los diferentes modelos de predicción de insolvencias económicas, ponemos a disposición del lector este apartado donde podrá encontrar de manera esquemática las ventajas e inconvenientes de cada modelo.

#### 3.6.1 Comparativa de modelos

Tomando como punto de partida el diagrama 1 construido a partir del listado histórico de modelos empleados (Anexo 1), observamos que la categoría de modelos más utilizada es la de modelos estadísticos con un 50,44%.

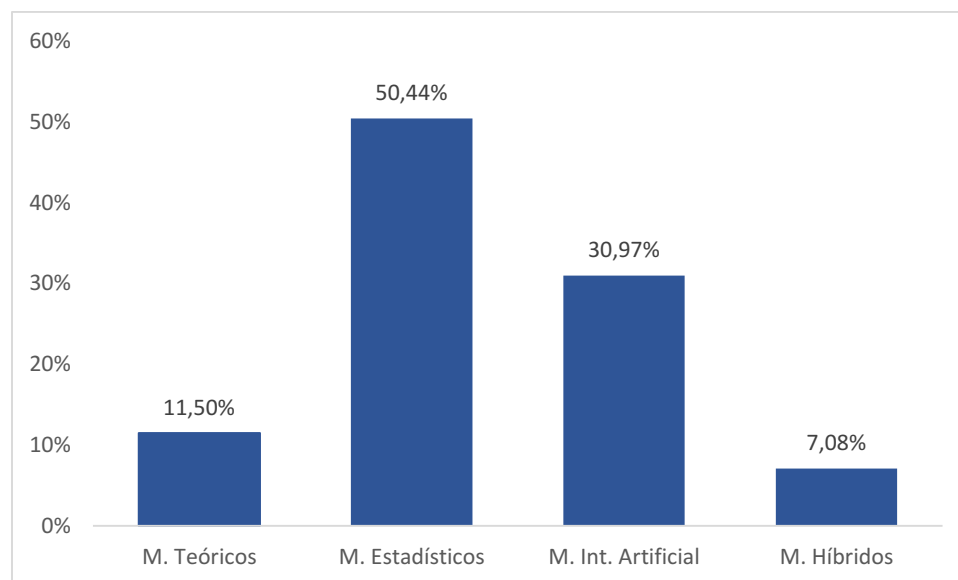


Figura 10. Diagrama de porcentajes de modelos de predicción empleados por categoría

Aparentemente, este resultado podría ser explicado debido al uso de técnicas estadísticas durante los primeros años de estudio, sin embargo, observando el listado histórico, podemos afirmar que las técnicas estadísticas (especialmente el análisis discriminante múltiple) han sido empleadas en prácticamente la totalidad de años o bien han acompañado a modelos teóricos y modelos basados en inteligencia artificial.




Figura 11. Diagrama de porcentajes de modelos teóricos empleados




Figura 12. Diagrama de porcentajes de modelos estadísticos empleados

Tal y como observamos en el Diagrama 3, la técnica estadística de análisis discriminante múltiple se ha empleado en un 30,09% de los estudios realizados.




Figura 13. Diagrama de porcentajes de modelos basados en IA empleados

El uso de las redes neuronales, en su conjunto, suman el 15,03% de utilización sobre el total de modelos utilizado, situándose en primer lugar como la técnica basada en IA más empleada en el estudio de la predicción de quiebras.

Dejando a un lado la cuantificación del número de ocasiones en las que se ha empleado un modelo u otro, pasamos a analizar la eficiencia de estos partiendo del estudio realizado por Aziz y Dar [4]. En este trabajo se lleva a cabo una extensiva revisión de la literatura, inventariando los modelos de predicción de quiebras utilizados desde los años 60 en 89 estudios empíricos de predicción de quiebras. En este inventario, anotan la precisión obtenida por parte de cada modelo en cada estudio. Basándonos en estos resultados, comprobamos el resultado de la precisión de modelos agrupados en categorías (modelos teóricos, estadísticos y basados en inteligencia artificial).

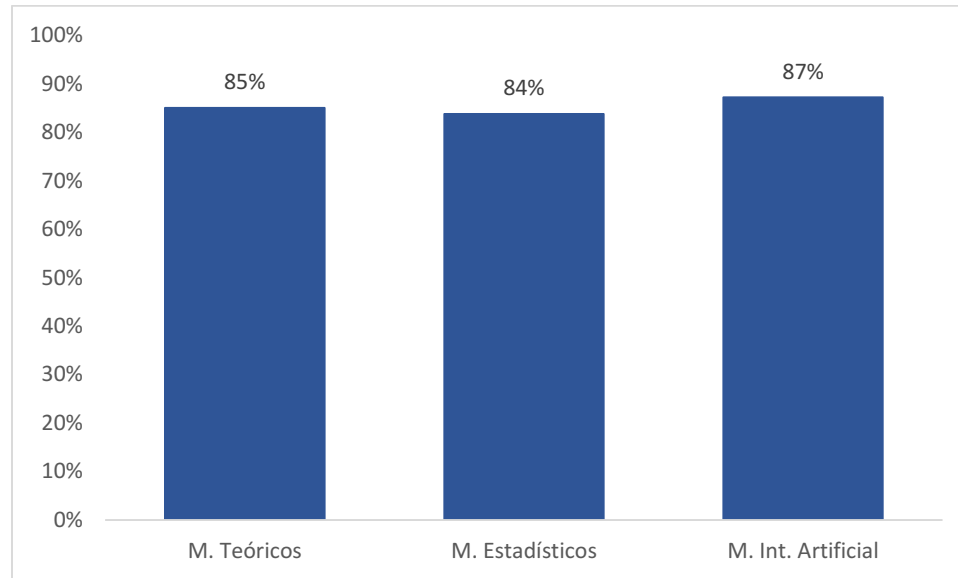


Figura 14. Diagrama de tasas de precisión predictiva por categoría

En el diagrama 5, las tres categorías muestran porcentajes satisfactorios, sin embargo los modelos basados en inteligencia artificial lideran la clasificación con un 87%, seguido por los modelos teóricos con un 85% y por los modelos estadísticos con un 84%.

La escasez de estudios basados en modelos teóricos altera positivamente la proporción de precisión de estos, sin embargo al analizar el número de errores de tipo I y tipo II, como forma alternativa de confirmar la robustez de los modelos, los resultados desestiman la alta precisión de los modelos teóricos y confirman la fortaleza de los modelos basados en inteligencia artificial:

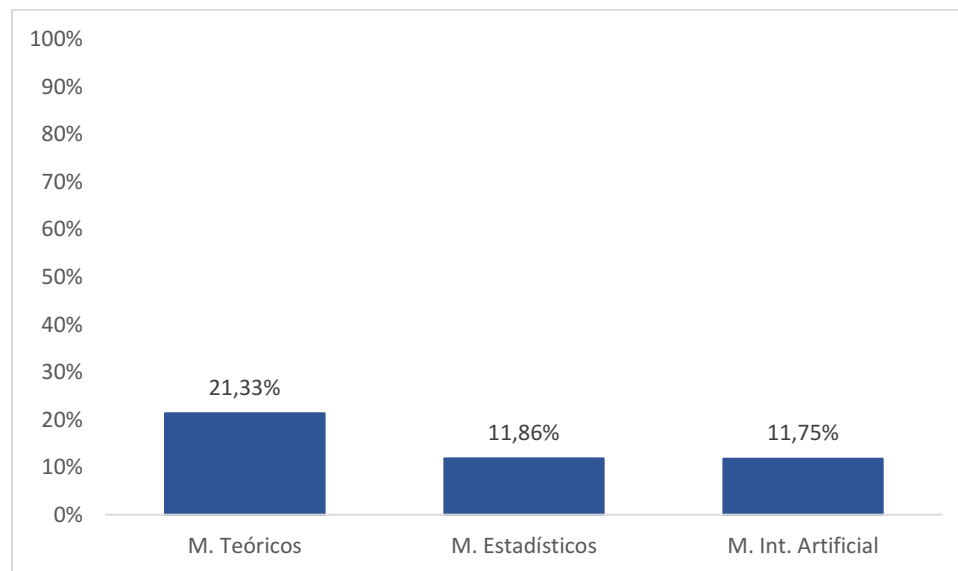



Figura 15. Diagrama de porcentajes de errores tipo I por categoría



*Figura 16. Diagrama de porcentajes de errores tipo II por categoría*

Los modelos teóricos en su conjunto, son los más desfavorecidos en cuanto a la aparición de ambos errores. Las predicciones realizadas mediante modelos teóricos obtienen los porcentajes más altos en aparición de errores de tipo I y tipo II con un 21,33 % y un 13 % respectivamente. Mientras, los modelos basados en inteligencia artificial reducen estos errores al 11,75 % y 6 %.

Aunque los modelos basados en inteligencia artificial son más precisos y obtienen menores errores tipo I y II, los modelos estadísticos son empleados con mayor frecuencia en la predicción de quiebras. Con el propósito de encontrar la causa profundizamos en la efectividad de los modelos estadísticos y basados en inteligencia artificial:

**Modelos Estadísticos**

**Técnicas Basadas en Inteligencia Artificial**

**Precisión Individual**




Figura 17. Diagrama de tasas de precisión predictiva de modelos estadísticos




Figura 18. Diagrama de tasas de precisión predictiva de modelos basados en IA

**% Errores Tipo I**

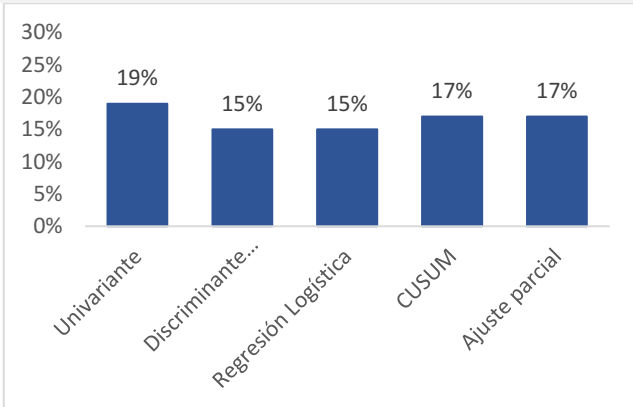


Figura 19. Diagrama de porcentajes de errores tipo I de modelos estadísticos




Figura 20. Diagrama de porcentajes de errores tipo I de modelos basados en IA

**% Errores Tipo II**




Figura 21. Diagrama de porcentajes de errores tipo II de modelos estadísticos




Figura 22. Diagrama de porcentajes de errores tipo II de modelos basados en IA

Tabla 5. Rendimiento Modelos Estadísticos vs Modelos Basados en IA

Interpretando la tabla de diagramas, comprobamos que los modelos de regresión logística poseen el rendimiento más elevado para los modelos estadísticos, tanto en precisión (88%) como en aparición de errores de tipo I y II (15% y 10%). Seguido por el análisis discriminante múltiple (85% de precisión, 15% errores tipo I y 12% errores tipo II).

En cuanto a los modelos basados en inteligencia artificial, los conjuntos aproximados alcanzan la mejor precisión frente al resto de modelos (91%), junto a una aparición de errores tipo I y tipo II del 8% y 5% respectivamente. Es seguido de cerca por los algoritmos genéticos, con una probabilidad de predicción del 88% y errores tipo I y II del 6% y 5%.

### **3.6.1.1 Comparativa de Modelos Teóricos**

Tal y como se ha podido observar en el diagrama 2, los modelos teóricos de predicción suponen una minoría tanto en variedad de métodos, como en porcentaje de utilización (11,82%). Incluso la mayor parte de modelos teóricos empleados han podido aplicarse gracias a la ayuda complementaria que facilitan técnicas estadísticas.

La mayoría de modelos teóricos no actúa directamente sobre un conjunto de datos, sino que atiende a principios cualificativos formulando restricciones y normas generalizadas que asisten a los procesos de predicción de quiebras.

A pesar de la escasez de información disponible acerca las particularidades de estos modelos teóricos, resumimos en este cuadro las capacidades y limitaciones de cada modelo:

Modelo	Ventajas	Inconvenientes
<b>Medidas de Descomposición del Balance</b>	<ul style="list-style-type: none"> <li>• Establece medidas de control en la estructura financiera de una empresa.</li> <li>• Modelo teórico más popular [4]<sup>14</sup>; existen más recursos acerca del procedimiento.</li> <li>• Horizonte temporal.</li> </ul>	<ul style="list-style-type: none"> <li>• No facilita resultados ventajosos si no se aplica junto a otras técnicas.</li> </ul>
<b>Teoría de la Ruina del Jugador</b>	<ul style="list-style-type: none"> <li>• Plantea un enfoque diferente ateniendo a la continuidad de la actividad de la empresa.</li> <li>• Obtienen la precisión más alta según estudios [4]<sup>15</sup>.</li> </ul>	<ul style="list-style-type: none"> <li>• Posee grandes limitaciones para resolver situaciones complejas.</li> <li>• No facilita resultados ventajosos si no se aplica junto a otras técnicas.</li> </ul>
<b>Teoría de Gestión de Tesorería</b>	<ul style="list-style-type: none"> <li>• Establece medidas de control en los flujos de efectivo realizados por la empresa.</li> <li>• Horizonte temporal.</li> </ul>	<ul style="list-style-type: none"> <li>• Atiende únicamente a ciertos factores, ignorando otros más relevantes como la deuda.</li> <li>• Debe ser complementada con otros modelos.</li> </ul>
<b>Teoría de Riesgo de Crédito</b>	<ul style="list-style-type: none"> <li>• Suelen tener en cuenta factores macroeconómicos.</li> <li>• Facilitan cantidad de información acerca de la situación.</li> <li>• Poseen gran flexibilidad y adaptación a los datos disponibles.</li> </ul>	<ul style="list-style-type: none"> <li>• Son modelos de elevada complejidad.</li> <li>• Precio del producto elevado.</li> <li>• Los modelos se desarrollan con fines comerciales, por lo que son de difícil acceso y análisis.</li> </ul>

Tabla 6. Ventajas y limitaciones de los modelos de predicción teóricos

<sup>14</sup> En cualquier caso, sólo ha sido empleado en el 4,5% de los estudios.

<sup>15</sup> Aparentemente, consiguen la mejor actuación con una precisión media del 94%. Sin embargo, este dato no es del todo fiable, ya que únicamente ha sido empleada en un 1,82% de los estudios.



Dentro de los modelos comerciales basados en teorías de riesgo de crédito, diferenciamos las siguientes características:

<i>Propiedad</i> <i>Modelo</i>	<b>Definición de Riesgo de Crédito</b>	<b>Eventos de Crédito</b>	<b>Fuentes de Riesgo</b>	<b>Tipo de Cálculo</b>	<b>Propietario</b>
<b>CreditMetrics</b>	Incertidumbre en valor de mercado	Cambio de rating / Riesgo fallido	Valor de los activos	Analítico/ Simulación	JP Morgan
<b>KMV</b>	Pérdidas por riesgo fallido	Probabilidades de riesgo fallido continuas	Valor de los activos	Analítico	Moody's
<b>CreditRisk+</b>	Pérdidas por riesgo fallido	Riesgo fallido	Tasas esperadas de riesgo fallido	Analítico	CSFB
<b>CreditPortfolio</b>	Incertidumbre en valor de mercado	Cambio de rating / Riesgo fallido	Factores macroeconómicos	Simulación	Mckinsey

Tabla 7. Comparativa de modelos de crédito

### 3.6.1.2 Comparativa de Modelos Estadísticos

<b>Modelo</b>	<b>Ventajas</b>	<b>Inconvenientes</b>
<b>Análisis Univariante</b>	<ul style="list-style-type: none"> <li>Muy simple.</li> <li>Útil como fase previa para tomar decisiones.</li> </ul>	<ul style="list-style-type: none"> <li>Parte de la restricción de que existe una relación lineal entre todas las variables explicativas y la situación de quiebra (poco realista).</li> <li>Difícilmente aprovechable por sí misma.</li> </ul>
<b>Análisis Discriminante</b>	<ul style="list-style-type: none"> <li>Elevado potencial para examinar el perfil completo de una empresa.</li> </ul>	<ul style="list-style-type: none"> <li>Asume que los ratios se distribuyen normalmente.</li> </ul>



	<ul style="list-style-type: none"><li>• Analiza combinaciones de ratios en conjunto para eliminar ambigüedades y clasificaciones equívocas.</li><li>• Consideran el perfil completo de características comunes a todas las empresas estudiadas y la interacción de estas características.</li><li>• Reduce las dimensiones del espacio en análisis: transforma el problema de la predicción de quiebras de dos dimensiones (empresas quebradas y empresas solventes) a una dimensión.</li><li>• Técnica más utilizada en términos absolutos (abundancia de recursos, fiabilidad y buenos resultados).</li></ul>	<ul style="list-style-type: none"><li>• Cabe la posibilidad de que se excluyan ratios relevantes para la predicción.</li><li>• Los puntos de corte se determinan de forma subjetiva. [50]</li><li>• La mayoría de los trabajos que utilizan esta técnica, no cumplen con los supuestos que requiere la estimación de máxima verosimilitud. Como consecuencia, los resultados obtenidos mediante esta técnica, pueden no reflejar la situación real. [51]</li></ul>
<b>Logit</b>	<ul style="list-style-type: none"><li>• No necesita asumir distribuciones normales.</li><li>• Las matrices de covarianzas entre ambas clases, no tienen que ser iguales. [52]</li><li>• No impone restricciones de número ni tipo de variables independientes. [52]</li><li>• Resuelve problemas asociados con la metodología del análisis discriminante múltiple. [50]</li></ul>	<ul style="list-style-type: none"><li>• Es necesario identificar todas las variables independientes antes de aplicar el modelo. [54]</li><li>• Requiere observaciones no relacionadas entre sí. [54]</li><li>• En ocasiones exageran la precisión de sus predicciones (sobreajustamiento). [54]</li></ul>

	<ul style="list-style-type: none"> <li>• Calcula la probabilidad de quiebra (valor binario).</li> </ul>	
<b>Probit</b>	<ul style="list-style-type: none"> <li>• Calcula la probabilidad de quiebra (valor binario).</li> <li>• No impone restricciones de número ni tipo de variables independientes. [52]</li> <li>• Resuelve problemas asociados con la metodología del análisis discriminante múltiple. [50]</li> <li>• Coeficientes más difíciles de interpretar [53]</li> </ul>	<ul style="list-style-type: none"> <li>• Establece la restricción de utilizar ratios con distribución normal.</li> <li>• Obtiene peores resultados que su homólogo Logit.</li> </ul>
<b>Probabilidad Lineal</b>	<ul style="list-style-type: none"> <li>• Simplicidad para estimar coeficientes.</li> <li>• Interpretación directa de coeficientes.</li> </ul>	<ul style="list-style-type: none"> <li>• El valor para la probabilidad puede estar fuera del rango (0 -1). [55]</li> <li>• Asume que los cambios sucedidos en las variables explicativas son constantes (poco realista).</li> <li>• Problemas de heterocedasticidad: la varianza de las observaciones no es constante. [55]</li> <li>• Dificultades para trabajar con grandes muestras.</li> </ul>
<b>Gráficos de Control de Suma Acumulada</b>	<ul style="list-style-type: none"> <li>• Eficiente para detectar cambios en la distribución conjunta de variables financieras.</li> <li>• Analiza la situación financiera a partir de datos actuales y antiguos de la empresa. [56]</li> <li>• Provechoso con un número de muestras reducido.</li> </ul>	<ul style="list-style-type: none"> <li>• Complicados de diseñar.</li> <li>• Son lentos.</li> <li>• Malos resultados frente a cambios abruptos en las muestras. [57]</li> </ul>

	<ul style="list-style-type: none"> <li>• Posee una corta memoria para las buenas conductas de una empresa, mientras que tiene una memoria muy extensa para las malas interpretaciones. [56]</li> </ul>	
<b>Modelos de Ajuste Parcial</b>	<ul style="list-style-type: none"> <li>• Realiza benchmarking con la situación de empresas similares.</li> <li>• Simula el proceso de ajuste llevado a cabo por los ratios financieros.</li> </ul>	<ul style="list-style-type: none"> <li>• No son capaces de realizar predicciones por sí mismos, sino que desarrollan un comportamiento previamente definido.</li> </ul>
<b>Técnica de Escalado Multidimensional</b>	<ul style="list-style-type: none"> <li>• Los datos pueden estar medidos en cualquier escala</li> <li>• No es necesario identificar las variables relevantes. Evita influencia del investigador. [59]</li> <li>• Fácilmente interpretables con mapas perceptuales.</li> <li>• Define las distancias de manera más efectiva que los mapas autoorganizados.</li> <li>• No necesita asunciones de linealidad, escalas o normalidad en los datos</li> </ul>	<ul style="list-style-type: none"> <li>• Dificultades para hallar una solución estable única.</li> <li>• La introducción de una nueva empresa en la muestra puede influir en los datos estandarizados y modificar el resultado final. [60]</li> <li>• Incrementa la dimensionalidad del problema (mayor complejidad de representación, disminución de la capacidad de interpretación de los datos, subjetividad de significados).</li> </ul>

Tabla 8. Ventajas y limitaciones de los modelos estadísticos

### 3.6.1.3 Comparativa de Técnicas de Predicción Basadas en IA

Según los resultados, tanto categórica como individualmente, los modelos basados en inteligencia artificial producen los mejores resultados prediciendo quiebras. Para entender las causas del buen funcionamiento de estos modelos y orientando este trabajo al estudio de los modelos basados en inteligencia artificial, a continuación se recogen en una comparativa individual las virtudes y desventajas de los modelos de inteligencia artificial.



