



Modelos centrados vs descentrados para la predicción de quiebra: evidencia empírica para España

*Focused vs unfocused models for bankruptcy prediction:
Empirical evidence for Spain*

Gonzalo Laguillo, Agustín del Castillo, Manuel Ángel Fernández*,
Rafael Becerra

Universidad de Málaga, España

Recibido el 24 de abril de 2017; aceptado el 6 de octubre de 2017

Disponible en Internet el: 8 de noviembre de 20

Resumen

Usando información financiera de empresas españolas pertenecientes a distintos sectores económicos, este estudio ha desarrollado modelos centrados y descentrados para la predicción de quiebra. La comparación de ambos tipos de modelos nos ha permitido determinar la superioridad de los modelos descentrados, que en la mayor parte de los casos muestran una gran capacidad de predicción y un fuerte ahorro de costes de elaboración frente al desarrollo de numerosos modelos centrados. Este estudio también aporta conocimiento acerca de las variables que explican la quiebra en los diferentes sectores económicos y ayuda a la toma de decisiones sobre la utilización de un determinado modelo de predicción de quiebra.

Códigos JEL: C53; G33

Palabras clave: Predicción de quiebra; ratios financieros; regresión logística; sectores económicos.

Abstract

Using financial information from Spanish companies belonging to different economic sectors, this study has developed focused and unfocused models for bankruptcy prediction. The comparison of both types of models has allowed us to

*Autor para correspondencia.

Correo electrónico: mangel@uma.es (M. Á. Fernández)

La revisión por pares es responsabilidad de la Universidad Nacional Autónoma de México.

determine the superiority of unfocused models, which in most cases show a great predictive capacity and reduce the elaboration cost of numerous focused models. This study also provides insight into the variables that explain bankruptcy in different economic sectors and helps decision making on the use of a specific model of bankruptcy prediction.

JEL Codes: C53; G33

Keywords: bankruptcy prediction; financial ratios; logistic regression; economic sectors

Introducción

La predicción de la quiebra empresarial ha sido objeto de especial atención en la investigación financiera durante las últimas cinco décadas, siendo muy numerosos los trabajos orientados a determinar los factores que la provocan. Esta ingente tarea de investigación ha generado una amplia variedad de modelos, soportados, a su vez, en muy diversas metodologías. Uno de los caminos inicialmente tomados por la literatura fue el desarrollo de modelos que habían sido contruidos a partir de una muestra de empresas pertenecientes a varios sectores, y que por tanto, bien podían considerarse como modelos descentrados (Casey y Bartczak, 1985; Odom y Sharda, 1990; Altman, Marco y Varetto, 1994; Wilson y Sharda, 1994). El desarrollo de estos modelos descentrados ha sido importante a través del tiempo, predominando los contruidos con muestras de medianas y grandes empresas de diferentes sectores (Charalambous, Chatitou y Kaourou, 2000; Chen, Härdle y Moros, 2011; Sangjae y Wu, 2013). En la literatura sobre predicción de quiebra también destaca el desarrollo de modelos elaborados a partir de muestras de empresas pertenecientes a sectores de actividad específicos, y que han sido denominados modelos contrados. El más popular de los modelos contrados es el utilizado para entidades de crédito (Santomero y Vinso, 1977; Martín-del-Brio y Serrano-Cinca, 1995; Alam et al., 2000). Otro de los más populares modelos contrados ha sido para las empresas industriales (Altman, 1968; Appetiti, 1984; Zavgren, 1985). Recientemente también se han desarrollado modelos contrados en empresas de otros sectores, como en empresas de Internet (Wang, 2004), en empresas de hostelería (Park y Hancer, 2012; Fernández, Cisneros y Callejón, 2016), en empresas agrarias (Mateos-Ronco et al., 2011), en empresas de construcción (Gill de Albornoz y Giner, 2013) y para empresas de comercios y servicios (Keener, 2013).

Un análisis detallado de la literatura sobre predicción de quiebra permite constatar la existencia de un patrón definido por lo que se refiere a la construcción de modelos descentrados frente a modelos contrados, siendo los primeros mucho más numerosos que los segundos. En cambio, no es posible inducir una conclusión definitiva sobre la superioridad de un tipo de modelo frente a otro (Bellovary, Giacomino y Akers, 2007). Es posible que la ausencia de una conclusión práctica sobre la superioridad de un modelo contrado sobre un modelo descentrado sea debida a que no se haya podido comparar, de forma homogénea, un tipo de modelo y otro debido a la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países, entre otras cuestiones. Por lo tanto, la existencia de este hueco en la literatura, que no permite dilucidar la superioridad de los modelos descentrados frente a los modelos contrados, es una importante cuestión de investigación que el presente trabajo trata de resolver. Para ello, el presente trabajo ha seleccionado diferentes muestras de empresas españolas quebradas y no quebradas en el período 2010-2015. Entre estas muestras, algunas están integradas por empresas que pertenecen a distintos sectores económicos, y han sido

utilizadas para la construcción de modelos descentrados. Otras de las muestras contienen sólo empresas de un determinado sector de actividad, y se han reservado para la construcción de modelos centrados. Todos los modelos han sido construidos con una misma metodología, concretamente, la de Regresión Logística. Disponer tanto de modelos descentrados como de modelos centrados desarrollados a partir de muestras homogéneas, referidas a un mismo período temporal y a un mismo país, y construidos con una misma metodología, nos ha permitido obtener conclusiones robustas sobre el diseño de los modelos de predicción de la quiebra en diferentes sectores económicos. También, sobre la eficiencia de los modelos descentrados, que en gran parte de los casos implica un gran ahorro de costes frente a la elaboración y desarrollo de numerosos modelos centrados.

Nuestro trabajo se compone de las siguientes partes. Tras esta introducción, el apartado 2 ofrece una taxonomía de los estudios sobre predicción de quiebra. En el apartado 3 se analizan los métodos de análisis utilizados en la presente investigación. En el apartado 4 se exponen tanto el proceso de obtención y el tratamiento de las muestras como las variables utilizadas y los criterios tenidos en cuenta para la selección de las mismas. El apartado 5 presenta los resultados de la investigación empírica. Finalmente, se detallan las principales conclusiones obtenidas.

Revisión de la literatura e hipótesis de investigación

El análisis de la quiebra empresarial ha sido objeto de gran atención en la investigación financiera durante las últimas cinco décadas. Se han realizado numerosos trabajos de investigación orientados a determinar los factores que provocan la quiebra empresarial, con una especial incidencia en cómo predecirla antes de que ésta suceda. Los autores pioneros de los estudios empíricos sobre predicción de quiebra fueron Beaver (1966) y Altman (1968), aplicando métodos de Análisis Discriminante y Multidiscriminante, respectivamente. A partir de estos estudios iniciales, la principal cuestión en la literatura sobre predicción de quiebra no sólo fue determinar qué variables incluir en los modelos, sino valorar qué método era el más eficaz para realizar predicciones. Atendiendo a este criterio, gran parte de los trabajos se han desarrollado en torno a los llamados clasificadores individuales puros. Dentro de éstos se encuentran los clasificadores estadísticos, tales como el análisis Multidiscriminante y los modelos de Regresión Logística, que están basados en la teoría estadística (Jones, Johnstone y Wilson, 2017; Ohlson, 1980; Zavgren, 1985; Tseng y Hu, 2010; Piñeiro, de Llano y Rodríguez, 2013). Y los clasificadores basados en la programación matemática, como Data Envelopment Analysis (Li, Crook y Andreeva, 2017). A partir de los años 90 también se han utilizado otros métodos como los de inteligencia artificial, basados en Redes Neuronales (Mselmi, Lahiani y Hamza, 2017; Callejón et al., 2013; Tam, 1991; Tam y Kiang, 1992; Wu et al., 2008), en Máquinas de Soporte Vectorial (Shin, Lee y Kim, 2005; Min y Lee, 2005), en Algoritmos de Genéticos (Rafiei, Manzari y Bostanian, 2011; Etemadi, Rostamy y Dehkordi, 2009), en Árboles de Decisión (Chen, 2011; Li, Sun y Wu, 2010), y en la Combinación de Clasificadores (Ravisankar y Ravi, 2010; Li et al., 2013; Sun et al., 2016).

De otra parte, y en referencia a las variables consideradas en la literatura previa como predictores de quiebra, puede deducirse que la más común fue el ratio “Beneficio después de Impuestos/Total Activo”, y que el segundo factor más frecuentemente utilizado fue el ratio “Activo corriente/Pasivo corriente”. Además, que el número de variables consideradas en la construcción de los modelos ha oscilado entre 1 y 57 (Bellovary, Giacomino y Akers, 2007).

Otro término utilizado en la literatura es el de modelos globales de predicción de quiebra, y que se refiere a aquéllos que se han desarrollado para empresas de todo un país o región. Korol (2013) incorpora este enfoque y hace una comparación entre dos regiones, Platt y Platt (2008) para tres regiones del mundo, y Alaminos, del Castillo y Fernández (2016) a nivel global utilizando un modelo de Regresión Logística. De igual forma, Altman et al. (2017) aplica el Z-score para una amplia base mundial de empresas quebradas y Jabeur (2017) utiliza Regresión Logística de mínimos cuadrados parciales a partir de una base diversa de empresas francesas.

