

PREDICCIÓN DEL RIESGO DE IMPAGO DE EMPRESAS ESPAÑOLAS MEDIANTE UN MODELO LOGIT ROBUSTO

BANKRUPTCY PREDICTION OF SPANISH FIRMS BY MEANS OF A ROBUST LOGIT MODEL

Inmaculada BARTUAL

Universidad Politécnica de Valencia, Facultad de Administración y Dirección de Empresas. Spain.

Email: conbarsa@upvnet.upv.es

Resumen:

El presente estudio aplica un modelo de regresión logit a una amplia base de datos de empresas españolas con el fin de predecir su insolvencia a partir de información económica financiera. La base de datos está equilibrada, en el sentido de que contiene más de un 25% de empresas insolventes. Para comprobar la robustez de la metodología y el impacto de la base de datos empleada en la estimación del modelo, se han realizado 1000 simulaciones en las que se han generado dos grupos aleatorios, uno con el 80% de las empresas de la muestra que se emplea para generar los modelos y otro con las restantes empresas para testear los modelos obtenidos.

Palabras clave: riesgo de crédito, modelos econométricos, simulación

Abstract:

This paper applies a logit regression model on a vast database of Spanish firms to predict their insolvency using accounting information. The database is balanced, in the sense that more than 25% of the companies included are insolvent. In order to contrast the robustness of the methodology, as well as the impact of the selected database on the results obtained by the logit model, 1000 simulations have been undertaken. In each simulation two random groups have been created, one with 80% of the firms and

another group with the remaining companies. The first group has been employed to generate the model, whereas the second group has been used to test the model obtained.

Keywords: credit risk, econometric models, simulation

JEL: G2

1. INTRODUCCIÓN

La contabilidad es un sistema de información cuya finalidad principal es ofrecer la imagen fiel de la empresa y ayudar en la toma de decisiones, tanto de los directivos de la empresa como de los usuarios externos. Precisamente, por ir destinada también a terceras personas ajenas a la empresa, la contabilidad está regulada y debe seguir una normativa, que facilite su correcta interpretación. En un mundo cada vez más globalizado, estas normas contables han pasado de ser normas de carácter nacional a normas internacionales, las NIIF. Este sólo hecho ya pone en evidencia la importancia de la información económico-financiera para diversos actores económicos, a escala nacional e internacional. Y es que son muchos los usos que se le pueden dar a la información disponible en la contabilidad empresarial, desde la valoración de las empresas (García *et al.* 2009), a la elaboración de rankings (García *et al.* 2010; Guijarro, 2014), pasando por modelos de predicción de impago.

La elaboración de modelos de predicción de la insolvencia empresarial es uno de los primeros usos que se dio a la información contable. Efectivamente, el estudio de la probabilidad de impago y la elaboración de ratings cobró una importancia relevante ya en 1909, cuando las agencias de rating comenzaron a analizar la situación de las compañías de ferrocarril norteamericanas. No obstante, el origen de los modelos de predicción de impago se sitúa a finales de la década de 1960. Beaver (1966) demostró a partir del análisis de 30 ratios elaborados con información contable que el valor de algunos de esos ratios variaba de forma significativa entre las empresas sanas y las

empresas con dificultades. Por otro lado, Altman (1968) aplicó el análisis discriminante sobre varios ratios económico-financieros en un contexto multivariante y desarrolló un modelo para predecir la insolvencia empresarial. Aquél trabajo fue el comienzo de un interés que aún perdura por elaborar modelos de impago más precisos aplicando las metodologías más novedosas.

Son muchas las metodologías que se han utilizado para obtener modelos que permitan predecir el impago empresarial a partir de la información económico financiera aportada por la contabilidad (García *et. al.*, 2013).