Técnica	Ventajas	Inconvenientes
<b>Razonamiento Basado en Casos</b>	<ul style="list-style-type: none"><li>- Proporciona soluciones rápidas. No emplea tiempo elaborando bases desde 0.</li><li>- Único algoritmo que ofrece formas de evaluación de soluciones.</li><li>- Facilita apoyo a la interpretación de dominios abiertos o conceptos complejos.</li><li>- Utiliza la experiencia previa para evitar errores previos y prevenir problemas.</li><li>- Genera aproximaciones desde diferentes perspectivas para un mismo problema y amplía cada punto de vista de cada aproximación.</li><li>- Sistema de fácil mantenimiento.</li><li>- Aprende y crece de manera progresiva.</li><li>- Permite especializarse en un campo de estudio determinado.</li><li>- Parte de soluciones globales, por lo que no es necesario descomponer los problemas.</li><li>- Da respuesta a situaciones poco comunes.</li><li>- Permite razonamiento mediante analogía.</li><li>- Es posible resolver problemas con valores ausentes y utilizar</li></ul>	<ul style="list-style-type: none"><li>- Es un sistema complejo de crear.</li><li>- Puede tener tendencia a utilizar los casos almacenados sin comprobar si las soluciones son válidas para el nuevo problema.</li><li>- Si los casos almacenados no son representativos, pueden afectar al razonamiento y generar soluciones deficientes.</li><li>- Ocasionalmente, no se recuerdan los casos más apropiados para razonar (usuarios, sistemas inexpertos).</li><li>- No tiene fundamento teórico que soporte una correcta semántica.</li><li>- Pueden proponer soluciones en dominios no comprensibles por el usuario.</li></ul>



	<p>razonamiento por defecto con facilidad.</p> <ul style="list-style-type: none"><li>- Imita el razonamiento humano, lo que facilita comprender las soluciones y justificaciones.</li></ul>	
<b>Redes de Neuronas Artificiales</b>	<ul style="list-style-type: none"><li>- No asumen ninguna distribución de probabilidad o dispersiones iguales.</li><li>- Las funciones input y output no están sujetas a restricciones (salvo que sean continuas y diferenciables).</li><li>- Poseen una gran capacidad de adaptación a cambios en los ejemplos que analizan, debido a que los datos más recientes van ajustando el modelo. Esta característica aporta gran robustez al modelo.</li><li>- Algunos autores [40] [41] afirman que en comparación con técnicas estadísticas tales como el análisis discriminante simple, el análisis discriminante múltiple o los análisis de respuesta binaria (Logit y Probit) tanto en la predicción como en la estimación de la tasa de clasificación especialmente cuando los datos disponibles son limitados.</li></ul>	<ul style="list-style-type: none"><li>- Invierten gran cantidad de tiempo para desarrollar el modelo.</li><li>- La composición del grupo de empresas que sirven para entrenar al modelo es determinante en la precisión final de las predicciones: una muestra equitativa de empresas fracasadas y no fracasadas mejora la predicción [42].</li><li>- No existen métodos que determinen el número de neuronas ocultas óptimo. Es necesario probar diferentes configuraciones hasta dar con el mejor resultado.</li><li>- Ausencia de fundamento teórico.</li><li>- Dificultad de interpretar los coeficientes de las variables</li></ul>
<b>Conjuntos Aproximados</b>	<ul style="list-style-type: none"><li>- Procesa grandes cantidades de información con rapidez.</li></ul>	<ul style="list-style-type: none"><li>- Dificultad de ejecución.</li><li>- Consumen gran cantidad de recursos.</li></ul>



	<ul style="list-style-type: none"><li>- Procesa información cualitativa y/o cuantitativa.</li><li>- Las reglas generadas son sencillas y comprensibles.</li><li>- Es posible realizar un diagnóstico de manera directa a partir de las reglas generadas.</li><li>- Fundamento matemático.</li></ul>	<ul style="list-style-type: none"><li>- Pueden no dar con una solución provechosa.</li><li>- Escasa documentación disponible.</li></ul>
<b>Algoritmos Genéticos</b>	<ul style="list-style-type: none"><li>- Poseen una gran habilidad para trabajar con muchos parámetros simultáneamente [43].</li><li>- Funcionan bien con problemas en los que la función de aptitud cambia con el tiempo, tiene muchos óptimos locales o es discontinua.</li><li>- Resuelven satisfactoriamente problemas que tienen numerosas soluciones.</li><li>- Pueden trabajar con datos incompletos o contradictorios, informando al usuario sobre los motivos de la toma de decisiones.</li></ul>	<ul style="list-style-type: none"><li>- Tienen un alto coste informático debido al número elevado de variables y generaciones con las que opera.</li><li>- Al encontrar un dato más apto en poblaciones pequeñas, puede condicionar el algoritmo a convergir hacia un óptimo local, en lugar de profundizar en la muestra y encontrar el óptimo global.</li><li>- Presentan una alta complejidad y baja interpretabilidad [45].</li><li>- Existen dificultades para incluir restricciones en el algoritmo.</li></ul>
<b>Máquinas de Soporte Vectorial</b>	<ul style="list-style-type: none"><li>- Baja probabilidad de sobreajustamiento frente a las redes de neuronas.</li><li>- Buenas propiedades de generalización.</li><li>- Permite el aprendizaje correcto de problemas con dificultad debido a su base matemática sólida, no tiene muchos parámetros configurables y</li></ul>	<ul style="list-style-type: none"><li>- Dificultades para encontrar una función de transformación conveniente.</li><li>- La fase de prueba emplea mucho tiempo.</li><li>- Al trabajar con fuentes de datos complejas y abundantes, la precisión disminuye y el tiempo computacional aumenta.</li></ul>

	<p>la capacidad para soportar fronteras de clases complejas.</p>	<ul style="list-style-type: none"> <li>- El coste de convertir vectores de X en vectores de F es elevado.</li> <li>- El coste de calcular los productos escalares en F sobre grandes vectores es elevado.</li> </ul>
<p><b>Algoritmo de Particionamiento Recursivo</b></p>	<ul style="list-style-type: none"> <li>- Realiza un planteamiento del problema que analiza todas las opciones.</li> <li>- Permite comprobar las posibles consecuencias de tomar una determinada solución.</li> <li>- Pueden cuantificar el coste de un resultado y la probabilidad de que ocurra.</li> <li>- Facilidad de interpretación.</li> <li>- Son versátiles.</li> </ul>	<ul style="list-style-type: none"> <li>- Elevado coste computacional con muestras grandes.</li> <li>- Existen complicaciones para organizar las ideas, debido a que no se establecen claridad de objetivos.</li> <li>- No alcanzan la capacidad predictiva de las redes neuronales. [61]</li> </ul>
<p><b>K-vecinos más cercanos</b></p>	<ul style="list-style-type: none"> <li>- Coste de entrenamiento es nulo.</li> <li>- No realiza asunciones teóricas.</li> <li>- Es posible evitar empates clasificatorios determinando números impares para el valor K.</li> </ul>	<ul style="list-style-type: none"> <li>- Poco útil con muestras pequeñas.</li> <li>- Muy sensible al ruido.</li> <li>- Buscar los K vecinos más cercanos para muestras grandes tiene un coste computacional alto.</li> <li>- Su rendimiento depende del número de dimensiones o atributos de los que se dispone (mayor número de dimensiones = más prototipos son necesarios).</li> </ul>

Tabla 9. Ventajas y limitaciones de las técnicas basadas en IA

### 3.7 Ratios empleados en modelos de IA

Según el trabajo de Aziz y A. Dar, el 60% de los estudios de quiebra empresarial, utilizaban como variables explicativas ratios financieros que median la liquidez, la solvencia, los beneficios, la composición de activos, el crecimiento, el tamaño de una empresa, etc. Con el objetivo de predecir



la quiebra de una empresa. El 33% incorporaba ratios financieros y otras variables (macroeconómicas, características del sector, geografía, etc.). El 7% restante únicamente empleaba información proveniente de los flujos de caja.

Dada la tendencia general de seleccionar ratios financieros como variables explicativas de la quiebra de empresas, seleccionamos aleatoriamente 7 de los 32 estudios que emplean modelos basados en inteligencia artificial y registramos en una tabla los ratios empleados (Anexo 2). Tras contabilizar el número de apariciones de 39 ratios, estos fueron los más empleados:

Ratios	Nº de estudios
Activo Circulante/Pasivo Circulante	4
BAlI/Activo Total	2
Beneficios No Distribuidos/Activo Total	2
Beneficio Neto/Activo Total	2
Capital/Activo total	2
Gastos Financieros/Ventas	2

*Tabla 10. Recuento de ratios más empleados*

Pese al pequeño tamaño de la muestra analizada, si contrastamos el resultado obtenido a partir de nuestra muestra con el recuento de los 8 ratios más frecuentes realizado por Francisco Javier Castaño en su tesis doctoral [46], cuyo recuento de ratios incluye a todos los modelos utilizados en la predicción de quiebras, comprobamos que los ratios Activo Circulante/Pasivo Circulante, BAlI/Activo, Beneficios No Distribuidos/Activo Total y Beneficio Neto/Activo Total también se encuentran en su clasificación. Luego podemos decir que estos ratios no son triviales en cuanto a su utilización como variable explicativa en los modelos de predicción de quiebras.

Con la misión de encontrar fundamentos teóricos que relacionen nuestros 6 ratios financieros más frecuentes con la quiebra económica empresarial, definimos e indagamos en cada uno de los componentes de estos ratios:

- **Activo Circulante y Pasivo circulante:**

El Activo Circulante, conocido también como activo corriente, es el activo líquido al momento de cierre de un ejercicio o que es convertible en dinero en un plazo inferior a 12 meses. Se consideran en el Activo Circulante conceptos como: valores negociables e inventarios, efectivo en caja y bancos, documentos y cuentas por cobrar.

Al igual que el Activo Circulante, el pasivo circulante es la parte del pasivo que contiene las obligaciones a corto plazo de la empresa, es decir, inferiores a un año.

Es evidente que debe estar financiado por deudas con un vencimiento inferior a un año. Si el importe del pasivo circulante (deudas a pagar en el plazo de un año) termina por superar el importe del Activo Circulante (importe de las partidas que se transformarán en dinero en el plazo de un año) daría lugar una situación de suspensión de pagos técnica (Ilustración 3), siendo precedente de quiebra empresarial [47].

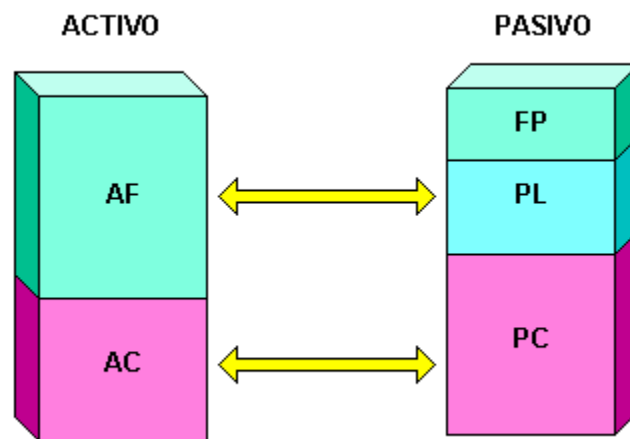


Figura 23. Representación gráfica: Pasivo circulante > Activo Circulante [65]

Donde AC es el Activo Circulante, PC el pasivo circulante, AF es el activo fijo, FP los fondos propios, PL el pasivo exigible a largo plazo y PC el pasivo exigible a corto plazo.

Si la situación se agrava y las deudas contraídas con terceros sean mayores que el valor contable de los activos de la empresa, implicaría la negatividad de los fondos propios, y como consecuencia, la empresa se encontraría en una situación de quiebra técnica.

- **BAIL:**

El BAIL (Beneficios Antes de Intereses e Impuestos) o EBIT (Earnings Before Interest and Taxes) es un indicador del resultado de explotación de una empresa sin tener en cuenta ingresos y costes financieros, que dependen de la forma en que está financiada la empresa y los tipos de interés y sin tener en cuenta el impuesto sobre sociedades (Definición Wikipedia).

Este valor puede ser afectado de manera negativa por diversos factores, por ejemplo una subida de la tasa de inflación o un aumento de los costes de explotación. Si el BAII de una empresa disminuye, esta puede encontrarse en una situación de falta de fondos que no le permitiría hacer frente al pago de sus deudas contraídas [48].

- **Beneficios No Distribuidos:**

Es la parte del beneficio después de impuestos que no se reparte en forma de dividendos, sino que permanece en la empresa (generalmente se aplica a la constitución de reservas). La no distribución de beneficios responde a una decisión estratégica de la empresa (adoptada por la Junta General de accionistas), que puede estimar conveniente un aumento de los recursos propios.

Los beneficios no distribuidos se reflejan en el pasivo de la empresa

- **Activo Total:**

Este indicador se utiliza en la construcción de numerosos ratios como denominador. Lejos de suponer una variable clave en la predicción de quiebras, tiene una gran utilidad ya que es capaz de controlar cualquier variable, ya tenga un valor elevado o reducido, para que muestre la proporcionalidad de la variable en comparación con el activo total de una empresa frente a los de otras.

- **Beneficio Neto:**

Como es lógico, el beneficio que le queda a una empresa tras el ciclo operativo que resta sus ingresos es una variable fundamental en la predicción de quiebras. Una empresa es capaz de hacer frente a sus deudas siempre y cuando genere beneficio neto. Tanto si no obtiene beneficios, como si son tan bajos que desaparecen tras la resta de intereses, impuestos, amortizaciones, etc. La empresa agotará todos sus recursos para pagar los intereses y devolver la deuda, hasta el momento en que se agoten y se encuentre en situación de quiebra.

### 3.8 Conclusiones del Capítulo

- El objeto de estudio son las empresas declaradas en situación de quiebra o suspensión de pagos de manera indiferente.
- Los ratios financieros son las variables explicativas más empleadas en los estudios de predicción de quiebras. Habitualmente, suelen basarse en datos que tienen como origen las cuentas de la compañía, haciendo un uso marginal del resto de fuentes.
- El valor de los resultados ha mejorado debido al uso de muestras reservadas (parte de la muestra se utiliza para estimar el modelo y parte se utiliza para que el modelo seleccionado trabaje).
- Los problemas de predicción de quiebras son vulnerables ante muestras pequeñas.
- Los ratios financieros de los que se sirven los modelos de inteligencia artificial con más frecuencia, coinciden con los ratios financieros más frecuentados por el resto de modelos.
- Existen fundamentos teóricos que relacionan a los ratios financieros más utilizados con la quiebra empresarial.
- Uno de los problemas existentes en este campo de estudio es la recopilación de datos procedentes de empresas que han quebrado. La mayoría de empresas que publican su información no quiebran, por lo que es complicado encontrar muestras de tamaño relevante.
- Ciertos modelos predictivos no han sido lo suficientemente experimentados, especialmente los basados en inteligencia artificial. Debido a ello, no se incluyen tasas de rendimiento fiables. (Escalado Multidimensional, Razonamiento Basado en Casos, Mapas autoorganizados, Máquinas de Soporte Vectorial, K-Vecinos más cercanos).
- La utilización de modelos teóricos de manera aislada, es muy limitada. Tienen las tasas de errores más altas en comparación con el resto de modelos. Debido a ello han sido empleados en reducidas ocasiones.
- Es posible emplear las teorías de crédito en la predicción de quiebras, permitiendo datos fiables y de calidad. Sin embargo, al ser herramientas de pago, su funcionamiento y acceso están reservados, a causa de ello no se tiene información contrastada sobre el rendimiento de estas herramientas.
- El horizonte temporal que manejan los modelos teóricos es de alto valor, siempre que se complemente de otras técnicas no teóricas. Podría ser interesante utilizar los principios que



plantean en sistemas expertos, con el fin de crear una base de conocimiento a partir del conjunto de modelos teóricos.

- Las técnicas estadísticas tienen la virtud de no tener conocimiento teórico de los datos que trabaja, por tanto siempre pueden ser utilizadas para reforzar un modelo teórico sin parcialidad. La operativa de los modelos basados en inteligencia artificial, tampoco tiene conocimientos “teóricos de los datos que maneja” sin embargo, los modelos de inteligencia artificial suelen ser entrenados con problemas, casos y/o fundamentos, luego, al presentar un nuevo caso a estudiar, tienen conocimientos aprendidos que utilizarán para estimar un resultado.
- Las técnicas estadísticas más empleadas en el estudio de la predicción de quiebras, han sido el análisis discriminante múltiple y la regresión logística. Probablemente, debido a que obtienen las tasas de precisión más altas.
- Los modelos basados en inteligencia artificial se han empleado de manera continuada desde su aparición, sin embargo estas nuevas técnicas no han desplazado a otros modelos anteriores.
- Los Conjuntos Aproximados y los Algoritmos Genéticos obtienen las mejores tasas de precisión.
- A pesar del aparente buen rendimiento de las técnicas basadas en inteligencia artificial, el número de estudios que las emplean es reducido en comparación con las técnicas estadísticas (a excepción de las redes neuronales).



## Capítulo 4.

# Estudio Empírico

En este capítulo dejamos a un lado los estudios de terceros para realizar nuestro propio estudio sobre la predicción de quiebras empresariales empleando técnicas de inteligencia artificial. Contrastaremos el rendimiento de diferentes modelos de predicción desde un punto de vista propio.

## 4.1 Introducción

En esta parte del trabajo se analizarán, mediante técnicas de inteligencia artificial, variables financieras consideradas potencialmente como predictivas de quiebra empresarial. Desarrollando aspectos empíricos del estudio mediante el uso de estas variables, utilizando como objeto de investigación una muestra de empresas francesas.

Para lograr estos objetivos, comenzaremos describiendo las variables utilizadas, así como su cálculo y clasificación en función de su naturaleza.

## 4.2 Muestra estudiada

Debido al coste que implica la obtención de muestras grandes por cuenta propia, ha sido llevada a cabo una revisión de investigaciones empíricas sobre la quiebra empresarial, con el fin de encontrar una muestra<sup>16</sup> apto para realizar nuestra propia experimentación.

Tras realizar esta revisión, seleccionamos como fuente de información para aplicar las técnicas de inteligencia artificial, la base de datos construida por el profesor Philippe du Jardin. Esta muestra se encuentra disponible de cara al público en la página web del Departamento de Ciencias de la Computación de la Universidad de Aalto (Finlandia).

En la muestra se recogen valores de 41 variables para 500 empresas francesas de 2002 (250 solventes y 250 en quiebra) pertenecientes al sector comercial, con una estructura similar desde el punto de vista de los activos [49]. Las empresas que figuran como “solventes”, continuaron con su actividad hasta el año 2005, es decir, permanecieron en funcionamiento al menos cuatro años más; sin embargo, debido al anonimato de esta información, desconocemos si posteriormente quebraron.

Las variables pertenecen a seis grupos distintos:

1. **Rentabilidad:** ratios que manifiestan la capacidad de obtener beneficios.
2. **Eficiencia:** los ratios pertenecientes a este grupo muestran la capacidad de generar el máximo de resultados con un mínimo de recursos.

---

<sup>16</sup> Una muestra, dataset o conjunto de datos, es una colección de datos tabulada, donde cada columna representa una variable en concreto y cada fila representa un individuo/miembro particular del conjunto de datos.



3. **Problemas Financieros:** ratios que indican posibles amenazas de cara a la estabilidad y bienestar financiero de una empresa.
4. **Estructura Financiera:** ratios que reflejan la composición del capital o recursos financieros que la empresa ha originado.
5. **Liquidez:** estos ratios plasman la capacidad de hacer frente a sus obligaciones a corto plazo.
6. **Rotación:** ratios que miden los rendimientos originados por los activos que obtiene en un período. Complementan a los ratios de rentabilidad.
7. **Cambios:** incluye los ajustes contables realizados sobre el patrimonio de la empresa y sobre el pasivo.

La variable de salida responde a un comportamiento dicotómico, pudiendo tomar los valores 1 o 2, donde 1 indica un resultado solvente y 2 indica la quiebra empresarial tras doce meses.



#### 4.2.1 Variables Estudiadas

Naturaleza	Código	Descripción	Nº
Rentabilidad	RE1	BAII/Fondos de los accionistas	1
	RE2	Ingresos netos/Fondos de los accionistas	2
	RE3	Resultado Operativo/Activos Totales	3
	RE4	Resultado Operativo/Activos Permanentes	4
	RE5	BAI/Activos Totales	5
	RE6	Ingresos Netos/Activos Totales	6
Eficiencia	EF1	Valor Añadido/Activos Totales	7
	EF2	Ventas Totales/Fondos de los accionistas	8
	EF3	BAI/Ventas Totales	9
	EF4	Ventas Totales/Activos Totales	10
	EF5	Beneficio Comercial Bruto/Ventas Totales	11
	EF7	Flujo de Caja Operativo/Activos Totales	12
	EF8	Flujo de Caja Operativo/Ventas Totales	13
Problemas Financieros	PR1	Gastos Financieros/Ventas Totales	14
	PR2	Gastos de Mano de Obra/Ventas Totales	15
Estructura Financiera	SF1	Fondos de los Accionistas/Activos Totales	16
	SF2	Deuda Total/Fondos de los Accionistas	17
	SF7	Deuda Total/Activos Totales	18
	SF8	Capital de Trabajo Neto de Explotación/ Activos Totales	19
	SF10	Deuda a LP/Activos Totales	20
	SF11	Deuda a LP/Fondos de los Accionistas	21
Liquidez	LI1	Efectivo + Valores Negociables/Activos Totales	22
	LI2	Efectivo/Activos Totales	23
	LI3	Efectivo + Valores Negociables/Ventas Totales	24
	LI4	Razón rápida (Quick Ratio): (Efectivo + Títulos o valores negociables + Cuentas por Cobrar)/ Pasivos Corrientes	25
	LI5	Efectivo/Pasivo circulante	26
	LI6	Activo Circulante/Pasivo circulante	27
	LI7	Activo Disponible/Ventas Totales	28
	LI8	Pasivo circulante/Activos Totales	29
	LI9	Activo disponible/Activos Totales	30
	LI10	Resultado Operativo/Ventas Totales	31
	LI11	Deuda Financiera/Flujo de caja	32
	LI12	Efectivo/Deuda Total	33
Rotación	RO1	Efectivo/Ventas Totales	34
	RO2	Inventario/Ventas Totales	35
	RO3	Capital de Trabajo Neto de Explotación/Ventas totales	36
	RO4	Cuentas pendientes de cobro/Ventas Totales	37
	RO5	Cuentas pendiente de pagar/Ventas Totales	38
	RO6	Activo Circulante/Ventas Totales	39



Cambios	AP1	Cambios en el Patrimonio <sup>17</sup>	40
	AP2	Cambios en otras deudas	41