Junto a los trabajos referidos anteriormente, que en gran parte han desarrollado modelos descentrados, también destacan en la literatura aquéllos que han sido construidos a partir de muestras de empresas de un sector económico específico, y que por ello reciben la denominación de modelos centrados. En el sector Agricultura destacan los trabajos de D'Antoni, Mishra y Chintawar (2009) y de Mateos-Ronco et al. (2011). D'Antoni, Mishra y Chintawar (2009) utilizaron una muestra de empresas agrarias y llegaron a la conclusión de que características como el tamaño, el tipo de propiedad y la edad del empresario eran decisivas para la probabilidad de quiebra. Por su parte, Mateos-Ronco et al. (2011) estudiaron las cooperativas agrarias españolas, y seleccionaron qué variables eran las más adecuadas para predecir la quiebra. En el sector Industrial, Callejón et al. (2013) desarrollaron un modelo que consigue una precisión del 92%, revelando que la quiebra está negativamente relacionada con la capacidad de devolución de la deuda a través de los fondos generados y con la rentabilidad de la empresa. Bartoloni y Baussola (2014) proporcionaron un modelo centrado empleando para ello métodos de Análisis Multidiscriminante y de Análisis Envoltante de Datos, y concluyeron sobre la superioridad de este último en cuanto a capacidad de predicción. Para los sectores Construcción e Inmobiliario, Gill de Albornoz y Giner (2013) compararon la precisión de los modelos centrados frente a los modelos descentrados, comprobando la superioridad de los primeros frente a los segundos. Igualmente, con empresas del sector Construcción, Spicka (2013) construyó un modelo centrado que permitió constatar que la inadecuada relación entre endeudamiento/rentabilidad y la generación de reservas insuficientes son causas potenciales de quiebra. Con empresas de los sectores Comercio y Servicios, Keener (2013) desarrolló un modelo centrado con el que demostró que las empresas quebradas presentaban menor número de empleados, menor ratio de caja sobre pasivos corrientes y mayores ratios de deuda sobre capital, y Fallahpour, Lakvan y Zadeh (2017) probaron diversos Algoritmos Genéticos encontrando las variables de rentabilidad como las más significativas. Finalmente, y con empresas del sector Hostelería, Park y Hancer (2012) construyeron un modelo centrado con el que detectaron que las variables Fondo de Maniobra/Total Activo, Total Pasivo/Patrimonio Neto y Total Pasivo/Total Activo eran los mejores predictores de quiebra. Por su parte, Fernández, Cisneros y Callejón (2016) demostraron que usando información cercana al momento de la quiebra (uno o dos años antes), la variable más relevante para predecir la quiebra en hoteles es la que relaciona EBITDA con el pasivo corriente, pero que utilizando información más lejana al momento de la quiebra (tres años antes), la rentabilidad de los activos es la variable más significativa.

Aunque el desarrollo de modelos de predicción de quiebra ha sido importante, en la literatura existente, no es posible encontrar conclusiones sobre la superioridad de los modelos descentrados o de los centrados. Como señalábamos anteriormente, esta ausencia de conclusiones que comparen ambos tipos de modelos puede ser debida a que no se hayan podido comparar de forma homogénea un tipo de modelo y otro, dada la disparidad de metodologías, enfoques, bases de datos disponibles, periodos temporales y países con los que se han construido

los modelos existentes. En consecuencia, este hueco en la literatura, que no permite dilucidar la superioridad de los modelos descentrados frente a los modelos centrados, nos ha motivado a formular las siguientes hipótesis de investigación:

Hipótesis 1 (H1): La introducción de variables cualitativas sectoriales en un modelo descentrado mejora su capacidad de predicción de quiebra.

Hipótesis 2 (H2): Un modelo descentrado con variables cualitativas sectoriales predice la quiebra correctamente en cualquier sector económico de actividad.

El caso de la aceptación de la hipótesis H1 modificaría el modelo descentrado, indicando que existen diferencias sectoriales para explicar el proceso de quiebra de las empresas, pero procurando mantener el máximo grado de similitud entre los sectores. Por su parte, no rechazar la hipótesis H2 permitiría una sola explicación de cómo las empresas quiebran en los diferentes sectores.

Metodología

El presente trabajo utiliza técnicas de Regresión Logística y Criterios de Selección de Modelos para el contraste de las hipótesis de investigación planteadas. Regresión Logística es una técnica de clasificación en la que la variable dependiente considera exclusivamente dos categorías. Además, parte de unos supuestos menos restrictivos que otras técnicas estadísticas de clasificación y permite que el modelo incorpore variables cualitativas (Visauta, 2003). La función logística se encuentra acotada entre 0 y 1, proporcionando la probabilidad de que un elemento se encuentre en uno de los dos grupos establecidos. Es decir, a partir de un suceso dicotómico, predice la probabilidad de que el evento tenga o no lugar. Si la estimación de la probabilidad es superior a 0.5 entonces la predicción es que sí pertenece a ese grupo, y en caso contrario, supondría que pertenece al otro grupo considerado.

Para estimar el modelo se parte del cociente entre la probabilidad de que un suceso ocurra y la probabilidad de que éste no ocurra. Así, la probabilidad de que un suceso ocurra, $P(Y_i = 1/x_i)$, vendrá determinada por la expresión (1).

$$P(Y_i = 1/x_i) = \frac{e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}{1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} \quad (1)$$

$$\text{Odds} = \frac{P(Y_i = 1)}{1 - P(Y_i = 1)} = \frac{1/(1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)})}{1/(1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)})} =$$

$$\frac{1 + e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)}} = e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)} \quad (2)$$

Los coeficientes estimados $(\beta_1, \dots, \beta_k)$ representan medidas de los cambios en el Odd ratio. En este sentido, un coeficiente positivo aumenta la probabilidad de ocurrencia del suceso, mientras que un valor negativo disminuye la probabilidad de ocurrencia del mismo (Hair et al., 1999). Aplicando logaritmos en (2) se obtiene una expresión lineal del modelo, tal y

como aparece en (3), en la que los coeficientes se estimarían aplicando el método de máxima verosimilitud.

$$Y_i^* = \ln \frac{P(Y_i = 1)}{1 - P(Y_i = 1)} = \ln e^{(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)} = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k \quad (3)$$

De otra parte, y en referencia a los Criterios de Selección de Modelos, el presente trabajo utiliza tanto Akaike (AIC), como Schwarz (BIC) y Hannan-Quinn (HQC) con el fin de que las conclusiones obtenidas tengan una gran robustez. Estos criterios han sido empleados con éxito en investigaciones anteriores sobre predicción de quiebra (por ejemplo, Alaminos, del Castillo y Fernández, 2016). AIC es el criterio básico de entre los que se fundamentan en la información estadística (Akaike, 1973). En el caso general, viene expresado como aparece en (4).

$$AIC = 2k - 2\ln(L) \quad (4)$$

Donde k es el número de parámetros y L el máximo valor de la función de verosimilitud del modelo estimado. La idea básica subyacente al uso del criterio AIC para la selección de modelos es la maximización del logaritmo de la función de verosimilitud esperada de un modelo determinado. Schwarz (1978) sugirió que el criterio AIC podría no ser asintóticamente justificable y presentó un criterio de información alternativo a partir de un enfoque bayesiano (BIC). Con este criterio se penaliza el número de parámetros con $\ln(n)$ en lugar de con 2. Así, la expresión del criterio de BIC quedaría según aparece en (5).

$$BIC = -2\ln(L) + \ln(n) \times k \quad (5)$$

Siendo k el número de parámetros, L el máximo valor de la función de verosimilitud del modelo estimado y n el número de observaciones.

Por su parte, HQC puede ser considerado una variante del criterio BIC, con una penalización de la magnitud del tamaño muestral. Hannan y Quinn (1979) sugirieron inicialmente este criterio para seleccionar el orden de una autoregresión, bajo la forma que aparece en la expresión (6). Al igual que para los criterios AIC y BIC, este criterio selecciona el modelo que minimice el valor de HQC.

$$HQC = -2\ln(L) + 2\ln[\ln(n)] \times k \quad (6)$$

mientras que un valor negativo disminuye la probabilidad de ocurrencia del mismo (Hair et al., 1999). Aplicando logaritmos en (2) se obtiene una expresión lineal del modelo, tal y como aparece en (3), en la que los coeficientes se estimarían aplicando el método de máxima verosimilitud.

Datos y variables

Para el contraste de las hipótesis de investigación establecidas en el presente trabajo, se ha dispuesto de 12 muestras de empresas españolas, 6 de ellas utilizando información correspondiente a 1 año antes de la quiebra de las empresas (t-1) y otras 6 con información

de 2 años antes de la quiebra (t-2). Tanto para t-1 como para t-2 se han considerado muestras que incluyen empresas pertenecientes a cinco sectores económicos (Agricultura, Industria, Construcción, Comercio y Servicios, y Hostelería), y que son utilizadas para la construcción de modelos descentrados. Así mismo, se ha dispuesto de muestras integradas por empresas de un solo sector para el desarrollo de modelos centrados. En todas las muestras se ha considerado el mismo número de empresas quebradas y no quebradas, siguiendo el criterio aplicado en gran parte de los estudios de predicción de quiebra (Du Jardin, 2015). En el ámbito del presente trabajo se considera que una empresa está en quiebra si cuenta con el estatus legal de situación concursal, según las consideraciones realizadas por la ley concursal española 22/2003 de 9 de julio, así como las siguientes modificaciones realizadas de la misma (Real Decreto Ley 3/2009 de 27 de marzo de medidas urgentes ante la evolución de la situación económica y la Ley 38/2011, de 10 de Octubre). Por su parte, la identificación de las empresas pertenecientes a cada sector de actividad se ha realizado en función de la clasificación realizada por los códigos CNAE-2009, y la información financiera de dichas empresas se ha obtenido de la base de datos SABI (Sistema de Análisis de Balances Ibéricos) perteneciente a Bureau van Dijk (para los ejercicios 2010-2015). Un detalle del número de empresas en cada muestra aparece en la tabla 1. Para la construcción de los modelos estimados en el presente trabajo se ha reservado el 70% de los datos de cada muestra (datos de validación) para la construcción de los modelos, mientras que el 30% de los datos restantes se han utilizado para comprobar la capacidad predictiva de dichos modelos (datos de testeo).

