



Una revisión sistemática de la literatura en torno a la quiebra empresarial para el período 2012-2017

A systematic review of the literature on corporate bankruptcy for the period 2012-2017

TÁMARA, Armando L. [1](#); VILLEGAS, Gladis C. [2](#); DE ANDRÉS, Javier [3](#)

Recibido: 01/10/2018 • Aprobado: 21/01/2019 • Publicado 04/02/2019

Contenido

- [1. Introducción](#)
- [2. Metodología](#)
- [3. Resultados](#)
- [4. Conclusiones](#)

[Referencias bibliográficas](#)

RESUMEN:

Este trabajo desarrolla un marco general estableciendo los lineamientos mínimos requeridos para el estudio de la quiebra empresarial, enmarcado en cinco elementos como son la definición, muestra, costo del error, técnicas estadísticas y variables de los modelos de predicción. Se analizan 143 artículos publicados en ISI Web of Science y SCOPUS para el período 2012-2017, encontrando que las técnicas más utilizadas son las redes neuronales, modelos de vector de apoyo y árboles de decisión, mientras que, los modelos discriminantes y logísticos son utilizados como benchmark.

Palabras clave: Quiebra empresarial, modelos de predicción, indicadores financieros

ABSTRACT:

This paper develops a general framework establishing the minimum guidelines required for the study of corporate bankruptcy, framed in five elements such as the definition, sample, cost of error, statistical techniques and variables of prediction models. We analyze 143 articles published in ISI Web of Science and SCOPUS for the period 2012-2017, finding that the most used techniques are neural networks, support vector models and decision trees, while discriminant and logistic models are used as a benchmark.

Keywords: Business bankruptcy, prediction models, financial indicators

1. Introducción

Los primeros estudios comienzan con Fitzpatrick (1932) utilizando el análisis financiero para tratar de entender el fenómeno de la quiebra empresarial, le siguieron los estudios de Beaver (1966) y Altman (1968) apoyados en las técnicas de análisis univariado y multivariado, estos trabajos se caracterizaron por realizar modelos de pronóstico de quiebra empresarial. Con el paso del tiempo los estudios sobre la quiebra empresarial se han

multiplicado, en parte, por el desarrollo que ha tenido la estadística y en especial la implementación de algoritmos, permitiendo el uso y la aplicación de técnicas más avanzadas en la búsqueda del mejor modelo que permita predecir la quiebra empresarial.

Este trabajo presenta una revisión basada en artículos empíricos publicados en las bases de datos ISI Web of Science y SCOPUS para el período 2012-2017, el objetivo es desarrollar un marco general que permita establecer los lineamientos mínimos requeridos para cualquier estudio referente a la quiebra empresarial, lo anterior, enmarcado en cinco elementos fundamentales como son la definición, muestra, costo del error, técnica estadística y variables integrantes del modelo.

Dado lo anterior, se continua con la sección que describe la metodología de revisión sistemática implementada en la investigación, posteriormente, se muestra la clasificación de los artículos teniendo en cuenta si son revisiones de literatura o estudios empíricos, luego, se analiza la evolución del término "quiebra" empresarial, para pasar a consolidar los estudios según la técnica estadística aplicada, establecer cuáles han sido las variables más utilizadas en los modelos de predicción en este período y, finalmente, presentar las conclusiones.

2. Metodología

Con el objeto de garantizar que los artículos utilizados en la investigación pertenezcan a revistas de alto impacto, se utilizaron las bases de datos ISI Web of Science y Scopus, adicionalmente, se toma como referencia la estructura de búsqueda en cada una de estas bases ingresando las palabras "*business bankruptcy, failure or financial distress*" y, se delimitó la búsqueda seleccionando la opción "*articles*" simultáneamente con la opción "*Business Finance*", posteriormente, los investigadores basados en su experiencia realizaron una selección y refinamiento por año de los trabajos encontrados, conformando una base de datos de 143 artículos.

Para llegar a la selección definitiva de los artículos base de esta investigación, en primer lugar, se procedió a seleccionar aquellos que pertenecían a revisiones de literatura identificando 16 artículos a lo largo del período 1932-2017, Zavgren (1983), Altman (1984), Barnes (1987), Keasey y Watson (1991), Dimitras, Zopounidis, y Zanakis (1996), Grice y Dugan (2001), Balcaen y Ooghe (2006), Perez (2006), Ravi y Ravi (2007), Bahrammirzaee (2010), Tascon y Castaño (2012), De Andres, Lorca, Sanchez, y Javier (2012), Sun, Li, Huang, y He (2014), Appiah, Chizema, y Arthur (2015), Alaka et al.(2016), Alaka et al. (2018). Posteriormente, dadas las revisiones actuales se procedió a establecer que el período de estudio sería 2012-2017, basados en que las últimas seis revisiones dejaban de lado un importante número de artículos publicados en estas dos bases de datos. Cabe anotar que la última fecha para la selección de los artículos fue enero del 2018, a lo cual, ya algunas revistas tenían publicado su primer ejemplar de ese año, dando la oportunidad para referenciar dos artículos del 2018.

En segundo lugar, se procedió a seleccionar aquellos artículos que hacían referencia a la pronosticación de la quiebra empresarial y en cuyos trabajos utilizaban métodos estadísticos de pronosticación, así, se logró encontrar 127 artículos cuyo enfoque era la pronosticación de la quiebra. En términos generales, la cantidad promedio de artículos publicados por año fue de 16 artículos en el período 2012-2015, sin embargo, para el 2016 y 2017 el número de artículos subió a 27 y 34 respectivamente (2 de ellos corresponden al 2018).

3. Resultados

3.1. Evolución del término "quiebra" empresarial

Para analizar el concepto de quiebra empresarial, primero se tiene que partir del término fracaso, el cual se deriva de frangere que en latín significa "romper, estrellarse". El primero en aplicar el término "fracaso" a una condición empresarial fue Beaver (1966), por lo que, se considera referencia obligada para cualquier investigación que se haga sobre quiebra empresarial, dicho estudio empleó la palabra "fracaso" para lo que hoy se denomina

“quiebra” empresarial. De los 127 artículos revisados en esta investigación, solo cuatro utilizaron el término “fracaso”, Rodríguez, Pineiro y De Llano (2014), Wang, Gopal, Shankar y Pancras (2015), Blanco, Irinmia y Vázquez (2016), De Llano, Piñeiro y Rodríguez (2016) y Rodríguez, Maté y López (2017).

En cuanto al término “quiebra”, es el trabajo de Altman (1968) donde inicia la temática referente a la quiebra empresarial definiendo por primera vez en la literatura el término “quiebra”, dándole un significado completamente jurídico y legal. En esta revisión solo seis artículos trabajan con definiciones propias de quiebra y 105 utilizan la definición legal de quiebra para cada uno de los países referentes del fenómeno. Los investigadores concluyen que no existe una definición convergente del término, basados en que la mayoría de trabajos utilizan el término “quiebra” fundamentados en el marco jurídico establecido por cada país, adicionalmente, utilizan bases de datos de empresas catalogadas legalmente en quiebra. Por lo tanto, es importante señalar la diferencia entorno a la exactitud de la quiebra, dado que, en algunos casos se hace referencia a la “quiebra” definitiva y en otros a la “quiebra” temporal u ocasional, estos mismos hallazgos se mencionan en el trabajo de Tascon y Castaño (2012).

3.2. Técnica empleada en la modelación de la “quiebra”

Un primer análisis de los 127 artículos empíricos arrojó que los modelos logísticos y discriminante son las metodologías más usadas en el período de estudio, sin embargo, un análisis más profundo indicó que estas dos metodologías realmente son tomadas como un benchmark para medir el incremento en la eficiencia clasificadora de los modelos propuestos en los nuevos estudios, así, el segundo análisis determina que las metodologías más utilizadas en la actualidad son las redes neuronales, máquinas de vector de apoyo y árboles de decisión. Por lo tanto, se detectó un cambio en la implementación de técnicas estadísticas en la modelación y pronóstico de la quiebra empresarial, a diferencia de lo encontrado en el trabajo de Tascon y Castaño (2012).