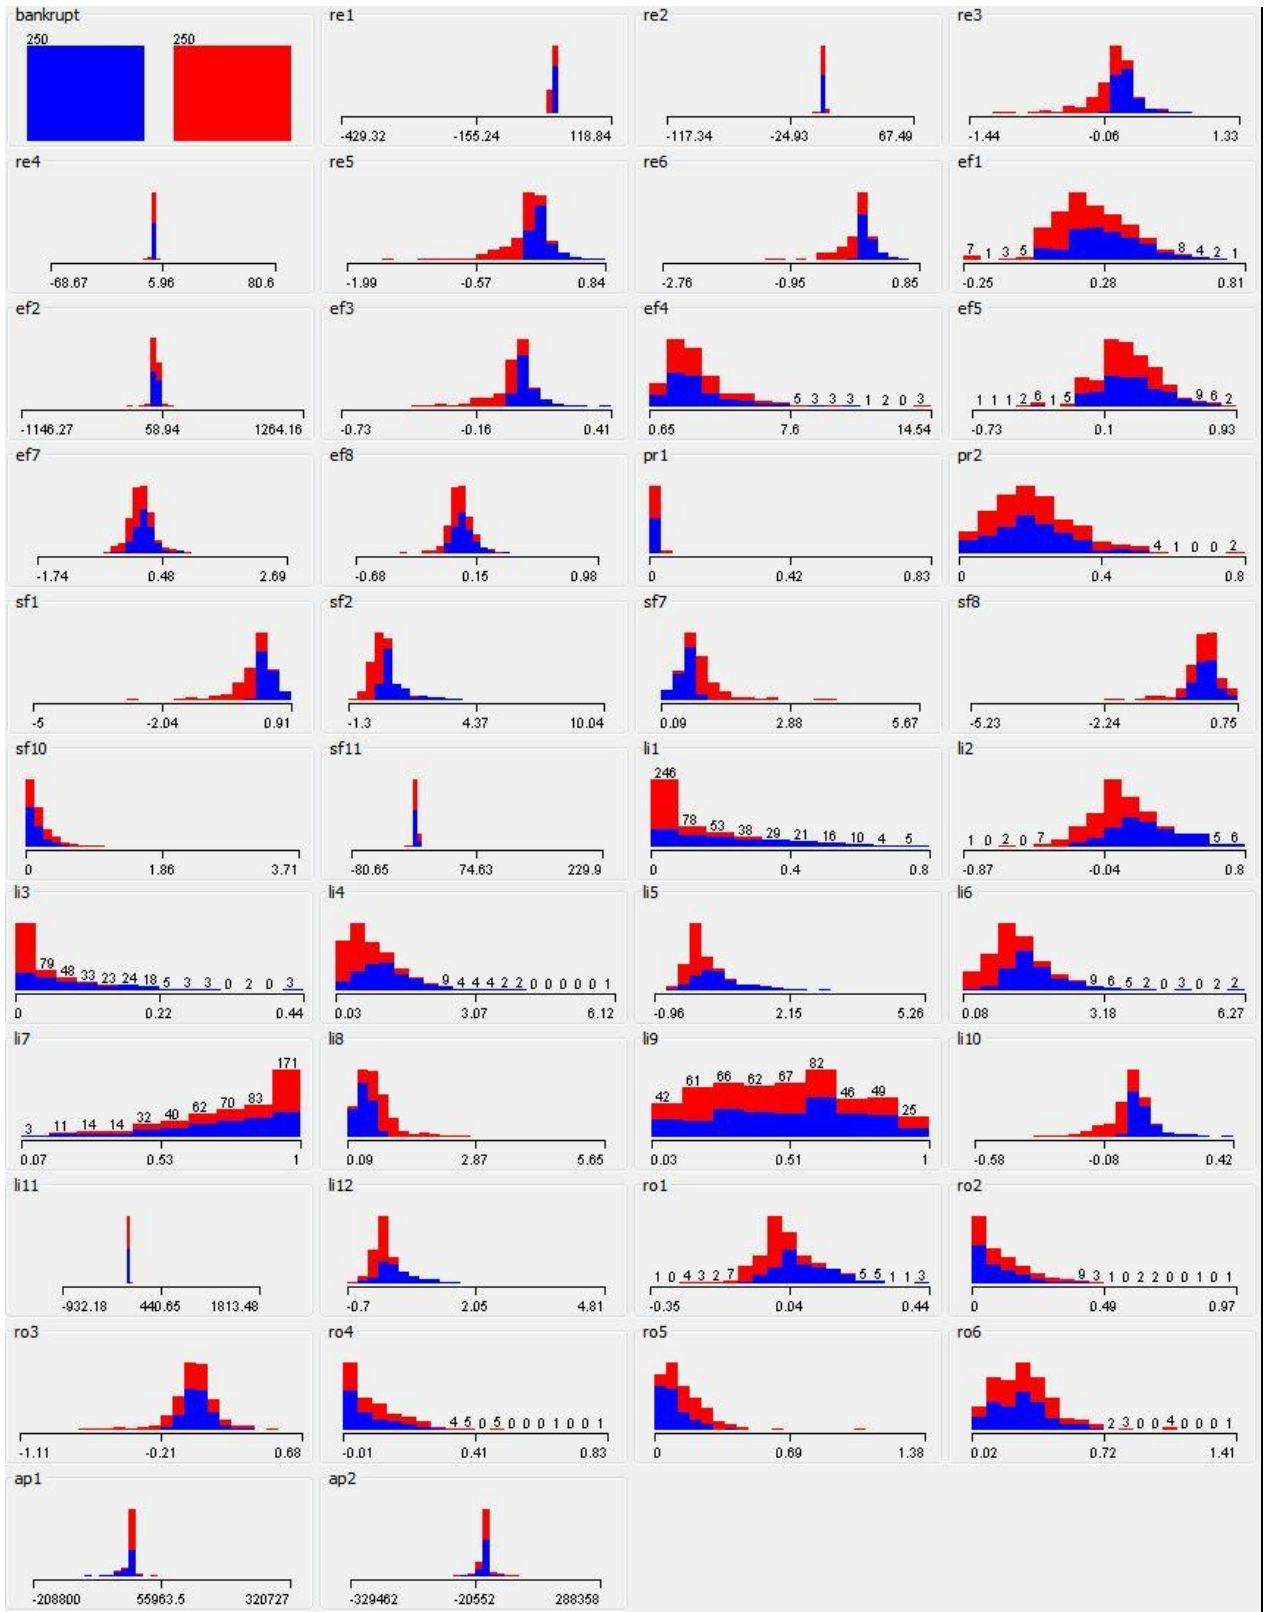
*Tabla 11. Variables incluidas en la muestra estudiada*

Inicialmente, la muestra original contenía como primer atributo (columna) la variable “Quiebra”, sin embargo, para poder trabajar adecuadamente con PRTTools en Matlab, ha sido necesario modificar la estructura de la muestra reservando las primeras 250 posiciones de la misma, para las empresas cuyo valor de la variable “Quiebra” era 1 (empresas solventes) y las siguientes 250 instancias con “Quiebra” igual a 2 (empresas en quiebra). Una vez ordenada la muestra, se ha procedido a eliminar la variable “Quiebra”, para que únicamente figuren variables independientes y sea posible realizar el análisis.

---

<sup>17</sup> Detalla los cambios en el patrimonio neto por todos los ingresos y gastos, tanto los incluidos en el resultado del ejercicio de la cuenta de pérdidas y ganancias, añadiendo las variaciones originadas por operaciones con propietarios de la empresa. (Fuente: Wikipedia).

### 4.2.2 Distribución de Variables



Los diagramas acumulativos anteriores describen la distribución de las variables incorporadas en la muestra estudiada. El primer diagrama de la imagen hace referencia a la variable de estudio “Quiebra”, distinguiendo en azul y en rojo el número de empresas solventes frente a las empresas en quiebra. Este criterio de colores se mantiene para el resto de diagramas.

### 4.3 Selección de Atributos

Como ha sido explicado anteriormente, la muestra empleado para evaluar las técnicas de predicción, contiene 40 variables (atributos), un número lo suficientemente elevado como para dificultar el ajuste de los modelos, haciéndolo más complejo y produciendo sobreentrenamiento<sup>18</sup>.

Para evitar esta adversidad, empleamos las técnicas de selección de atributos, ya implementadas en el software Weka, con el objetivo de principal de eliminar los atributos redundantes e irrelevantes, e intentar reseñar aquellas variables que impactan en mayor medida en la quiebra empresarial:

#### 4.3.1 Correlación Atributo - Quiebra

La evaluación de atributos mediante el cálculo del coeficiente de correlación de Pearson permite medir el grado de relación lineal existente entre un atributo determinado y la quiebra de la empresa.

Tras aplicar esta técnica, observamos que no existen fuertes correlaciones entre los ratios financieros y la quiebra empresarial, únicamente las correlaciones más significativas (mayores de 0,55) son obtenidas por los atributos ef3 (BAI/Ventas Totales), li10 (Resultado Operativo/Ventas Totales) y re3 (Resultado Operativo/Ventas Totales). Como podemos apreciar en los datos de salida generados, 27 de las 41 variables se encuentran por debajo de 0,5, lo que indica una débil correlación con respecto a la quiebra. Sin embargo, existe un ratio muy cercano a la ausencia absoluta de correlación lineal (0,0069), este ratio se corresponde con ef4 (Ventas Totales/Activos Totales).

---

<sup>18</sup> Se produce al entrenar un sistema demasiado o con datos extraños. El algoritmo de aprendizaje puede quedar ajustado a las características particulares de un conjunto de datos de entrenamiento, originándose un empeoramiento de la actuación con muestras nuevas.

### 4.3.2 Ratio de Ganancia de Información

Es posible estimar el valor de un atributo con respecto de la clase quiebra, calculando el criterio de ganancia de información y el ratio de ganancia entre el atributo y dicha clase.

$$\text{Ganancia de información (Quiebra, Atributo)} = H(\text{Quiebra}) - H(\text{Quiebra} | \text{Atributo}).$$

$$\begin{aligned} \text{Ratio Ganancia (Quiebra, Atributo)} \\ = (\text{Entropía}(\text{Quiebra}) - \text{Entropía}(\text{Quiebra} | \text{Atributo})) / \text{Entropía}(\text{Atributo}). \end{aligned}$$

Los resultados obtenidos al comprobar ambos criterios en Weka asignan valores más altos para sf1 (Fondos de los Accionistas/Activos Totales), sf2 (Deuda Total/Fondos de los Accionistas) y re6 (Ingresos Netos/Activos Totales). Los atributos cuyo resultado se corresponde con la valoración más baja posible (0) son ro4 (Cuentas pendientes de cobro/Ventas Totales), ro6 (Activos Circulantes/Ventas Totales), li9 (Activo disponible/Activos Totales), ro2 (Inventario/Ventas Totales), ef4 (Ventas Totales/Activos Totales), ef5 (Beneficio Comercial Bruto/Ventas Totales) y pr2 (Gastos de Mano de Obra/Ventas Totales).

### 4.3.3 Clasificador OneR

El clasificador OneR se caracteriza por su sencillez y velocidad para seleccionar los atributos que mejor explican la quiebra empresarial. Su funcionamiento consiste en la elaboración de reglas para probar todos los pares atributo-clase y evaluar en función de aquellos que obtengan el menor número de errores.

Tras aplicar este clasificador sobre la muestra estudiada, obtenemos valores por encima del 85% para los atributos sf1 (Fondos de los Accionistas/Activos Totales), sf2 (Deuda Total/Fondos de los Accionistas), sf7 (Deuda Total/Activos Totales), re6 (Ingresos Netos/Activos Totales). A la cola del ranking, por debajo del 50% se encuentran ro4 (Cuentas pendientes de cobro/Ventas Totales), ro2 (Inventario/Ventas Totales), pr2 (Gastos de Mano de Obra/Ventas Totales), ro6 (Activo Circulante/Ventas Totales) y ef4 (Ventas Totales/Activos Totales).

### 4.3.4 ReliefF

Este algoritmo de clasificación de características utilizado en los problemas de clasificación binarios, posee la ventaja de ser tolerante al ruido y robusto en cuanto a interacciones entre características.

Los resultados muestran al ratio li1 (Efectivo + Valores Negociables/Activos Totales) como mejor valorado, seguido por sf1 (Fondos de los Accionistas/Activos Totales), sf7 (Deuda

Total/Activos Totales) y li3 (Efectivo + Valores Negociables/Ventas Totales) cuyos valores son muy similares. Los que obtienen calificaciones más bajas son pr1 (Gastos Financieros/Ventas Totales), re4 (Resultado Operativo/Activos Permanentes) y re1 (BAII/Fondos de los accionistas).

#### 4.3.5 Incertidumbre Simétrica

Por último, evaluamos los atributos en función del método de Incertidumbre Simétrica, el cual mide la dependencia de dos variables mediante el cálculo de la reducción de entropía o incertidumbre de un atributo, conociendo previamente si la empresa ha quebrado o no.

sf1 (Fondos de los Accionistas/Activos Totales), sf2 (Deuda Total/Fondos de los Accionistas), re1 (BAII/Fondos de los accionistas) y sf7 (Deuda Total/Activos Totales) obtienen los mejores resultados (por encima de 0.4). Mientras que ro6 (Activo Circulante/Ventas Totales), li9 (Activo disponible/Activos Totales), ro4 (Cuentas pendientes de cobro/Ventas Totales), r02 (Inventario/Ventas Totales), ef5 (Beneficio Comercial Bruto/Ventas Totales), ef4 (Ventas Totales/Activos Totales) y pr2 (Gastos de Mano de Obra/Ventas Totales).

#### 4.3.6 Resultado global de la selección de atributos

A pesar de que existen variables cuyas valoraciones lideran ciertos rankings, los valores frente a otros atributos son muy similares. Si tenemos en cuenta, que existen circunstancias de dificultosa interpretación como en el caso de la variable re1 (BAII/Fondos de los accionistas), la cual obtiene la primera posición en el ranking establecido por la técnica del Ratio de Ganancia, mientras que es la tercera peor variable para el análisis Relief; no podemos afirmar con seguridad que existan variables provechosas, al menos para la muestra estudiado.

Sin embargo, existe una variable que obtiene buenas posiciones (según el ranking establecido: 6ª, 2ª, 1ª, 2ª, 1ª) frente al resto de variables en todas las técnicas empleadas: sf1 (Fondos de los Accionistas/Activos Totales).

No obstante, el objetivo principal establecido de realizar el proceso de selección de atributos, no es identificar las variables más valiosas, sino detectar aquellas variables no

significativas. Debido a ello, seleccionamos<sup>19</sup> las variables peor valoradas para las diferentes técnicas:

Tª Selección Variable	Peor en Correlación	Peor en Ratio de Ganancia	Peor en One R	Peor en Relief	Peor en Incertidumbre Simétrica	Peor Posición Media
<b>ef4</b> (Ventas Totales/Activos Totales)	1º (0.0069)	2º (0)	1º (46)	17º (0.0090771)	2º (0)	<b>1.232º</b>
<b>ro6</b> (Activo Circulante/Ventas Totales)	10º (0.9804)	7º (0)	2º (48.2)	18º (0.0094651)	7º (0)	<b>1.889º</b>
<b>ef5</b> (Beneficio Comercial Bruto/Ventas Totales)	14º (0.1439)	3º (0)	6º (50.2)	4º (0.0003043)	3º (0)	<b>2.009º</b>
<b>pr2</b> (Gastos de Mano de Obra/Ventas Totales)	6º (0.03528)	1º (0)	4º (48.4)	15º (0.0076602)	1º (0)	<b>2.013º</b>
<b>ro2</b> (Inventario/Ventas Totales)	16º (0.17)	4º (0)	3º (48.4)	16º (0.0077826)	4º (0)	<b>2.034º</b>
<b>ro4</b> (Cuentas pendientes de cobro/Ventas Totales)	15º (0.16177)	5º (0)	5º (49.8)	20º (0.012859)	5º (0)	<b>2.158º</b>
<b>li9</b> (Activo disponible/Activos Totales)	9º (0.08314)	6º (0)	8º (52.2)	19º (0.011191)	6º (0)	<b>2.185º</b>

Tabla 12. Variables menos significativas según técnicas de selección

<sup>19</sup> El criterio fijado para seleccionar estas variables no deseadas, consiste en ordenar las variables en función de la media de su posición, es decir, se suman las posiciones logradas en cada uno de los 5 rankings y se divide entre 5.

## 4.4 Experimentos planteados

Mediante la realización de los siguientes ensayos, perseguimos el objetivo de identificar las técnicas de clasificación más efectivas para la predicción de quiebras.

En los experimentos, utilizamos la librería PRTools como recurso complementario a Matlab, para probar las diferentes técnicas clasificatorias<sup>20 21</sup> y contrastar sus rendimientos:

1. Clasificador Discriminante Lineal
2. Clasificador Discriminante Cuadrático
3. Clasificador Regresión Logística (Función sigmoide)
4. Clasificador Parzen
5. Clasificador 5-vecinos más cercanos
6. Clasificador 7-vecinos más cercanos
7. Clasificador 11-vecinos más cercanos
8. Perceptron Multicapa BPNN (1 neurona en la capa oculta)
9. Perceptron Multicapa BPNN (5 neuronas en la capa oculta)
10. Perceptron Multicapa BPNN (10 neuronas en la capa oculta)
11. Perceptron Lineal
12. Red de Neuronas de Base Radial (5 funciones de base radial)
13. Red de Neuronas de Base Radial (10 funciones de base radial)
14. Red de Neuronas de Base Radial (15 funciones de base radial)
15. Máquina de Soporte Vectorial
16. Árbol de decisión binario

Para analizar la precisión de cada técnica generamos la siguiente información para cada experimento:

1. Tasa de error de precisión medio sobre el conjunto de test.
2. Tasa de precisión de precisión sobre sobre el conjunto de test.
3. Matriz de confusión media resultante sobre la muestra completo para identificar los errores de tipo I y tipo II:

---

<sup>20</sup> Todas estas técnicas son explicadas en el apartado 3.4 de esta memoria.

<sup>21</sup> En el anexo 2 de la memoria, se indica la parametrización escogida para cada técnica empleada.



		Predicción	
		Quiebra	Solvente
Clase Actual	Quiebra	Positivo Verdadero	Negativo Falso
	Solvente	Positivo Falso	Negativo Verdadero

Tabla 13. Matriz de Confusión

Las entradas en la matriz de confusión tienen el siguiente significado:

- **Positivos Verdaderos (PV):** empresas clasificadas como en quiebra que, efectivamente, lo están.
- **Negativos Verdaderos (NV):** compañías clasificadas como solventes que realmente son solventes.
- **Positivos Falsos (PF):** empresas clasificadas como en quiebra, cuando realmente son solventes.
- **Negativos Falsos (NF):** compañías clasificadas como solventes, sin embargo están en quiebra.

Estos parámetros son de gran utilidad para el cálculo de la especificidad y la sensibilidad:

$$Especificidad = \frac{|NV|}{|PF| + |NV|}$$

$$Sensibilidad = \frac{|PV|}{|PV| + |NF|}$$

A la hora de contrastar las tasas de error de diferentes experimentos para los mismos clasificadores, la reducción o el aumento porcentual de los errores, quedará recogida en tablas señalizadas mediante colores (verde = disminución de error, amarillo = error constante, naranja = aumento del error).

### Experimento 1

Configuramos el set de entrenamiento seleccionando, aleatoriamente, el 60% de las empresas de la muestra original, el 40% de empresas restantes es empleado para construir el set de test que pretendemos clasificar.



Repetimos el proceso 30 veces, seleccionando diferentes sets de entrenamiento y test en cada iteración y finalmente, obtener el rendimiento medio de cada clasificador.

### **Experimento 2**

Repetimos el experimento llevado a cabo en el experimento anterior utilizando la muestra original, excluyendo, mediante la herramienta CSVed, los atributos catalogados como redundantes o de poca capacidad explicativa: ef4, ef5, li9, pr2, ro2, ro4 y ro6.

La finalidad de este experimento es comprobar si el rendimiento de los clasificadores mejora, al descartar previamente los atributos menos útiles en la determinación de la quiebra empresarial.

### **Experimento 3**

Tras analizar los resultados obtenidos en los experimentos I y II, se seleccionan los cinco clasificadores con mejores resultados (Discriminante Lineal, Cuadrático, Perceptron Lineal, Máquina de Soporte Vectorial y Árbol de decisión) y, tras entrenar este conjunto de clasificadores destacados en las mismos sets de entrenamiento, se selecciona la clase de salida en función de seis criterios distintos:

1. Combinación por Producto: se selecciona la clase que produce el valor más alto del producto de las salidas de los clasificadores.
2. Combinación por Media: es elegida la clase correspondiente a la media de las salidas de los clasificadores.
3. Combinación por Mediana: esta opción selecciona la clase correspondiente a la mediana de las salidas de los clasificadores
4. Combinación por Máximo: escoge la clase que da la salida con el valor máximo de las salidas de los clasificadores.
5. Combinación por Mínimo: selecciona la clase que da la salida con el valor mínimo de las salidas de los clasificadores.
6. Combinación por Votación: se toma la clase más votada (la más dada) de las salidas de los clasificadores.

Con la finalidad de evitar la distorsión de los resultados, repetiremos el proceso 30 veces y mostraremos las tasas medias de error y precisión para cada clasificador generado.

#### Experimento 4

Realizamos las mismas combinaciones de clasificadores, utilizando esta vez la muestra excluyendo los atributos redundantes de la muestra original, al igual que se lleva a cabo en el experimento 2.