Tabla 1
 Número de empresas en las muestras

	Estado	t-1	t-2
Modelos descentrados	No Quiebra	1.500	1.500
	Quiebra	1.500	1.500
Modelos centrados. Agricultura	No Quiebra	300	300
	Quiebra	300	300
Modelos centrados. Industria	No Quiebra	300	300
	Quiebra	300	300
Modelos centrados. Construcción	No Quiebra	300	300
	Quiebra	300	300
Modelos centrados. Comercio y Servicios	No Quiebra	300	300
	Quiebra	300	300
Modelos centrados. Hostelería	No Quiebra	300	300
	Quiebra	300	300

De todas las empresas de las muestras se ha dispuesto de información financiera para conformar un conjunto de variables como predictores de quiebra. Todas las variables han sido seleccionadas de la literatura previa sobre modelos centrados y descentrados. Para los modelos descentrados se han seleccionado aquellas que han sido consideradas en 20 o más trabajos de predicción quiebra (Bellovary, Giacomino y Akers, 2007). Para los modelos centrados en Agricultura, las variables propuestas por D'Antoni, Mishra y Chintawar (2009), Mateos-Ronco et al. (2011), Dietrich, Arcelus y Srinivisan (2005) y Wasilewski y Madra (2008). Para los del sector Industria, las utilizadas previamente por Callejón et al. (2013), Bartoloni y Baussola (2014), Zhang et al. (2013), Grünberg y Lukason (2014) y De Andrés, Landajo y Lorca (2005). Para los centrados en Construcción las variables propuestas por Spicka (2013), Gill de Albornoz y Giner (2013), Mínguez-Conde (2006) y Stroe y Barbuta-Misu (2010). Para

Comercio y Servicios, las utilizadas en los trabajos de Keener (2013) y He y Kamath (2006). Por último, para Hostelería, las variables específicas han sido las utilizadas en los modelos de Park y Hancer (2012), Fernández, Cisneros y Callejón (2016), Cho (1994), Gu (2002), Youn y Gu (2010) y Kim (2011). Adicionalmente, y para ser utilizadas en los modelos descentrados, se han incorporado otras variables de tipo cualitativo (Dummy Agricultura, Dummy Industria, Dummy Construcción, Dummy Comercio y Servicios, Dummy Hostelería) que toman el valor 1 si la empresa pertenece a uno de los cinco sectores económicos considerados, y 0 en caso contrario. Junto a las anteriores variables, se ha utilizado otra variable dicotómica como variable dependiente, que toma el valor 1 si la empresa se identifica como quebrada y 0 en caso contrario. En la tabla 2 puede observarse la definición de todas las variables utilizadas como predictores de quiebra.

Tabla 2

Definición de las variables cuantitativas

Código	Definición
Variables modelos descentrados	
VD1	Beneficio después de Impuestos/Total Activo
VD2	Activo Corriente/Pasivo Corriente
VD3	Fondo Maniobra/Total Activo
VD4	EBIT/Total Activo
VD5	Total Ingresos/Total Activo
VD6	Quick Ratio
VD7	Total Deuda/Total Activo
VD8	Activo Corriente/Total Activo
VD9	Beneficio después de Impuestos/Patrimonio Neto
Variables modelos centrados, Agricultura	
VCA1	Fondos Propios/Total Deuda
VCA2	EBIT/Gastos Financieros
VCA3	EBIT/Total Ingresos
Variables modelos centrados, Industria	
VCI1	Resultado de Explotación/Total Ingresos
VCI2	Ventas/Clientes
VCI3	(Activo Corriente-Pasivo Corriente)/Capital
VCI4	Fondos Propios/Pasivo no Corriente
VCI5	Gastos Financieros/Total Ingresos
VCI6	Ln (Total Activo)
VCI7	Resultado de Explotación/Patrimonio Neto
VCI8	Total Ingresos/Activo no corriente
Variables modelos centrados, Construcción	
VCC1	Gastos Financieros/EBIT
VCC2	Resultado de Explotación/Total Ingresos
VCC3	Fondos Propios/Total Deuda
Variables modelos centrados, Comercio y Servicios	
VCCS1	EBITDA/Total Pasivo
VCCS2	EBIT/Gastos Financieros
VCCS3	EBIT/Pasivo Corriente
VCCS4	Ventas/Existencias
VCCS5	Ventas/Total Activo
Variables modelos centrados, Hostelería	
VCH1	EBITDA/Pasivo Corriente
VCH2	EBITDA/Total Pasivo
VCH3	Total Deuda Financiera/EBITDA
VCH4	Total Deuda Financiera/Capital
VCH5	Ventas a Crédito/Clientes
VCH6	Flujos Libres de Caja/Total Deuda

Resultados

Las tablas 3-8 presentan los principales estadísticos descriptivos de las variables seleccionadas para la construcción de modelos descentrados y centrados en cada una de las muestras. En general, las variables presentan valores medios distintos para las empresas quebradas respecto a las no quebradas, lo que permite constatar que pueden ser utilizadas para la construcción de los modelos propuestos.

Tabla 3
 Estadísticos descriptivos. Modelos descentrados

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9
t-1									
No quiebra	0.05 (0.21)	3.37 (11.68)	0.24 (0.30)	0.05 (0.41)	2.14 (11.34)	2.34 (10.25)	0.23 (0.28)	0.60 (0.29)	0.04 (1.95)
Quiebra	-0.25 (1.00)	1.81 (4.67)	0.32 (0.44)	-0.20 (0.72)	1.33 (1.89)	0.74 (1.22)	0.42 (0.47)	0.59 (0.31)	0.30 (2.39)
t-2									
No quiebra	0.05 (0.21)	3.39 (11.80)	0.24 (0.30)	0.05 (0.41)	2.14 (11.43)	2.36 (10.37)	0.23 (0.28)	0.60 (0.29)	0.03 (1.95)
Quiebra	-0.10 (0.50)	2.74 (20.69)	0.37 (0.38)	-0.07 (0.44)	1.46 (2.76)	1.63 (20.27)	0.38 (0.86)	0.61 (0.31)	0.07 (2.58)

Desviación estándar entre paréntesis

Tabla 4
 Estadísticos descriptivos. Modelos centrados. Agricultura.

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9	VCA1	VCA2	VCA3
t-1												
No quiebra	0.02 0.03	1.55 0.97	0.20 0.28	0.04 0.04	0.93 0.67	1.03 0.95	0.33 0.21	0.45 0.28	0.08 0.07	2.87 4.56	4.99 13.18	0.08 0.17
Quiebra	-0.03 0.07	0.99 0.87	0.27 0.28	-0.01 0.08	0.66 0.84	0.46 0.42	0.47 0.30	0.46 0.29	0.16 0.57	0.75 2.20	-1.14 17.64	-0.02 0.29
t-2												
No quiebra	0.05 (0.21)	3.39 (11.80)	0.24 (0.30)	0.05 (0.41)	2.14 (11.43)	2.36 (10.37)	0.23 (0.28)	0.60 (0.29)	0.03 (1.95)	2.52 (4.31)	2.85 (2.24)	0.08 (0.17)
Quiebra	-0.10 (0.50)	2.74 (20.69)	0.37 (0.38)	-0.07 (0.44)	1.46 (2.76)	1.63 (20.27)	0.38 (0.86)	0.61 (0.31)	0.07 (2.58)	0.96 (1.19)	1.88 (2.93)	0.09 (0.10)

Desviación estándar entre paréntesis.

Tabla 5
Estadísticos descriptivos. Modelos centrados. Industria.