Siguiendo a Ravi Kumar y Ravi (2007), las técnicas empleadas para la valoración del riesgo de crédito empresarial se pueden dividir en dos grandes grupos: las estadísticas y las basadas en la inteligencia artificial, siendo las estadísticas las más veteranas. La magnitud de trabajos realizados es enorme, lo que pone de manifiesto la importancia de poder predecir el impago de las empresas y el interés que despierta esta problemática en los ámbitos académicos y profesionales. Sin ánimo de ser exhaustivos podemos citar las siguientes técnicas: Dentro de las técnicas estadísticas encontramos el análisis discriminante (Yim y Mitchell, 2004; Bandyopadhyay, 2006); el análisis factorial, el modelo probit (Ginoglou y Agorastos, 2002; Gray *et al.*, 2006) y la regresión logística (Ohlson, 1980), que es la que se va a aplicar en este trabajo y sobre la que volveremos más adelante. Dentro de las técnicas de inteligencia artificial, tenemos las redes neuronales (Sen y Stivason, 2004-, Neves y Vieira, 2006; Ravi y Pramodh, 2008), árboles de decisión (Lin y McClean, 2001; Korol, 2013), rough sets (Tay y Shen, 2002; McKee, 2003), análisis envolvente de datos (Cielen *et al.*, 2004), máquinas de vector soporte (Ding *et al.*, 2008; Kim y Sohn, 2010) y algoritmos genéticos (McKee y Lensberg, 2002; Pendharkar y Rodger, 2004; Etemadi *et al.*, 2009), por mencionar algunas de las más comunes.

A pesar de la aparición de numerosas metodologías alternativas, el modelo logit sigue gozando de amplia difusión, tanto en el ámbito profesional, donde es el más utilizado, como en el académico. Efectivamente, las principales agencias de rating utilizan modelos logit para realizar sus clasificaciones. Por otro lado, son numerosos los estudios académicos recientes que utilizan el modelo logit para predecir el impago de

las empresas (Joo-Ha y Taehong, 2000; Kolari *et al.*, 2002; Lin y Piesse, 2004; Jones y Hensher, 2004; Canbas *et al.*, 2005; Chen y Zhang, 2006; Altman y Sabato, 2007; Pang-Tien *et al.* 2008; Psilalaki *et al.*, 2010; Hernández y Wilson, 2013; Zagdoudi, 2013) o como benchmark para valorar las nuevas metodologías de medición del riesgo de crédito (Min y Jeong, 2009; Kim y Sohn, 2010; Li *et al.*, 2010; Su y Huang, 2010; Chen, 2011; Li *et al.*, 2011; Chaudhuri, 2013). Uno de los principales problemas al que se enfrentan los investigadores cuando se aplica el modelo logit es el disponer de una muestra lo suficientemente amplia que garantice la robustez del modelo y la precisión de las predicciones (Bartual *et al.*, 2012).

El objetivo del presente trabajo es obtener un modelo de predicción del impago empresarial para las empresas españolas utilizando un modelo logit robusto. Se trata de resolver un problema de gran importancia para la economía española, que se halla inmersa en una profunda crisis de naturaleza económica y financiera. No sólo las entidades financieras, sino también los clientes, los proveedores y otros agentes económicos precisan hoy en día de conocer la probabilidad de fracaso de las compañías con las que se relacionan. Para obtener el modelo de predicción se ha construido una base de datos con la información contable del ejercicio 2010 de 2.783 empresas, año en el que los efectos de la incipiente crisis ya se comenzaban a notar en la economía. Se trata de una base de datos muy superior a la que se utilizan en trabajos similares y que permite valorar la robustez del modelo obtenido, algo de gran importancia.

El resto del trabajo se estructura de la siguiente manera. En la siguiente sección se describe la base de datos empleada. La tercera sección describe la selección de las variables explicativas del modelo. La cuarta sección explica someramente la técnica de SVM. La quinta sección presenta el modelo logit, la sexta muestra los resultados obtenidos y el análisis de sensibilidad. Finalmente, las principales conclusiones se recogen en la séptima y última sección.