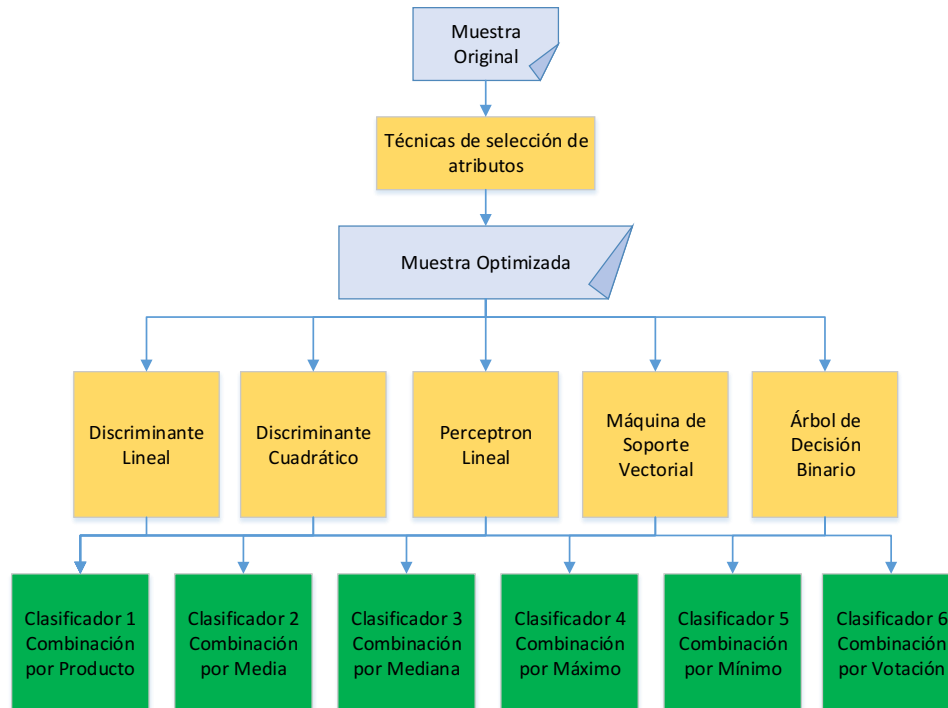


Figura 24. Diagrama Completo del Experimento 4

## 4.5 Resultados

### 4.5.1 Experimento 1

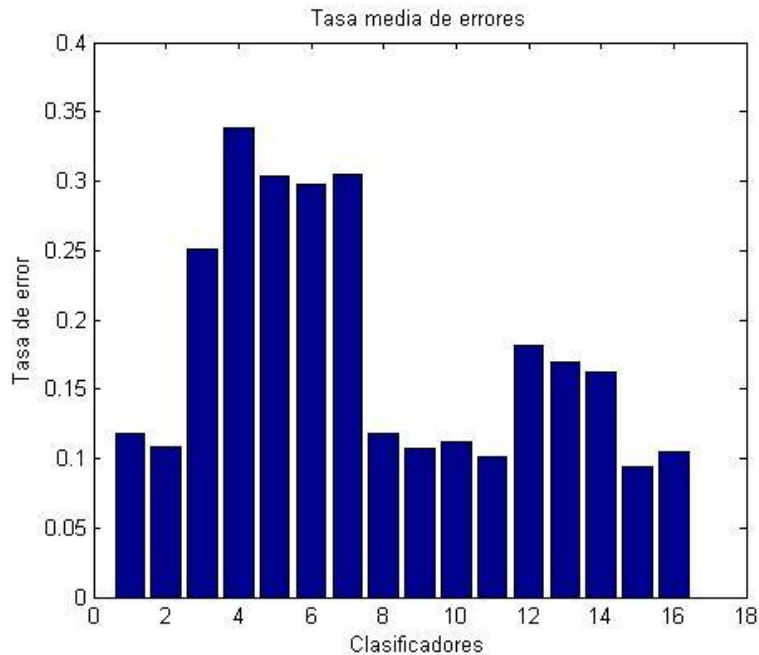


Figura 25. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 1)

Nº	Clasificador	% Error medio	% Precisión medio	Efectividad	Sensibilidad
1	Análisis Discriminante Lineal	11,75%	88,25%	94,40%	86,76%
2	Análisis Discriminante Cuadrático	10,85%	89,15%	94,95%	88,60%
3	Regresión Logística (Función sigmoide)	25,12%	74,88%	77,16%	79,88%
4	Parzen	33,80%	66,20%	58,97%	75,83%
5	5 - vecinos más cercanos	30,32%	69,68%	74,75%	76,91%
6	7 - vecinos más cercanos	29,77%	70,23%	73,03%	77,07%
7	11 - vecinos más cercanos	30,47%	69,53%	69,72%	77,03%
8	Multicapa BPNN (1 neurona en capa oculta)	11,83%	87,89%	87,40%	92,80%
9	Multicapa BPNN (5 neurona en capa oculta)	10,73%	89,21%	87,73%	94,07%
10	Multicapa BPNN (10 neurona en capa oculta)	11,17%	88,51%	87,87%	91,30%
11	Perceptron Lineal	10,12%	89,88%	92,96%	91,93%

12	Red de Neuronas de Base Radial (5 funciones)	18,10%	81,90%	90,00%	89,07%
13	Red de Neuronas de Base Radial (10 funciones)	16,90%	83,10%	90,00%	89,93%
14	Red de Neuronas de Base Radial (15 funciones)	16,28%	83,72%	90,93%	90,60%
15	Máquina de Soporte Vectorial	9,37%	90,63%	95,67%	90,80%
16	Árbol de decisión	10,47%	89,53%	95,76%	95,87%

Tabla 14. Especificidad y Sensibilidad de clasificadores (Experimento 1)

#### 4.5.2 Experimento 2




Figura 26. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 2)

Nº	Clasificador	% Error medio	% Precisión media	Efectividad	Sensibilidad
1	Análisis Discriminante Lineal	12,15%	87,85%	92,95%	86,47%
2	Análisis Discriminante Cuadrático	10,85%	89,15%	95,49%	86,75%
3	Regresión Logística (Función sigmoide)	18,30%	81,70%	86,23%	83,11%
4	Parzen	35,08%	64,92%	60,64%	73,00%
5	5 - vecinos más cercanos	29,60%	70,40%	74,88%	77,51%
6	7 - vecinos más cercanos	29,47%	70,53%	73,35%	76,37%

7	11 - vecinos más cercanos	28,87%	71,13%	70,33%	77,35%
8	Multicapa BPNN (1 neurona en capa oculta)	13,65%	86,35%	84,87%	93,60%
9	Multicapa BPNN (5 neurona en capa oculta)	12,16%	87,84%	84,72%	94,93%
10	Multicapa BPNN (10 neurona en capa oculta)	11,73%	88,27%	83,93%	95,53%
11	Perceptron Lineal	9,97%	90,03%	91,76%	91,59%
12	Red de Neuronas de Base Radial (5 funciones)	17,78%	82,22%	90,00%	89,33%
13	Red de Neuronas de Base Radial (10 funciones)	15,95%	84,05%	90,00%	90,07%
14	Red de Neuronas de Base Radial (15 funciones)	15,19%	84,01%	91,00%	90,67%
15	Máquina de Soporte Vectorial	8,10%	91,90%	96,04%	90,48%
16	Árbol de decisión	9,57%	90,43%	96,31%	96,04%

Tabla 15. Tasas de error, precisión, especificidad y sensibilidad de clasificadores (Experimento 2)

Nº	Clasificador	% Error medio Experimento 1	% Error Medio Experimento 2	Diferencia
1	Análisis Discriminante Lineal	11,75%	12,15%	<b>+0,40%</b>
2	Análisis Discriminante Cuadrático	10,85%	10,85%	<b>0,00%</b>
3	Regresión Logística (Función sigmoide)	25,12%	18,30%	<b>-6,82%</b>
4	Parzen	33,80%	35,08%	<b>+1,28%</b>
5	5 - vecinos más cercanos	30,32%	29,60%	<b>-0,72%</b>
6	7 - vecinos más cercanos	29,77%	29,47%	<b>-0,30%</b>
7	11 - vecinos más cercanos	30,47%	28,87%	<b>-1,60%</b>
8	Multicapa BPNN (1 neurona en capa oculta)	11,83%	13,65%	<b>+1,82%</b>
9	Multicapa BPNN (5 neurona en capa oculta)	10,73%	12,16%	<b>+1,43%</b>
10	Multicapa BPNN (10 neurona en capa oculta)	11,17%	11,73%	<b>+0,56%</b>
11	Perceptron Lineal (Tasa de aprendizaje = 0,1)	10,12%	9,97%	<b>-0,15%</b>
12	Red de Neuronas de Base Radial (5 funciones)	18,10%	17,78%	<b>-0,32%</b>
13	Red de Neuronas de Base Radial (10 funciones)	16,90%	15,95%	<b>-0,95%</b>
14	Red de Neuronas de Base Radial (15 funciones)	16,28%	15,19%	<b>-1,09%</b>
15	Máquina de Soporte Vectorial	9,37%	8,10%	<b>-1,27%</b>
16	Árbol de decisión	10,47%	9,57%	<b>-0,90%</b>

Tabla 16. Comparativa de tasas de error en experimentos 1 y 2

### 4.5.3 Experimento 3

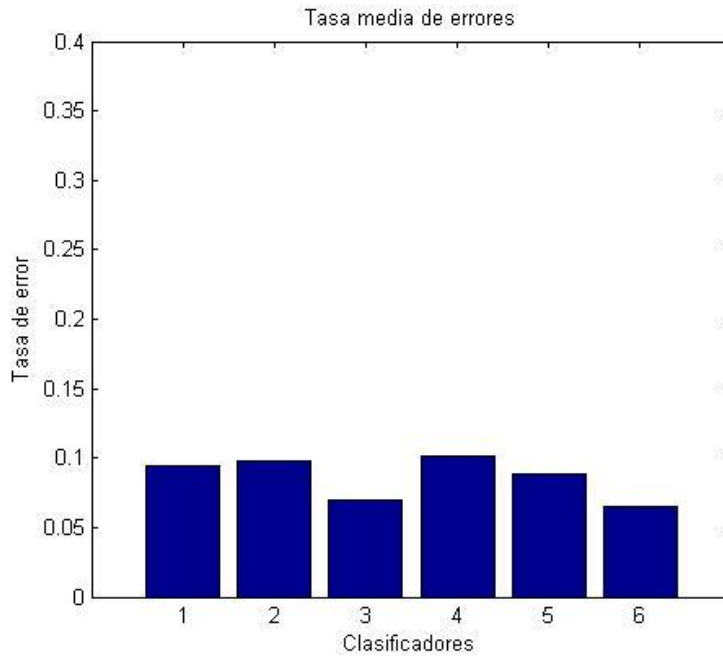


Figura 27. Diagrama de tasas medias de error generadas por los clasificadores (Experimento 3)

Clasificador	% Error medio	% Precisión media
<b>Clasificador 1</b> (Comb. Producto)	9,44%	90,56%
<b>Clasificador 2</b> (Comb. Medio)	9,82%	90,18%
<b>Clasificador 3</b> (Comb. Mediana)	7,02%	92,98%
<b>Clasificador 4</b> (Comb. Máximo)	10,14%	89,86%
<b>Clasificador 5</b> (Comb. Mínimo)	8,89%	91,11%
<b>Clasificador 6</b> (Comb. Votación)	6,53%	93,47%

Tabla 17. Tasas de error y precisión medias de clasificadores combinados (Experimento 2)

#### 4.5.4 Experimento 4

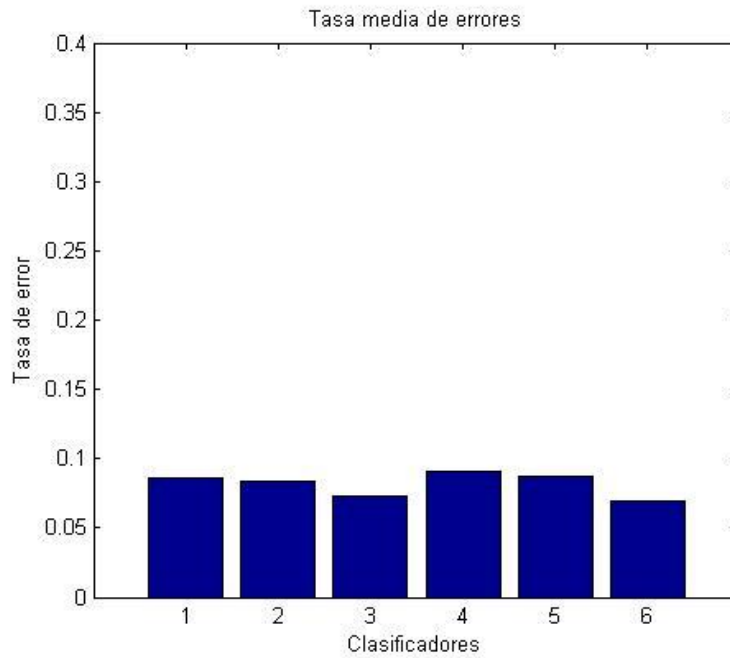


Figura 28. Diagrama de tasas medias de error generadas por los clasificadores combinatorios (Experimento 4)

Nº	Clasificador	% Error Medio Exp 3	% Error Medio Exp 4	Diferencia
1	<b>Clasificador 1</b> (Com. Producto)	9,44%	8,64%	<b>-0,80%</b>
2	<b>Clasificador 2</b> (Com. Medio)	9,82%	8,41%	<b>-1,41%</b>
3	<b>Clasificador 3</b> (Com. Mediana)	7,02%	7,27%	<b>+0,25%</b>
4	<b>Clasificador 4</b> (Com. Máximo)	10,14%	9,05%	<b>-1,09%</b>
5	<b>Clasificador 5</b> (Com. Mínimo)	8,89%	8,76%	<b>-0,13%</b>
6	<b>Clasificador 6</b> (Com. Votación)	6,53%	6,92%	<b>+0,39%</b>

Tabla 18. Comparativa de tasas de error en experimentos 3 y 4



## 4.6 Conclusiones del Capítulo

- Existen siete clasificadores que obtienen tasas cercanas al 10% de error: Máquina de soporte vectorial (9,37%), Perceptron Lineal (10,12%), Árbol de decisión (10,47%), Clasificador Cuadrático (10,85%) y Análisis Discriminante Lineal (11,75%).
- Los análisis discriminantes mantienen tasas medias de error bajas durante dos primeros experimentos contrastados. Sin embargo, atendiendo a los resultados generados en los experimentos 1 y 2 por ambos análisis discriminantes (lineal y cuadrático), observamos que el análisis discriminante cuadrático obtiene mejor tasa de error que la generada por el lineal. Una posible explicación a este comportamiento podría tener que ver con la existencia de desigualdad de las matrices de covarianza generadas a partir de la muestra. Al darse esta condición, se incumpliría una de las condiciones necesarias para el buen rendimiento del análisis discriminante lineal, generando una ligera diferencia.
- Las tasas de error obtenidas mediante el clasificador de los K-vecinos más cercanos se encuentran entorno al 70%, tasas poco eficientes para un sistema de predicción fiable.
- Al aumentar los K no se observan patrones de mejora en el rendimiento de este algoritmo sobre la muestra estudiada para el experimento 1, mientras que para el experimento 2 aparentemente se reduce el error mínimamente.
- Las Redes multicapa BPNN, obtienen tasas de precisión satisfactorias cercanas al 88%. Al igual que en el caso de los K-vecinos más cercanos, no es observable, un patrón de mejora al incrementar el número de neuronas situadas en la capa oculta para el primer experimento, sin embargo en el experimento 2 se aprecia una ligera disminución del error.
- El Perceptron lineal alcanza porcentajes de acierto satisfactorios cercanos al 90%. En base a este resultado y conociendo el hecho de que se encuentra entre los cinco mejores comportamientos de entre todas las técnicas para ambos experimentos, seleccionamos el Perceptron Lineal con tasa de aprendizaje 0,1 como integrante del clasificador combinado.
- Las tasas de error asociada a las Redes de Neuronas de base radial decrecen paulatinamente al aumentar el número de funciones de base radial (del 17% al 15%).
- La máquina de soporte vectorial genera las tasas de acierto más altas entre las técnicas probadas en ambos ejercicios (9,37% y 8,10%). Motivo suficiente para incluir esta técnica como componente del clasificador combinado en los ejercicios 3 y 4.



- Los resultados del árbol de decisión muestran una tasa de acierto cercana al 90%. Por ello, también seleccionamos el árbol de decisión como quinto integrante del clasificador combinado.
- Los porcentajes de especificidad y sensibilidad, están directamente relacionados con la tasa de error, sin embargo, podemos las tasas de sensibilidad generadas por la máquina de soporte vectorial son notablemente inferiores a las de especificidad, lo que indica una mayor dificultad para clasificar negativos verdaderos que para clasificar positivos verdaderos. Encontramos el caso contrario con el clasificador Parzen y con los Perceptrones Multicapa, que como podemos apreciar, clasifican mejor los negativos verdaderos que los positivos verdaderos.
- Mediante las técnicas de selección de atributos, confirmamos que los ratios menos significativos en la muestra estudiada son: Ventas Totales/Activos Totales, Activo Circulante/Ventas Totales, Beneficio Comercial Bruto/Ventas Totales, Gastos de Mano de Obra/Ventas Totales), Inventario/Ventas Totales, Cuentas pendientes de Cobro/Ventas Totales y Activo disponible/Ventas Totales.
- De manera generalizada, podemos afirmar que el rendimiento global de los 16 clasificadores aumenta al excluir los atributos menos significativos del dataset original. Los resultados manifiestan que diez de los clasificadores (Regresión Logística, todos los K-vecinos, todas las redes de neuronas de base radial, máquina de soporte vectorial y árbol de decisión) reducen su tasa de error, uno mantiene la misma tasa (Análisis Discriminante Cuadrático) y cinco clasificadores la incrementan (Análisis Discriminante Lineal, Clasificador Parzen y todos los Perceptrones Multicapa BNPP).  
Destaca especialmente la disminución del error efectuada por el clasificador de Regresión Logística del 25,12% al 18,30%, así como la reducción del error para la máquina de soporte vectorial del 9.37% al **8.10%**. En este último caso, logramos el mayor porcentaje de acierto de los dos primeros ejercicios sobre la muestra estudiada, gracias a la eliminación de variables redundantes.
- Las tasas de precisión de los clasificadores combinados generadas son aceptables. La mayoría de ellas se encuentra por encima del 90%, lo que manifiesta una clara conformidad en cuanto a las técnicas de clasificación elegidas para integrar el clasificador combinado. En especial, existen dos criterios combinatorios cuyos resultados clasificatorios alcanzan la tasa de error más baja de todo el estudio empírico: el criterio combinador por mediana



(clasificador 3) y el criterio combinador por votación (clasificador 6) obtienen **7.02% y 6,53%** de error respectivamente.

- Al repetir la metodología del experimento 2 con los clasificadores combinados, obtenemos una disminución generalizada de las tasas de error (cuatro de los seis clasificadores combinados reducen sus errores). Sin embargo, los clasificadores combinados que habían obtenido los mejores resultados en el experimento anterior, el clasificador 3 y el clasificador 6, aumentan mínimamente esta tasa de error.
- De manera generalizada, podemos afirmar que la identificación y eliminación de atributos redundantes o poco explicativos, mejora las tasas de acierto de los clasificadores.



## Capítulo 5.

# Conclusiones, Limitaciones y Trabajo Futuro

El quinto capítulo incluye las conclusiones finales del trabajo tras contrastar las evidencias recogidas en la parte teórica con los resultados obtenidos del estudio empírico. De la misma forma, se recopilan las dificultades y limitaciones encontradas a lo largo del trabajo, con objeto de plantear trabajos futuros que puedan explotar las conclusiones de este trabajo y reducir las limitaciones existentes.

## 5.1 Conclusiones

La consecución de este trabajo de investigación, expone al público una imagen general sobre el problema de la predicción de quiebras, así como de los modelos teóricos, estadísticos y basados en Inteligencia Artificial disponibles para su resolución, en el momento actual.

Según la investigación llevada a cabo, los modelos teóricos establecen una reducida variedad de hipótesis e ideas, que carecen de capacidad predictiva si no son aplicadas con la ayuda de otros modelos. Al contrario, los modelos estadísticos y basados en Inteligencia Artificial, son independientes, numerosos y de diversa utilización, aunque, si bien es cierto, que durante la última década, se observa una tendencia favorable a emplear modelos híbridos en la predicción de quiebras empresariales.

Afirmamos de forma genérica, que las técnicas aplicadas en nuestro estudio empírico obtienen rendimientos similares a los obtenidos por el conjunto de investigaciones de terceros. Ejemplo de ello son el análisis discriminante, técnica que alcanza tasas de acierto cercanas al 88% en la práctica frente al 85% de la teoría, los algoritmos de particionamiento recursivo con un 90% de acierto en los experimentos y un 87% en la teoría, o las redes de neuronas artificiales (exceptuando las neuronas de base radial), las cuales obtienen tasas de acierto próximas al 88% frente al 87% de otras investigaciones.

También se desarrolla un modelo híbrido propio, realizando diferentes combinaciones de resultados clasificatorios por parte de las técnicas que han obtenido mejores porcentajes de acierto sobre la muestra de estudio. Concretamente, la combinación por votación, logra obtener una tasa de acierto cercana al 94% sobre la muestra estudiada, porcentaje ciertamente mejorado en comparación al resto de investigaciones consideradas.

Otro de los aspectos estudiados, es el tipo de información que reciben los modelos para predecir la posible quiebra empresarial. Habitualmente se emplean ratios financieros procedentes de los libros contables de las empresas para los diferentes modelos de predicción, sin embargo, los modelos basados en Inteligencia Artificial pueden clasificar erróneamente en base al aprendizaje adquirido durante un momento económico anterior, es decir puede encontrarse desactualizado respecto de la situación actual. Debido a ello, es recomendable incorporar tanto información proveniente de los estados contables, como de fuentes alternativas que describan la situación del mercado actual.

Tal y como hemos comprobado en nuestro estudio empírico, es preferible partir de un problema de predicción con abundancia de datos, considerando que es posible excluir las variables redundantes o menos significativas de una muestra mediante técnicas de selección de atributos. En nuestro caso, mejorando las tasas de precisión.

Por último, y tras haber analizado, tanto la información obtenida a partir de investigaciones de terceros, como la generada a través de nuestro estudio empírico, esta investigación corrobora que las técnicas de predicción basadas en Inteligencia Artificial obtienen mejores resultados que el resto de modelos predictivos.

## 5.2 Limitaciones

La predicción de quiebras empresariales, es un extenso campo de estudio que dispone de un gran número de alternativas para la obtención de resultados y caracterizado por una permanente transformación de las leyes que lo definen. A causa de ello, la elaboración de este trabajo ha entrañado abundantes dificultades y limitaciones:

- El número de estudios que han contrastado modelos teóricos es muy reducido. Debido a ello, existe los datos relativos a su rus resultados se encuentran demasiado sesgados.
- A pesar de intentar estudiar las teorías de crédito, encontramos escasez de información respecto a la operativa interna de estos proyectos. Esto se debe principalmente a que son productos de pago, por lo que, evidentemente, protegen la información para evitar posibles imitaciones de su producto.
- Algunas técnicas de inteligencia artificial como el razonamiento basado en casos, las máquinas de soporte vectorial o el algoritmo de los K-vecinos más cercanos, no han sido empleados en tantos estudios como las redes de neuronas. A causa de ello, es posible que los resultados no muestren la realidad del problema.
- **Limitaciones de la muestra estudiada:**
  - Debido al elevado coste que implica la obtención de una muestra de datos abundantes, en nuestro estudio empírico hemos empleado una muestra de empresas correspondiente al año 2002. Debido a ello, consideramos que sería más recomendable emplear datos de empresas en la actualidad, para así adecuar el estudio al momento actual.