Cabe anotar que los estudios realizados en los últimos años muestran un desarrollo complementario en cada una de estas metodologías, donde se proponen y desarrollan modelos híbridos, todo ello dirigido a realizar una comparación entre las diferentes metodologías tradicionales y no tradicionales, con el objeto de poder hacer una selección del modelo con mayor efectividad en la pronóstico de la quiebra empresarial.

En esta investigación no se describen las técnicas estadísticas utilizadas en cada uno de los 127 artículos seleccionados, y más bien remitimos al trabajo de Tascon y Castaño (2012) para consultar sobre las técnicas tradicionales como el análisis discriminante y la regresión logística, adicionalmente, se explican los modelos de inteligencia artificial y el análisis envolvente de datos (DEA). De Andres et al. (2012) presentan una explicación de los sistemas híbridos, identificando cuatro tipos: algoritmos híbridos, clasificadores de conjunto, selectores de funciones y, agrupación y dispositivos clasificatorios. Sun et al. (2014) segmenta los métodos estadísticos en clasificador único simples y clasificador único de inteligencia artificial, dando una explicación de cada uno de ellos. Appiah et al. (2015) describen de manera resumida las técnicas tradicionales (discriminante y logit) y las técnicas de inteligencia artificial, haciendo énfasis en las limitaciones de cada una de ellas. Finalmente, Alaka et al. (2018) en su trabajo hace una descripción somera de las técnicas de análisis discriminante múltiple y regresión logística, además, las complementa con la explicación de seis técnicas de inteligencia artificial: red neuronal artificial, máquinas de vectores de soporte, conjuntos aproximados, razonamiento basado en casos, árbol de decisión y algoritmo genético.

La tabla 1 muestra por orden cronológico y alfabético de los autores los 127 artículos estudiados y analizados, al ser comparados en cuanto al período de estudio, no se muestra una tendencia ni aspecto común entre estos, igual pasa con la población de estudio, cada uno presenta una población acorde a la información ofrecida en el mercado. La mayoría de estudios presentan aciertos iguales o superiores al 70% en cuanto al acierto total de los diferentes modelos referente a la predicción de la quiebra empresarial, sin embargo, hay que anotar que se encontraron algunos estudios que carecen de esta información.

Gavurová, Janke, Packová y Prídavok (2017)	Eslovenia	2009-2014	D, AD	1.182	No	85,00	Si
Georgescu (2017)	Rumania	ND	AG	130	No	96,40	ROC
Jabeur (2017)	Francia	2006-2008	ML	800	Si	93,25	Si
Jones (2017)	EU	1987-2013	ML, MEL	1.115	No	92,70	ROC
Jones, Johnstone y Wilson (2017)	EU	2000-2013	ML, D, RN, MVA, MEL	30.129	No	82,00	ROC
Karas y Reznakova (2017)	Republica Checa	2011-2014	AD	1.540	No	91,53	Si/ROC
Klepac y Hampel (2017)	EU	2009-2013	ML, MVA, AD, MEL	250	No	80,30	Si/ROC
Mselmi, Lahiani y Hamza (2017)	Francia	2010-2013	ML, RN, MVA	212	Si	94,28	Si/ROC
Oz y Yelkenci (2017)	EU, Reino Unido, Japón, Canadá, Australia, Alemania, Francia, Nueva Zelandia	2000-2014	ML, RN	2.500	No	81,00	Si
Rodríguez et al. (2017)	España	2011-2013	EJC	2.796	No	ND	ND
Sun, Fujita, Chen y Li (2017)	China	2000-2012	MVA	932	Si	90,00	ND
Tobback, Moeyersoms, Stankova, Martens y Bellotti (2017)	Bélgica, Reino Unido	2011-2014	MEL	200	No	84,71	ROC
Traczynski (2017)	EU	1987-2009	MB	51.189	No	ND	ROC
Volkov, Benoit y Van den Poel (2017)	Bélgica, Luxemburgo	2007-2015	ML, D, MVA	12.848	No	ND	ROC
Wang y Wu (2017)	China	2012-2014	MVA, AG, MEL	216	Si	85,00	Si
Wang et al. (2017)	Japón	1995-2009	AG	240	No	90,18	Si/ROC
Zelenkov, Fedorova y Chekrizov (2017)	Rusia	ND	D, RN, AG, MEL	912	Si	93,40	ND

Zhao et al. (2017)	Polonia	1997-2001	ML, MVA, AG, VC	240	No	82,50	Si/ROC
Zhou y Lai (2017)	EU, Japón	1981-2009	ML, RN, AD, AG	286	Si	83,30	ROC
Abdullah (2016)	Malasia	2001-2012	ML, D	158	Si	88,00	ROC
Abdullah, Ma'aji y Khaw (2016)	Malasia	2000-2012	ML	172	Si	93,60	Si
Achim, Borlea y Gaban (2016)	Rumania	2002-2013	ML	37	No	83,33	Si
Agrawal y Maheshwari (2016)	India	2000-2012	ML, D,	270	Si	ND	Si
Alaminos, del Castillo y Fernandez (2016)	Japón, Cora, Singapur, Taiwán, Europa, Reino Unido, Bermuda, Canadá, EU	1990-2013	ML	2.592	Si	82,14	ND
Altman, Iwanicz, Laitinen y Suvas (2016)	Finlandia	2004-2013	D	59.099	No	80,00	ROC
Blanco et al. (2016)	Europa	1999-2008	ML, AD	39.710	Si	85,00	Si/ROC
Bodle, Cybinski y Monem (2016)	Australia	1991-2004	D	96	Si	76,30	Si
Brozyna, Mentel y Pisula (2016)	Eslovaquia	ND	ML, D, AD	180	Si	86,00	Si/ROC
Charalambakis y Garrett (2016)	Reino Unido, India	1980-2011	D	2.277	No	89,00	ND
Chung, Chen, Lin, Lin y Lin (2016)	Taiwán	1998-2014	D, RN, AG	360	No	97,50	Si
Cleofas, Sánchez, García y Marqués (2016)	Australia, Alemania, Japón, Irán, España, EU	2007	ML, RN, MVA	8.576	No	ND	Si
Cultrera y Bredart (2016)	Bélgica	2002-2012	ML	7.152	Si	79,23	Si
De Llano et al. (2016)	España	1899-2009	ML, D, RN, AD	120	Si	90,00	Si

García, Sánchez y Tomaseti (2016)	España	2005-2013	DM	ND	No	90,00	ND
Kim, Jo y Shin (2016)	Corea	2002-2007	RN	22.500	No	80,00	ROC
Laitinen y Suvas (2016)	Europa	2007-2010	ML	1.278.662	No	75,30	Si/ROC
Liang, Lu, Tsai y Shih (2016)	Taiwán	1999-2009	ML, D, AG	478	Si	83,64	Si/ROC
Manzaneque, Priego, y Merino (2016)	España	2007-2012	ML	308	Si	82,00	Si
Nouri y Soltani (2016)	Chipre	2007-2012	ML	53	No	82,10	Si
Pal, Kupka, Aneja y Militky (2016)	EU	2012-2013	MVA	198	No	96,00	ROC
Salehi, Shiri y Pasikhani (2016)	Irán	2011-2014	RN, MVA	117	No	97,62	Si
Sartori, Mazzucchelli y Gregorio (2016)	Italia	2012-2013	RBC	1.160	No	86,00	Si
Singh y Mishra (2016)	India	2006-2014	ML, D,	208	Si	87,17	ROC
Wu, Wang y Shi (2016)	China	ND	MVA	166	No	82,60	ND
Zhang y Hu (2016)	China	2006-2014	ML, D, RN, MVA, AD, AG, MDD	406	Si	80,00	ND
Zięba, Tomczak y Tomczak (2016)	Polonia	2000-2012	ML, D, RN, MVA, AD, AG	10.700	No	ND	ROC
Amendola, Restaino y Sensini (2015)	Italia	2004-2009	ML	1.462	No	88,19	Si/ROC
Babu (2015)	India	2000-2014	D	21	No	79,40	ND
Blanco, Irimia, Oliver y Wilson (2015)	Reino Unido	1999-2008	D	39.710	No	69,00	Si/ROC
Burganova y Salahieva (2015)	Tartaristán	2010-2013	D	52	No	90,40	ND