2. DESCRIPCIÓN DE LA BASE DE DATOS Y VARIABLES EXPLICATIVAS SELECCIONADAS

En esta sección se presenta la base de datos a partir de la cual se realizan todos los análisis. La correcta selección de las empresas a analizar, así como la veracidad de los datos es fundamental para garantizar la obtención de un modelo fiable y robusto. Por otro lado, para realizar los análisis de sensibilidad era necesario contar con un número elevado de empresas. Finalmente, hay que mencionar que otro factor importante es que el número de empresas insolventes de la muestra sea elevado. Efectivamente, si el número de empresas insolventes es muy bajo en las submuestras analizadas, una solución naif, que predijera que todas las empresas son solventes, sería muy difícil de batir por un modelo de predicción. Teniendo en consideración todos estos condicionantes, se recurrió a la base de datos de SABI-Infirma (Sistema de Análisis de Balances Ibéricos), que contiene la información contable de la práctica totalidad de las empresas no financieras de España. Con el fin de garantizar la veracidad de la información contable y mantener una muestra homogénea en cuanto al tamaño de las empresas, se seleccionaron aquellas sociedades con activos totales entre 2 millones de euros y 50 millones de euros en el año 2010. Se seleccionó este año por ser el primero en el que se sintió el efecto de la crisis económica, aumentando el número de impagos empresariales, frente a los años anteriores en los que prácticamente no hubo insolvencias en las empresas españolas del tamaño escogido. De las 2.783 empresas seleccionadas, 736 fueron calificadas como insolventes, es decir el 26,5% de la muestra. Se han definido como empresas insolventes tanto aquellas inmersas en un proceso concursal, como aquellas que presentan quiebra técnica, es decir, con un patrimonio neto negativo. De las 736 empresas definidas como insolventes, 485 lo fueron por su situación legal y 251 por quiebra técnica.

3. SELECCIÓN DE LAS VARIABLES EXPLICATIVAS

Una vez seleccionadas las empresas que participarán en el estudio, el siguiente paso consiste en seleccionar las variables explicativas a usar en el análisis. Se ha considerado un conjunto de magnitudes contables y ratios económico financieros tradicionales en el análisis contable que son habituales en los estudios de riesgo de crédito. Se trata de información obtenida a partir del balance y de la cuenta de pérdidas y ganancias de las empresas y que pertenecen a diversas categorías como la liquidez, la solvencia, la rentabilidad, la cobertura, la estructura económica o el tamaño. Las variables seleccionadas y los ratios calculados son las que aparecen a continuación:

- Activo total
- Activo circulante
- Tesorería
- Fondos propios
- Pasivo circulante
- Ventas
- Coste de las materias primas
- Coste de la mano de obra
- Margen industrial
- Margen financiero
- Beneficios antes de impuestos
- Fondos propios / Activo total
- Tesorería / Pasivo circulante
- Coste de la mano de obra / Ventas
- Margen industrial / Ventas
- Margen industrial / Activo total

La selección de las variables explicativas se ha realizado siguiendo a Bartual *et al.*, 2012.

3. CONSTRUCCIÓN DEL MODELO LOGIT

Cuando se dispone de una variable dependiente dicotómica, la regresión logística permite construir un modelo que predice a cuál de los dos grupos pertenecerá una observación, usando una o varias variables independientes o explicativas. En el caso que nos ocupa, las variables explicativas son los ratios y las magnitudes contables mencionadas, es decir, variables cuantitativas. En otras palabras, mediante el uso del modelo logit se crea una combinación lineal de las variables independientes que reflejan la situación de la empresa a partir de la información contable que permite estimar la probabilidad de que una empresa pertenezca al grupo de empresas solventes o al grupo de empresas insolventes. Así, si la variable dependiente toma el valor de 0, la empresa se asignará al grupo de empresas solventes. Si el valor es 1, se entiende que la empresa pertenece al grupo de las insolventes. Cada empresa sólo puede pertenecer a un grupo. El modelo calcula la probabilidad “p” de que la empresa analizada pertenezca al grupo de las empresas insolventes mediante la siguiente expresión:

$$p = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k)}} \quad [1]$$

Con el fin de identificar el modelo más significativo y robusto, se ha empleado el método stepwise y se ha optimizado mediante el índice de Akaike (AIC). El modelo obtenido se muestra en la tabla 3.1.