- La muestra estudiada hace referencia a empresas pertenecientes al sector comercial, por tanto, desconocemos si el resto de sectores se comportan de forma similar.
- A pesar de ser una muestra de cuantiosa información (500 empresas x 41 variables), probablemente sea una cantidad insuficiente para caracterizar al resto de empresas. Como consecuencia de ello, es posible que al introducir una nueva empresa, esta pueda ser clasificada erróneamente por algún modelo de predicción.
- **Limitaciones de las herramientas empleadas:**
  - Al experimentar con los Perceptrones Multicapa implementados y con las Redes de Neuronas de Base Radial en PRTools (MATLAB) se han obtenido tasas de error muy elevadas. Debido a ello, hemos tenido que realizar las 30 iteraciones de los experimentos 1 y 2 de forma manual en WEKA, donde se han obtenido resultados más razonables.
  - Contrastando con los resultados obtenidos en investigaciones de terceros, las Redes de Neuronas de Base Radial siguen alcanzando tasas de error ligeramente elevadas (15% - 18%) en WEKA.
  - A pesar de los intentos efectuados para probar el rendimiento de las redes probabilísticas, estas no se encuentran implementadas en ninguna de las herramientas utilizadas. Como recurso alternativo, y conociendo su comportamiento similar, se ha probado el rendimiento del clasificador Parzen.

### 5.3 Trabajo Futuro

Como se ha descrito en este capítulo, la predicción de quiebras es un campo que dispone de un gran número de métodos para dirimir diversas situaciones.

A pesar de que en este trabajo, se analizan sintéticamente, un total de 27 modelos de predicción de quiebras, la aplicación de cada uno de estos modelos sobre la predicción de quiebras, podría dar lugar a un trabajo diferente atendiendo a unas necesidades completamente diferentes, por ejemplo, en función del momento económico o del sector industrial al que pertenecen las empresas.



Atendiendo a los buenos resultados que obtienen las máquinas de soporte vectorial y los árboles de decisión, sería interesante desarrollar un trabajo de investigación que contrastase el rendimiento de ambas técnicas en la resolución del problema de la predicción de quiebras. Este trabajo acotaría considerablemente el abanico de opciones en comparación con nuestro trabajo, por tanto, sería posible realizar más hincapié en la parametrización de estas técnicas, identificando los valores que optimicen los resultados de las mismas.

Por otro lado, la utilización de modelos híbridos, indica una clara intención de aprovechar las capacidades de dos o más métodos, integrando un único modelo. Debido a ello, podría elaborarse un estudio acerca de las posibilidades de integración de técnicas predictivas, realizando un estudio empírico que determine los rendimientos de las diferentes conformaciones.

En relación al párrafo anterior y en base a los conocimientos adquiridos en nuestra investigación, creemos que la construcción un sistema híbrido que se adapte a las características específicas de un problema en particular obtendría mejores resultados que cualquier modelo. Un posible proyecto a llevar a cabo, podría ser la creación de un sistema híbrido de modelos predictivos, que fuese capaz de hacer una selección de los modelos más apropiados para el problema en cuestión, que aplicase estos modelos y tomase una decisión optimizada, en base a criterios combinatorios como los aplicados en nuestro estudio empírico. El modelo, podría contemplar las ideas manifestadas por los modelos teóricos como preceptos adecuados para la toma de decisiones. En este sistema, la selección y posterior aplicación de los modelos óptimos podría seguir el funcionamiento y estructura que plantea la técnica de Razonamiento Basado en Casos. Es decir, la base de conocimiento podría estar formada de datos y de modelos estadísticos y basados en Inteligencia Artificial. De tal manera que al ser planteado un problema de predicción, pudiese buscar la manera de resolverlo en su fuente de información, así como presentar un número determinado de modelos de predicción con unos pesos asociados (ver figura 29).



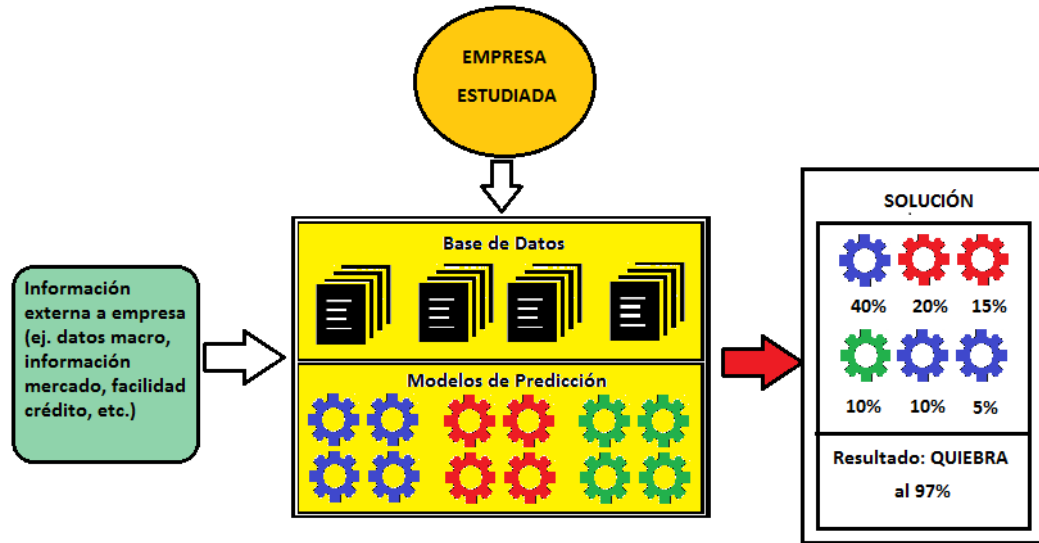


Figura 29. Diseño Inicial del Sistema Híbrido Propuesto

El sistema planteado, podría tener un flujo constante de información alternativa a la interna de la empresa, que sería descartada o recopilada, con la ayuda de técnicas de selección de variables como las que utilizamos en este trabajo. De esta manera, se permitiría la actualización y renovación automática del aprendizaje a los tiempos actuales.

Otros de los trabajos propuestos, a partir de los resultados de esta investigación, sería el de confirmar los resultados obtenidos por las Redes de Neuronas de Base Radial. Como hemos comentado, este comportamiento difiere considerablemente de los resultados esperados.

Por último, consideramos que sería significativo para la mejora de los resultados, realizar una investigación de los atributos más importantes en la predicción de quiebras, similar a la correspondiente en el apartado 3.7 (Ratios empleados en los modelos de Inteligencia Artificial), haciendo referencia a la totalidad de modelos y estudios de predicción de quiebra. Este trabajo podría ordenar un listado con los atributos vinculados a la quiebra empresarial, en función de su frecuencia de uso y su significatividad. Para ello, también podrían incluirse técnicas de selección de atributos como las utilizadas en el apartado 4.3 de nuestra investigación.



## Capítulo 7.

# Planificación y Presupuesto

En este apartado se detallan los tiempos y los costes estimados para la realización del proyecto explicado en la memoria. Se incluye una planificación inicial planteada en el momento del *kickoff*, así como la planificación finalmente realizada. Tanto planificación como presupuesto, han sido calculados en base a la experiencia de terceros especializados en consultoría, así como en los proyectos similares llevados a cabo anteriormente.



## 6.1 Planificación

### 6.1.1 Planificación Inicial

La planificación estimada al comienzo del trabajo constaba de siete etapas:

- **Etapla 1. Planteamiento del Problema**

Una vez seleccionado el tema de investigación, se consideran de manera general la estructura del contenido del trabajo, las herramientas necesarias para su consecución, son convocadas reuniones con los tutores asignados con el fin de hacer hincapié en los aspectos más relevantes y se proyectan los siguientes pasos a seguir. Duración sugerida: 5 días

- **Etapla 2. Exploración e Investigación**

Después de haberse esbozado el problema a resolver, da comienzo una revisión de los artículos científicos publicados con el fin de conocer el estado actual del ejercicio, mientras que se profundiza en los fundamentos teóricos que amparan a estas investigaciones. La metodología empleada durante el desarrollo de esta etapa consiste en llevar a cabo una lectura amplia lectura de documentos, anotando las ideas relevantes y conclusiones en un borrador. Duración sugerida: 60 días

- **Etapla 3. Desarrollo de Ideas**

Se realiza la construcción del bloque teórico del trabajo a partir de la información destacada en la etapa anterior. El desarrollo parte de la definición y explicación de términos generales y se dirige paulatinamente hacia el esclarecimiento de puntos más específicos como descripción modelos de predicción o la demostración de hechos notables. Duración sugerida: 37 días

- **Etapla 4. Experimentación**

Tras habernos familiarizado con los términos frecuentes y haber conocido las diferentes investigaciones llevadas a cabo, se procede con el diseño y realización de nuestro experimento. Probamos diferentes configuraciones y situaciones mediante las herramientas seleccionadas. Se realiza iterativamente un contraste de resultados teniendo en cuenta la posibilidad de rediseñar fases del experimento en función de los rendimientos obtenidos. Duración sugerida: 16 días

▪ **Etapa 5. Redacción de Memoria**

Utilizamos el desarrollo de las ideas de la tercera etapa junto a las conclusiones obtenidas en la etapa de experimentación para redactar el documento que evidencia el trabajo realizado en todas y cada una de las etapas. En ella se muestran los resultados y las conclusiones extraídas del trabajo. Duración sugerida: 55 días

▪ **Etapa 6. Presentación y Formato**

En esta etapa se asigna el formato más conveniente para plasmar la información, se construyen tablas de contenidos, bibliografía y otros formalismos. Duración sugerida: 5 días

**Etapa 7. Revisión Final**

Por último, se lleva a cabo un repaso exhaustivo de la memoria realizada. El autor del trabajo realiza la revisión junto a 3 voluntarios con el fin de localizar y eliminar faltas ortográficas, modificar los párrafos incoherentes y verificar cualquier circunstancia que pueda deteriorar la imagen del trabajo. Duración sugerida: 3 días

Por último establecemos un intervalo de holgura de diez días con anterioridad al cumplimiento del deadline del trabajo (24 de febrero) con el propósito de cubrirnos en caso de retrasos inesperados.

En total se dedican 181 días para elaborar este trabajo. Estableciendo un presupuesto de 3 horas de trabajo por día, obtenemos como resultado 543 horas de trabajo.




Figura 30. Diagrama de la planificación presupuestada

### 6.1.2 Planificación Real

A pesar de haber intentado seguir los pasados establecidos en la planificación inicial como hoja de ruta para cumplir con los objetivos en los plazos fijados, al finalizar el proyecto, hemos comprobado que diferentes etapas de la planificación han sufrido alteraciones con respecto a lo establecido.

Gracias a la inmediata respuesta de los tutores colaboradores del trabajo ante las dudas iniciales, la realización de la primera etapa, no solo no sufrió demoras, sino que incluso fue posible dar paso a la segunda etapa un día antes de lo previsto, al emplear únicamente 4 días para consumación de la primera etapa.

Tal y como se había planificado, la etapa de exploración e investigación fue la etapa que más tiempo agotó, aprovechando también el tiempo extra facilitado por la etapa 1. Hay que destacar, que en las etapas finales del proyecto se realizaron consultas relacionadas con el funcionamiento de las herramientas, o se accedieron a recursos bibliográficos con el fin de completar algunas de las explicaciones ya redactadas en la memoria, sin embargo y a pesar de que había sido contemplada esta posibilidad, consideramos que estas consultas no pertenecen a la segunda etapa, puesto que únicamente se realizaron consultas aisladas para mejorar la explicación de varios modelos y ,además, ya se habían cumplido los objetivos fijados por la etapa de investigación y exploración.

La fase de desarrollo de ideas se prolongó en el tiempo en cuanto a lo previamente estimado. Las sucesivas correcciones estrechamente relacionadas con las conclusiones obtenidas de la parte experimental de este proyecto, readaptaron la estructura de las ideas originales en varias ocasiones. Por lo que finalmente esta etapa se extendió en 10 días más de lo presupuestado.

La fase de experimentación ha supuesto una de las etapas más críticas y problemáticas del proyecto. A pesar de haber comenzado en el día establecido, surgieron numerosos problemas con la herramienta seleccionada para realizar los experimentos, forzándose así un cambio de herramienta y un derroche de tiempo inesperado para aprender a manejar la misma. Esta situación supuso un retraso notable en las fechas definidas, extendiéndose la duración de esta etapa hasta el 12 de febrero.

Como consecuencia de los problemas manifestados, las siguientes etapas vieron modificadas sus plazos de consecución.

En el caso de la etapa correspondiente a la redacción de la memoria, se extendió tres días más de lo establecido, para poder incorporar los comentarios y resultados convenientes de la experimentación.

Las etapas de presentación y formato y la revisión final, respetaron las duraciones estimadas, aunque se vieron obligadas a comenzar cinco días más tarde de lo previsto.

Gracias a los diez días de holgura asignados, ha sido posible finalizar este proyecto tres días antes de la fecha límite de entrega.

Inicialmente se estimaron 181 días de trabajo a 3 horas de media trabajadas al día. Considerándose de esta manera 543 horas de trabajo. Sin embargo, los contratiempos comentados elevaron el tiempo de trabajo total a 684 horas.

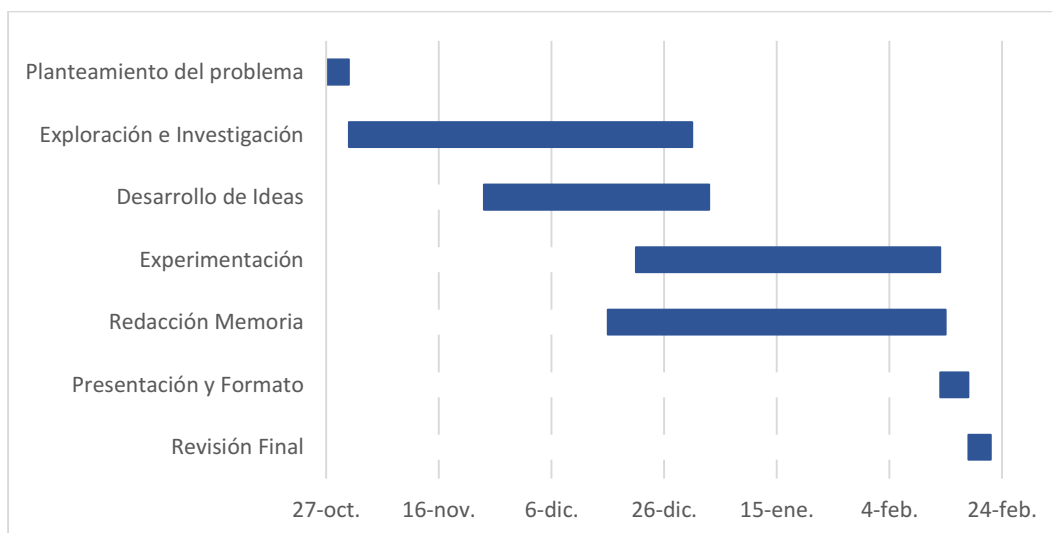


Figura 31. Diagrama de la planificación real

## 6.2 Presupuesto

PERSONAL				
Nombre y Apellidos	Puesto	Tarifa	Horas	Coste Total
Álvaro Montero Casarejos	Analista I	50 €	543	27.150 €
			<b>TOTAL</b>	<b>27.150 €</b>
EQUIPAMIENTO				
Descripción	Duración	Amortización	Coste	Coste Imputable
Ordenador portátil Toshiba Portégé R700	6 Meses	48 Meses	900 €	112,5 €
			<b>TOTAL</b>	<b>112,5 €</b>
SOTWARE				
Descripción	Duración	Amortización	Coste	Coste Imputable
Licencia Microsoft Office 2013 Professional Plus	6 Meses	36 Meses	149 €	24,84 €
Licencia Windows 7 Enterprise	6 Meses	36 Meses	340 €	56,67 €
			<b>TOTAL</b>	<b>81,51 €</b>

RESUMEN	
Concepto	Coste
Personal	27.150 €
Equipo	112,5 €
Software	81,51 €
<b>Total sin IVA</b>	<b>27.344,01 €</b>
I.V.A (21%)	5.742,25 €
<b>TOTAL</b>	<b>33.086,26 €</b>

Por tanto:

“El presupuesto total del proyecto asciende a la cantidad de **TREINTA Y TRES MIL OCHENTA Y SEIS CON VEINTISEIS euros**”.

Colmenarejo, a 24 de Febrero de 2016



Álvaro Montero Casarejos

## Referencias

- [1] Lev, B. (1973), "Decomposition measures for financial analysis", *Financial Management*, Spring, pp. 56-63.
- [2] Booth, P. J., (1983). "Decomposition Measure and the Prediction of Financial Failure". *Journal of Business Finance & Accounting* Volume 10 (1), 67–82.
- [3] Wilcox, J. (1973), "A prediction of business failure using accounting data", *Journal of Accounting Research*, Supplement on Empirical Research in Accounting, pp. 163-90.
- [4] Aziz, A., Dar, A. (2004). "Predicting Corporate Bankruptcy: whither do we stand?". *Economic Research Papers*, no. 04-01. Loughborough University Institutional Repository. Loughborough. Reino Unido.
- [5] Domínguez Martínez J.M, López del Paso R. Los Patrones de Demanda de Efectivo y su Impacto en los Sistemas Financieros. Pág. 4.
- [6] Merton, R. C (1974), *On the Pricing of Corporate Debt: The Risk Structure of Interest Rates*, *Journal of Finance*, Nº. 29, 449-70.
- [7] Ringeling Papic, E.A. (2004) "Análisis comparativo de modelos de predicción de quiebra y la probabilidad de bancarrota". Universidad de Chile. Santiago, Chile.
- [8] De Lara, A. (2003) "Medición y control de riesgos financieros".
- [9] Gutiérrez, J., Elizondo, J. A. (2002). "Riesgo de crédito: El enfoque actuarial". *Trans27th ICA*. Méjico.
- [10] Altman, E.I. (1968) "Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy". *The Journal of Finance*, 23(4), pp. 589–609.
- [11] Mora Enguádanos, A. (1994a). "Limitaciones metodológicas de los trabajos empíricos sobre la predicción del fracaso empresarial". *Revista Española de Financiación y Contabilidad*, 24(80), 709-732.
- [12] Bellovary, J. et al. (2007). "A Review of Bankruptcy Prediction Studies: 1930-Present". *Journal of Financial Education*, Vol. 33, 1-42.





- [13] Back Barbro et al. (1996) "Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms". Turku Centre for Computer Science. Finland.
- [14] Ohlson, J.A. (1980). "Financial Ratios and the Probabilistic Prediction of Bankruptcy". Journal of Accounting Research, Vol 18(1), 109-131
- [15] Shumway, T. (1999) "Hazard Model: Forecasting Bankruptcy More Accurately. A Simple Hazard Model". University of Michigan Business School. Michigan.
- [16] Mark E. Zmijewski. (1984). "Methodological Issues Related to the Estimation of Financial Distress Prediction Models". Journal of Accounting Research Vol. 22, 59-82.
- [17] Ho, S., Lee, C.F. y Wu, C. (1997). "Inter-company dynamics in the financial ratio adjustment", Advances in Quantitative Analysis of Finance and Accounting. 5, 17-31.
- [18] Kallunki, J.P y Martikainen, M. (1999). "Do Firms Use Industry-Wide Targets When Managing Earnings? Finnish Evidence". The International Journal of Accounting. 34, (2): 249-259.
- [19] Guerrero, M y Ramírez, J. "El Análisis de Escalamiento Multidimensional: Una Alternativa y un Complemento a Otras Técnicas Multivariantes". Departamento de Economía de la Empresa. Universidad Pablo de Olavide. Sevilla.
- [20] Bell, T., Ribar, G., Verchio, J. (1990) "Neural nets vs. logistic regression: a comparison of each model's ability to predict commercial bank failures. Deloitte and Touche-University of Kansas Symposium on Auditing Problems, 29-58.
- [21] De Andrés, J., Bonsón, E., Escobar, T. y Serrano, C. (2005) "Inteligencia Artificial y Contabilidad". Documentos AECA. Serie Nuevas Tecnologías y Contabilidad. 5. Madrid.
- [22] Kolodner, J.L. (1992). "An Introduction to Case-Based Reasoning". Georgia Institute of Technology. Atlanta.
- [23] Lozano, L., Fernández, J. "Razonamiento Basado en Casos: Una Visión General". Pág. 11. Universidad de Valladolid.
- [24] EVANNAi. (2015). "Tema 3: Perceptron Multicapa". Material de clase de la asignatura Redes de Neuronas Artificiales. Universidad Carlos III de Madrid.



- [25] Ancona, F., Colla, A., Rovetta, A., Zunino, R. (1998). "Implementing probabilistic neural networks", p. 1. Department of Biophysical and Electronics Engineering. Universidad de Genova. Italia
- [26] Figura 6. Redes de NBarrero, E., Fernández, B. Llanes, O. (2014). "Propuesta de procedimiento para configurar una red neuronal artificial de Base Radial con aplicaciones en el diagnóstico de fallos". Ingeniería Electrónica, Automática y Comunicaciones. Vol. 35, no. 3, p. 60-75.
- [27] Lima, A. R. G. (2002). "Máquinas de Vetores Suporte na Classificação de Impressões Digitais, Dissertação de Mestrado". Universidade Federal do Ceará. Brasil.
- [28] Betancourt, G.A. (2005). "Las Máquinas de Soporte vectorial (SVMs)". Scientia et Technica, 27, pp. 67-72.
- [29] Ribadas F.J. (2012) "TEMA 6. SVM - Support Vector Machines (Máquinas de Vectores Soporte)", pp.10. Universidad de Vigo. España.
- [30] Frydman, H., Altman, E., Kao, D. (1985) "Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress". The Journal of Finance, Vol 40, pp. 269-291.
- [31] Marose, R. A. (1992). "A Financial Neural Network Application: Neural Networks in Finance and Investing". Probus Publishing. Chicago. EEUU.
- [32] Back Barbro et al. (1996) "Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms". Turku Centre for Computer Science. Finland.
- [33] Shin, K.S.; Shin, T.S., y Han, I. (1998): "Intelligent corporate credit rating system using bankruptcy probability matrix". Proceedings of the IV International Conference on Artificial Intelligence and Emerging Technologies in Accounting, Finance and Tax. Huelva. España.
- [34] Ahn. B.S., Cho, S.S., Kim, C.Y. (2000). "The integrated methodology of rough set theory and artificial neural network for business failure prediction. Expert Syst. Appl. 18, 65-74.
- [35] Mckee, T., Lensberg, T. (2002) "Genetic programming and rough sets: A hybrid approach to bankruptcy classification". European Journal of Operational Research 138(2), 436-451.
- [36] Ravisankar, P., Ravi, V., Raghava, G., Bose, I. (2010). "Detection of financial statement fraud and feature selection using data mining techniques". Institute for Development and Research in Banking Technology, Hyderabad, India.