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9	VCI1	VCI2	VCI3	VCI4	VCI5	VCI6	VCI7	VCI8
No quiebra t-1	0.03 (0.05)	1.75 (1.40)	0.26 (0.21)	0.05 (0.06)	1.37 (0.75)	1.14 (1.20)	0.27 (0.19)	0.53 (0.22)	0.10 (0.15)	0.04 (0.05)	14.28 (29.18)	-0.09 (2.09)	27.49 (82.89)	0.01 (0.02)	7.36 (1.81)	0.20 (0.31)	4.75 (5.15)
Quiebra	-0.1 (0.21)	1.26 (1.10)	0.47 (0.27)	-0.06 (0.19)	1.32 (0.93)	0.82 (0.80)	0.3 (0.31)	0.57 (0.23)	0.08 (1.09)	-0.12 (0.37)	8.33 (14.47)	0.07 (3.06)	7.49 (39.01)	0.02 (0.02)	6.71 (0.98)	0.35 (0.96)	4.75 (4.80)
No quiebra t-2	0.03 (0.03)	1.72 (1.29)	0.27 (0.21)	0.05 (0.04)	1.30 (0.71)	1.11 (1.10)	0.28 (0.19)	0.54 (0.22)	0.09 (0.18)	0.04 (0.04)	11.8 (19.41)	-0.27 (3.70)	57.63 (239.00)	0.01 (0.02)	7.40 (1.73)	0.14 (0.61)	4.82 (5.74)
Quiebra	-0.03 (0.08)	1.24 (1.02)	0.51 (0.23)	0.02 (0.09)	1.32 (0.80)	0.76 (0.70)	0.23 (0.21)	0.6 (0.21)	-0.92 (5.39)	-0.03 (0.15)	7.41 (7.37)	0.03 (2.61)	5.64 (22.00)	0.03 (0.02)	6.75 (0.95)	-0.49 (5.53)	5.85 (6.23)

Desviación estándar entre paréntesis.

Tabla 6
Estadísticos descriptivos. Modelos centrados. Construcción.

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9	VCC1	VCC2	VCC3
No quiebra t-1	0.05 (0.10)	4.04 (7.74)	0.33 (0.30)	0.00 (0.43)	0.72 (0.89)	2.27 (4.44)	0.34 (0.29)	0.60 (0.31)	0.24 (1.12)	0.03 (0.71)	0.34 (0.80)	5.11 (10.31)
Quiebra	-0.07 (0.22)	4.20 (7.69)	0.61 (0.32)	-0.04 (0.21)	0.65 (0.77)	0.83 (1.60)	0.55 (0.30)	0.81 (0.22)	0.35 (2.05)	0.14 (1.19)	-0.19 (1.26)	0.36 (2.77)
No quiebra t-2	0.04 (0.07)	4.28 (8.12)	0.34 (0.30)	-0.01 (0.43)	0.63 (0.74)	2.49 (5.12)	0.34 (0.29)	0.6 (0.31)	0.19 (0.90)	0.09 (1.13)	0.38 (0.99)	4.99 (10.53)
Quiebra	-0.01 (0.07)	3.52 (5.86)	0.62 (0.29)	0.01 (0.08)	0.79 (0.80)	0.77 (0.71)	0.48 (0.29)	0.82 (0.20)	0.08 (0.96)	0.60 (1.40)	-0.15 (2.50)	1.11 (6.02)

Desviación estándar entre paréntesis.

Tabla 7
Estadísticos descriptivos. Modelos centrados. Comercio y Servicios.

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9	VCCS1	VCCS2	VCCS3	VCCS4	VCCS5
No quiebra t-1	0.02 (0.05)	1.52 (1.01)	0.28 (0.29)	0.04 (0.06)	1.66 (1.26)	0.94 (0.93)	0.21 (0.21)	0.70 (0.24)	0.10 (0.61)	0.07 (0.08)	11.33 (37.25)	0.12 (0.21)	21.22 (61.04)	1.69 (1.26)
Quiebra	-0.14 (0.22)	1.07 (0.69)	0.35 (0.31)	-0.12 (0.23)	1.19 (0.90)	0.59 (0.49)	0.43 (0.30)	0.61 (0.23)	0.18 (1.19)	-0.09 (0.23)	-6.65 (16.79)	-0.13 (0.34)	32.78 (135.17)	1.19 (0.90)
No quiebra t-2	0.01 (0.04)	1.52 (1.27)	0.30 (0.28)	0.04 (0.06)	1.70 (1.30)	0.88 (0.94)	0.21 (0.21)	0.69 (0.24)	0.08 (0.32)	0.06 (0.06)	4.78 (30.88)	0.09 (0.16)	13.03 (19.48)	1.70 (1.30)
Quiebra	-0.03 (0.09)	1.18 (0.59)	0.40 (0.28)	0.00 (0.08)	1.46 (1.24)	0.70 (0.48)	0.32 (0.25)	0.66 (0.26)	0.28 (1.39)	0.01 (0.09)	0.91 (20.60)	-0.01 (0.21)	28.61 (93.34)	1.46 (1.24)

Desviación estándar entre paréntesis.

Tabla 8
Estadísticos descriptivos. Modelos centrados. Hostelería.

	VD1	VD2	VD3	VD4	VD5	VD6	VD7	VD8	VD9	VCH1	VCH2	VCH3	VCH4	VCH5	VCH6
No quiebra t-1	0.03 (0.06)	1.61 (1.73)	0.13 (0.22)	0.06 (0.07)	1.95 (1.52)	1.14 (1.49)	0.42 (0.35)	0.40 (0.27)	0.21 (0.50)	0.49 (0.51)	0.11 (0.08)	6.13 (9.90)	3.71 (8.59)	250.16 (806.83)	1.16 (3.50)
Quiebra	-0.16 (0.22)	0.68 (0.73)	0.06 (0.20)	-0.15 (0.22)	1.25 (1.21)	0.54 (0.66)	0.56 (0.35)	0.32 (0.26)	0.00 (1.54)	-0.13 (0.43)	-0.10 (0.21)	-5.37 (23.29)	1.45 (9.80)	152.45 (608.31)	-0.12 (2.32)
No quiebra t-2	0.03 (0.06)	1.61 (1.73)	0.13 (0.22)	0.06 (0.07)	1.95 (1.52)	1.14 (1.49)	0.42 (0.35)	0.40 (0.27)	0.21 (0.50)	0.49 (0.51)	0.11 (0.08)	6.13 (9.90)	3.71 (8.59)	250.16 (806.83)	1.16 (3.50)
Quiebra	-0.16 (0.22)	0.68 (0.73)	0.06 (0.20)	-0.15 (0.22)	1.25 (1.21)	0.54 (0.66)	0.56 (0.35)	0.32 (0.26)	0.00 (1.54)	-0.13 (0.43)	-0.10 (0.21)	-5.37 (23.29)	1.45 (9.80)	152.45 (608.31)	-0.12 (2.32)

Desviación estándar entre paréntesis.

Con objeto de contrastar las hipótesis de investigación planteadas, se han construido los modelos descentrados y centrados que aparecen en la tabla 9. Para la construcción de los modelos descentrados se han utilizado sólo las variables predictoras que en la literatura previa han resultado significativas en tales modelos. Por su parte, para la construcción de los modelos centrados se han utilizado tanto las variables predictoras de modelos descentrados como las variables específicas de cada sector. De la comparación de los modelos estimados es posible detectar significativas diferencias entre los mismos, pues los modelos centrados seleccionan variables específicas de cada sector y también algunas propias de los modelos descentrados. Los modelos descentrados están compuestos principalmente por seis variables: Beneficio después de Impuestos/Total Activo (VD1), Activo Corriente/Pasivo Corriente (VD2), Fondo de Maniobra/Total Activo (VD3), EBIT/Total Activo (VD4), Total Ingresos/Total Activo (VD5), Quick ratio (VD6) y Beneficio después de Impuestos/Patrimonio Neto (VD9). Por tanto, seleccionan como mejores predictores de quiebra variables que hacen referencia a la rentabilidad, a la liquidez y a la eficiencia. En el caso de los modelos centrados en Agricultura, las principales variables seleccionadas han resultado ser cuatro: Beneficio después de Impuestos/Total Activo (VD1), Quick ratio (VD6), Fondos Propios/Total Deuda (VCA1) y EBIT/Gastos Financieros (VCA2). En este caso, dichas variables están relacionadas con la rentabilidad, la liquidez y el endeudamiento. Por su parte, en la construcción de modelos centrados en Industria, destacan las variables Beneficio después de Impuestos/Total Activo (VD1), Activo Corriente/Pasivo Corriente (VD2), Fondo de Maniobra/Total Activo (VD3), EBIT/Total Activo (VD4), Quick ratio (VD6), Activo Corriente/Total Activo (VD8), Fondos Propios/Pasivo no Corriente (VCI4) y Resultado Explotación/Patrimonio Neto (VCI7), que en conjunto hacen referencia a la rentabilidad, la liquidez y al endeudamiento. Respecto a los modelos centrados en Construcción, las variables seleccionadas más representativas han sido Beneficio después de Impuestos/Total Activo (VD1), Quick ratio (VD6), Total Deuda/Total activo (VD7), Activo Corriente/Total Activo (VD8) y Gastos Financieros/EBIT (VCC1), que también recogen aspectos de rentabilidad, de liquidez y de endeudamiento. Para el sector de Comercio y Servicios, los modelos construidos seleccionan principalmente cinco variables: Beneficio después de Impuestos/Total Activo (VD1), Activo Corriente/Pasivo Corriente (VD2), Fondo de Maniobra/Total Activo (VD3), Total Deuda/Total activo (VD7) y Ventas/Existencias (VCCS4). Estas variables hacen referencia a aspectos de rentabilidad, de liquidez, de endeudamiento y de eficiencia. Finalmente, en los modelos centrados en Hostelería las variables significativas han resultado ser cuatro: Beneficio después de Impuestos/Total Activo (VD1), Activo Corriente/Pasivo Corriente (VD2), EBITDA/Pasivo Corriente (VCH1) y Total Deuda Financiera/EBITDA (VCH3). En este caso, recogen aspectos de rentabilidad, de liquidez y de endeudamiento.