Tabla 3.1. Resultado de la regresión logística stepwise

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	3.837e-01	8.698e-02	4.411	1.03e-05 ***
Activo corriente	-1.842e-04	5.047e-05	-3.649	0.000263 ***
Fondos propios	1.577e-04	5.179e-05	3.046	0.002320 **
Pasivo corriente	1.764e-04	4.920e-05	3.585	0.000337 ***
Resultado financiero	1.648e-03	4.108e-04	4.011	6.06e-05 ***
Beneficio antes de impuestos	8.911e-04	1.832e-04	4.864	1.15e-06 ***
Fondos propios / Activo total	5.281e+00	3.222e-01	16.391	< 2e-16 ***
Tesorería / Pasivo corriente	8.275e-01	2.184e-01	3.790	0.000151 ***
Margen industrial / Activo total	5.910e+00	5.226e-01	11.309	< 2e-16 ***
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1				
AIC: 1650.7				
Número de iteraciones: 9				

El proceso ha convergido después de nueve iteraciones y las siguientes variables explicativas tienen unos coeficientes significativos con un nivel de confianza del 99%:

- Activo circulante
- Fondos propios
- Pasivo circulante
- Margen financiero
- Beneficios antes de impuestos
- Fondos propios / Activo total
- Tesorería / Pasivo corriente
- Margen industrial / Activo total

El valor del AIC de Akaike es 1.650,7.

Simplemente con observar el signo de los coeficientes ya se pueden extraer conclusiones interesantes. El coeficiente con el mayor z value es el del ratio Fondos propios / Activo total, y tiene signo positivo. Esto se debe a la importancia de tener un

valor elevado de recursos propios en comparación con los pasivos. Es decir, pone de relieve una obviedad, cual es que a menor apalancamiento, menor es la probabilidad de entrar en bancarrota, *ceteris paribus*. El segundo valor más elevado del z value corresponde al coeficiente del ratio Margen industrial / Activo total, y también tiene signo positivo. Este resultado incide en la necesidad de tener un beneficio elevado en relación al tamaño de la empresa para garantizar su supervivencia. El ratio Tesorería / Pasivo corriente, con su signo positivo, muestra que, para no entrar en una situación de impago, las empresas deben tener suficiente liquidez como para hacer frente a sus deudas a corto plazo. En caso de no tener liquidez suficiente, la empresa tendrá problemas con los pagos. En cuanto al resto de variables, sus coeficientes están en línea con lo expuesto hasta ahora, así como su significado económico.

Al aplicar el modelo obtenido a la base de datos completa, los resultados que se obtienen son los que se muestran en la tabla 3.2. De las 738 empresas que han entrado en impago, el modelo predice correctamente esta situación para el 77,6% de ellas. El 22,4% restante se asigna, de forma incorrecta, al grupo de empresas solventes. En el caso de las empresas solventes, el 91,9% se identifican como tales, siendo el porcentaje de empresas definidas erróneamente como insolventes el 8,1%. En términos globales, el modelo asigna correctamente al 88,1% de las empresas en el grupo correspondiente (solventes vs. Insolventes). Este resultado es a todas luces mejor que el que se obtendría mediante un modelo naïve que predijera que todas las empresas son solventes, pues este modelo asignaría correctamente al 73,5% de las empresas. Por lo tanto, podemos considerar que el comportamiento del modelo logit es aceptable.

