



Forum Empresarial

ISSN: 1541-8561

forum@uprrp.edu

Centro de Investigaciones Comerciales e

Iniciativas Académicas

Puerto Rico

Romani Chocce, Gianni A.; Aroca González, Patricio; Aguirre Aguirre, Nelson; Leiton Vega, Paola;
Muñoz Carrazana, Javier

Modelos de clasificación y predicción de quiebra de empresas: una aplicación a empresas chilenas

Forum Empresarial, vol. 7, núm. 1, mayo, 2002, pp. 33-50

Centro de Investigaciones Comerciales e Iniciativas Académicas

San Juan, Puerto Rico

Disponible en: <http://www.redalyc.org/articulo.oa?id=63170102>

- ▶ Cómo citar el artículo
- ▶ Número completo
- ▶ Más información del artículo
- ▶ Página de la revista en redalyc.org

redalyc.org

Sistema de Información Científica

Red de Revistas Científicas de América Latina, el Caribe, España y Portugal

Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

*Gianni A. Romani Chocce, Ph.D.**
*Patricio Aroca González, Ph.D.** Nelson Aguirre Aguirre***
*Paola Leiton Vega** / Javier Muñoz Carrazana***

Modelos de clasificación y predicción de quiebra de empresas: una aplicación a empresas chilenas

Introducción

El análisis financiero a través de índices o razones sirve como insumo principal en los diversos modelos existentes para clasificar y predecir la quiebra de empresas. Debido a esto, el objetivo de esta investigación es identificar el modelo que clasifique con mayor grado de exactitud y prediga con mayor grado de confiabilidad la quiebra de empresas en Chile.

A fin de alcanzar este objetivo se comparan los modelos más comúnmente utilizados en estudios de esta naturaleza: *Análisis Discriminante (ADM)*, *Regresión Logística (LOGIT)* y *Redes Neuronales (RN)*. Se empleó como herramienta principal las razones o índices financieros de liquidez, actividad, rentabilidad y endeudamiento, así como variables macroeconómicas y otras variables de control, que permitan a estos modelos identificar aquellos factores que son

*Directora Programas de Postgrado/Universidad Católica del Norte, Chile

**Universidad Católica del Norte, Chile.

relevantes al momento de clasificar una entidad como quebrada o no-quebrada.

El artículo consta de tres partes: en la primera, se describe la evolución de los modelos de clasificación y predicción de quiebra de empresas y en la segunda se describe la metodología incluyendo la determinación de la Base de Datos, el ajuste de los datos, la especificación de la muestra y de las variables. En la tercera parte, se presentan y analizan los resultados. Finalmente, se resaltan las conclusiones y recomendaciones de la investigación, seguida de la bibliografía.

Evolución de los Modelos de clasificación y Predicción de Quiebra de Empresas

La literatura revisada menciona que los estudios realizados con el propósito de clasificar y predecir la quiebra de empresas datan de la década de los 30, entre los cuales se puede citar el de Smith y Winakor (1935). Posteriormente se desarrollaron otros estudios, en todos ellos se utilizaron los índices financieros basados en datos contables y se llegó a la conclusión de que ciertos índices contable-financieros diferían significativamente entre empresas en quiebra y no quiebra. Sin embargo, los estudios hasta esa época fueron considerados poco formales (serios). En la década de los 60 se comienzan a utilizar los modelos matemáticos y estadísticos con el objetivo de predecir una posible quiebra de empresas. Entre los estudios más destacados de esa época se encuentran: Tamari (1966), Beaver (1967) y Altman (1968) entre otros.

Posteriormente en la década de los 70, los estudios realizados por Edmister (1972), Blum (1974), Deakin (1972), Libby (1975) y Wilcox (1973) entre otros, utilizaron como técnica el *Análisis Discriminante Múltiple (ADM)*. Sin embargo, debido a sus características operacionales esta técnica fue criticada por algunos estudiosos que trataban de utilizar metodologías similares a fin de mejorar el ADM.

En la década de los 80 y 90, la mayoría de los autores que escribió sobre quiebra utilizó otros modelos más complejos, pero al mismo tiempo más precisos, para determinar la probabilidad de quiebra de la empresa; especialmente los modelos *Logit*, *Probit* y *de Redes*

Neuronales. Entre estos autores se encuentra Ohlson (1980), Gentry, Newbold & Whitford (1985), Basch y Montenegro (1989), Theodossiu (1991), Narváez (1994), Platt, Platt & Gunnar (1994), Mora (1994), Boritz et al. (1995), Episcopos (1996), Almeida & Siqueira (1997), Gallizo & Serrano (1998), Golinski (1998) y otros.