- [37] Yeh, C., Chi, D., Hsu, M. (2010). "A hybrid approach of DEA, rough set and support vector machines for business failure prediction". *Expert Systems with Applications*, vol. 37, pp. 1535-1541.
- [38] Lin, F., Yeh, C., Lee, M. (2013). "A Hybrid Business Failure Prediction Model using Locally Linear Embedding and Support Vector Machines". *Romanian Journal of Economic Forecasting*, 1/2013, pp. 82-97.
- [39] Zhang, Y., Shuihua, W., Genlin, J. (2013). "A Rule-Based Model for Bankruptcy Prediction Based on an Improved Genetic Ant Colony Algorithm". *Mathematical Problems in Engineering*, pp. 1–10.
- [40] Zhang, G., Hu, M. Y., Patuwo, B. E., Indro, D. C., Artificial neural networks in bankruptcy prediction: General framework and crossvalidation analysis, *European Journal of Operational Research*, Vol.116, 1999, pp. 16-32.
- [41] Fletcher, D., & Gross, E. (1993). Forecasting with neural networks: an application using bankruptcy data. *Information and Management*, 24(3), pp. 159-167.
- [42] Wilson, R. L., Sharda, R. (1994). "Bankruptcy prediction using neural networks". *Decision Support Systems*, 11, 545-557.
- [43] Forrest, S. (1993). "Genetic algorithms: Principles of natural selection applied to computation". *Science*, Vol. 261, nº 5123, pp. 872-878.
- [44] Marczyk, A. (2004). "Genetic Algorithms: ¿What are the strenghts of GAs?". [www.talkorigins.org/](http://www.talkorigins.org/)
- [45] Frias, E., Magoulas, G., Chen, S. y Macredie, R. (2005). "Modelling human behavior in user-adaptative systems: Recent advances using soft computing techniques". *Expert Systems With Applications*, vol. 29, Nº 2, pp. 320-329.
- [46] Castaño, F. (2013). "Variables y modelos para la evaluación del fracaso empresarial. Propuesta de una metodología de fronteras basada en percentiles". Departamento de Dirección y Economía de la Empresa. Universidad de León. España.
- [47] Contabilidad.tk. (2016). "Análisis de Estados Financieros: Situaciones patrimoniales del balance de situación".
- [48] Montserrat, R., Bertra, J. (2013). "La financiación de la empresa. Cómo optimizar las decisiones de financiación para crear valor". Barcelona. PROFIT Editorial.



- [49] Yu, Q., Miche, Y., Lendasse, A., Séverin, E. "Bankruptcy Prediction with Missing Data", pp. 4. Department of Information and Computer Science, Aalto University, Espoo, Finland.
- [50] Macías, M. (2007). "Análisis de estados contables de entidades financieras". Material de clase de la asignatura Análisis Contable. Universidad Carlos III de Madrid.
- [51] Gabriela, M., Acevedo, I., Castillo, A. "Análisis económico-financiero de los modelos de predicción de quiebra y la probabilidad de quiebra". Universidad Autónoma del Estado de Hidalgo. Escuela Superior. Tepeji. Méjico.
- [52] Ringeling, E. (2004). "Análisis Comparativo de Modelos de Predicción de Quiebra y la probabilidad de Bancarrota". Facultad de Ciencias Económicas y Administrativas. Escuela de Economía y Administración. Universidad de Chile. Chile.
- [53] Vega, L. (2012) "Estudio de la Insolvencia". Universidad de Oviedo. España.
- [54] Robinson, N. "The Disadvantages of Logistic Regression". [www.eHow.com](http://www.eHow.com)
- [55] Giuliadori, D. "Metodos y Modelos Cuantitativos para la toma de Decisiones". Universidad Empresarial Siglo 21.
- [56] Balcaen, S., Ooghe, H. (2004). Alternative methodologies in studies on business failure: do they produce better results than the classical statistical methods? Faculteit Economie en Bedrijfskunde. Hoveniersberg. Gante. Bélgica.
- [57] Oakland, J.S., Fowell, R.F. (1990). "Quality Process Control". Ed. Heinemann Publishing Ltd. Gran Bretaña. Pp. 261
- [58] Lev, B. (1969), 'Industry Averages as targets for Financial Ratios', Journal of Accounting Research. Autumn, pp. 290-299.
- [59] Guerrero, M., Ramírez, J.M. "El Análisis de Escalamiento Multidimensional: Una Alternativa y un Complemento a Otras Técnicas Multivariantes". Departamento de Economía y Empresa. Universidad Pablo de Olavide. Sevilla. España
- [60] Molinero, M., Serrano, C. Serrano, C. (1994). "Bank Failure: A Multidimensional Scaling Approach". Management Science. University of Southampton, UK. Departamento de Contabilidad y Finanzas. Universidad de Zaragoza, España.



[61] Díaz, Z., Fernández, J., Segovia, J. “Sistemas de Inducción de Reglas y Árboles de Decisión Aplicados a la Predicción de Insolvencias en Empresas Aseguradoras”. Departamento de Economía Financiera y Contabilidad I. Universidad Complutense de Madrid. España.

[62] Permuy, I.B. (12/01/2016). “La crisis se salda con 45.000 empresas españolas en quiebra”. Periódico ABC. Recuperado de <http://www.abc.es>

[63] Figura 4. Arquitectura de una red neuronal de tres capas. En “Redes Neuronales Artificiales” por González, E. [http://html.rincondelvago.com/redes-neuronales-artificiales\\_1.html](http://html.rincondelvago.com/redes-neuronales-artificiales_1.html)

[64] Figura 5. Arquitectura de redes probabilísticas. En “Probabilistic Neural Network” por Shahsavarani, S. [http://cse-wiki.unl.edu/wiki/index.php/Probabilistic\\_Neural\\_Network](http://cse-wiki.unl.edu/wiki/index.php/Probabilistic_Neural_Network)

[65] Figura 21. Representación gráfica: Pasivo circulante > Activo circulante. En “3. Situaciones patrimoniales del balance de situación”. Introducción a la Contabilidad PGC de 1990. <http://www.contabilidad.tk/node/156>

[66] Chen, H., Yang, B., Wang, G., Liu, J., Xu, X., Wang, S., Liu, D. (2011). “A novel bankruptcy prediction model based on an adaptive fuzzy k-nearest neighbor method”. College of Computer Science and Technology. Jilin University. Changchun. China.

[67] Yu, Q., Lendasse, A., Severin, E. (2014). “Ensemble KNNs for Bankruptcy Prediction”. -Helsinki University of Technology. Information and Computer Science Department. Espoo. Finland. University of Lille. Laboratoire Economie Management. Villeneuve d’Ascq cedex. France.

[68] Bonsón, E., Escobar, T., Rodríguez, M., Zamora, M. “Sistemas de inducción de árboles de decisión: Utilidad en el análisis de crisis bancarias”. Grupo de Inteligencia Artificial en Contabilidad y Administración de Empresas. Universidad de Huelva. España

## Anexo 1

Año	Autores	Metodologías
1954	Page	CUSUM
1966	Beaver	Análisis Univariante
1968	Altman	Análisis Discriminante Múltiple
1968	Beaver	Análisis Univariante
1969	Theil	Medidas de Descomposición del Balance (BSDM)
1970	Meyer y Pifer	Análisis Discriminante Múltiple
1971	Wilcox	Teoría de la Ruina del Jugador
1972	Deakin	Análisis Discriminante Múltiple
1972	Edmister	Análisis Discriminante Múltiple
1973	Merton	Teoría de Riesgo de Crédito
1973	Lev	Medidas de Descomposición del Balance (BSDM)
1974	Blum	Análisis Discriminante Múltiple
1975	Libby	Análisis Discriminante Múltiple
1975	Sinkey	Análisis Discriminante Múltiple
1977	Altman, Haldeman y narayan	Análisis Discriminante Múltiple
1977	Martín	Análisis de Regresión Logística
1980	Dambolena y Khoury	Análisis Discriminante Múltiple
1980	Ohlson	Regresión Logística
1981	Scott	Teoría de la Ruina del Jugador
1982	Collins y Green	Análisis Discriminante Múltiple
1982		Regresión Logística
1982		Análisis de Regresión Logística
1983	Booth	Medidas de Descomposición del Balance (BSDM)
1983	Gombola y Ketz	Análisis Discriminante Múltiple
1983	Taffler	Análisis Discriminante Múltiple
1984	Mensah	Análisis de Regresión Logística
1984	Zmijewski	Regresión Logística
1984	Licolln	Análisis Discriminante Múltiple
1985	Casey y Bartczak	Análisis Discriminante Múltiple
1985	Frydman, Altman y Kao	Particionamiento Recursivo
1985	Gentry, Newbold y Whitford	Análisis Discriminante Múltiple
1985	Laffarga, Martín y Vázquez	Análisis Univariante
1985		Análisis de Regresión Logística
1987	Keasey y Watson	Análisis de Regresión Logística
1987	Healy	CUSUM
1987	Rodríguez Fernández	Análisis de Regresión Logística
1987	Laffarga, Martín y Vázquez	Análisis Discriminante Múltiple



1987		Análisis de Regresión Logística
1988	Aziz et al.	Teoría de Gestión de Tesorería
1988	Edmister	Análisis Discriminante Múltiple
1988	Messier y Hansen	Sistemas expertos
1989	Martínez, Navarro y Sanz	Análisis de Regresión Logística
1989	Pina	Análisis de Regresión Logística
1989	Rodríguez Fernández	Análisis Univariante
1989		Análisis de Regresión Logística
1990	Bell, Ribar y Verchio	Redes de Neuronas
1990		Análisis de Regresión Logística
1990	Rodríguez Acebes	Análisis de Regresión Logística
1990	Gabás	Análisis Univariante
1990		Análisis Discriminante Múltiple
1990		Análisis de Regresión Logística
1990		Particionamiento Recursivo
1991	Koh	Análisis de Regresión Logística
1991	Platt y Platt	Análisis de Regresión Logística
1991	Mar Molinero y Ezzamel	Escalamiento Multidimensional
1991	Tam	Redes de Neuronas (BPNN)
1992	Tam y Kiang	Redes de Neuronas (BPNN)
1992	Surkan y Singleton	Redes de Neuronas
1992	Dutta y Shekhar	Redes de Neuronas
1992	Odom y Sharda	Redes de Neuronas
1992	Marose	Híbrido (Técnicas estadísticas y Redes de neuronas)
1993	Fletcher y Goss	Redes de Neuronas (BPNN)
1993	Rughupathi, Schkade y Raju	Inteligencia Artificial
1993	Serrano y Martín del Brio	Redes de Neuronas
1993	Kolodner	Razonamiento Basado en Casos
1993	De Miguel, Revilla, Rodríguez y Cano	Inteligencia Artificial
1994	Altman, Marco y Varetto	Análisis Discriminante Simple
1994	Platt, Platt y Pederson	Redes de Neuronas (BPNN)
1994	Wilson y Sharda	Redes de Neuronas (BPNN)
1994	Tsukuda y Baba	Redes de Neuronas (BPNN)
1994	López Moreno y Rodríguez	Análisis Univariante
1994	Reis	Regresión Lineal
1994	Mora	Análisis Discriminante Múltiple
1994	Serrano Cinca	Redes de Neuronas
1995	Slowinski y Zopounidis	Conjuntos aproximados
1995	Lacher, Coats, Sharma y Faut	Inteligencia Artificial
1995	García, Arqués y Calvo-Flores	Análisis Discriminante Múltiple
1995	Fernandez y Olmeda	Análisis de Regresión Logística



1995		Redes de Neuronas
1996	Greenstein y Welsh	Inteligencia Artificial
1996	Serrano Cinca	Mapas Autoorganizados
1996		Redes de Neuronas
1996		Análisis Discriminante Simple
1996	Lesho y Spector	Redes de Neuronas (BPNN)
1996	Del Rey	Redes de Neuronas
1996	Back et al.	Híbrido (Algoritmos Genéticos y Redes de neuronas)
1996	Martínez	Inteligencia Artificial
1997	Credit Suisse	Teoría de Riesgo de Crédito
1997	Wilson	Teoría de Riesgo de Crédito
1997	Bamiv, Anurag y Leach	Redes de Neuronas (BPNN)
1997	Bell	Redes de Neuronas (BPNN)
1997	Lizarraga	Análisis Discriminante Múltiple
1997		Análisis de Regresión Logística
1997	Gallego, Gómez y Yáñez	Análisis de Regresión Logística
1997	Bonsón, Escobar y Martín	Particionamiento Recursivo
1997	Serrano Cinca	Análisis Univariante
1997		Análisis de Regresión Logística
1997		Redes de Neuronas
1998	Wilson	Teoría de Riesgo de Crédito
1998	Morris	Teoría de la Ruina del Jugador
1998	Laitinen y Laitinen	Teoría de Gestión de Tesorería
1998		Ajuste Parcial
1998	Shin, Shin y Han	Híbrido (Logit y Redes de neuronas)
1998	Varetto	Algoritmos Genéticos
1998	Piramuthy, Ragavan y Shaw	Redes de Neuronas (BPNN)
1998	Kiviluoto	Redes de Neuronas (Mapas Autoorganizados)
1998		Análisis de Regresión Logística
1998	Ferrando y Blanco	Análisis Discriminante Múltiple
1998		Análisis de Regresión Logística
1998	Lizarraga	Análisis Discriminante Múltiple
1998		Análisis de Regresión Logística
1998	Gujarati	Ajuste Parcial
1999	Kahya y Theodossiou	CUSUM
1999	Lennox	Análisis Discriminante Múltiple
1999		Análisis de Regresión Logística
1999	Laitinen y Kankaanpaa	Análisis Discriminante Simple
1999		Análisis de Regresión Logística
1999		Particionamiento Recursivo
1999		Redes de Neuronas





1999	Zhang, Hu, Patuwo e Indro	Inteligencia Artificial
1999	Koh y Tan	Inteligencia Artificial
1999	Altay Guvenir, H. et Al.	K-Vecinos más cercanos
1999	López y Flórez	Redes de Neuronas
2000	McKee	Conjuntos aproximados
2000	Ahn, Cho y Kim	Análisis Discriminante Múltiple
2000		Redes de Neuronas
2000		Híbrido: Conjuntos aproximados y Redes de neuronas
2000	Crespo	Análisis Discriminante Múltiple
2001	Grice e Ingram	Análisis Discriminante Múltiple
2001	Westgaard y Wijst	Análisis de Regresión Logística
2001	Atiya	Redes de Neuronas (BPNN)
2001	Swicegood y Clark	Redes de Neuronas (BPNN)
2001		Análisis Discriminante Múltiple
2001	Kaski, Sinkkonen y Peltonen	Mapas Autoorganizados
2001	Rodríguez López	Análisis Discriminante Múltiple
2001		Análisis de Regresión Logística
2001	Somoza	Análisis de Regresión Logística
2001	De Andrés	Análisis Discriminante Múltiple
2001		Análisis de Regresión Logística
2002	Shin y Lee	Algoritmos Genéticos
2002	Platt y Platt	Análisis de Regresión Logística
2002	Román, De La Torre, Castillo y Merelo	Análisis de Regresión Logística
2002		Redes de Neuronas
2002	McKee y Lensberg	Híbrido (Alg. genéticos y Razmto. Basado en casos)
2003	Correa, Acosta y González	Análisis de Regresión Logística
2003		Particionamiento Recursivo
2004	Cielen, Peeters y Vanhoof	Neuronas de Base Radial
2005	Beaver, McNichols y Rhie	Análisis de Regresión Logística
2005	Lee, Booth y Alam	Redes de Neuronas (BPNN)
2005		Mapas Autoorganizados
2005	Canbas, Calbuk y Kilic	Análisis Discriminante Múltiple
2005		Análisis de Regresión Logística
2005		Regresión Logística
2005	Weisberg	Regresión Lineal
2005	De La Torre, Gómez y Román	Análisis de Regresión Logística
2005	Rodríguez y Díaz	Conjuntos Aproximados
2005	De Andrés	Análisis de Regresión Logística
2005		Redes de Neuronas
2005		Razonamiento Basado en Casos
2006	Min, Lee y Han	Algoritmos Genéticos



2006		Máquinas de Soporte Vectorial
2006	Calvo-Flores, García y Madrid	Análisis de Regresión Logística
2007	Kumar y Ravi	Razonamiento Basado en Casos
2008	Jones Y Hensher	Análisis de Regresión Logística
2008		Regresión Logística
2008	Arquero, Abad y Jiménez	Regresión Logística
2009	Beaver, Correia y McNichols	Análisis de Regresión Logística (multiperíodo)
2009	Premachandra, Bhabra y Sueyoshi	Análisis de Regresión Logística
2009	Sueyoshi y Goto	Análisis Discriminante Múltiple
2009	Xu y Zhang	Análisis Discriminante Múltiple
2009		Análisis de Regresión Logística
2010	Baixauli y Módica-Milo	Análisis de Regresión Logística
2010		Análisis Discriminante Múltiple
2010	Ravisankar et al.	Híbrido (Redes de neuronas, Conjuntos aproximados y Algoritmos Genéticos)
2010	Yeh et al.	Híbrido (Conjuntos aproximados y máquinas de soporte vectorial)
2010	Psillaki, Tsolas y Margaritis	Análisis de Regresión Logística
2011	Chen, H et al.	K-Vecinos más cercanos
2011	Kilgour	Medidas de Descomposición del Balance (BSDM)
2012	Blanco, Irimia y Oliver	Análisis de Regresión Logística
2012	Cook, Pandit y Milman	Análisis de Regresión Logística
2013	Pozuelo, Labatut y Veres	Análisis de Regresión Logística
2014	Yu, Q., Lendasse, A., Severin, E	K-Vecinos más cercanos
2014	Zhang, W. et al.	Híbrido (Conjuntos aproximados y Algoritmos Genéticos)

Tabla 19. Histórico de Metodologías



Año	1991	1993	1994	1996	1999	2001	2002
Autores	Tam	Fletcher y Goss	Tsukuda y Baba	Serrano Cinca	Latinen y Kankaanpaa	Atiya	Shin y Lee
Activo circulante/Pasivo circulante		X	X		X		X
Activos Líquidos/Pasivo Circulante			X				
BAll/Activo Total				X	X		
Beneficios no distribuidos/Activo Total				X			X
Beneficio Neto/activo total	X					X	
Cash Flow recursos generados/Activo Total						X	
Capital No Financiero/Número de empleados			X				
Capital/activo total	X						X
Capital circulante/Activo Total				X			
Cotización/Ratio de Cash Flow						X	
Deuda Total/Activo total					X		
Deuda corto plazo/Activo Total							X
Fondos + Valores/Total Activos	X						
Fondos propios/Activo total						X	
Gastos financieros/Valor añadido			X				
Gastos financieros/Ventas			X				X
Gastos no de explotación/Ventas			X				
Gastos totales/Activo Total	X						
Ingresos/Gastos	X						
Ingresos de explotación/Ventas			X				
Ingresos de explotación/Gastos de explotación							X
Ingresos de explotación/Capital							X
Ingresos de explotación/Capital circulante		X					
Inmov. Material-Inmov. en construcción/Número de empleados			X				
Intereses depósitos/total depósitos	X						
Quick flow ratio							X
Quick ratio (Activo Circulante/Pasivo Circulante)		X					
Préstamos Individuales/Préstamos netos + Arrendamientos	X						



Préstamos con vto sup. a 90 días/Préstamos netos + Arrendamientos	X						
Préstamos Totales +Arrendamientos/Total Activos	X						
Préstamos Totales no acumulativos +Arrendamientos/Préstamos netos +Arrendamientos	X						
Resultado de actividades ordinarias/Capital No Financiero			X				
Resultado de actividades ordinarias/Activo Total						X	
Tasa variación flujo de caja/Acción						X	
Tasa de variación del precio de las acciones						X	
Tesorería+Deudores)/(Coste de ventas+Ventas y Gastos-Amortizaciones)			X				
Valor añadido/Capital No Financiero			X				
Valor añadido/Activo Total							X
Valor mercado Fondos Propios/Activo Total				X			

Tabla 20. Ratios seleccionados para los estudios escogidos [46]