Charalambakis (2015)	Grecia	2002-2010	ML, RN	303	No	82,70	Si
Elshahat, Elshahat y Rao (2015)	Mundial	2004-2006	ML, RN	58	No	80,00	Si
Kim, Kang y Kim (2015)	Corea	2001-2005	D	10.000	Si	66,97	Si/ROC
López y Sanz (2015)	EU	2002-2012	RN, MVA, AD	ND	No	ND	ROC
Lu, Yang y Huang (2015)	EU	1990-2011	RN	190	No	94,23	ROC
Mousavi, Ouenniche y Xu (2015)	Reino Unido	1989-2006	AG	12.452	No	82,00	ROC
Obermann y Waack (2015)	Alemania, Australia	ND	D	5.162	No	ND	ND
Piatti, Cincinelli y Castellani (2015)	Italia	2007-2009	ML, MEL	8.145	No	88,20	Si
Ramage, Pongsatatt y Lawrenc (2015)	Tailandia	ND	ML, D	120	Si	81,94	ND
Reznakova y Karas (2015)	Republica Checa, Hungría, Polonia, Eslovaquia	2007-2012	AS	5.977	No	72,00	ND
Salimi (2015)	Mundial	2000-2005	ML, D, AS, DEA	89	No	ND	ND
Sinarti y Sembiring (2015)	Indonesia	2009	ML	11	No	ND	ND
Tian, Yu y Guo (2015)	Mundial	1980-2009	AS	1.588.685	No	ND	ROC
Wang et al. (2015)	EU	2012-2013	ML, MB0	686	No	95,00	Si
Abellán y Mantas (2014)	Australia, Alemania, Japón	ND	EE	2.380	Si	73,20	ROC
Acosta y Fernández (2014)	España	2000-2004	D, RN, AD, AG	347	No	92,00	ROC
Antonowicz (2014)	Polonia	2012-2013	RN, MVA, AD, MEL	865	No	85,65	ND

Du Jardin (2014)	Francia	2003-2012	ML, D	16.880	Si	94,12	Si
Gordini (2014)	Italia	2010-2012	ML, AS, MB	3.584	No	85,00	Si
Heo y Yang (2014)	Corea	2008-2012	ML, D, RN	29.862	No	96,90	ND
Komera (2014)	India	1992-2009	RN, MVA, TC	84.152	No	87,82	ND
Levy, Kanat, Kunin, Tooshknov y Tzruya (2014)	Israel	2007-2011	ML, D, RN, AS, MAO	62	Si	81,60	Si
Rodriguez et al. (2014)	España	1990-1997	AD	120	Si	81,00	Si
Serrano, Fuertes, Gutiérrez y Cuellar (2014)	EU	2003-2009	ML, RN, AD, MEL	9.966	No	86,79	ND
Trabelsi, He, He y Kusy (2014)	EU	1980-2010	ML, AS, MB	917	No	86,30	Si
(Tsai, Hsu y Yen (2014)	Australia, Alemania, Japón, Taiwán	ND	D	440	No	90,30	Si
Virág y Nyitrai (2014)	Hungría	ND	AS	156	Si	85,00	Si
Wang, Yang y Ma (2014)	Europa	1997-2001	LQ	372	Si	ND	Si
Wang y Shiu (2014)	Taiwán	2000-2011	ML	228	No	85,00	ND
Ahmadpour, Divsalar, Javid y Ebrahimian (2013)	Irán	1999-2006	D, MVA	136	Si	97,86	ROC
Caro, Díaz y Porporato (2013)	Argentina	1993-2000	PD	47	No	99,00	Si
Chen, Ribeiro, Vieira y Chen (2013)	Francia	2003-2006	D, RN, AD	110723	No	96,66	Si
De Albornoz y Giner (2013)	España	2005-2010	ML, RN	368.647	No	90,00	Si
Fedorova, Gilenko y Dovzhenko (2013)	Rusia	2007-2011	ML, D, AD	3.505	No	88,80	Si

García y Mures (2013)	España	2004-2006	MA	41.584	Si	ND	Si
Horta y Camanho (2013)	Portugal	2008-2010	D, RN	15.470	No	96,40	ROC
Kim (2013)	EU	1978-2007	ML, MVA	74.737	No	96,50	Si
Korol (2013)	Latinoamérica, Europa Central	1996-2009	ML, D, RN, AD	185	No	88,80	Si
Lee y Choi (2013)	Corea	2000-2009	AC	229	No	ND	Si
Mazurencu, Nijkamp y Pele (2013)	Rumania	2002-2008	ML	68.000	No	90,60	ND
Mokhova y Zinecker (2013)	Republica Checa	2006-2010	ML, RN	38.866	No	95,45	ND
Piñeiro, De Llano y Rodríguez (2013)	España	2000-2009	ML, RN, MVA	256	Si	85,00	Si
Platt y Platt (2013)	EU, EUA	2005-2007	ML	295	No	91,00	ND
Pozuelo, Labatut y Veres (2013)	España	2005-2008	ML	1.150	Si	90,69	Si
Serrano y Gutiérrez (2013)	EU	2008-2010	ML, D, RN, MVA, AD, MEL, MB	8.293	Si	100,00	Si
Balcaen, Manigart, Buyze y Ooghe (2012)	Bélgica	1998-2000	RN, MAO, S	6.118	No	99,78	ND
Beaver, Correia y McNichols (2012)	EU	1962-2002	MDD	135.455	No	80,00	ND
Bisogno (2012)	Italia	2000-2007	RN, MVA, AD	143	No	94,80	Si
(Brezigar y Masten (2012)	Eslovenia	1985-2001	D, RN, MVA, AD, RBC	1.184	No	80,00	Si
Bruneau, De Bandt y El Amri (2012)	Francia	1990-2006	AG	259.890	No	80,00	ROC
Buehler, Kaiser y Jaeger (2012)	Suiza	1994-2000	RN, MAO	74.000	No	85,10	ND
Cao (2012)	China	2003-2009	ML	191	No	77,10	Si

Chen (2012)	Taiwán	1998-2008	ML, D, RN, MVA, AD	1.615	Si	86,64	Si
Huang, Tang, Lee y Chang (2012)	Taiwán	2000-2007	ML, AD	150	No	98,90	ND
Kim y Jeong (2012)	Corea	2001-2004	D, MVA	2.542	No	97,80	ND
Kim y Kang (2012)	Corea	2002-2005	VAR	1.200	Si	80,30	ROC
Kwak, Shi y Kou (2012)	Corea	1997-2003	ML	195	No	80,00	Si
Lin, Ansell y Andreeva (2012)	Reino Unido	2006-2009	MVA, AD, AG	429	No	94,44	ROC
(Olson, Denle y Meng (2012)	EU	2005-2009	AS	1.321	No	80,02	Si
Sánchez, De Andrés, Lorca y De Cos (2012)	España	2008	ML, D	63.107	No	88,70	Si
Shetty, Pakkala y Mallikarjunappa (2012)	India	1998-2006	ML	66	No	88,50	ND
Shie, Chen y Liu (2012)	EU	2006-2009	ML, AS	54	No	80,00	Si

ML: Modelo logístico; D: Análisis discriminante; RN: Redes neuronales;
MVA: Modelo de vector de apoyo; ARD: Arboles de decisión; AG: Algoritmo genético;
AS: Análisis de supervivencia; MEL: Modelo de ensamble Learning; MAO: Mapa de autoorganización;
MB: Modelo bayesiano; VC: Vecino más cercano; DEA: Análisis envolvente de datos;
MDD: Modelo distancia direccional; MM: Modelo Merton; RBC: Razonamiento basado en casos;
S: Spline; AC: Análisis de correlación; LQ: Coeficiente de Location Quotient; DM: Data mining;
EE: Ecuaciones estructurales; JC: Estadístico Join-count; VAR: Modelo Var; PD: Panel data;
TC: Teoría de conjunto; ROC: Receiver operating characteristic curve; ND: No disponible.