Como se ha podido comprobar, las variables de rentabilidad y de liquidez han resultado explicativas en todos los modelos estimados. Además, dichos modelos alcanzan un alto porcentaje de precisión en la clasificación (generalmente superior al 80%).

Si comparamos los resultados obtenidos en la literatura previa en los denominados modelos descentrados, o elaborados a partir de muestras heterogéneas de sectores, con los estimados en este trabajo, puede constatar que los resultados obtenidos se sitúan en un rango intermedio, existiendo trabajos previos que muestran mejores y peores resultados. Así, encontramos trabajos que presentan excelentes resultados en la muestra de testeo como el de Shuk-Wern, Voon Choong y Khong (2011), con un porcentaje de acierto del 90%, y otros que se sitúan por

debajo de nuestros resultados como el de Charalambous, Chatitou y Kaourou (2000) con un 77.9% en el testeo, e incluso el resultado de Chen, Härdle y Moros (2011) con un porcentaje de acierto en la muestra de testeo del 64.5%. Con respecto a las variables utilizadas, hay mucha heterogeneidad, sin encontrarse un patrón común entre los trabajos previos y los modelos globales desarrollados en el presente trabajo.

De otra parte, y en relación con el modelo estimado para el sector Agricultura, tan solo el trabajo de Vavrina, Hampel y Janová (2013) empleó la Regresión Logística en su estudio, con un porcentaje de clasificación en la muestra de entrenamiento del 71.9% para un año antes de la quiebra. En este sentido, nuestro modelo ofrece un mejor resultado, alcanzando el 78.5% en la muestra de entrenamiento y el 75.6% en la muestra de testeo. Nuestro modelo estimado del sector Industria para t-1 obtuvo un resultado en la muestra de testeo del 89.2%, resultado muy similar al obtenido por Lin (2009) con un 89.4%. Tan solo supera nuestro resultado el modelo de Zhang et al. (2013), con un poder de clasificación en el testeo del 95.2%. Por debajo de estos resultados se encuentran los trabajos de Zhang et al. (1999), Darayseh, Waples y Tsoukalas (2003) y el de Hu y Tseng (2005). Con el trabajo de Lin (2009) únicamente encontramos en común la variable VD5. Con el trabajo de Zhang et al. (2013) tan solo se comparten las variables VD1 y VCI7. En el sector Construcción nuestro resultado se ha situado en el 81.5% de acierto en la clasificación con la muestra de testeo para t-1, que mejora el resultado obtenido por Mínguez-Conde (2006), pues alcanzó sólo un 76.9%. Entre las variables utilizadas, compartimos con Mínguez-Conde (2006) la variable VD1. Por lo que se refiere al sector Comercio y Servicios, nuestro modelo ha obtenido un porcentaje de clasificación del 83.5% en la muestra de testeo. Por debajo de estos resultados se encuentra el modelo de Kim (2011), que obtuvo un porcentaje con la muestra de entrenamiento del 80.0%. Por su parte, el mejor modelo estimado para t-1 resultó ser el del sector Hostelería, con un porcentaje de acierto en la clasificación del 91.2%. Si bien este es un resultado notable, se encuentra algo por debajo del obtenido por Kim y Gu (2006b) que consiguió un 93%. Dos años antes de la quiebra (t-2) nuestro modelo del sector de Hostelería registró un porcentaje de acierto del 81% en la muestra de testeo. Los trabajos de Kim y Gu (2006a) y Youn y Gu (2010) registraron un 84% y un 85% de acierto con la muestra de entrenamiento. Sin embargo, ellos no validaron sus modelos con muestras de testeo.

Tabla 9
Modelos descentrados y modelos centrados

		Ajuste de los modelos				Precisión en la clasificación (%)	
		Test Omnibus	Test Hosmer Lemeshow	-2 log verosimilitud	R2 Nagelkerke	Validación	Testeo
Descentrados (sin variables cualitativas)	t-1	Y = -0.460 - 21.653 VD1*** + 1.358 VD3*** + 7.758 VD4** - 0.286 VD5***	0.139***	453.922	0.359	80.12	80.89
	t-2	Y = -0.159 - 14.156 VD1*** - 0.080 VD2** + 1.451 VD3*** - 0.400 VD9**	0.085***	398.738	0.441	73.04	71.13
Descentrados (con variables cualitativas)	t-1	Y = -0.755 - 28.574 VD1*** - 1.189 VD2*** + 1.345 VD3*** + 13.108 VD4*** + 1.243 VD6*** - 0.1492 Dummy Construcción** - 0.665 Dummy Comercio y Servicios**	0.400***	318.395	0.611	82.53	81.77
	t-2	Y = -0.048 - 14.530 VD1*** - 0.086 VD2** + 1.497 VD3*** - 0.425 VD9*** - 0.470 Dummy Industria	0.100***	450.885	0.365	73.35	72.74
Centrados (Agricultura)	t-1	Y = 0.753 - 32.529 VD1*** - 0.973 VD6** + 0.004 VCA2***	0.487***	78.310	0.560	78.77	75.60
	t-2	Y = 0.804 - 13.429 VD1** - 0.147 VCA1***	0.210***	98.333	0.327	65.64	69.65
Centrados (Industria)	t-1	Y = 1.202 - 39.344 VD1*** - 1.422 VD2** + 8.394 VD3*** + 16.676 VD4** - 1.371 VD5*** + 1.803 VD6*** - 3.367 VD8*** + 1.059 VCI7***	0.000***	159.940	0.657	86.67	89.22
	t-2	Y = -1.413 - 105.627 VD1*** - 2.581 VD2** + 21.487 VD3*** + 6.0678 VD4*** + 3.603 VD6** - 9.142 VD7*** - 12.284 VD8*** - 3.351 VD9** - 0.039 VCI4**	0.000***	66.261	0.832	94.51	78.13
Centrados (Construcción)	t-1	Y = -2.092 - 14.624 VD1*** - 0.138 VD6** + 1.377 VD7** + 2.134 VD8** - 0.390 VCCI***	0.117***	361.278	0.496	77.02	74.52
	t-2	Y = -2.006 - 16.729 VD1*** + 1.775 VD3*** - 0.139 VD6** + 1.247 VD7** + 1.584 VD8** + 0.289 VCCI**	0.177***	260.006	0.559	80.86	81.54
Centrados (Comercio y Servicios)	t-1	Y = -0.066 - 28.061 VD1*** - 0.785 VD2** + 2.992 VD3*** + 2.165 VD7*** - 2.112 VD8** + 0.006 VCCI***	0.000***	217.607	0.584	79.96	83.54
	t-2	Y = -0.788 + 9.135 VD1*** - 0.307 VD2** + 1.637 VD3*** + 2.118 VD7***	0.000***	364.380	0.277	70.98	79.53
Centrados (Hostelería)	t-1	Y = 1.186 - 13.196 VD1*** - 1.096 VD2** - 0.440 VD5*** - 1.447 VCI1*** - 0.027 VCI3**	0.000***	249.873	0.690	84.22	91.26
	t-2	Y = 0.231 - 0.476 VD2** - 14.835 VD4*** + 0.733 VD6***	0.082***	234.212	0.379	72.64	81.01

Sig. al nivel 0.05; *Sig. al nivel 0.01

Para el contraste de la hipótesis H1, es decir, si la introducción de variables cualitativas sectoriales en un modelo descentrado mejora su capacidad de predicción, se han comparado los modelos descentrados contruidos con variables cualitativas y los modelos descentrados sin variables cualitativas, utilizando para ello los criterios AIC, BIC y HQC. Los resultados de la comparación aparecen en la tabla 10. Teniendo en cuenta que la regla de decisión para los tres criterios es seleccionar el modelo que ofrece el menor valor en la comparación, es posible concluir que los modelos descentrados (con variables cualitativas) son superiores a los modelos descentrados (sin variables cualitativas). De esta forma, los resultados obtenidos permiten aceptar la hipótesis H1 implicando que la inclusión de variables cualitativas representativas de sectores económicos enriquece y aumenta la capacidad de explicación de los modelos descentrados.

Tabla 10
 Comparación de los modelos descentrados. Hipótesis H₁

Criterios de Selección de Modelos	Modelos descentrados (sin variables cualitativas)		Modelos descentrados (con variables cualitativas)	
	t-1	t-2	t-1	t-2
AIC	398.74	461.92	330.40	458.89
BIC	405.34	468.52	341.35	466.19
HQC	395.24	458.42	325.39	455.55

Una vez que se ha podido constatar que los modelos descentrados (con variables cualitativas) son superiores a los modelos descentrados (sin variables cualitativas) procede abordar la hipótesis H2, que trata de contrastar si un modelo descentrado predice la quiebra correctamente en cualquier sector económico. Para ello se ha comprobado la capacidad de predicción del modelo descentrado (con variables cualitativas) utilizando las muestras de testeo de cada uno de los cinco sectores económicos seleccionados en el presente trabajo (tabla 11). Los resultados obtenidos ponen de manifiesto que los modelos descentrados (con variables cualitativas) son capaces de predecir con éxito en las muestras sectoriales. No obstante, y con el fin de conseguir una mayor robustez en las conclusiones, se han sometidos estos resultados a los Criterios de Selección de Modelos AIC, BIC y HQC (tabla 12). Para t-1, la hipótesis H2 queda aceptada, pues los modelos descentrados (con variables cualitativas) son superiores a cualquier modelo centrado. Sin embargo, para t-2, esta hipótesis es rechazada, pues el modelo centrado en Industria es superior al modelo descentrado.