## Anexo 2

### Selección de Atributos

Correlación	Ratio de Ganancia	One R	Relieff	Incertidumbre Simétrica
Ranked attributes:	Ranked attributes:	Ranked attributes:	Ranked attributes:	Ranked attributes:
0.55367 9 ef3	0.373 1 re1	88.2 16 sf1	0.0487542 22 li1	0.4438 16 sf1
0.55309 31 li10	0.3502 16 sf1	87.8 17 sf2	0.0343937 16 sf1	0.44 17 sf2
0.55263 5 re5	0.3475 17 sf2	87.2 18 sf7	0.0338929 18 sf7	0.4129 1 re1
0.54815 3 re3	0.3383 32 li11	87 6 re6	0.0329749 24 li3	0.4107 18 sf7
0.54463 6 re6	0.3187 18 sf7	84.4 32 li11	0.0321805 5 re5	0.3928 6 re6
0.54241 16 sf1	0.3108 4 re4	84 5 re5	0.0305234 27 li6	0.384 32 li11
0.53738 18 sf7	0.3082 6 re6	83.6 1 re1	0.0278966 3 re3	0.3708 5 re5
0.53637 17 sf2	0.3033 3 re3	83.2 3 re3	0.0278027 31 li10	0.3697 3 re3
0.53047 23 li2	0.2989 31 li10	82.8 8 ef2	0.0277042 6 re6	0.3676 8 ef2
0.51483 34 ro1	0.2935 8 ef2	81.6 9 ef3	0.0270276 9 ef3	0.3596 31 li10
0.51454 29 li8	0.2912 21 sf11	80.6 31 li10	0.0267913 23 li2	0.3367 21 sf11
0.50626 22 li1	0.2908 5 re5	80 29 li8	0.0255209 29 li8	0.3358 9 ef3
0.50246 26 li5	0.2679 27 li6	79.4 21 sf11	0.0237353 17 sf2	0.3316 4 re4
0.48175 33 li12	0.258 33 li12	78.8 33 li12	0.0233841 26 li5	0.3021 33 li12
0.47567 24 li3	0.2557 26 li5	78.2 4 re4	0.0220221 34 ro1	0.2963 26 li5
0.46015 27 li6	0.2551 9 ef3	77.6 26 li5	0.0219181 7 ef1	0.2944 29 li8
0.45678 25 li4	0.2236 29 li8	74.8 2 re2	0.0207109 33 li12	0.2656 27 li6
0.38364 38 ro5	0.2083 2 re2	73.2 27 li6	0.0189356 25 li4	0.2363 2 re2
0.34743 7 ef1	0.191 40 ap1	72.2 34 ro1	0.0160347 36 ro3	0.2119 34 ro1
0.28578 40 ap1	0.1804 34 ro1	70.6 24 li3	0.0151578 19 sf8	0.2107 23 li2
0.23295 13 ef8	0.178 23 li2	70.4 40 ap1	0.0144381 38 ro5	0.1944 24 li3
0.2276 19 sf8	0.1658 24 li3	69.8 23 li2	0.012859 37 ro4	0.1799 40 ap1
0.20161 36 ro3	0.1614 19 sf8	69.2 22 li1	0.011191 30 li9	0.1748 22 li1
0.19366 12 ef7	0.1507 36 ro3	65.6 7 ef1	0.0094651 39 ro6	0.1631 25 li4
0.19326 20 sf10	0.1397 25 li4	64.8 25 li4	0.0090771 10 ef4	0.1284 38 ro5
0.17642 35 ro2	0.1337 22 li1	63.8 14 pr1	0.0077826 35 ro2	0.1091 14 pr1
0.16177 37 ro4	0.1103 14 pr1	63 38 ro5	0.0076602 15 pr2	0.1051 36 ro3
0.1439 11 ef5	0.1088 38 ro5	58.6 12 ef7	0.0076114 13 ef8	0.1049 19 sf8
0.13298 1 re1	0.0975 7 ef1	57.8 13 ef8	0.0075673 28 li7	0.0935 7 ef1
0.11882 28 li7	0.0834 41 ap2	56.4 19 sf8	0.0063355 12 ef7	0.0921 13 ef8
0.09804 39 ro6	0.0834 13 ef8	54.4 41 ap2	0.0038944 41 ap2	0.0801 12 ef7
0.08968 14 pr1	0.0804 12 ef7	52.6 28 li7	0.0035215 8 ef2	0.0447 41 ap2
0.08314 30 li9	0.0429 20 sf10	52.4 20 sf10	0.0033496 20 sf10	0.0379 28 li7
0.06634 41 ap2	0.0411 28 li7	52.2 30 li9	0.0022741 40 ap1	0.0364 20 sf10
0.06575 8 ef2	0 39 ro6	50.4 36 ro3	0.0016948 21 sf11	0 39 ro6
0.03528 15 pr2	0 30 li9	50.2 11 ef5	0.0007299 32 li11	0 30 li9
0.02027 2 re2	0 37 ro4	49.8 37 ro4	0.0003942 2 re2	0 37 ro4
0.01915 32 li11	0 35 ro2	48.4 15 pr2	0.0003043 11 ef5	0 35 ro2
0.01841 21 sf11	0 11 ef5	48.4 35 ro2	0.0000624 1 re1	0 11 ef5
0.01472 4 re4	0 10 ef4	48.2 39 ro6	-0.0005251 4 re4	0 10 ef4
0.0069 10 ef4	0 15 pr2	46 10 ef4	-0.0005797 14 pr1	0 15 pr2

Tabla 21. Comparativa de selección de atributos



**Experimento 1**

<b>Clasificador 1. Análisis Discriminante Lineal</b>				<b>Clasificador 2. Cuadrático</b>																																							
<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>216,9</td> <td>33,1</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>14</td> <td>236</td> <td>250</td> </tr> <tr> <td>Total</td> <td>230,9</td> <td>269,1</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	216,9	33,1	250	Solvente	14	236	250	Total	230,9	269,1	500	<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>221,5</td> <td>28,5</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>12,63</td> <td>237,36</td> <td>250</td> </tr> <tr> <td>Total</td> <td>234,13</td> <td>265,86</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	221,5	28,5	250	Solvente	12,63	237,36	250	Total	234,13	265,86	500
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	216,9	33,1	250																																								
Solvente	14	236	250																																								
Total	230,9	269,1	500																																								
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	221,5	28,5	250																																								
Solvente	12,63	237,36	250																																								
Total	234,13	265,86	500																																								
<b>Clasificador 3. Regresión Logística (Función sigmoide)</b>				<b>Clasificador 4. Parzen</b>																																							
<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>199,7</td> <td>50,3</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>57,1</td> <td>192,9</td> <td>250</td> </tr> <tr> <td>Total</td> <td>256,8</td> <td>243,2</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	199,7	50,3	250	Solvente	57,1	192,9	250	Total	256,8	243,2	500	<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>189,567</td> <td>60,4333</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>102,567</td> <td>147,4333</td> <td>250</td> </tr> <tr> <td>Total</td> <td>292,133</td> <td>207,8666</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	189,567	60,4333	250	Solvente	102,567	147,4333	250	Total	292,133	207,8666	500
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	199,7	50,3	250																																								
Solvente	57,1	192,9	250																																								
Total	256,8	243,2	500																																								
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	189,567	60,4333	250																																								
Solvente	102,567	147,4333	250																																								
Total	292,133	207,8666	500																																								
<b>Clasificador 5. 5-vecinos más cercanos</b>				<b>Clasificador 6. 7-vecinos más cercanos</b>																																							
<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>192,267</td> <td>57,7333</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>63,1333</td> <td>186,8667</td> <td>250</td> </tr> <tr> <td>Total</td> <td>255,4</td> <td>244,6</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	192,267	57,7333	250	Solvente	63,1333	186,8667	250	Total	255,4	244,6	500	<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>192,667</td> <td>57,3333</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>67,4333</td> <td>182,5667</td> <td>250</td> </tr> <tr> <td>Total</td> <td>260,1</td> <td>239,9</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	192,667	57,3333	250	Solvente	67,4333	182,5667	250	Total	260,1	239,9	500
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	192,267	57,7333	250																																								
Solvente	63,1333	186,8667	250																																								
Total	255,4	244,6	500																																								
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	192,667	57,3333	250																																								
Solvente	67,4333	182,5667	250																																								
Total	260,1	239,9	500																																								
<b>Clasificador 7. 11-vecinos más cercanos</b>				<b>Clasificador 8. Multicapa BPNN (1 neurona en la capa oculta)</b>																																							
<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>192,56</td> <td>57,43</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>75,7</td> <td>174,3</td> <td>250</td> </tr> <tr> <td>Total</td> <td>268,267</td> <td>231,7333</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	192,56	57,43	250	Solvente	75,7	174,3	250	Total	268,267	231,7333	500	<table border="1"> <thead> <tr> <th rowspan="2">Clase Actual</th> <th colspan="2">Predicción</th> <th rowspan="2">Total</th> </tr> <tr> <th>Quiebra</th> <th>Solvente</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>232,00</td> <td>18,00</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>31,50</td> <td>218,50</td> <td>250</td> </tr> <tr> <td>Total</td> <td>263,5</td> <td>236,5</td> <td>500</td> </tr> </tbody> </table>				Clase Actual	Predicción		Total	Quiebra	Solvente	Quiebra	232,00	18,00	250	Solvente	31,50	218,50	250	Total	263,5	236,5	500
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	192,56	57,43	250																																								
Solvente	75,7	174,3	250																																								
Total	268,267	231,7333	500																																								
Clase Actual	Predicción		Total																																								
	Quiebra	Solvente																																									
Quiebra	232,00	18,00	250																																								
Solvente	31,50	218,50	250																																								
Total	263,5	236,5	500																																								

<b>Clasificador 9. Multicapa BPNN (5 neurona en la capa oculta)</b>				<b>Clasificador 10. Multicapa BPNN (10 neurona en la capa oculta)</b>																																											
<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>235,17</td> <td>14,83</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>30,67</td> <td>269,33</td> <td>250</td> </tr> <tr> <td>Total</td> <td>265,83</td> <td>234,17</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	235,17	14,83	250	Solvente	30,67	269,33	250	Total	265,83	234,17	500	<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>228,00</td> <td>21,67</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>30,33</td> <td>219,67</td> <td>250</td> </tr> <tr> <td>Total</td> <td>258,33</td> <td>241,33</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	228,00	21,67	250	Solvente	30,33	219,67	250	Total	258,33	241,33	500
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	235,17	14,83	250																																												
Solvente	30,67	269,33	250																																												
Total	265,83	234,17	500																																												
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	228,00	21,67	250																																												
Solvente	30,33	219,67	250																																												
Total	258,33	241,33	500																																												
<b>Clasificador 11. Perceptron Lineal (Tasa de aprendizaje 0,1)</b>				<b>Clasificador 12. Red de Neuronas de Base Radial (5 funciones)</b>																																											
<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>229,833</td> <td>20,1667</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>17,6</td> <td>232,4</td> <td>250</td> </tr> <tr> <td>Total</td> <td>247,433</td> <td>252,5667</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	229,833	20,1667	250	Solvente	17,6	232,4	250	Total	247,433	252,5667	500	<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>222,67</td> <td>27,33</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>25,00</td> <td>225,00</td> <td>250</td> </tr> <tr> <td>Total</td> <td>247,67</td> <td>252,33</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	222,67	27,33	250	Solvente	25,00	225,00	250	Total	247,67	252,33	500
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	229,833	20,1667	250																																												
Solvente	17,6	232,4	250																																												
Total	247,433	252,5667	500																																												
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	222,67	27,33	250																																												
Solvente	25,00	225,00	250																																												
Total	247,67	252,33	500																																												
<b>Clasificador 13. Red de Neuronas de Base Radial (10 funciones)</b>				<b>Clasificador 14. Red de Neuronas de Base Radial (15 funciones)</b>																																											
<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>224,83</td> <td>25,17</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>25,00</td> <td>225,00</td> <td>250</td> </tr> <tr> <td>Total</td> <td>249,83</td> <td>250,17</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	224,83	25,17	250	Solvente	25,00	225,00	250	Total	249,83	250,17	500	<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>226,50</td> <td>23,50</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>22,67</td> <td>227,33</td> <td>250</td> </tr> <tr> <td>Total</td> <td>249,17</td> <td>250,83</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	226,50	23,50	250	Solvente	22,67	227,33	250	Total	249,17	250,83	500
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	224,83	25,17	250																																												
Solvente	25,00	225,00	250																																												
Total	249,83	250,17	500																																												
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	226,50	23,50	250																																												
Solvente	22,67	227,33	250																																												
Total	249,17	250,83	500																																												
<b>Clasificador 15. Máquina de Soporte Vectorial</b>				<b>Clasificador 16. Árbol de decisión</b>																																											
<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>227</td> <td>23</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>10,8333</td> <td>239,1667</td> <td>250</td> </tr> <tr> <td>Total</td> <td>237,833</td> <td>262,1667</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	227	23	250	Solvente	10,8333	239,1667	250	Total	237,833	262,1667	500	<table border="1"> <thead> <tr> <th colspan="4">Predicción</th> </tr> <tr> <th>Clase Actual</th> <th>Quiebra</th> <th>Solvente</th> <th>Total</th> </tr> </thead> <tbody> <tr> <td>Quiebra</td> <td>239,667</td> <td>10,3333</td> <td>250</td> </tr> <tr> <td>Solvente</td> <td>10,6</td> <td>239,4</td> <td>250</td> </tr> <tr> <td>Total</td> <td>250,267</td> <td>249,7333</td> <td>500</td> </tr> </tbody> </table>				Predicción				Clase Actual	Quiebra	Solvente	Total	Quiebra	239,667	10,3333	250	Solvente	10,6	239,4	250	Total	250,267	249,7333	500
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	227	23	250																																												
Solvente	10,8333	239,1667	250																																												
Total	237,833	262,1667	500																																												
Predicción																																															
Clase Actual	Quiebra	Solvente	Total																																												
Quiebra	239,667	10,3333	250																																												
Solvente	10,6	239,4	250																																												
Total	250,267	249,7333	500																																												

Tabla 22. Matrices de confusión medias de los clasificadores

**Experimento 2**

<b>Clasificador 1. Análisis Discriminante Lineal</b>				<b>Clasificador 2. Cuadrático</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	216,1667	33,8333	250	Quiebra	216,8667	33,1333	250
Solvente	17,6333	232,3667	250	Solvente	11,2667	238,7333	250
Total	233,8	266,2	500	Total	228,1334	271,8666	500
<b>Clasificador 3. Regresión Logística (Función sigmoide)</b>				<b>Clasificador 4. Parzen</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	207,7667	42,2333	250	Quiebra	182,5	67,5	250
Solvente	34,4333	215,5667	250	Solvente	98,4	151,6	250
Total	242,2	257,8	500	Total	280,9	219,1	500
<b>Clasificador 5. 5-vecinos más cercanos</b>				<b>Clasificador 6. 7-vecinos más cercanos</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	193,7667	56,2333	250	Quiebra	190,9333	59,0667	250
Solvente	62,8	187,2	250	Solvente	66,6333	183,3667	250
Total	256,5667	243,4333	500	Total	257,5666	242,4334	500
<b>Clasificador 7. 11-vecinos más cercanos</b>				<b>Clasificador 8. Multicapa BPNN (1 neurona en la capa oculta)</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	193,3667	56,6333	250	Quiebra	234,00	16,00	250
Solvente	74,1667	175,8333	250	Solvente	37,83	212,17	250
Total	267,5334	232,4666	500	Total	271,83	228,17	500



<b>Clasificador 9. Multicapa BPNN (5 neurona en la capa oculta)</b>				<b>Clasificador 10. Multicapa BPNN (10 neurona en la capa oculta)</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	237,33	12,67	250	Quiebra	238,83	11,17	250
Solvente	38,50	213,17	250	Solvente	40,17	209,83	250
Total	275,83	225,83	500	Total	279,00	221,00	500
<b>Clasificador 11. Perceptron Lineal (Tasa de aprendizaje 0,1)</b>				<b>Clasificador 12. Red de Neuronas de Base Radial (5 funciones)</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	228,9667	21,0333	250	Quiebra	223,33	26,67	250
Solvente	20,6	229,4	250	Solvente	25,00	225,00	250
Total	249,5667	250,4333	500	Total	248,33	251,67	500
<b>Clasificador 13. Red de Neuronas de Base Radial (10 funciones)</b>				<b>Clasificador 14. Red de Neuronas de Base Radial (15 funciones)</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	225,17	24,83	250	Quiebra	226,67	23,33	250
Solvente	25,00	225,00	250	Solvente	22,50	227,50	250
Total	250,17	249,83	500	Total	249,17	250,83	500
<b>Clasificador 15. Máquina de Soporte Vectorial</b>				<b>Clasificador 16. Árbol de decisión</b>			
	Predicción				Predicción		
Clase Actual	Quiebra	Solvente	Total	Clase Actual	Quiebra	Solvente	Total
Quiebra	226,2	23,8	250	Quiebra	240,1	9,9	250
Solvente	9,9	240,1	250	Solvente	9,2333	240,7667	250
Total	236,1	263,9	500	Total	249,3333	250,6667	500

Tabla 23. Matrices de confusión medias de los clasificadores

**Experimento 3**

Iteración	C1	C2	C3	C4	C5	C6
1	12.50%	10.00%	7.00%	10.50%	13.00%	6.50%
2	10.50%	11.00%	7.00%	12.00%	10.50%	7.00%
3	10.50%	11.00%	8.00%	12.00%	9.00%	7.00%
4	13.50%	10.50%	7.00%	10.00%	12.00%	6.50%
5	10.00%	11.50%	8.00%	12.50%	8.00%	8.00%
6	10.50%	11.50%	9.50%	12.00%	10.50%	9.00%
7	7.50%	8.00%	6.50%	8.00%	8.00%	4.50%
8	8.00%	8.00%	7.00%	8.00%	7.50%	7.00%
9	8.00%	8.00%	6.50%	7.50%	8.00%	4.50%
10	10.50%	12.50%	9.00%	14.50%	9.00%	8.00%
11	7.00%	8.00%	8.00%	9.00%	8.50%	8.00%
12	8.50%	9.00%	5.50%	10.00%	9.00%	5.00%
13	8.00%	8.00%	6.00%	8.50%	8.50%	5.50%
14	11.00%	9.00%	7.50%	10.50%	12.00%	7.50%
15	10.50%	9.50%	6.00%	9.00%	6.50%	5.00%
16	9.00%	12.50%	9.50%	12.00%	8.50%	8.50%
17	8.00%	9.00%	6.00%	9.00%	7.00%	7.50%
18	8.50%	9.00%	6.50%	9.00%	7.50%	5.50%
19	11.00%	12.50%	9.00%	12.50%	9.00%	8.00%
20	8.00%	11.00%	6.00%	11.50%	7.00%	7.50%
21	7.00%	9.00%	7.00%	9.50%	7.50%	5.50%
22	11.50%	9.50%	7.00%	10.50%	12.00%	8.00%
23	10.00%	8.50%	5.50%	9.00%	11.00%	4.50%
24	12.50%	12.00%	8.50%	12.00%	8.50%	8.50%
25	10.00%	10.00%	6.50%	8.50%	9.00%	5.50%
26	8.00%	9.00%	7.00%	9.50%	9.00%	6.00%
27	10.00%	12.00%	7.00%	12.00%	7.00%	7.50%
28	11.50%	9.50%	6.00%	9.50%	11.00%	6.00%
29	10.00%	11.50%	12.50%	12.50%	11.50%	13.50%
30	10.50%	10.50%	5.50%	11.50%	10.50%	6.50%
<b>MEDIA</b>	<b>9.44%</b>	<b>9.82%</b>	<b>7.02%</b>	<b>10.14%</b>	<b>8.89%</b>	<b>6.53%</b>

Tabla 24. Errores obtenidos por clasificador e iteración (Experimento 3)

**Experimento 3**

Iteración	C1	C2	C3	C4	C5	C6
1	9.50%	7.50%	7.00%	7.50%	8.00%	7.00%
2	8.50%	6.50%	6.50%	6.50%	10.00%	6.00%
3	12.50%	12.00%	9.50%	13.50%	10.00%	10.00%
4	9.50%	12.00%	7.50%	11.50%	7.00%	6.00%
5	7.50%	7.50%	6.50%	8.50%	8.50%	5.50%
6	7.50%	7.50%	5.50%	8.00%	7.00%	5.00%
7	7.00%	7.00%	6.50%	7.50%	8.00%	6.00%
8	9.00%	8.00%	6.00%	9.00%	8.50%	6.50%
9	10.00%	10.50%	9.50%	11.00%	9.50%	8.50%
10	7.00%	8.00%	5.50%	8.50%	7.50%	4.50%
11	7.50%	9.50%	8.50%	10.50%	7.50%	8.00%
12	10.50%	9.50%	8.00%	10.00%	10.00%	8.00%
13	6.00%	7.00%	7.00%	7.50%	7.00%	7.00%
14	9.50%	10.50%	9.00%	11.00%	8.50%	8.50%
15	11.00%	9.50%	7.50%	11.50%	10.00%	8.50%
16	11.50%	11.00%	7.00%	11.50%	9.50%	8.00%
17	8.00%	5.50%	8.50%	7.50%	10.00%	9.00%
18	7.00%	9.00%	8.50%	9.50%	6.50%	8.00%
19	8.00%	7.50%	7.00%	8.50%	9.00%	5.50%
20	11.00%	9.00%	9.00%	8.50%	9.50%	8.50%
21	9.50%	9.00%	7.50%	9.00%	8.50%	7.50%
22	12.00%	10.00%	7.00%	10.50%	11.50%	8.00%
23	8.50%	9.50%	8.50%	9.50%	8.00%	7.50%
24	11.50%	10.50%	8.00%	12.50%	12.50%	8.00%
25	9.00%	7.50%	7.00%	9.00%	11.00%	7.00%
26	11.00%	10.50%	7.50%	11.50%	10.50%	7.00%
27	8.50%	7.00%	7.50%	7.50%	10.50%	7.50%
28	5.00%	6.00%	6.00%	6.00%	7.00%	5.50%
29	7.50%	8.00%	6.00%	8.50%	8.00%	6.50%
30	11.00%	10.00%	8.00%	10.50%	11.50%	6.50%
<b>MEDIA</b>	<b>8.64%</b>	<b>8.41%</b>	<b>7.27%</b>	<b>9.05%</b>	<b>8.76%</b>	<b>6.92%</b>

Tabla 25. Errores obtenidos por clasificador e iteración (Experimento 4)

**Parametrización empleada**

Técnica	Configuración de parámetros
<b>Análisis Discriminante Lineal</b>	(Sin opción de ajustar parámetros en PRTools).
<b>Clasificador Cuadrático</b>	R=0, S=0 (parámetros de regularización empleados para construir la matriz de covarianza en PRTools).
<b>Clasificador Regresión Logística (Función sigmoide)</b>	(Sin opción de ajustar parámetros en PRTools)
<b>Clasificador Parzen</b>	(Sin opción de ajustar parámetros en PRTools)
<b>Clasificador K-vecinos más cercanos</b>	Se realizan diferentes pruebas con K=5,7 y 11
<b>Perceptron Multicapa BPNN</b>	<p>Inicialmente fue usada la herramienta PRTools para trabajar con esta técnica, con los parámetros: 1 capa oculta, inicialización de pesos automática mediante Matlab's neural network toolbox, neuronas en capa oculta 1,5 y 10.</p> <p>Sin embargo, debido a los bajos porcentajes de acierto obtenidos, esta prueba se terminó realizando manualmente mediante WEKA: Tasa de aprendizaje = 0,3; momentum = 0,2; tiempo de entrenamiento = 500; semilla = aleatoria en cada iteración.</p>
<b>Perceptron Lineal</b>	Se ha comprobado el rendimiento resultante al configurar tres tasas de aprendizajes distintas= 0,1; 0,5 y 0,9. Finalmente elegimos 0,1 debido a la mejoría de sus resultados. Número máximo de iteraciones = 100. Inicialización de pesos = aleatoria. Type = batch.
<b>Red de Neuronas de Base Radial</b>	De nuevo, debido a los malos resultados obtenidos con PRTools, se ha llevado a cabo la prueba manualmente en WEKA, mediante el clasificador "RBF Classifier", el cual realiza una supervisión completa que optimiza el resultado, a diferencia de las redes de base radial estándares. La parametrización seleccionada: batchSize = 100, numFuction=2; semilla = aleatoria en cada iteración.
<b>Máquina de Soporte Vectorial</b>	Función Kernel = Lineal. Parámetro de regularización = 1.
<b>Árbol de decisión binario</b>	Criterio de particionamiento = máxima pureza (purity). Poda = 0 (sin poda).

Tabla 26. Parametrización en técnicas empleadas



## Anexo 3

### Abstract

Corporate Bankruptcy Prediction research has increased its interest and importance in recent years, especially since the beginning of the 2008 crisis, different actors of the global economy have required capable systems in detecting insolvency signals, in order to avoid the adverse effects of the bankruptcy.