Un aporte de este trabajo es debatir con respecto al tipo de muestra utilizada en los estudios de modelación de la quiebra empresarial, en torno, a si son o no balanceadas, así, de los 127 artículos se encontraron 36 trabajos con muestras balanceadas, 89 con muestras no balanceadas y, solo 2 trabajaron ambas opciones. Los investigadores plantean la necesidad de trabajar con muestra balanceada por dos razones, evitar el sesgo hacia la proporción mayor y no tener problemas en la clasificación de la clase minoritaria, dado que lo que se busca es minimizar la tasa de error global, sin embargo, como se mencionó anteriormente dicha tasa en general superan el 70% en los artículos analizados.

Para los estudios de quiebra empresarial, el costo de error cumple un papel fundamental en torno a las clasificaciones de precisión, lo que implica que cada técnica estadística implementada para modelar la pronosticación requiere ser evaluada en torno a este. Como lo menciona Lado y Vivel (2018), existen dos tipos de errores: Tipo I y Tipo II, siendo el más costoso el error Tipo I, dado que clasifica erróneamente una empresa potencialmente en quiebra como sana, mientras que, el error Tipo II realiza una clasificación errada de una empresa sana en quiebra. Otra herramienta para analizar el costo de error es la curva ROC (*Receiver operating characteristic curve*), que muestra el punto de corte que permite discriminar el test de diagnóstico entre dos grupos, en este caso, entre empresas sanas y quebradas.

En esta investigación se encontraron 55 artículos que presentan el error Tipo I y Tipo II, 28 la curva ROC, 12 trabajan con ambas opciones y, 32 no hacen referencia al tema. Dada la importancia de esta información, los investigadores plantean la necesidad y obligatoriedad que cualquier estudio referente a la modelación de la quiebra empresarial presenten en los artículos, por lo menos uno de las dos herramientas relacionados con el costo de error de los modelos, permitiendo al lector tener claridad sobre la pronóstico de la técnica estadística utilizada en la clasificación entre empresas sanas y quebradas. Finalmente, la investigación ratifica lo encontrado por Lado y Vivel (2018), son las redes neuronales y las máquinas de vector de soporte, las técnicas estadísticas que tienen menor error tipo I, a la vez que, el análisis discriminante posee el más alto error tipo I.

3.3. Variables explicativas

Desde los inicios en la investigación de la quiebra empresarial se han venido utilizando los indicadores financieros como una variable explicativa, tal y como se referencia en los trabajos de Beaver (1966) y de Altman (1968). Tascon y Castaño (2012) indican que los diferentes trabajos empíricos desarrollados durante el período 1966-2009 habían combinado todos los indicadores posibles, dada la información financiera que se poseía de las empresas e indican que los indicadores de rentabilidad y endeudamiento fueron los más utilizados, con un 17,44% y un 14,99% respectivamente.

Este estudio encontró que para el período 2012-2017 los indicadores más utilizadas son liquidez, rentabilidad y endeudamiento, ratificando en gran parte lo encontrado por Tascon y Castaño (2012). Sin embargo, a diferencia de las otras revisiones nombrados en este trabajo, se resalta la importancia que vienen teniendo los indicadores relacionados con el flujo de caja, adicionalmente, se detectó que la variable "tamaño" empieza a tomar relevancia, en cuanto a que es utilizada como parámetro para subdividir la población en submuestras. Adicionalmente, al analizar los motivos por los cuales son tan frecuente las variables liquidez, rentabilidad y endeudamiento, se encontró que la mayoría de los estudios atribuyen el uso de estos indicadores a tres aspectos básicamente. En primera instancia, a la popularidad dada a través de la literatura contable y financiera, segundo, a la misma frecuencia de uso en los diferentes estudios y, en tercer lugar, a la significancia estadística que arrojan los diferentes modelos. Estos argumentos ya se habían planteado en el estudio de Tascon y Castaño (2012), por lo tanto, se establece que cualquier estudio que se proponga sobre la predicción de la quiebra empresarial deberá tener en cuenta estos mismos tres aspectos.

4. Conclusiones

Este trabajo hace contribuciones en torno al concepto de "quiebra", visualizando como el término "fracaso" deja de ser común en los estudios y se consolida el término "quiebra", siendo utilizado desde un planteamiento jurídico y sujeto al país donde se realiza el estudio. Además, se amplían los factores que con mayor frecuencia se emplean en los modelos de predicción, no solo confirmando el componente financiero, sino, el componente macroeconómico, a la vez, se hace un llamado a prestar más atención a las variables tamaño y ubicación.

Se muestra como los estudios de quiebra empresarial ya no están enfocados en la aplicación de una sola metodología estadística, por el contrario, los últimos estudios profundizan sobre la necesidad de utilizar diferentes metodologías que permitan hacer comparaciones sobre qué modelo tiene mayor precisión de pronóstico. Los investigadores creen que los futuros estudios no solo realizaran comparaciones entre modelos, sino, que empezaran a profundizar en el desarrollo de modelos híbridos y comparar los resultados con los modelos desarrollados a través de las técnicas tradicionales.

En el tema de la implementación de una muestra balanceada en la búsqueda de los modelos de pronóstico, la investigación muestra que los aciertos globales de los modelos son indiferentes de si la muestra es o no balanceada, dado que sus niveles de acierto superan el 70%. Los investigadores aportan argumentos estadísticos que conllevan a implementar el uso

de muestras balanceadas en el proceso, es por eso, que las futuras investigaciones deben considerar dichos aspectos a la hora de implementar cualquier técnica estadística de modelación.

Una última anotación hace referencia al costo del error, es de anotar, la importancia que tiene presentar los resultados en torno a las herramientas que permitan ver la precisión en la clasificación por parte de los modelos. Los estudios analizados mostraron que prima la curva ROC frente a la tabla consolidada de los errores tipo I y tipo II, sin embargo, preocupa los artículos que de alguna manera no informaron sobre el costo de error arrojado por la técnica estadística utilizada en su pronóstico. Adicionalmente, se confirma lo encontrado por Lado y Vivel (2018) en torno a las técnicas como menos errores tipo I, en este caso, las redes neuronales y las máquinas de vector de soporte, mientras que el análisis discriminante se consolida como la técnica con mayor error tipo I. Finalmente, los estudios futuros deben enfocarse en comparar la capacidad de predicción de las diferentes técnicas estadísticas en torno a dos puntos esenciales, el primero, entre las muestras pequeñas y las grandes, y el segundo, entre muestra no balanceadas y balanceadas.

Referencias bibliográficas

- Abdullah, A. (2016). Comparing the Reliability of Accounting-Based and Market-based Prediction Models. *Asian Journal of Accounting and Governance*, 7, 41-55. doi:10.17576/ajag-2016-07-04
- Abdullah, N., Ma'aji, M., & Khaw, K. (2016). The value of governance variables in predicting financial distress among small and medium-sized enterprises in Malaysia. *Asian Academy Of Management Journal Of Accounting & Finance*, 12, 77-91. doi:10.21315/aamjaf2016.12.S1.4
- Abellán, J., & Mantas, C. (2014). Improving experimental studies about ensembles of classifiers for bankruptcy prediction and credit scoring. *Expert Systems With Applications*, 41(8), 3825-3830. doi:10.1016/j.eswa.2013.12.003
- Achim, M., Borlea, S., & Gaban, L. (2016). Failure prediction from the investors' view by using financial ratios. Lesson from Romania. *E & M Economie a Management*, 19(4), 117-133. doi:10.15240/tul/001/2016-4-009
- Acosta, E., & Fernández, F. (2014). Forecasting Financial Failure of Firms via Genetic Algorithms. *Computational Economics*, 43(2), 133-157. doi:10.1007/s10614-013-9392-9
- Acosta, E., Fernández, F., & Ganga, H. (2017). Predicting corporate financial failure using macroeconomic variables and accounting data. *Computational Economics*.
- Affes, Z., & Hentati, R. (2017). Predicting US Banks Bankruptcy: Logit Versus Canonical Discriminant Analysis. *Computational Economics*. doi:10.1007/s10614-017-9698-0
- Agrawal, K., & Maheshwari, Y. (2016). Predicting financial distress: revisiting the option-based model. *South Asian Journal of Global Business Research*, 5(2), 268-284. doi:10.1108/sajgbr-04-2015-0030
- Ahmadpour, A., Divsalar, M., Javid, M., & Ebrahimian, S. (2013). Prediction of bankruptcy Iranian corporations through artificial neural network and Probit-based analyses. *Neural Computing and Applications*, 23(3), 927-936. doi:10.1007/s00521-012-1017-z
- Alaka, H., Oyedele, L., Owolabi, H., Ajayi, S., Bilal, M., & Akinade, O. (2016). Methodological approach of construction business failure prediction studies: a review. *Construction Management and Economics*, 34(11), 808-842. doi:10.1080/01446193.2016.1219037
- Alaka, H., Oyedele, L., Owolabi, H., Kumar, V., Ajayi, S., Akinade, O., & Bilal, M. (2018). Systematic Review of Bankruptcy Prediction Models: Towards A Framework for Tool Selection. *Expert Systems With Applications*, 94, 164-184. doi:10.1016/j.eswa.2017.10.040
- Alaminos, D., del Castillo, A., & Fernandez, M. (2016). A Global Model for Bankruptcy Prediction. *Plos One*, 11(11), 18. doi:10.1371/journal.pone.0166693
- Altman, E. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589-609. doi:10.2307/2978933