Los resultados obtenidos asumen, por tanto, la existencia de un modelo global para predecir la quiebra cuando se utiliza información próxima al momento de la quiebra (t-1). Estos resultados pueden explicarse por evidencias en la investigación previa que sostienen que el riesgo de quiebra depende de efectos globales y no tanto del efecto de los sectores (Jabeur, 2017; Altman et al., 2017; Alaminos, del Castillo y Fernández, 2016; Korol, 2013; Platt y Platt, 2008).

Tabla 11
Resultados de los modelos descentrados (con variables cualitativas) en muestras sectoriales. Hipótesis H₂

	t-1					t-2				
	Agricultura	Industria	Construcción	Com. y Serv.	Hostelería	Agricultura	Industria	Construcción	Com. y Serv.	Hostelería
Ajuste de los modelos										
Prueba Omnibus	0.012	0.000	0.000	0.000	0.000	0.004	0.000	0.000	0.000	0.000
Test Hosmer-Lemeshow	0.562	0.589	0.757	0.884	0.975	0.578	0.402	0.654	0.600	0.100
R2 Nagelkerke	0.414	0.728	0.624	0.703	0.757	0.369	0.415	0.374	0.461	0.605
Matriz de clasificación (%)										
No quiebra	75.00	93.00	84.60	91.50	88.90	69.20	79.30	72.00	75.90	76.60
Quiebra	70.00	78.30	80.30	83.10	87.00	63.60	72.20	69.40	74.70	84.00
Total	72.70	85.80	82.50	87.30	88.00	66.70	75.90	70.80	75.30	80.40
Criterios de Selección de Modelos										
AIC	56.34	112.69	128.25	117.10	98.44	58.72	175.93	170.28	167.73	131.49
BIC	63.64	123.96	138.68	127.90	109.38	63.55	183.45	177.23	174.93	138.77
HQC	50.43	107.75	123.12	112.05	93.43	54.77	172.64	166.86	164.37	128.14

AIC: Akaike, BIC: Bayesian, HQC: Hannan-Quinn

Tabla 12

Comparación entre modelos descentrados (con variables cualitativas) y modelos centrados. Hipótesis H₂

	t-1			t-2		
	AIC	BIC	HQC	AIC	BIC	HQC
<i>Agricultura</i>						
Modelo centrado	84.31	87.96	81.36	102.33	104.75	100.36
Modelo descentrado	56.34	63.64	50.43	58.72	63.55	54.77
<i>Industria</i>						
Modelo centrado	175.94	190.97	169.36	84.26	101.17	76.86
Modelo descentrado	112.69	123.96	107.75	175.93	183.45	172.64
<i>Construcción</i>						
Modelo centrado	270.01	278.69	265.73	373.28	383.70	368.15
Modelo descentrado	128.25	138.68	123.12	170.28	177.23	166.86
<i>Comercio y Servicios</i>						
Modelo centrado	229.61	240.41	224.56	373.38	379.58	369.02
Modelo descentrado	117.10	127.90	112.05	167.73	174.93	164.37
<i>Hostelería</i>						
Modelo centrado	259.87	268.98	255.70	240.21	245.68	237.71
Modelo descentrado	98.44	109.38	93.43	131.49	138.77	128.14

AIC: Akaike, BIC: Bayesian, HQC: Hannan-Quinn

Conclusiones

El objetivo del presente trabajo es cubrir el gap existente en la literatura sobre la superioridad de los modelos descentrados o de los centrados para la predicción de quiebra. Se ha tratado de dilucidar esta cuestión con un diseño ad-hoc, superando la ausencia de conclusiones definitivas en la literatura previa debido a la disparidad de métodos, enfoques, bases de datos disponibles, periodos temporales y países que han sido considerados. A tal efecto, en este trabajo se han construido modelos centrados en cinco sectores económicos y modelos descentrados, todos ellos utilizando información del período 2010-2015 correspondientes a empresas españolas, un año (t-1) y dos años (t-2) antes de la quiebra.

Los resultados empíricos obtenidos han permitido confirmar, en primer lugar, que la inclusión de variables cualitativas sectoriales mejora la capacidad predictiva de los modelos descentrados. Y en segundo lugar, que los modelos descentrados son superiores a los modelos centrados al predecir con mayor precisión que éstos cuando se utiliza información próxima al momento de la quiebra (un año antes). Sin embargo, utilizando información más alejada al momento de la quiebra, los modelos descentrados resultan superiores a los centrados sólo en determinados sectores económicos, pues el modelo centrado en Industria ha resultado ser superior al modelo descentrado testeado con la muestra de empresas de dicho sector.

Como consecuencia de las conclusiones anteriores y de la investigación documental y empírica desarrollada creemos que el presente trabajo contribuye al conocimiento financiero empresarial en diferentes aspectos. En primer lugar, consigue dilucidar una cuestión que, aunque ya apuntada por otros autores, no había sido objeto de estudio con un diseño, un método y una muestra específica. En segundo lugar, permite obtener conclusiones a la hora de abordar una estrategia de predicción de la quiebra en diferentes sectores económicos. Prácticamente, en buena parte de los casos, un modelo descentrado es capaz de predecir con éxito la quiebra en muestras de empresas pertenecientes a sectores económicos concretos, lo que implicaría un ahorro de costes considerable en la elaboración y desarrollo de numerosos modelos centrados. En tercer lugar, este trabajo ha puesto de manifiesto el concurso de variables explicativas

sectoriales, de carácter específico, que permiten tener un conocimiento mucho más concreto de los factores que explican la quiebra. El conocimiento de estas variables como específicamente sectoriales en la explicación del fracaso empresarial puede ayudar a los agentes económicos y usuarios de esta información a actuar preventivamente. Por último, y dado que el primer paso en la gestión de los riesgos es realizar una medición de los mismos, una adecuada puntuación del riesgo de quiebra puede ayudar en este sentido. Por ello, antes de la decisión de utilizar un determinado modelo, son necesarios fundamentos que orienten sobre las limitaciones de éstos y sobre cuál de ellos (descentrados o centrados) se adaptan mejor a sus circunstancias.

Las conclusiones obtenidas en el presente trabajo hacen pensar en futuras líneas de investigación que pueden resultar de suma utilidad para perfeccionar los modelos de predicción de quiebra. Así, y en primer lugar, sería interesante comprobar si los resultados obtenidos con la muestra de empresas españolas son los mismos que cuando los modelos se construyen con empresas de otros ámbitos geográficos, lo que dotaría a estas conclusiones de una elevada capacidad de generalización. Del mismo modo, también podría resultar relevante modificar la definición de los sectores considerados, ampliando el tamaño de la muestra, y de esta forma comprobar si las conclusiones aquí obtenidas serían las mismas en sectores económicos más o menos ampliamente definidos. Por último, y como la eficacia de los modelos posiblemente variará en función de las condiciones macroeconómicas, sería interesante conocer los resultados de clasificación de dichos modelos en diferentes etapas del ciclo económico.

Referencias

- Akaike, H. (1973). *Information theory and an extension of the maximum likelihood principle*. In B. N. Petrov and F. Csaki (Eds.), *Second international symposium on information theory*, 267-281.
- Alam, P., Booth, D., Lee, K. & Thordarson, T. (2000). The use of fuzzy clustering algorithm and self-organizing neural networks for identifying potentially failing banks: An experimental study. *Expert Systems with Applications* 18, 185-199. [https://doi.org/10.1016/s0957-4174\(99\)00061-5](https://doi.org/10.1016/s0957-4174(99)00061-5)
- Alaminos, D., Del Castillo, A. & Fernández, M.A. (2016). A global model for bankruptcy prediction. *PLoS ONE* 11, 11: e0166693. <https://doi.org/10.1371/journal.pone.0166693>
- Altman, E.I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *Journal of Finance*, 23(4), 589-609. <http://dx.doi.org/10.2307/2978933>
- Altman, E.I., Iwanicz-Drozdzowska, M., Laitinen, E.K. & Suvas, A. (2017). Financial distress prediction in an international context: A review and empirical analysis of Altman's Z-score model. *Journal of International Financial Management & Accounting*, 28(2), 131-171. <https://doi.org/10.1111/jifm.12053>
- Altman E.I., Marco, G. & Varetto, F. (1994). Corporate distress diagnosis: Comparisons using linear discriminant analysis and neural networks (The Italian experience). *Journal of Banking and Finance*, 18, 505-529. [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8)
- Appetiti, A. (1984). Identifying unsound firms in Italy: An attempt to use trend variables. *Journal of Banking and Finance*, 8(2), 269-279. [https://doi.org/10.1016/0378-4266\(84\)90007-4](https://doi.org/10.1016/0378-4266(84)90007-4)
- Bartoloni, E. & Baussola, M. (2014). Financial Performance in Manufacturing Firms: A comparison between parametric and non-parametric approaches. *Business Economics*, 49(1), 32-45. <https://doi.org/10.1057/be.2013.31>
- Beaver, W.H. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 5, 71-111. <http://dx.doi.org/10.2307/2490171>
- Bellovary, J., Giacomino, D. & Akers, M. (2007). A Review of Bankruptcy Prediction Studies: 1930 to Present. *Journal of Financial Education*, 33(4), 1-42. <https://www.jstor.org/stable/41948574>