In the 90s, Artificial Intelligence techniques were used into Corporate Bankruptcy Prediction investigation, obtaining a remarkable improvement in predictive rate comparing to statistical and theoretical models.

This thesis has been carried out in order to set a genesis in the prediction models development, presenting a comparison of different predictive methods used over the last 50 years, based on scientific publications and own empirical study.

Empirical study results indicate Support Vector Machines and Decision Trees reach the best hit rate on the selected dataset. However, experiments also show reveal an overall improvement of classification rates after a previous dataset optimization using attribute selection techniques.

Lastly, this research proves the current trend of employing Hybrid models in Bankruptcy Prediction, reaching the highest accuracy rate (93.47%) engaging five predictive methods using Voting combining classifier.

**Keywords:** Bankruptcy, Prediction, Corporate, Artificial Intelligence, Solvency, Failure, Analysis, Hybrid, Financial Ratios.



# Introduction

Among the consequences originated from the 2008 economic and financial crisis, it is found the failure of many companies around the world. Concretely in Spain, 45.232 corporations were declared in bankruptcy from the beginning of the depression.

Although bankruptcy prediction has been a frequent topic during last fifty years, crisis has returned the interest in research on the prediction of business failure. Its main goal is to detect if a company will not be able to pay its debts, in order to prevail over this situation and to establish the appropriate action to prevent or minimize adverse consequences.

Considering each company as unique and different according to its specific characteristics (economic sector activity performed, financial structure, market situation, etc.), the realization of this objective entails many difficulties. While unpredictable market events may accentuate the problem.

However, there are certain prediction methods, scientifically studied and evolved, which may be used in the business environment in order to improve investor's, manager's and other stakeholder's decisions making to avoid the untoward impact of bankruptcy.

Due to the progress made by the field of Artificial Intelligence over the last thirty years, motivated to technological advances of computer system, new techniques are currently able to obtain better results predicting business failure given complex financial situations.

## **RESEARCH GOALS**

- Define the Bankruptcy framework through the clarification of regulatory and economic terms as well as the explanation of its typology and problematic.
- Starting from the publication made by M. Adnan, A. Aziz and Humayon Dar, which summarizes the performance and usability of principal techniques in predicting bankruptcies in 2006, this thesis will develop an extension of the models reviewed in that publication and will try to update its content to current days.
- Contrast skills and handicaps of the studied models.
- Measure quantitatively the use of predictive models for the last fifty years.

- Identify the variables that best explain the company failure.
- Undertake an independent scientific empirical study to test the performance of different prediction techniques implemented by available software.
- Propose recommended guidelines for developing a prediction system from the lessons learned.

## Corporate Bankruptcy Framework

It is known as “bankruptcy” to the legal proceeding involving a company that is unable to repay contracted debts, producing an adverse financial situation originated from an asset book value lower to the value of the debt.

In relation to the previous description, bankruptcy prediction intends to foresee if a company will fail in the short term from information available today. This issue, responds to a classificatory problem: given certain data from a company or its environment, it is necessary to class the company between two different groups, bankrupt companies or healthy companies.

Predict business failure involves many difficulties, firstly, due to changes in the market behavior or in the economic features, it is hard to find predictive models that remain stable over time. In addition, parameters that define a company are distinctive over the rest of them (financial structure, industry, number of employers, market situation, etc.). There are also restrictions to get data from a bankruptcy company because of managers usually are reluctant to show their accounting books. Finally, most of data is irrelevant or tough to relate, so it is difficult to find the best explicative variables of business failure.

It is possible to measure the performance of a model by gaining the generated hit rates / error rates or checking which model minimizes type I error(model classifies a bankrupt company as healthy one) and type II error (model classifies a healthy company as a bankrupt one).

In real life, it is as important the predictive model performance as the cost of errors.

# Bankruptcy Prediction Models - Review

Bankruptcy prediction models may be classified according to different criteria:

- **Models Based on the source of used information:**
  - Accounting information source: They use quantitative and qualitative methods applied to corporate solvency from financial statements information.
  - Alternative sources: Those models which use dynamic market information to estimate probabilities of bankruptcy. It means, data collection is open to any information source related to corporate failure (e.g. stock information, regulation, financial facts, etc.).
- **Models according to investigative purpose:**
  - Theoretical models: Focus on qualitative causes of bankruptcy, uses data that meets the theoretical argument, multivariate, use statistical techniques to make it work.
  - Statistical models: Focus on signs of failure, uses data from the company financial statements, univariate or multivariate, follow classical statistical processes.
  - Models based on Artificial Intelligence: Focus on signs of failure, uses data from the company financial statements, generally multivariate, developed from the technological and informational advancement, strong dependence on computer systems.
  - Hybrid models: It is a very open category, composed by every model build from the parallel or sequentially integration of different classical models. This models are created in order to exploit certain capabilities of standard models or to mitigate adverse effects by the cooperation of them.

## THEORITICAL PREDICTION MODELS

<b>Model</b>	<b>Description</b>
Balance Sheet Decomposition Measures	This theory follows the main argument of “companies tend to maintain a balance state that ensures the maintenance of the structure of existing business in order to avoid financial insolvencies. The occurrence of significant changes in the balance reveals an inability to maintain balance by the company. One of these changes may be the trigger for the business failure.



---

Gambler's Ruin Theory	Within the context of corporate bankruptcy, company plays the role of a gambler: it will continue carrying out their activities until its equity is equal to 0, moment when company will broke. If the company obtains a negative cash flow over several periods of time, ultimately will bankrupt.
Cash Management Theory	The theory involves the management of cash since it began its transition to the company to its end in payments. A monitoring mistake may be materialized as the imbalance between inflows and outflows, which may lead the company to a state of inability to face its financial obligations.
Credit Risk Theories	Credit Risk refers to the risk that a counterparty defaults on its payment obligations, therefore, models which continues this theories, are available to predict possible business failures. This models and its risk predictions are based on economic theories of corporate finance and usually are implemented by payment tools as BSM – Prob, CreditMetrics, Moody's KMV, CSFB's CreditRisk+ or Mcikinsey's CreditPortfolio View.

### **STATISTICAL PREDICTION MODELS**

<b>Model</b>	<b>Description</b>
Univariate Analysis	The model tries to determine the significance of each variable to explain the economic insolvency, setting a complete reliance on a single variable to explain the business failure. Most of the scientific studies use any of these techniques in the first stages (e.g. analysis of variance).
Discriminant Analysis	This model generates a linear combination of certain discriminatory variables to calculate a bankruptcy score. It may be simple or multiple depending on the number of groups to be analyzed.
Logistic Regression Models	This models estimates the probability of bankrupt or healthy situation of a company through a dichotomous variable using a logistic function. Model changes depending on the chosen logistic function e.g. Logit model, Probit model.
Linear Probability Model	LPM works relating a set of observations (financial ratios) with the behavior of dependent variable Y (Bankruptcy) in an equation.
Cumulative sums (CUSUM)	This tool detects distribution changes from a good quality to a bad one. It works plotting a time weighted control time graphic that represents cumulative sums deviations of each value respect to the dependent variable Y.

Partial Adjustment Models	Through the use of this method, it is possible to characterize the adjustment process of ratios started by any active movement of the company. The model includes two parts: a static stage where it is described how to calculate a particular result and a dynamic part where the previous rules are adjusted.
Multidimensional Scaling	From the obtaining of preferences and perceptions of given data, this model represents a two or more dimensional map, called perceptual map, that ease the classification of companies.

### **PREDICTIVE MODELS BASED ON ARTIFICIAL INTELLIGENCE**

<b>Model</b>	<b>Description</b>
Case Based Reasoning	This technique may solve new prediction problems based on solutions previously solved. The process consist in four phases: First recovers old experiences solved that keep similitudes with the new problem. Then re-uses the old solution applying it to the new problem. After that, it is carried out a revision of solution through different simulations that check the correctness of the result. Finally, the system saves the new case in its knowledge database to be used in future problems.
Neural Networks	Its structure consist in a system of interconnected processing units that cooperate with each other with the purpose of generate a single classification signal as output. There different types of neural networks used to predict bankruptcies are Multilayer Perceptron, Probabilistic Neural Network and Radial Basis Neural Network and Self-Organized Maps.
Rough Sets Model	RS is a collection of objects that usually have ambiguous cases that cannot be classified as members of a unique class. Due to the idea of assign any kind of feature or information to those unclassifiable cases, a system information codifies independent variables, transforming its continuous values according to previous given criteria. At the end of the process, it is obtained deduction rules in order to determinate if a member belongs to a specific class.
Genetic Algorithm	GA techniques works evolving a set of objects to simulated new set of objects with desired characteristics. This technique cannot predict corporate failure by itself, but it can optimize coefficients of other models or improve data quality.
Support Vector Machine	Using this AI technique, it is possible to classify objects by calculating exclusion hyperplanes in a space made from features of an additional dimension, which reach the maximum separation.

Recursively  
Partitioned Decision  
Trees

Constructing decision trees that configure the influence of certain explicative variables respect to the objective variable (Bankruptcy), it is possible to classify new objects in classes from the previous learning process of training data.

K-Nearest Neighbors

K-NN method divides a given space in several located regions and labels each region in order to the trained information to classify new information respect to the previous. If we locate a new object in the studied space and there is a most repeated class between the K prototypes, this new object will be assigned to the current class.

### HISTORICAL ANALYSIS OF PREDICTION MODELS




Diagram 1

According to Diagram 1, plotted from the information obtained in scientific review, statistical models category is the most used category over the last fifty years being applied in the 50,44% of bankruptcy researches. This result is mainly explained by the massive utilization of Multiple Discriminant Analysis (Diagram 2).




Diagram 2

However, results show that Models based in AI have obtained better accuracy rates (Diagram 3 and Diagram 4).




Diagram 3

Diagram 4

In first position, Rough Sets reach the highest precision rate compared to the rest of the studied models (91%) with low type I and type II error (8% and 5%).

### **USED RATIOS IN ARTIFICIAL INTELLIGENCE MODELS**

Regarding to the current tendency of selecting financial ratios as explicative variables of bankruptcy, it is selected a random set of 7 of 32 bankruptcy prediction scientific researches focus on the application of AI models in order to identify and count the number of employed ratios.

This exercise indicates that exists six ratios frequently used: Assets / Liabilities, EBIT / Total Assets, Retained earnings / Total Assets, Net Income / Total Assets, Capital / Total Assets and Financial Expenses / Sales.

## Empirical Scientific Study

### **DATASET STUDIED**

Dataset studied include 41 variables for 500 French companies in 2002 (250 bankrupt companies and 250 healthy companies). This companies operate in trading sector and it is known healthy companies keep on working until 2005.



RE1 Profit before Tax /Shareholders' Funds	LI1 (Cash + Marketable Securities)/Total Assets
RE2 Net Income/Shareholders' Funds	LI2 Cash/Total Assets
RE3 EBITDA/Total Assets	LI3 (Cash + Marketable Securities)/Total Sales
RE4 EBITDA/Permanent Assets	LI4 Quick Ratio
RE5 EBIT/Total Assets	LI5 Cash/Current Liabilities
RE6 Net Income/Total Assets	LI6 Current Assets/Current Liabilities
EF1 Value Added/Total Sales	LI7 Quick Assets/Total Assets
EF2 Total Sales/Shareholders' Funds	LI8 Current Liabilities/Total Assets
EF3 EBIT/Total Sales	LI9 Quick Assets/Total Assets
EF4 Total Sales/Total Assets	LI10 EBITDA/Total Sales
EF5 Gross Trading Profit/Total Sales	LI11 Financial Debt/Cash Flow
EF7 Operating Cash Flow/Total Assets	LI12 Cash/Total Debt
EF8 Operating Cash Flow/Total Sales	RO1 Cash/Total Sales
PR1 Financial Expenses/Total Sales	RO2 Inventory/Total Sales
PR2 Labor Expenses/Total Sales	RO3 Net Operating Working Capital/Total Sales
SF1 Shareholder's Funds/Total Assets	RO4 Accounts Receivable/Total Sales
SF2 Total Debt/Shareholders' Funds	RO5 Accounts Payable/Total Sales
SF7 Total Debt/Total Assets	RO6 Current Assets/Total Sales
SF8 Net Operating Working Capital/Total Assets	AP1 Change in Equity Position
SF10 Long Term Debt/Total Assets	AP2 Change in Other Debts
SF11 Long Term Debt/Shareholders' Funds	

### ATTRIBUTE SELECTION

The high number of ratios considered in this dataset may difficult the models adjustment, increasing the complexity and producing overtraining.

To decrease the probabilities of these adverse situations, are employed five techniques of attribute selection (Correlation test, Gain ratio test, One R test, ReliefF test and Symetrical uncertainty test) in order to identify redundant or irrelevant ratios and discard them.

Following the criteria of select the ratios with the worst average position in rankings, there are seven ratios that are marked as "unhelpful ratios": EF4 Total Sales/Total Assets, RO6 Current Assets/Total Sales, EF5 Gross Trading Profit/Total Sales, PR2 Labor Expenses/Total Sales, RO2 Inventory/Total Sales, RO4 Accounts Receivable/Total Sales and LI9 Quick Assets/Total Assets.

### EXPERIMENTATION

16 classification techniques are tested in exercise 1 and exercise 2 over the studied dataset:

Nº	Classifier
1	Linear Discriminant
2	Cuadratic Discriminant
3	Logistic Regression (sigmoid function)
4	Parzen
5	5-Nearest Neighbors
6	7-Nearest Neighbors
7	11-Nearest Neighbors
8	Multilayer Perceptron BPNN (1 neuron in hidden layer )
9	Multilayer Perceptron BPNN (5 neurons in hidden layer)
10	Multilayer Perceptron BPNN (10 neurons in hidden layer)
11	Linear Perceptron
12	Radial Basis Neural Network (5 radial basis functions)
13	Radial Basis Neural Network (5 radial basis functions)
14	Radial Basis Neural Network (5 radial basis functions)
15	Support Vector Machine
16	Binary Decision Tree

- **Experiment 1.**

Training and testing sets are configured splitting 60% - 40% of dataset studied randomly. Process is repeated 30 times, selecting different training and testing sets in each iteration. Average hit rate it is obtained as performance result for each of the classifiers.

- **Experiment 2.**

First experiment it is repeated, excluding unhelpful ratios from the studied dataset. This experiment it is carried out in order to check if classifiers performance improves by discarding the redundant ratios.

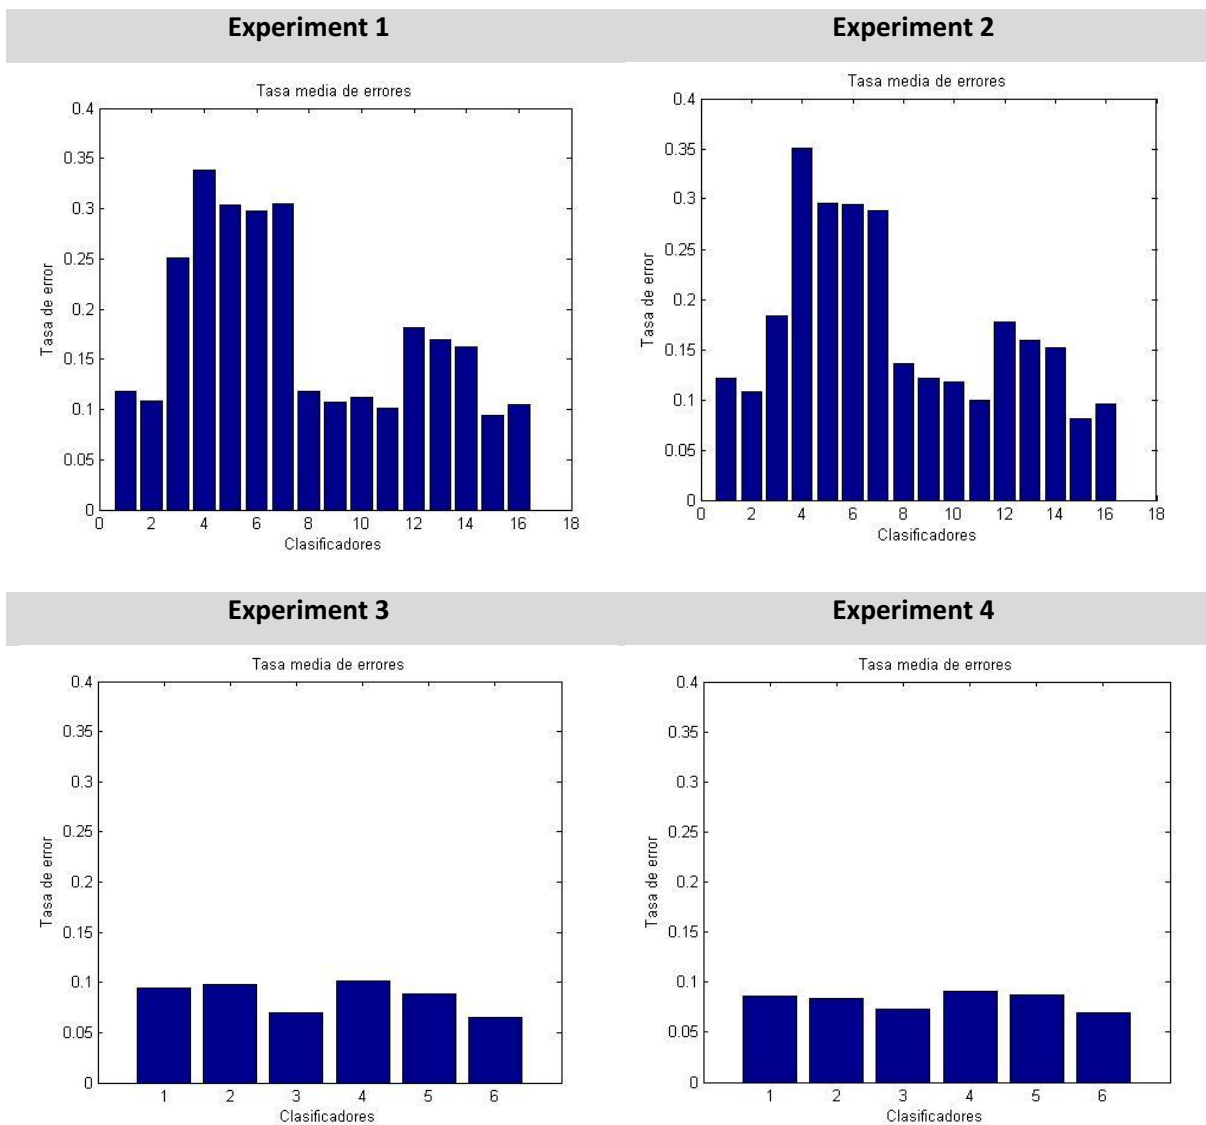
- **Experiment 3.**

Top five classifiers from previous experiments are selected to combine its obtained results over the original data. Configuration of sets keeps intact.

- **Experiment 4.**

It is repeated experiment three, but this time, it is tested over the dataset without unhelpful ratios.

### RESULTS



Nº	Classifier	% Error Exp. 1	% Error Exp. 2	Difference
1	Linear Discriminant	11,75%	12,15%	+0,40%
2	Cuadratic Discriminant	10,85%	10,85%	0,00%
3	Logistic Regression (sigmoid function)	25,12%	18,30%	-6,82%
4	Parzen	33,80%	35,08%	+1,28%
5	5-Nearest Neighbors	30,32%	29,60%	-0,72%
6	7-Nearest Neighbors	29,77%	29,47%	-0,30%
7	11-Nearest Neighbors	30,47%	28,87%	-1,60%
8	Multilayer Perceptron BPNN (1 neuron in hidden layer )	11,83%	13,65%	+1,82%
9	Multilayer Perceptron BPNN (5 neurons in hidden layer)	10,73%	12,16%	+1,43%
10	Multilayer Perceptron BPNN (10 neurons in hidden layer)	11,17%	11,73%	+0,56%
11	Linear Perceptron	10,12%	9,97%	-0,15%
12	Radial Basis Neural Network (5 radial basis functions)	18,10%	17,78%	-0,32%
13	Radial Basis Neural Network (5 radial basis functions)	16,90%	15,95%	-0,95%
14	Radial Basis Neural Network (5 radial basis functions)	16,28%	15,19%	-1,09%
15	Support Vector Machine	9,37%	8,10%	-1,27%
16	Binary Decision Tree	10,47%	9,57%	-0,90%

Table 1. Comparison experiment 1 and experiment 2

Nº	Classifier	% Error Exp. 3	% Error Exp. 3	Difference
1	<b>Classifier 1</b> (Com. Product)	9,44%	8,64%	-0,80%
2	<b>Classifier 2</b> (Com. Media)	9,82%	8,41%	-1,41%
3	<b>Classifier 3</b> (Com. Median)	7,02%	7,27%	+0,25%
4	<b>Classifier 4</b> (Com. Maximum)	10,14%	9,05%	-1,09%
5	<b>Classifier 5</b> (Com. Minimum)	8,89%	8,76%	-0,13%
6	<b>Classifier 6</b> (Com. Voting)	6,53%	6,92%	+0,39%

Table 2. Comparison experiment 3 and experiment 4





## Conclusions

This research presents a global view of Bankruptcy Prediction problem, as well the theoretical, statistical and based on Artificial Intelligence models available to solve the issue at the present time.

According to the results, theoretical prediction models provide a restricted variety of assumptions and ideas that lack predictive power if they are not applied with the help of other models. On the other hand, statistical and Artificial Intelligence techniques useful for themselves, abundant and have diverse uses. However, over the last decade, a favorable tendency to use hybrid models in corporate bankruptcy prediction has emerged.

Generically, performances of techniques tried in our study are almost equal to performances of reviewed scientific investigations, especially Support Vector Machine and Decision Tree techniques obtain the best accuracy rates over the dataset studied. But the best prediction result is obtained by a hybrid model built by several combinations of the best five experimented classifiers. Concretely, the best classification result is derived from voting combining classifier, achieving a success rate close to 94% on the studied dataset.

Concerning the type of information to be used by Bankruptcy Prediction models, it is observed financial ratios from companies accounting data are frequently used in bankruptcy prediction problems. About data redundancy, it may be avoided using attribute selection techniques, as it is demonstrated in the empirical study.

Finally this investigation corroborates prediction models based on Artificial Intelligence obtain better results than the rest of the models.

For future work, it is recommended to analyze prediction models performance over different industries from a larger dataset of companies. It also would be interesting to developed specific researches around Support Vector Machine and Decision Trees knowing its satisfactory results on Bankruptcy Prediction.