- Altman, E. (1984). The Success of Business Failure Prediction Models: An International Survey. *Journal Of Banking And Finance*, 8(2), 171-198. doi:10.1016/0378-4266(84)90003-7
- Altman, E., Iwanicz, M., Laitinen, E., & Suvas, A. (2016). Financial and nonfinancial variables as long-horizon predictors of bankruptcy. *Journal of Credit Risk*, 12(4), 49-78. doi:10.21314/jcr.2016.216
- Altman, E., Iwanicz, M., Laitinen, E., & 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 and Accounting*, 28, 131-171. doi:10.1111/jifm.12053
- Amendola, A., Restaino, M., & Sensini, L. (2015). An analysis of the determinants of financial distress in Italy: A competing risks approach. *International Review Of Economics And Finance*, 37, 33-41. doi:10.1016/j.iref.2014.10.012
- Antonowicz, P. (2014). The multi-dimensional structural analysis of bankruptcy of enterprises in Poland in 2013 - results of empirical studies. *Journal of international studies*, 7(1), 35-45. doi:10.14254/2071-8330.2014/7-1/3
- Antunes, F., Ribeiro, B., & Pereira, F. (2017). Probabilistic modeling and visualization for bankruptcy prediction. *Applied Soft Computing*. doi:10.1016/j.asoc.2017.06.043
- Appiah, K., Chizema, A., & Arthur, J. (2015). Predicting corporate failure: a systematic literature review of methodological issues. *International Journal of Law & Management*, 57(5), 461-485. doi:10.1108/IJLMA-04-2014-0032
- Babu, S. (2015). Prediction of bankruptcy of non-life insurance companies in India - A study. *International Journal of Applied Business and Economic Research*, 13(3), 1431-1444.
- Bahrammirzaee, A. (2010). A comparative survey of artificial intelligence applications in finance: artificial neural networks, expert system and hybrid intelligent systems. *Neural Computing & Applications*, 19(8), 1165-1195. doi:10.1007/s00521-010-0362-z
- Balcaen, S., Manigart, S., Buyze, J., & Ooghe, H. (2012). Firm exit after distress: differentiating between bankruptcy, voluntary liquidation and M&A. *Small Business Economics*, 39(4), 949-975. doi:10.1007/s11187-011-9342-7
- Balcaen, S., & Ooghe, H. (2006). 35 years of studies on business failure: an overview of the classic statical methodologies and their related problems. *British accounting review*, 38(1), 63-93.
- Barboza, F., Kimura, H., & Altman, E. (2017). Machine learning models and bankruptcy prediction. *Expert Systems With Applications*, 83, 405-417. doi:10.1016/j.eswa.2017.04.006
- Barnes, P. (1987). The analysis and use of financial ratios: a review article. *Journal Of Business Finance & Accounting*, 14(4), 449-461. doi:10.1111/j.1468-5957.1987.tb00106.x
- Beaver, W. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4(1), 71-111. doi:10.2307/2490171
- Beaver, W., Correia, M., & McNichols, M. (2012). Do differences in financial reporting attributes impair the predictive ability of financial ratios for bankruptcy? *Review Of Accounting Studies*, 17(4), 969-1010. doi:10.1007/s11142-012-9186-7
- Bisogno, M. (2012). The accessibility of the Italian bankruptcy procedures: an empirical analysis. *Eurasian Business Review*, 2(2), 1-24. doi:10.14208/BF03353810
- Blanco, A., Irimia, A., Oliver, M., Wilson, & N. (2015). Improving Bankruptcy Prediction in Micro-Entities by Using Nonlinear Effects and Non-Financial Variables. *Finance A Uver: Czech Journal Of Economics & Finance*, 65(2), 144-166.
- Blanco, A., Irimia, A., & Vázquez, M. (2016). Design of a Specific Model for Predicting Micro-Entities Failure. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 22, 3-18.
- Bodle, K., Cybinski, P., & Monem, R. (2016). Effect of IFRS adoption on financial reporting quality Evidence from bankruptcy prediction. *Accounting Research Journal*, 29(3), 292-312.

doi:10.1108/arj-03-2014-0029

Brezigar, A., & Masten, I. (2012). CART-based selection of bankruptcy predictors for the logit model. *Expert Systems With Applications*, 39(11), 10153-10159.

doi:10.1016/j.eswa.2012.02.125

Brozyna, J., Mentel, G., & Pisula, T. (2016). Statistical methods of the bankruptcy prediction in the logistics sector in poland and slovakia. *Transformations in Business & Economics*, 15(1), 93-114.

Bruneau, C., De Bandt, O., & El Amri, W. (2012). Macroeconomic fluctuations and corporate financial fragility. *Journal Of Financial Stability*, 8(4), 219-235.

doi:10.1016/j.jfs.2012.02.002

Buehler, S., Kaiser, C., & Jaeger, F. (2012). The geographic determinants of bankruptcy: evidence from Switzerland. *Small Business Economics*, 39(1), 231-251.

doi:10.1007/s11187-010-9301-8

Burganova, R., & Salahieva, M. (2015). Z-Score for Bankruptcy Forecasting of the Companies Producing Building Materials. *Asian Social Science*, 11(11), 109-114.

doi:10.5539/ass.v11n11p109

Cao, Y. (2012). Aggregating multiple classification results using Choquet integral for financial distress early warning. *Expert Systems With Applications*, 39(2), 1830-1836.

doi:10.1016/j.eswa.2011.08.067

Caro, N., Arias, V., & Ortiz, P. (2017). Prediction of Failure in Latin-American Companies Using the Nearest-Neighbor Method to Predict Random Effects in Mixed Models. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 24, 5-24.

Caro, N., Díaz, M., & Porporato, M. (2013). Bankruptcy Prediction in Emerging Economies: Use of a Mixed Logistic Model. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 16(1), 200-215.