- Callejón, A.M., Casado, A.M., Fernández, M.A. & Peláez, J.I. (2013). A System of Insolvency Prediction for industrial companies using a financial alternative model with neural networks. *International Journal of Computational Intelligence Systems*, 4, 1-13. <http://dxdoiorg/101080/187568912013754167>
- Casey, C. & Bartczak, N. (1985). Using Operating Cash Flow Data to Predict Financial Distress: Some Extensions. *Journal of Accounting Research*, 23(1), 384-401. <https://doi.org/10.2307/2490926>
- Charalambous, C., Chatitou, A. & Kaourou, F. (2000). Comparative analysis of artificial neural network models: Application in bankruptcy prediction. *Annals of Operations Research*, 99(1), 403-419. <https://doi.org/10.1109/ijcnn.1999.830776>
- Chen, M.Y. (2011). Bankruptcy prediction in firms with statistical and intelligent techniques and a comparison of evolutionary computation approaches. *Computers and Mathematics with Applications*, 62, 4514-4524. <https://doi.org/10.1016/j.camwa.2011.10.030>
- Chen, S., Härdle, W.K. & Moros, R.A. (2011). Modeling default risk with support vector machines. *Quantitative Finance*, 11(1), 135-154. <https://doi.org/10.1080/14697680903410015>
- Cho, M. (1994). *Predicting business failure in the hospitality industry: An application of logit model*. PhD Dissertation. Virginia Polytechnic Institute and State University. (Disponible en: https://vtechworks.lib.vt.edu/bitstream/handle/10919/40201/LD5655.V856_1994.C564.pdf?sequence=1). (Consultado: 16/01/2019).
- D'Antoni, J., Mishra, A. & Chintawar, S. (2009). *Predicting Financial Stress in Young and Beginning Farmers in the United States*. Department of Agricultural Economics and Agribusiness, Louisiana State University. (Disponible en: <https://ageconsearch.umn.edu/bitstream/46861/2/Predicting%20Financial%20Stress%20in%20Young%20and%20Beginning%20Farmers.pdf>). (Consultado: 16/01/2019).
- Darayseh, M., Waples, E. & Tsoukalas, D. (2003). Corporate failure for manufacturing industries using firms specifics and economic environment whit logit analysis. *Managerial Finance*, 29(8), 23-37. <https://doi.org/10.1108/03074350310768409>
- De Andrés, J., Landajo, M. & Lorca, P. (2005). Forecasting business profitability by using classification techniques. A comparative analysis based on a Spanish case. *European Journal of Operational Research*, 167(2), 518-542. <https://doi.org/10.1016/j.ejor.2004.02.018>
- Dietrich, J., Arcelus, F.J. & Srinivasan, G. (2005). Predicting Financial Failure: Some Evidence from New Brunswick Agricultural Co-ops. *Annals of Public and Cooperative Economics*, 76(2), 179-194. <https://doi.org/10.1111/j.1370-4788.2005.00275.x>
- Dimitras, A., Zanakis, S. & Zopounidis, C. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal of Operational Research*, 90, 487-513. [https://doi.org/10.1016/0377-2217\(95\)00070-4](https://doi.org/10.1016/0377-2217(95)00070-4)
- Du Jardin, P. (2015). Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, 242, 286-303. <http://dxdoiorg/101016/jeor201409059>
- Etemadi, H., Rostamy, A. & Dehkordi, H. (2009). A genetic programming model for bankruptcy prediction: empirical evidence from Iran. *Expert Systems Applications*, 36(2), 3199-3207. <https://doi.org/10.1016/j.eswa.2008.01.012>
- Fallahpour, S., Lakvan, E.N. & Zadeh, M.H. (2017). Using an ensemble classifier based on sequential floating forward selection for financial distress prediction problem. *Journal of Retailing and Consumer Services*, 34, 159-167. <https://doi.org/10.1016/j.jretconser.2016.10.002>
- Fernández, M.A., Cisneros, A.J. & Callejón, A.M. (2016). Applying a probabilistic neural network to hotel bankruptcy prediction. *Tourism & Management Studies*, 12(1), 40-52. <https://doi.org/10.18089/tms.2016.12104>
- Gill de Albornoz, B. & Giner, B. (2013). Predicción del fracaso empresarial en los sectores construcción e inmobiliario: modelos generales versus específicos. *Universia Business Review*, Tercer Trimestre, 118-131. <https://doi.org/10.12706/itea.2014.019>
- Grüenberg, M. & Lukason, O. (2014). Predicting Bankruptcy of Manufacturing Firms. *International Journal of Trade, Economics and Finance*, 5(1), 93-97. <https://doi.org/10.7763/ijtef.2014.v5.347>
- Gu, Z. (2002). Analyzing bankruptcy in the restaurant industry: A multiple discriminant model. *International Journal of Hospitality Management*, 21, 1, 25-42. [https://doi.org/10.1016/s0278-4319\(01\)00013-5](https://doi.org/10.1016/s0278-4319(01)00013-5)
- Hair, J.F., Anderson R.E., Tatham, R.L. & Black, W.C. (1999). *Análisis multivariante*, 5ª edición. Editorial Prentice Hall. Madrid.

- Hannan, E.J. & Quinn, B.G. (1979). The determination of the order of an autoregression. *Journal of the Royal Statistical Society, Series B*, 41(2), 190-195. <https://doi.org/10.1111/j.2517-6161.1979.tb01072.x>
- He, Y. & Kamath, R. (2006). Business Failure Prediction in Retail Industry: An empirical evaluation of generic bankruptcy models. *Academy of Accounting and Financial Studies Journal*, 10(2), 97-110. (Disponible en: <https://search.proquest.com/openview/5df0609b7394d09e2eeb5813d87ff48a/1?pq-origsite=gscholar&cbl=38637>). (Consultado: 16/01/2019).
- Hu, Y.C. & Tseng, F.M. (2005). Applying back propagation neural networks to bankruptcy prediction, *International Journal of Electronic Business Management*, 3(2), 97-103. (Disponible en: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.664.1219&rep=rep1&type=pdf>). (Consultado: 16/01/2019).
- Jabeur, S.B. (2017). Bankruptcy prediction using Partial Least Squares Logistic Regression. *Journal of Retailing and Consumer Services*, 36, 197-202. <https://doi.org/10.1016/j.jretconser.2017.02.005>
- Jones, S., Johnstone, D. & Wilson, R. (2017). Predicting corporate bankruptcy: An evaluation of alternative statistical frameworks. *Journal of Business Finance & Accounting*, 44, (1-2), 3-34. <https://doi.org/10.1111/jbfa.12218>
- Keener, M. (2013). Predicting the financial failure of retail companies in the United States. *Journal of Business & Economics Research*, 11(8), 373-380. <https://doi.org/10.19030/jber.v11i8.7982>
- Kim, S.Y. (2011). Prediction of hotel bankruptcy using support vector machine, artificial neural network, logistic regression and multivariate analysis. *The Service Industries Journal*, 31(3), 441-468. <https://doi.org/10.1080/02642060802712848>
- Kim, H & Gu, Z. (2006a). A logistic regression analysis for predicting bankruptcy in the Hospitality Industry. *The Journal of Hospitality Financial Management*, 14(1), 17-34. <https://doi.org/10.1080/10913211.2006.10653812>
- Kim, H & Gu, Z. (2006b). Predicting Restaurant Bankruptcy. A Logit Model in Comparison with a Discriminant Model. *Journal of Hospitality and Tourism Research*, 30(4), 474-493. <https://doi.org/10.1177/1096348006290114>
- Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30. <http://dxdoiorg/101016/j.jeconmod201211017>
- Kwak, W., Shi, Y. & Gang, K. (2012). Bankruptcy prediction for Korean firms after the 1997 financial crisis: using a multiple criteria linear programming data mining approach. *Review of Quantitative Finance and Accounting*, 38, 441-453. <https://doi.org/10.1007/s11156-011-0238-z>
- Li, Z., Crook, J. & Andreeva, G. (2017). Dynamic prediction of financial distress using Malmquist DEA. *Expert Systems with Applications*, 80, 94-106. <https://doi.org/10.1016/j.eswa.2017.03.017>
- Li, H., Sun, J., Li, J.C. & Yan, X.Y. (2013). Forecasting business failure using two-stage ensemble of multivariate discriminant analysis and logistic regression. *Expert Systems*, 30(5), 385-397. <https://doi.org/10.1111/j.1468-0394.2012.00642.x>
- Li, H., Sun, J. & Wu, J. (2010). Predicting business failure using classification and regression tree: an empirical comparison with popular classical statistical methods and top classification mining methods. *Expert Systems with Applications*, 37(8), 5895-5904. <https://doi.org/10.1016/j.eswa.2010.02.016>
- Lin, T.H. (2009). A cross model study of corporate financial distress prediction in Taiwan: Multiple Discriminant Analysis, logit, probit and neural networks models. *Neurocomputing*, 72, 3507-3516. <https://doi.org/10.1016/j.neucom.2009.02.018>
- Martin-del-Brio, B. & Serrano-Cinca, C. (1995). *Self-organizing neural networks: The financial state of Spanish companies*. Article in *Neural Network in the Capital Markets*, Refenes (ed.). Chichester: Wiley, 341-357.
- Mateos-Ronco, A., Marín-Sánchez, M.M., Marí-Vidal, S. & Seguí-Mas, E. (2011). Los modelos de predicción del fracaso empresarial y su aplicabilidad en cooperativas agrarias. CIRIEC-España, *Revista de Economía Pública, Social y Cooperativa*, 70, abril, 179-208. <https://doi.org/10.12706/itea.2014.019>
- McKee, T.E. (2000). Developing a bankruptcy prediction model via rough sets theory. *Intelligent Systems Accounting Finance Management*, 9, 159-173. [https://doi.org/10.1002/1099-1174\(200009\)9:3<159::aid-isaf184>3.3.co;2-3](https://doi.org/10.1002/1099-1174(200009)9:3<159::aid-isaf184>3.3.co;2-3)
- McKee, T.E. & Greenstein, M. (2000). Predicting bankruptcy using recursive partitioning and a realistically proportioned data set. *Journal of Forecasting*, 19, 219-230. [https://doi.org/10.1002/\(sici\)1099-131x\(200004\)19:3<219::aid-for752>3.3.co;2-a](https://doi.org/10.1002/(sici)1099-131x(200004)19:3<219::aid-for752>3.3.co;2-a)
- Min, J.H. & Lee, Y.C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Application*, 28, 128-134. <http://dxdoiorg/101016/j.eswa.200509070>