Tabla 3.2. Predicción del estado de solvencia o insolvencia al aplicar el modelo logit

Solvencia observada	Predicción de la solvencia		
	0	1	Total Fila
0	573	165	738
	727.386	262.499	
	0.776	0.224	0.265
	0.776	0.081	
	0.206	0.059	
1	165	1880	2045
	262.499	94.731	
	0.081	0.919	0.735
	0.224	0.919	
	0.059	0.676	
Total Columna	738	2045	2783
	0.265	0.735	

4. RESULTADOS Y ANÁLISIS DE SENSIBILIDAD

Los resultados obtenidos en el apartado anterior muestran claramente la naturaleza de las variables a incluir en un modelo de regresión logística de predicción de insolvencia en España. Por otro lado, también queda patente el éxito obtenido por el modelo logit a la hora de discriminar las empresas en solventes e insolventes, siendo la tasa media de acierto el 88,1%. No obstante, este análisis es incompleto, puesto que el resultado podría estar condicionado por las empresas que configuran la muestra, ya que las mismas empresas que se han utilizado para estimar el modelo se han empleado después para realizar la predicción.


Para solventar este problema, la muestra total se ha dividido en dos submuestras, conteniendo la primera submuestra el 80% de las empresas y la segunda el 20% restante. La primera submuestra, la más grande, se ha empleado para obtener el

modelo de predicción. La segunda muestra se ha empleado para comprobar la bondad del modelo obtenido. Además, este proceso se ha repetido en 1.000 ocasiones, seleccionándose así, en mil ocasiones y de forma aleatoria, las empresas que pertenecen a una submuestra o a otra. De esta manera, el modelo que se obtiene con cada simulación, así como los resultados obtenidos y la tasa de acierto, es ligeramente diferente.

La figura 4.1. muestra el histograma de la variable “tasa de acierto”. La tasa de acierto indica el porcentaje de empresas que se asignan correctamente a su grupo, es decir, el porcentaje de empresas para las que su estado de solvencia o insolvencia se predice de forma correcta. Se observa cómo la distribución de la variable es similar a una distribución normal. El valor medio de la tasa de acierto es del 87,96% y la desviación estándar es 0,0148. Por lo tanto, la tasa de acierto obtenida en la sección 3, del 88,1%, se puede considerar dentro del rango esperado con un nivel de confianza del 99%.

En definitiva, una vez realizado el proceso de simulación, resulta evidente que el modelo logit es un método robusto para predecir el impago de las empresas manufactureras españolas a partir del empleo de las variables contables habituales.

Figura 4.1.Histograma de la variable “tasa de acierto”



5. CONCLUSIONES

El presente artículo presenta la aplicación de un modelo estadístico multivariante, el modelo logit, a la predicción del riesgo de impago de las empresas manufactureras españolas. Como variables independientes del modelo se han seleccionado magnitudes y ratios contables de uso habitual por analistas financieros. También cabe destacar la amplitud de la base de datos, consistente en más de 2.500 empresas manufactureras españolas.

En la muestra seleccionada, el 73,5% de las empresas son solventes, mientras que el 26,5% restante ha incurrido en impago. Al aplicar el modelo logit sobre la muestra total se obtiene un ratio de acierto de 88,1%, superior al que obtendría un modelo simple que asignara a todas las empresas al grupo de empresas solventes.

Con la finalidad de mejorar el conocimiento sobre la capacidad predictiva del modelo, se ha procedido a realizar 1000 simulaciones en las que el 80% de las empresas, de forma aleatoria, se asignan al subgrupo para la estimación del modelo y el 20% restante se emplea para testear la bondad del modelo obtenido.

Los resultados obtenidos muestran que el modelo logit es una metodología robusta y apropiada para predecir la insolvencia empresarial y, por lo tanto, es un modelo que puede ser utilizado como benchmark para contrastar otras metodologías más novedosas, si bien hay que resaltar la importancia de realizar una correcta selección de la muestra de empresas para poder obtener resultados fiables.

6. BIBLIOGRAFÍA

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

Altman, E., Sabata, G. (2007) Modelling risk for SMEs –evidence from US market. *Abacus* 43 (3), 332-356.