Caro, N., Guardiola, M., & Ortiz, P. (2018). Árboles de clasificación como herramienta para predecir dificultades financieras en empresas Latinoamericanas a través de sus razones contables. *Contaduría y Administración*, 63(1), 1-14.

doi:10.22201/fca.24488410e.2018.1148

Charalambakis, E. (2015). On the Prediction of Corporate Financial Distress in the Light of the Financial Crisis: Empirical Evidence from Greek Listed Firms. *International Journal Of The Economics Of Business*, 22(3), 407-428. doi:10.1080/13571516.2015.1020131

Charalambakis, E., & Garrett, I. (2016). On the prediction of financial distress in developed and emerging markets: Does the choice of accounting and market information matter? A comparison of UK and Indian Firms. *Review Of Quantitative Finance & Accounting*, 47(1), 1-28. doi:10.1007/s11156-014-0492-y

Chen, J. (2012). Developing SFNN models to predict financial distress of construction companies. *Expert Systems With Applications*, 39(1), 823-827.

doi:10.1016/j.eswa.2011.07.080

Chen, N., Ribeiro, B., Vieira, A., & Chen, A. (2013). Clustering and visualization of bankruptcy trajectory using self-organizing map. *Expert Systems With Applications*, 40(1), 385-393. doi:10.1016/j.eswa.2012.07.047

Chou, C., Hsieh, S., & Qiu, C. (2017). Hybrid genetic algorithm and fuzzy clustering for bankruptcy prediction. *Applied Soft Computing*, 56, 298-316.

doi:10.1016/j.asoc.2017.03.014

Chung, C. C., Chen, T. S., Lin, L. H., Lin, Y. C., & Lin, C. M. (2016). Bankruptcy Prediction Using Cerebellar Model Neural Networks. *International Journal of Fuzzy Systems*, 18(2), 160-167. doi:10.1007/s40815-015-0121-5

Cleofas, L., Sánchez, J., García, V., & Marqués, A. (2016). Financial distress prediction using the hybrid associative memory with translation. *Applied Soft Computing Journal*, 44, 144-152. doi:10.1016/j.asoc.2016.04.005

Condello, S., Del Pozzo, A., & Loprevite, S. (2017). Potential and Limitations of D.E.A. as a

- Bankruptcy Prediction Tool in the Light of a Study on Italian Listed Companies. *Applied Mathematical Sciences*, 11(44), 2185 - 2207. doi:10.12988/ams.2017.77216
- Cultrera, L., & Bredart, X. (2016). Bankruptcy prediction: the case of Belgian SMEs. *Review of Accounting and Finance*, 15(1), 101-119. doi:10.1108/raf-06-2014-0059
- De Albornoz, B., & Giner, B. (2013). Corporate failure prediction in the construction and real estate industries: General versus industry-focused models. *Universia Business Review*, 39, 118-131.
- De Andres, J., Lorca, Sanchez, P., & Javier, F. (2012). Bankruptcy Prediction and Credit Scoring: A Review of Recent Developments Based on Hybrid Systems and Some Related Patents. *Recent Patents on Computer Science*, 5(1), 11-20. doi:10.2174/2213275911205010011
- De Bock, K. (2017). The best of two worlds: Balancing model strength and comprehensibility in business failure prediction using spline-rule ensembles. *Expert Systems With Applications*, 90, 23-39. doi:10.1016/j.eswa.2017.07.036
- De Llano, P., Piñeiro, C., & Rodriguez, M. (2016). Business failure prediction. A contribution to the synthesis of a theory, through comparative analysis of different prediction techniques. *Revista de Estudios de Economía*, 43(2), 163-198.
- Dimitras, A., Zopounidis, C., & Zanakis, S. (1996). A survey of business failures with an emphasis on prediction methods and industrial applications. *European Journal Of Operational Research*, 90(3), 487-513. doi:10.1016/0377-2217(95)00070-4
- Du Jardin, P. (2014). Bankruptcy prediction using terminal failure processes. *European Journal of Operational Research*, 242(1), 286-303.
- Du Jardin, P. (2017). Dynamics of firm financial evolution and bankruptcy prediction. *Expert Systems With Applications*, 75, 25-43. doi:10.1016/j.eswa.2017.01.016
- Elshahat, I., Elshahat, A., & Rao, A. (2015). Does corporate governance improve bankruptcy prediction? *Academy Of Accounting & Financial Studies Journal*, 19(1), 107-119.
- Fallahpour, S., Lakvan, E., & Zadeh, M. (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. doi:10.1016/j.jretconser.2016.10.002
- Fedorova, E., Gilenko, E., & Dovzhenko, S. (2013). Bankruptcy prediction for Russian companies: Application of combined classifiers. *Expert Systems With Applications*, 40(18), 7285-7293. doi:10.1016/j.eswa.2013.07.032
- Fitzpatrick, F. (1932). A Comparison of Ratios of Successful Industrial Enterprises with Those of Failed Firm. *Certified Public Accountant*, 6, 727-731.
- Fontaine, F., Da Silva, R., De Oliveira, F., & Lameira, V. (2017). Predicting financial distress in publicly-traded companies. *Revista Contabilidade & Finanças*, 28(75), 390-406. doi:10.1590/1808-057x201704460
- García, A., & Mures, M. (2013). The Sample of Firms in Business Failure Prediction Models: Influence on Classification Results. *Revista de Métodos Cuantitativos para la Economía y la Empresa*, 15(1), 133-155.
- García, J., Sánchez, J., & Tomaseti, E. (2016). Fracaso empresarial y efectos contagio. Un análisis espacial para España. *Trimestre Económico*, 83(330), 429-449.
- García, V., Marqués, A., Sánchez, J., & Ochoa, H. (2017). Dissimilarity-Based Linear Models for Corporate Bankruptcy Prediction. *Computational Economics*, 1-13. doi:10.1007/s10614-017-9783-4
- Gavurová, B., Janke, F., Packová, M., & Prídavok, M. (2017). Analysis of impact of using the trend variables on bankruptcy prediction models performance. *Ekonomicky Casopis*, 65(4), 370-383.
- Georgescu, V. (2017). Using genetic algorithms to evolve type-2 fuzzy logic systems for predicting bankruptcy. *Kybernetes*, 46(1), 142-156. doi:10.1108/K-06-2016-0152
- Gordini, N. (2014). A genetic algorithm approach for SMEs bankruptcy prediction: Empirical

- evidence from Italy. *Expert Systems With Applications*, 41(14), 6433-6445.
doi:10.1016/j.eswa.2014.04.026
- Grice, J., & Dugan, M. (2001). The Limitations of Bankruptcy Prediction Models: Some Cautions for the Researcher. *Review Of Quantitative Finance And Accounting*, 17(2), 151-166. doi:10.1023/A:1017973604789
- Heo, J., & Yang, J. (2014). AdaBoost based bankruptcy forecasting of Korean construction companies. *Applied Soft Computing Journal*, 24, 494-499. doi:10.1016/j.asoc.2014.08.009
- Horta, I., & Camanho, A. (2013). Company failure prediction in the construction industry. *Expert Systems With Applications*, 40(16), 6253-6257. doi:10.1016/j.eswa.2013.05.045
- Huang, S., Tang, Y., Lee, C., & Chang, M. (2012). Kernel local Fisher discriminant analysis based manifold-regularized SVM model for financial distress predictions. *Expert Systems With Applications*, 39(3), 3855-3861. doi:10.1016/j.eswa.2011.09.095
- Jabeur, S. (2017). Bankruptcy prediction using Partial Least Squares Logistic Regression. *Journal of Retailing and Consumer Services*, 36, 197-202.
doi:10.1016/j.jretconser.2017.02.005
- Jones, S. (2017). Corporate bankruptcy prediction: a high dimensional analysis. *Review of Accounting Studies*, 22(3), 1366-1422. doi:10.1007/s11142-017-9407-1
- Jones, S., Johnstone, D., & Wilson, R. (2017). Predicting Corporate Bankruptcy: An Evaluation of Alternative Statistical Frameworks. *Journal of Business Finance and Accounting*, 44(1-2), 3-34. doi:10.1111/jbfa.12218
- Karas, M., & Reznakova, M. (2017). Predicting the Bankruptcy of Construction Companies: A CART-Based Model. *Engineering Economics*, 28(2), 145-154. doi:10.5755/j01.ee.28.2.16353
- Keasey, K., & Watson, R. (1991). Financial Distress Prediction Models: A Review of Their Usefulness. *British Journal of Management*, 2(2), 89-102. doi:10.1111/j.1467-8551.1991.tb00019.x
- Kim, H., Jo, N., & Shin, K. (2016). Optimization of cluster-based evolutionary undersampling for the artificial neural networks in corporate bankruptcy prediction. *Expert Systems With Applications*, 59, 226-234. doi:10.1016/j.eswa.2016.04.027
- Kim, M., & Jeong, C. (2012). A tuning method for the architecture of neural network models incorporating GAM and GA as applied to bankruptcy prediction. *Expert Systems With Applications*, 39(3), 3650-3658. doi:10.1016/j.eswa.2011.09.056
- Kim, M., & Kang, D. (2012). Classifiers selection in ensembles using genetic algorithms for bankruptcy prediction. *Expert Systems With Applications*, 39(10), 9308-9314.
doi:10.1016/j.eswa.2012.02.072
- Kim, M., Kang, D., & Kim, H. (2015). Geometric mean based boosting algorithm with over-sampling to resolve data imbalance problem for bankruptcy prediction. *Expert Systems With Applications*, 42(3), 1074-1082. doi:10.1016/j.eswa.2014.08.025
- Kim, S. (2013). What is behind the magic of O-Score? An alternative interpretation of Dichev's (1998) bankruptcy risk anomaly. *Review Of Accounting Studies*, 18(2), 291-323.
doi:10.1007/s11142-012-9206-7
- Klepac, V., & Hampel, D. (2017). Predicting financial distress of agriculture companies in EU. *Agricultural Economics (Czech Republic)*, 63(8), 347-355. doi:10.17221/374/2015-AGRICECON
- Komera, S., & P, L. (2014). Corporate Bankruptcy, Soft Budget Constraints, and Business Group Affiliation: Evidence from Indian Firms. *Review of Pacific Basin Financial Markets and Policies*, 17(3), 1-28. doi:10.1142/S0219091514500167
- Korol, T. (2013). Early warning models against bankruptcy risk for Central European and Latin American enterprises. *Economic Modelling*, 31, 22-30.
doi:10.1016/j.econmod.2012.11.017
- Kwak, W., Shi, Y., & Kou, G. (2012). Bankruptcy prediction for Korean firms after the 1997 financial crisis: using a multiple criteria linear programming data mining approach. *Review*