Del análisis de los escritos citados anteriormente, se puede concluir que las técnicas más utilizadas para predecir quiebra de empresas son ADM, *LOGIT*, y en la última década las *Redes Neuronales*. Por esta razón se escogieron estos tres modelos para aplicarlos a una muestra de empresas chilenas. Con respecto a los índices financieros, se observó que la mayoría de los autores utiliza los índices pertenecientes a uno de los cuatro grandes grupos: liquidez, actividad, rentabilidad y endeudamiento, siendo los índices de liquidez y endeudamiento los que más contribuyen en la determinación de quiebra de empresas.

Determinación de la Base de Datos

Las empresas que componen la base de datos, pertenecen al grupo de Sociedades Anónimas abiertas sin restricción de giro comercial, que operan en Chile. Esta base está compuesta por 98 empresas pareadas, lo que significa que por cada empresa quebrada se incluyó otra no-quebrada del mismo giro y año. Las empresas quebradas (49) se seleccionaron de la lista de quiebras declaradas por la Fiscalía Nacional de Quiebras durante los últimos 14 años. El segundo grupo de empresas, las no quebradas (49), se obtuvo del programa “FECUS Plus” 1.0, desarrollado por la Bolsa de Comercio de Santiago.

El ajuste de los datos

Con el objetivo de cuantificar el efecto que produce en su salud financiera el desempeño de la industria a la cual pertenece cada empresa se seleccionó una muestra con los índices financieros de cada empresa y otra con estas mismas razones ajustadas por el

promedio industrial correspondiente. Es decir, cada índice se dividió por un ponderador construido a partir de las ventas de la industria y de las empresas. La fórmula para los índices ajustados se muestra a continuación:

$$\text{índice_ajustado}_i = \frac{\text{índice}}{\text{índice_promedio_industrial}_j}$$

$$\text{índice_promedio_industrial}_j = \sum_j^J \text{índice}_j * \frac{(\text{ventas}_j)}{\sum_j^J \text{ventas}_j}$$

Donde:

- índice representa al índice financiero de la empresa i, seleccionada para la conformación de la muestra constituyente de los modelos.
- índice_j^I corresponde al índice financiero calculado para la empresa j, perteneciente a la industria J.
- ventas_j corresponde a las ventas de la empresa j, perteneciente a la industria J.
- índice_i , índice_j y ventas_j pertenecen al mismo año.

Las variables de tipo macroeconómicas no sufrieron ajuste debido a que todas las empresas de la misma industria y del mismo año tenían idénticos valores. En el caso de las variables de control, éstas no se estandarizaron porque al hacerlo generaban valores distintos de cero y uno que era su formulación original.

Especificación de la muestra

Análisis Discriminante Múltiple (ADM)

De acuerdo a las consideraciones discutidas en la sección anterior, se seleccionó un número de 42 empresas quebradas y otras 42 no quebradas, las cuales conformaron la *muestra de estimación* de este

modelo. A ésta se le calcularon los índices que representan las variables independientes en la estimación. De esta muestra se obtiene la capacidad clasificatoria del modelo. La muestra de validación consistió de 14 empresas, 7 quebradas y 7 no quebradas, la cual determina el desempeño en la predicción.

Regresión Logística (LOGIT)

Al igual que el modelo ADM, la muestra utilizada para la estimación “Logit” tiene las mismas características mencionadas anteriormente.

Redes Neuronales (RN)

La RN de tipo “Back-Propagation” (en este estudio), utiliza dos tipos de datos, al igual que los modelos estadísticos: un conjunto de entrenamiento, que contiene la causa y efecto analizado; y un conjunto de prueba, que determina la exactitud en la predicción. De acuerdo a lo anterior, se utilizaron las mismas 84 empresas para el conjunto de entrenamiento y 14 para el conjunto de sustento o prueba.

Especificación de las Variables

Los índices utilizados en este estudio son los siguientes:

- **KWAT**: Capital de Trabajo/Activos totales
- **ACPC**: Activo Circulante/Pasivo Circulante
- **VTAT**: Ventas Totales/Activos Totales
- **UAIAT**: Utilidad antes de intereses e impuestos/Activos Totales
- **UNAT**: Utilidad Neta/Activos Totales
- **MEAT**: Margen de Explotación/Activos Totales
- **NOAT**: (Utilidad Neta - Utilidad Operacional)/ Activos Totales
- **DTAT**: Deuda Total/Activo Total
- **PLPPA**: Pasivo a Largo Plazo/Patrimonio
- **UAIGF**: Utilidad antes de intereses e impuestos /Gastos Financieros
- **LNAT**: Logaritmo Natural de los Activos Totales

Variables de Control:

- **INONE:** 1 si la empresa obtuvo pérdidas en el año correspondiente al balance analizado, 0 en otro caso. Se espera un efecto positivo (signo +) de la variable con respecto a la quiebra de la empresa.
- **OENEG:** 1 si las deudas de la empresa superan a los activos totales, 0 en otro caso. Se espera un efecto positivo (signo +) de la variable con respecto a la quiebra de la empresa.