Bandyopadhyay, A. (2006) Predicting probability of default of Indian corporate bonds – logistic and Z-score model approaches. *The Journal of Risk Finance*, 7 (3), 255-272.

- Bartual, C., García, F., Guijarro, F., Romero-Civera, A. (2012) Probability of default using the logit model: The impact of explanatory variable and data base selection. 2nd International Scientific Conference “Whither our Economies”, 118-124.
- Canbas, S., Cabuk, A., Kilic, S.B. (2005) Prediction of commercial bank failure via multivariate statistical analysis of financial structure: The Turkish case. *European Journal of Operational Research* 166, 528-546.
- Chaudhuri, A. (2013) Bankruptcy prediction using bayesian, hazard, mixed logit and rough Bayesian models: A comparative analysis. *Computer and Information Science*, 6, 103-125.
- Chen, J., Zhang, J. (2006) Financial distress prediction in China. *Review of Pacific Basin Financial Markets and Policies*, 9 (2), 317-336.
- Chen, M.Y. (2011) Predicting corporate financial distress based on integration of decision tree classification and logistic regression. *Expert Systems with Applications*, 38, 11261-11272.
- Chen, W.H., Shi, J.Y. (2006) A study of Taiwan’s issuer credit ranking systems using support vector machines. *Expert Systems with Applications* 30, 427-435.
- Cielen, A., Peeters, L., Vanhoof, K. (2004) Bankruptcy prediction using a data envelopment analysis. *European Journal of Operational research*, 154, 526-532.
- Ding, Y., Song, X, Zeng, Y. (2008) Forecasting financial condition of Chinese listed companies based on support vector machine. *Expert Systems with Applications* 34 (4), 3081-3089.
- Demyanyk, Y., Hasan, I. (2010) Financial crisis and bank failures: review of prediction methods. *Omega* 38, 315-324.
- Etemadi, H., Rostamy, A., Dehkordi, H. (2009) A genetic programming model for bankruptcy prediction: Empirical evidence from Iran. *Expert Systems with Applications*, 36 (2), 3199-3207.
- Galvao, R., Becerra, V., Abou-Seada, M. (2004) Ratio selection for classification models. *Journal of Data Mining and Knowledge Discovery*, 8, 151-170.
- García, F.; Guijarro, F.; Moya, I. (2009). An algorithm for variable selection in firm valuation models. *International Journal of Business Performance and Supply Chain Modelling*, 1, 144-161.

- García, F.; Guijarro, F.; Moya, I. (2010). A goal programming approach to estimating performance weights for ranking firms. *Computers and Operations Research*, 1597-1609.
- García, F.; Guijarro, F.; Giménez, V. (2013). Credit risk management: A multicriteria approach to assess creditworthiness. *Mathematical and Computer Modelling* (57), 2009-2015.
- Ginoglou, D., Agorastos, K. (2002) Predicting corporate failure of problematic firms in Greece with LPM, logit, probit and discriminant analysis models. *Journal of Financial Management and Analysis*, 15 (1), 1-15.
- Guijarro, F. (2014). Multicriteria ranking of the Spanish digital press. *Finance, Markets and Valuation*, 1 (1), 1-15.
- Hernandez Tinoco, M., Wilson, N. (2013) Financial distress and bankruptcy prediction among listed companies using accounting, market and macroeconomic variables. *International Review of Financial Analysis*.
- Huang, Z., Chena, H., Hsua, C.J. (2004) Credit rating analysis with support vector machines and neuronal networks: a market comparative study. *Decision Support Systems* 37, 543-548.
- Jones, S., Hensher, D.A. (2004) Predicting firm financial distress: A mixed logit model. *Accounting Review* 79 (4), 1011-1038.
- Joo-Ha, N. Taehong, J. (2000) Bankruptcy prediction- evidence from Korea listed companies during the IMF crisis. *Journal of International Financial Management and Accounting*, 11 (3), 178-197.
- Kim, H.S., Sohn, S.Y. (2010) Support vector machines for default prediction of SMEs based on technology credit. *European Journal of Operational Research*, 201, 838-846.
- Kolari, J., Glennon, D., Shin, H., Caputo, M. (2002) Predicting large US commercial bank failures. *Journal of Economics and Business* 54 (32), 318-324.
- Korol, T. (2013) Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.
- Li, H., Adeli, H., Sun, J., Han, J.G. (2011) Hybridizing principles of TOPSIS with case-based reasoning for business failure prediction. *Computers and Operations Research*, 38, 409-419.