- Of Quantitative Finance & Accounting*, 38(4), 441-453. doi:10.1007/s11156-011-0238-z
- Lado, R., & Vivel, M. (2018). Diagnosis of bankruptcy hospitality and tourist destination. *Lurralde: Investigacion y Espacio*, 41, 149-174.
- Laitinen, E., & Suvas, A. (2016). Financial distress prediction in an international context: Moderating effects of Hofstede's original cultural dimensions. *Journal of Behavioral and Experimental Finance*, 9, 98-118. doi:<https://doi.org/10.1016/j.jbef.2015.11.003>
- Lee, S., & Choi, W. (2013). A multi-industry bankruptcy prediction model using back-propagation neural network and multivariate discriminant analysis. *Expert Systems With Applications*, 40(8), 2941-2946. doi:10.1016/j.eswa.2012.12.009
- Levy, H., Kanat, Y., Kunin, A., Tooshknov, D., & Tzruya, P. (2014). Predicting defaults of highly-levered firms with an adapted Altman model. *Investment Analysts Journal*, 43(2), 14500121-14500122.
- Liang, D., Lu, C., Tsai, C., & Shih, G. (2016). Financial ratios and corporate governance indicators in bankruptcy prediction: A comprehensive study. *European Journal Of Operational Research*, 252(2), 561-572. doi:10.1016/j.ejor.2016.01.012
- Lin, S., Ansell, J., & Andreeva, G. (2012). Predicting default of a small business using different definitions of financial distress. *Journal Of The Operational Research Society*, 63(4), 539-548. doi:10.1057/jors.2011.65
- Lu, C., Yang, A., & Huang, J. (2015). Bankruptcy predictions for U.S. air carrier operations: a study of financial data. *Journal Of Economics & Finance*, 39(3), 574-589. doi:10.1007/s12197-014-9282-6
- López, F., & Sanz, I. (2015). Bankruptcy visualization and prediction using neural networks: A study of U.S. commercial banks. *Expert Systems With Applications*, 42(6), 2857-2868. doi:10.1016/j.eswa.2014.11.025
- Manzaneque, M., Priego, A., & Merino, E. (2016). Corporate governance effect on financial distress likelihood: Evidence from Spain. *Revista De Contabilidad*, 19(1), 111-121. doi:10.1016/j.rcsar.2015.04.001
- Mazurencu, M., Nijkamp, P., & Pele, D. (2013). An econometric analysis of ict-oriented companies' bankruptcy. A case study on Romania *Economic Computation & Economic Cybernetics Studies & Research*, 47(2), 57-65.
- Mokhova, N., & Zinecker, M. (2013). Liquidity, probability of bankruptcy and the corporate life cycle: the evidence from Czech Republic. *International Journal of Globalisation and Small Business*, 5(3), 189-208. doi:10.1504/IJGSB.2013.054912
- Mousavi, M., Ouenniche, J., & Xu, B. (2015). Performance evaluation of bankruptcy prediction models: An orientation-free super-efficiency DEA-based framework. *International Review Of Financial Analysis*, 42, 64-75. doi:10.1016/j.irfa.2015.01.006
- 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. doi:10.1016/j.irfa.2017.02.004
- Nouri, B., & Soltani, M. (2016). Designing a bankruptcy prediction model based on account, market and macroeconomic variables (Case Study: Cyprus Stock Exchange). *Iranian Journal of Management Studies*, 9(1), 125-147. doi:10.1371/journal.pone.0166693
- Obermann, L., & Waack, S. (2015). Demonstrating non-inferiority of easy interpretable methods for insolvency prediction. *Expert Systems With Applications*, 42(23), 9117-9128. doi:10.1016/j.eswa.2015.08.009
- Olson, D., Delen, D., & Meng, Y. (2012). Comparative analysis of data mining methods for bankruptcy prediction. *Decision Support Systems*, 52(2), 464-473. doi:10.1016/j.dss.2011.10.007
- Oz, I., & Yelkenci, T. (2017). A theoretical approach to financial distress prediction modeling. *Managerial Finance*, 43(2), 212-230. doi:10.1108/MF-03-2016-0084
- Pal, R., Kupka, K., Aneja, A., & Militky, J. (2016). Business health characterization: A hybrid

- regression and support vector machine analysis. *Expert Systems With Applications*, 49, 48-59. doi:10.1016/j.eswa.2015.11.027
- Perez, M. (2006). Artificial neural networks and bankruptcy forecasting: A state of the art. *Neural Computing And Applications*, 15(2), 154-163. doi:10.1007/s00521-005-0022-x
- Piatti, D., Cincinelli, P., & Castellani, D. (2015). Efficiency and corporate bankruptcy prediction. *Academy Of Accounting & Financial Studies Journal*, 19(3), 319-348.
- Piñeiro, C., De Llano, P., & Rodríguez, M. (2013). ¿Proporciona la auditoría evidencias para detectar y evaluar tensiones financieras latentes? Un diagnóstico comparativo mediante técnicas econométricas e inteligencia artificial. *Revista Europea de Dirección y Economía de la Empresa*, 22(3), 115-130. doi:10.1016/j.redee.2012.10.001
- Platt, H., & Platt, M. (2013). Risks to auto sector recovery: bankruptcies of auto suppliers in East Asia and the USA. *Journal of Asia Business Studies*, 7(3), 231-243. doi:10.1108/JABS-02-2013-0010
- Pozuelo, J., Labatut, G., & Veres, E. (2013). Validez de la información financiera en los procesos de insolvencia. Un estudio de la pequeña empresa española. *Cuadernos de economía y dirección de la empresa*, 16(1), 29-40. doi:10.1016/j.cede.2012.05.001
- Ramage, J., Pongsatit, S., & Lawrenc, H. (2015). The Use Of Ohlson's O-Score For Bankruptcy Prediction In Thailand. *The Journal of Applied Business Research*, 31(6), 2069-2078.
- Ravi, P., & Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research*, 180(1), 1-28. doi:10.1016/j.ejor.2006.08.043
- Reznakova, M., & Karas, M. (2015). The prediction capabilities of bankruptcy models in a different environment: An example of the altman model under the conditions in the visegrad group countries. *Ekonomicky casopis*, 63(6), 617-633.
- Rodríguez, M., Pineiro, C., & De Llano, P. (2014). Financial Risk Determination of Failure by Using Parametric Model, Artificial Intelligence and Audit Information. *Estudios de Economía*, 41(2), 187-217.
- Rodríguez, C., Maté, M., & López, F. (2017). The Contagion on Business Failure by the Geographical Proximity: An Analysis with the Join-Count Tests in the Service Sector. *Revista De Métodos Cuantitativos Para La Economía Y La Empresa*, 23, 75-95.
- Salehi, M., Shiri, M., & Pasikhani, M. (2016). Predicting corporate financial distress using data mining techniques An application in Tehran Stock Exchange. *International Journal of Law and Management*, 58(2), 216-230. doi:10.1108/ijlma-06-2015-0028
- Salimi, A. (2015). Validity of Altmans z-score model in predicting bankruptcy in recent years. *Academy Of Accounting & Financial Studies Journal*, 19(2), 233-238.
- Sartori, F., Mazzucchelli, A., & Gregorio, A. (2016). Bankruptcy forecasting using case-based reasoning: The CRePERIE approach. *Expert Systems With Applications*, 64, 400-411. doi:10.1016/j.eswa.2016.07.033
- Serrano, C., Fuertes, Y., Gutiérrez, B., & Cuellar, B. (2014). Path modelling to bankruptcy: causes and symptoms of the banking crisis. *Applied Economics*, 46(31), 3798-3811. doi:10.1080/00036846.2014.943882
- Serrano, C., & Gutiérrez, B. (2013). Partial least square discriminant analysis for bankruptcy prediction. *Decision Support Systems*, 54(3), 1245-1255. doi:10.1016/j.dss.2012.11.015
- Shetty, U., Pakkala, T., & Mallikarjunappa, T. (2012). A modified directional distance formulation of DEA to assess bankruptcy: An application to IT/ITES companies in India. *Expert Systems With Applications*, 39(2), 1988-1997. doi:10.1016/j.eswa.2011.08.043
- Shie, F., Chen, M., & Liu, Y. (2012). Prediction of corporate financial distress: an application of the America banking industry. *Neural Computing & Applications*, 21(7), 1687-1696. doi:10.1007/s00521-011-0765-5
- Sinarti, T., & Sembiring, M. (2015). Bankruptcy prediction analysis of manufacturing