- Mínguez-Conde, J.L. (2006). *El fracaso empresarial en la empresa constructora*. Tesis Doctoral. Universidad de Valladolid.
- Mselmi, N., Lahiani, A. & Hamza, T. (2017). Financial distress prediction: The case of French small and medium-sized firms. *International Review of Financial Analysis*, 50, 67-80. <https://doi.org/10.1016/j.irfa.2017.02.004>
- Odom, M.D. & Sharda, R. (1990). A neural networks for bankruptcy prediction. *IEEE INNS International Joint Conference on Neural Networks*, 2, 163-168. <http://dxdoiorg/101109/ijcnn1990137710>
- Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1), 109-131. <http://dxdoiorg/102307/2490395>
- Park, S.S. & Hancer, M. (2012). A comparative study of logit and artificial neural networks in predicting bankruptcy in the hospitality industry. *Tourism Economics*, 18(2), 311-338. <https://doi.org/10.5367/te.2012.0113>
- Piñeiro, C., de Llano, P. & Rodríguez, M. (2013). A parsimonious model to forecast financial distress, based on audit evidence. *Contaduría y Administración*, 58(4), 151-173. [https://doi.org/10.1016/s0186-1042\(13\)71237-3](https://doi.org/10.1016/s0186-1042(13)71237-3)
- Platt, H.D. & Platt, M.B. (2008). Financial distress comparison across three global regions. *Journal of Risk and Financial Management*, 1(1), 129-162. <http://dxdoiorg/103390/jrfm1010129>
- Rafiei, F.M., Manzari, S.M. & Bostanian, S. (2011). Financial health prediction models using artificial neural networks, genetic algorithm and multivariate discriminant analysis: Iranian evidence. *Expert Systems with Application*, 38, 10210-10217. <https://doi.org/10.1016/j.eswa.2011.02.082>
- Ravisankar, P. & Ravi, V. (2010). Financial distress prediction in banks using Group Method of Data Handling neural network, counter propagation neural network and fuzzy ARTMAP. *Knowledge-Based Systems*, 23, 823-831. <https://doi.org/10.1016/j.knosys.2010.05.007>
- Sangjae, L. & Wu, S.C. (2013). A multi-industry bankruptcy prediction model using back propagation neural network and multivariate discriminant analysis. *Expert Systems with Applications*, 40, 2941-2946. <https://doi.org/10.1016/j.eswa.2012.12.009>
- Santomero, A. & Vinso, J. (1977). Estimating the probability of failure for commercial banks and the banking system. *Journal of Banking and Finance*, 1(2), 185-205. [https://doi.org/10.1016/0378-4266\(77\)90006-1](https://doi.org/10.1016/0378-4266(77)90006-1)
- Schwarz, G. (1978). Estimating the dimension of a model. *Annals of Statistics*, 6, 461-464. <http://dxdoiorg/101214/aos/1176344136>
- Shin, K.S., Lee, T.S. & Kim, H.J. (2005). An application of support vector machines in bankruptcy prediction model. *Expert Systems with Applications*, 28, 127-135. <https://doi.org/10.1016/j.eswa.2004.08.009>
- Shuk-Wern, O., Voon Choong, Y. & Khong, R.W.L. (2011). Corporate failure prediction: a study of public listed companies in Malaysia. *Managerial Finance*, 37(6), 553-564. <https://doi.org/10.1108/03074351111134745>
- Spicka, J. (2013). The financial condition of the construction companies before bankruptcy. *European Journal of Business and Management*, 5(23), 160-169. (Disponible en: <https://www.iiste.org/Journals/index.php/EJBM/article/view/7487>). (Consultado: 16/01/2019).
- Stroe, R. & Barbuta-Misu, N. (2010). Predicting the financial performance of the building sector enterprises-Case Study of Galati County (Romania). *The Review of Finance and Banking*, 2(1), 29-39. (Disponible en: <https://core.ac.uk/download/pdf/6354205.pdf>). (Consultado: 16/01/2019).
- Sun, J., Li, H., Chang, P.C. & He, K.Y. (2016). The dynamic financial distress prediction method of EBW-VSTW-SVM. *Enterprise Information Systems*, 10(6), 611-638. <https://doi.org/10.1080/17517575.2014.986214>
- Sun, J., Li, H., Huang, Q.H. & He, K.Y. (2014). Predicting financial distress and corporate failure: A review from the state-of-the-art definitions, modeling, sampling, and featuring approaches. *Knowledge-Based Systems*, 57, 41-56. <https://doi.org/10.1016/j.knosys.2013.12.006>
- Tam, K. (1991). Neural network models and the prediction of bank bankruptcy. *Omega*, 19(5), 429-445. [https://doi.org/10.1016/0305-0483\(91\)90060-7](https://doi.org/10.1016/0305-0483(91)90060-7)
- Tam, K. & Kiang, M. (1992). Managerial applications of neural networks: the case of bank failure prediction. *Management Science*, 38(7), 926-947. <https://doi.org/10.1287/mnsc.38.7.926>
- Tseng, F. & Hu, Y. (2010). Comparing four bankruptcy prediction models: Logit, quadratic, interval logit, neural and fuzzy neural networks. *Expert Systems with Applications*, 37, 1846-1853. <https://doi.org/10.1016/j.eswa.2009.07.081>

- Vavrina, J., Hampel, D. & Janová, J. (2013). New approaches for the financial distress classification in agribusiness. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, 61(4), 1177-1182. <https://doi.org/10.11118/actaun201361041177>
- Visauta, B. (2003). *Análisis Estadístico con SPSS para Windows*, Vol. II. E. McGraw-Hill.
- Wang, B. (2004). *Strategy changes and internet firm survival*. Ph.D. dissertation, University of Minnesota. (Disponible en: <https://dl.acm.org/citation.cfm?id=1037617>). (Consultado: 19/01/2019).
- Wasilewski, M. & Madra, M. (2008). An assessment of the agricultural enterprises' solvency with the usage of the Altman Model. *Acta Oeconomica et informatica*, 2, 50-55. (Disponible en: <http://agris.fao.org/agris-search/search.do?recordID=SK2009100016>). (Consultado: 16/01/2019).
- Wilson R.L. y Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems*, 11, 545-557. [https://doi.org/10.1016/0167-9236\(94\)90024-8](https://doi.org/10.1016/0167-9236(94)90024-8)
- Wu, D., Liang, L. & Yang, Z. (2008). Analysing the financial distress of Chinese public companies using probabilistic neural networks and multivariate discriminate analysis. *Socio-Economic Planning Science*, 42(3), 206-220. <https://doi.org/10.1016/j.seps.2006.11.002>
- Yang, Z.R., Platt, M.B. & Platt, H.D. (1999). Probabilistic neural networks in bankruptcy prediction. *Journal of Business Research*, 44, 67-74. [https://doi.org/10.1016/s0148-2963\(97\)00242-7](https://doi.org/10.1016/s0148-2963(97)00242-7)
- Youn, H. & Gu, Z. (2010). Predicting Korean lodging firm failures: An artificial neural network model along with a logistic regression model. *International Journal of Hospitality Management*, 29, 120-127. <https://doi.org/10.1016/j.ijhm.2009.06.007>
- Zavgren, C. (1985). Assessing the vulnerability to failure of American industrial firms: A logistic analysis. *Journal of Business Finance & Accounting* 12(1), 19-45. <https://doi.org/10.1111/j.1468-5957.1985.tb00077.x>
- Zhang, G., Hu, M.Y., Patuwo, B.E. & Indro, D.C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European Journal of Operational Research*, 116(1), 16-33. [https://doi.org/10.1016/s0377-2217\(98\)00051-4](https://doi.org/10.1016/s0377-2217(98)00051-4)
- Zhang, L., Zhang, L., Teng, W.Y & Yibing, C. (2013). Based on Information Fusion Technique with Data Mining in the Application of Finance Early-Warning. *Procedia Computer Science*, 17, 695-703. <https://doi.org/10.1016/j.procs.2013.05.090>