Variables Macroeconómicas:

- **TCAMB:** Variación Porcentual del tipo de cambio registrada en el año anterior a la quiebra. Se espera que esta variable afecte negativamente a las empresas importadoras y positivamente a las empresas exportadoras.
- **TASA:** Variación porcentual de la tasa de interés real. Se espera que a mayor valor aumente la probabilidad de quiebra de la empresa, por tratarse de la tasa de colocación (endeudamiento).
- **PIBS:** Diferencia entre la variación porcentual del PIB del sector industrial al que pertenece la empresa y el PIB general de la economía. Se espera que a mayor valor de esta variable disminuya la probabilidad de quiebra de la empresa.

Presentación y Análisis de los Resultados

Análisis de significancia individual de las Variables

Según el análisis de significancia individual de las variables, el siguiente cuadro presenta un resumen de aquellos índices que fueron más importantes a la hora de clasificar y predecir la quiebra empresarial en Chile:

CUADRO 1
Resumen de los índices más significativos de quiebra de empresas en Chile

	ADM	LOGIT	RN
AJUSTADAS	VTAT	INONE	ACPC DTAT PLPPA LNAT
	INONE	VTAT	
NO AJUSTADAS	DTAT	LNAT	ACPC DTAT PLPPA LNAT
	INONE	DTAT	
	LNAT		

Como se observa en el cuadro 1, en lo que respecta al Análisis Discriminante, hubo cierta diferencia entre las bases de datos, en cuanto a las variables distinguidas en el modelo como más significativas. Para la base de datos *ajustada*, las variables que cumplieron con el criterio de significancia asignado por el análisis fueron: VTAT (4.3118) e INONE (38.5089); y para la base de datos *no ajustada* se usaron las variables DTAT (6.3906), INONE (8.6411) y LNAT (11.0165).

De estos resultados, se puede concluir que la variable *INONE* fue capaz de discriminar con mayor frecuencia entre empresas quebradas y no quebradas. Lo que sí cabe destacar, es que esta variable disminuyó considerablemente su significancia de una base a otra (de 38.5089 a 8.6411), lo que indica que cuando las empresas son comparadas con los resultados de su industria se hace mucho más visible la diferencia entre una empresa que quiebra y otra que no quiebra, en lo que respecta a si tiene pérdidas o no un año antes de producirse la quiebra.

En cuanto a la variable *DTAT*, ésta aparece como significativa en la base de datos *no ajustada*, lo que indica que en promedio, las empresas escogidas para calcular los promedios industriales, no presentaban una diferencia considerable en las deudas entre una empresa quebrada y una no quebrada.

Contrario a la variable recién nombrada, la variable *VTAT* aparece como significativa en la base de datos *ajustada*, lo que significa que el ajuste industrial permite al modelo visualizar de mejor manera la diferencia entre las ventas de una empresa quebrada y una no quebrada.

Por último, la *variable LNAT* aparece como una variable significativa en el modelo que utiliza la base de datos *no ajustada*, lo que significa que en el ámbito industrial, el tamaño no es determinante al momento de clasificar la quiebra de una empresa, al menos no al compararlo con la base de datos *no ajustada*.

A modo de observación, se puede acotar que el resto de las variables incluidas en los modelos, si bien no cumplieron con el criterio de significancia individual de la prueba aplicada, ayudaron a mejorar la significancia global del modelo, lo que no deja de ser una propiedad importante en un modelo de clasificación y predicción.

En el modelo de *Regresión Logística*, utilizando la base de datos *ajustada*, se pudo demostrar a través de la significancia de la variable LNAT (logaritmo natural de los activos totales) que el tamaño de una empresa, reflejado por su activos, es un excelente índice para tener en cuenta a la hora de predecir y clasificar la quiebra empresarial. Además, si esta variable era analizada en conjunto con el índice de control INONE, podía explicar satisfactoriamente el posible fracaso de una empresa, es decir, que si una empresa posee un tamaño reducido de activos y a la vez finaliza un ejercicio con pérdidas tiene, según este modelo y su base de datos, altas probabilidades de quebrar en el período de ejercicio siguiente.