companies listed in Indonesia stock exchange. *International Journal of Economics and Financial*, 5, 354-359.

Singh, B., & Mishra, A. (2016). Re-estimation and comparisons of alternative accounting based bankruptcy prediction models for Indian companies. *Financial Innovation*, 2(1), 1-28. doi:10.1186/s40854-016-0026-9

Sun, J., Fujita, H., Chen, P., & Li, H. (2017). Dynamic financial distress prediction with concept drift based on time weighting combined with Adaboost support vector machine ensemble. *Knowledge-Based Systems*, 120, 4-14. doi:10.1016/j.knosys.2016.12.019

Sun, J., Li, H., Huang, Q., & He, K. (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. doi:10.1016/j.knosys.2013.12.006

Sánchez, F., De Andrés, J., Lorca, P., & De Cos, F. (2012). A hybrid device for the solution of sampling bias problems in the forecasting of firms' bankruptcy. *Expert Systems With Applications*, 39(8), 7512-7523. doi:10.1016/j.eswa.2012.01.135

Tascon, M., & Castaño, F. (2012). Variables and Models for the Identification and Prediction of Business Failure: Revision of Recent Empirical Research Advances. *Revista de Contabilidad*, 15(1), 7-58. doi:10.1016/S1138-4891(12)70037-7

Tian, S., Yu, Y., & Guo, H. (2015). Variable selection and corporate bankruptcy forecasts. *Journal Of Banking And Finance*, 52, 89-100. doi:10.1016/j.jbankfin.2014.12.003

Tobback, E., Moeyersoms, J., Stankova, M., Martens, D., & Bellotti, T. (2017). Bankruptcy prediction for SMEs using relational data. *Decision Support Systems*, 102, 69-81. doi:10.1016/j.dss.2017.07.004

Trabelsi, S., He, R., He, L., & Kusy, M. (2014). A comparison of Bayesian, Hazard, and Mixed Logit model of bankruptcy prediction. *Computational Management Science*, 12(1), 81-97. doi:10.1007/s10287-013-0200-8

Traczynski, J. (2017). Firm Default Prediction: A Bayesian Model-Averaging Approach. *Journal Of Financial And Quantitative Analysis*, 52(3), 1211-1245. doi:10.1017/S002210901700031X

Tsai, C., Hsu, Y., & Yen, D. (2014). A comparative study of classifier ensembles for bankruptcy prediction. *Applied Soft Computing Journal*, 24, 977-984. doi:10.1016/j.asoc.2014.08.04

Virág, M., & Nyitrai, T. (2014). Is there a trade-off between the predictive power and the interpretability of bankruptcy models? The case of the first Hungarian bankruptcy prediction model. *Acta Oeconomica*, 64(4), 419-440.

Volkov, A., Benoit, D., & Van den Poel, D. (2017). Incorporating sequential information in bankruptcy prediction with predictors based on Markov for discrimination. *Decision Support Systems*, 98, 59-68. doi:10.1016/j.dss.2017.04.008

Wang, G., Yang, S., & Ma, J. (2014). An improved boosting based on feature selection for corporate bankruptcy prediction. *Expert Systems With Applications*, 41(5), 2353-2361. doi:10.1016/j.eswa.2013.09.033

Wang, L., Gopal, R., Shankar, R., & Pancras, J. (2015). On the brink: Predicting business failure with mobile location-based checkins. *Decision Support Systems*, 76, 3-13. doi:10.1016/j.dss.2015.04.010

Wang, L., & Wu, C. (2017). Business failure prediction based on two-stage selective ensemble with manifold learning algorithm and kernel-based fuzzy self-organizing map. *Knowledge-Based Systems*, 121, 99-110. doi:10.1016/j.knosys.2017.01.016

Wang, M., Chen, H., Li, H., Cai, Z., Zhao, X., Tong, C., . . . Xu, X. (2017). Grey wolf optimization evolving kernel extreme learning machine: Application to bankruptcy prediction. *Engineering Applications of Artificial Intelligence*, 63, 54-68. doi:10.1016/j.engappai.2017.05.003

Wang, M., & Shiu, H. (2014). Research on the common characteristics of firms in financial distress into bankruptcy or recovery. *Investment Management and Financial Innovations*, 11,

Wu, C., Wang, L., & Shi, Z. (2016). Financial Distress Prediction Based on Support Vector Machine with a Modified Kernel Function. *Journal of intelligent systems*, 25(3), 417-429. doi:10.1515/jisys-2014-0132

Zavgren, C. (1983). The prediction of corporate failure: the state of the art. *Journal of Accounting Literature*, 2, 1-38.

Zelenkov, Y., Fedorova, E., & Chekrizov, D. (2017). Two-step classification method based on genetic algorithm for bankruptcy forecasting. *Expert Systems With Applications*, 88, 393-401. doi:10.1016/j.eswa.2017.07.025

Zhang, X., & Hu, L. (2016). A nonlinear subspace multiple kernel learning for financial distress prediction of Chinese listed companies. *Neurocomputing*, 177, 636-642. doi:10.1016/j.neucom.2015.11.078

Zhao, D., Huang, C., Wei, Y., Yu, F., Wang, M., & Chen, H. (2017). An Effective Computational Model for Bankruptcy Prediction Using Kernel Extreme Learning Machine Approach. *Computational Economics*, 49(2), 325-341.

Zhou, L., & Lai, K. (2017). AdaBoost Models for Corporate Bankruptcy Prediction with Missing Data. *Computational Economics*, 50(1), 69-94. doi:10.1007/s10614-016-9581-4

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

1. Departamento de Finanzas. Universidad EAFIT. Msc. en Finanzas. atamaraa@eafit.edu.co

2. Departamento de Ciencias Económicas y Administrativas. Universidad de Medellín. Ph.D. in Management. gvillegas@udem.edu.co

3. Departamento de Contabilidad. Universidad de Oviedo. Doctor en Ciencias Económicas y Empresariales. jdandres@uniovi.es

Revista ESPACIOS. ISSN 0798 1015
Vol. 40 (Nº 04) Año 2019

[Índice]

[En caso de encontrar algún error en este website favor enviar email a webmaster]