- 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, 5895-5904.
- Lin, F., McClean, S. (2001) A data mining approach to the prediction of corporate failure. *Knowledge-Based Systems*, 14, 189-195.
- Lin, L., Piesse, J. (2004) Identification of corporate distress in UK industrials – a conditional probability analysis approach. *Journal of Applied Financial Economics*, 14, 73-82.
- McKee, T.E. (2003) Rough sets bankruptcy prediction models versus auditor signaling rates. *Journal of Forecasting*, 22, 569-589.
- McKee, T.E., Lensberg, T. (2002) Genetic programming and rough sets: A hybrid approach to bankruptcy classification. *European Journal of Operational Research*, 138, 436-451.
- Min, J.H., Jeong, C. (2009) A binary classification method for bankruptcy prediction. *Expert Systems with Applications*, 36, 5256-5263.
- Neves, J., Vieira, A. (2006) Improving bankruptcy prediction with hidden layer learning vector quantization. *The European Accounting Review*, 15 (2), 253-271.
- Ohlson, J.A. (1980) Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 109-131.
- Pang-Tien, L., Chin-Wen, L., Hui-Fun, Y. (2008) Financial early-warning models on cross-holding groups. *Journal of Industrial Management and Data Systems*, 108 (8), 1060-1080.
- Pendharkar, P.C., Rodger, J.A. (2004) An empirical study of impact of crossover operators on the performance of non-binary genetic algorithm based neuronal approaches for classification. *Computer and Operations Research*, 31, 481-498.
- Psillaki, M., Tsolas, I.E., Margaritis, D. (2010) Evaluation of credit risk based on firm performance. *European Journal of Operational Research*, 201, 873-881.
- Ravi, V., Pramodh, C. (2008) Threshold accepting trained principal component neuronal network and feature subset selection: Application to bankruptcy prediction in banks. *Applied Soft Computing*, 8 (4), 1539-1548.

- Ravi Kumar, P., Ravi, V. (2007) Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research*, 180, 1-28.
- Sen, T., Stivason, Ch. (2004) Improving prediction of neuronal networks- A study of two financial prediction tasks. *Journal of Applied Mathematics and Decision Sciences*, 8 (4), 219-233.
- Shin, K.S., Lee, Y.J. (2002) A genetic algorithm application in bankruptcy prediction modeling. *Expert Systems with Applications*, 23 (3), 321-328.
- Su, E.D., Huang, S.M. (2010) Comparing firm failure predictions between logit, KMV, and ZPP models-. Evidence from Taiwan's electronics industry. *Asia-Pacific Financial Markets*, 17, 209-239.
- Tay, F.E.H., Shen, L. (2002) Economic and financial prediction using rough set model. *European Journal of Operational Research*, 141 641-659.
- Yim, J. Mitchell, H. (2004) A comparison of Japanese failure models – hybrid neuronal networks, logit models and discriminant analysis. *International journal of Asian Management*, 3, 103-120.
- Wu, C.H., Tzeng, G.H., Goo, Y.J., Fang, W.C. (2007) A real-valued genetic algorithm to optimize the parameters of support vector machines for predicting bankruptcy. *Expert Systems with Applications*, 32 (2), 397-408.
- Zaghdoudi, T. (2013) Bank failure prediction with logistic regression. *International Journal of Economics and Financial Issues*, 3 (2), 537-543.