El mismo modelo de Regresión Logística, pero con una base *no ajustada* arrojó más significativas a dos variables. La primera fue la variable DTAT, con una significancia sobre el nivel requerido (1.96), que permitía deducir que las empresas cuya proporción de activos totales estaba, en gran medida, financiada con recursos de terceros, tenían gran probabilidad de quebrar. Con esta misma base, la variable LNAT fue la más significativa, lo que confirma que el tamaño de los activos de una empresa sí permite diferenciar entre una empresa quebrada y una no quebrada. Se puede concluir que una empresa que posee un alto porcentaje de deuda y además tiene un reducido tamaño de sus activos, es candidata segura para fracasar.

Además, se debe destacar que las tres variables señaladas anteriormente sufren importantes cambios en su significancia de una base a otra, es decir, LNAT que resultó significativa en ambas bases pasó de un 2.158 en la base *ajustada*, a un 2.902 en la base *no ajustada*. Esto indicaría que al corregirse la base por los efectos de

la industria, esta variable pierde significancia para explicar el fracaso empresarial. De la misma forma, es destacable el resultado de la variable DTAT en ambas bases. Esto es, de haber sido muy significativa en la base *no ajustada*, a no serlo en la base *ajustada*. Una posible explicación para esto podría ser que las deudas de una empresa se hacen más importantes al ser analizadas individualmente (por empresa), que al analizarlas incluyendo el efecto de la industria sobre ellas, es decir, se estaría generando un efecto distorsionador a la medida de deuda de la empresa.

Cabe destacar que las variables que no cumplieron con la prueba de significancia individual el modelo “Back-Propagation” de *Redes Neuronales*, las variables utilizadas fueron: ACPC, DTAT, PLPPA y LNAT; las cuales fueron escogidas de acuerdo a lo efectuado por los modelos estadísticos, los que tienen una mayor capacidad explicativa para el fenómeno de la quiebra empresarial. La selección de variables, aplicadas en ambas muestras (*ajustadas y no ajustadas*), fue guiada, primordialmente, por criterios estadísticos, pero también por criterios empíricos, los cuales mostraron que las variables escogidas producían un aumento en la predicción extrapolada, es decir, en el grupo escogido como prueba. Un aspecto interesante a señalar, es que las cuatro variables cubren tres ámbitos importantísimos en el control de la gestión financiera: liquidez (ACPC), endeudamiento (DTAT y PLPPA) y tamaño (LNAT), los cuales unidos permiten predecir con altos niveles de acierto la quiebra empresarial. Otro aspecto utilizado en la selección de variables de las *Redes Neuronales*, fue la desviación estándar que presentaba el conjunto de variables preseleccionadas, es decir, a mayor desviación estándar se producía un mejor aprendizaje de la Red, disminuyendo el número de iteraciones que llevaban a converger el modelo, es decir lograr el error cuadrático medio mínimo.

Análisis de la significancia global de los modelos

De acuerdo a los resultados obtenidos por los modelos de datos ajustados y no ajustados, se presenta a continuación sus respectivas matrices de clasificación y predicción:

Para los datos *no ajustados*, se tiene que:

CUADRO 2
Matriz de clasificación y predicción con datos no ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
GRUPO REAL	GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ	
GRUPO Q	36 85.7%	6 14.3%	4 57.14%	3 42.86%	
GRUPO NQ	7 16.7%	35 83.3%	0 0%	7 100%	
Agrupación Correcta	<i>Clasificación</i>		<i>Predicción</i>		
	84.52% = (71/84)		78.57% = (11/14)		

La matriz correspondiente a la muestra de datos *ajustados* por la industria es la siguiente:

CUADRO 3
Matriz de clasificación y predicción con datos ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
GRUPO REAL	GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ	
GRUPO Q	32 76.2%	10 23.8%	4 57.14%	3 42.86%	
GRUPO NQ	7 16.7%	35 83.3%	0 0%	7 100%	
Agrupación correcta	<i>Clasificación</i>		<i>Predicción</i>		
	79.76% = (67/84)		78.57% = (11/14)		

En relación con lo anterior se observa una mayor capacidad de clasificación para la muestra de datos *no ajustados*, con una diferencia de 4.76 puntos porcentuales (84.52%-79.76%), lo que señala que en cierta medida, para el desarrollo de este modelo en específico, la estandarización efectuada no produjo mejores resultados en térmi-

nos de exactitud clasificativa, mas aún corroborado por la diferencia existente en el *Error Tipo I* de 9.5 puntos porcentuales (23.8%-14.3%), aunque para el *Error Tipo II* no existan diferencias.

Con respecto a la capacidad predictiva del modelo ADM se tiene que, ambas muestras de datos obtienen la misma exactitud en la predicción (78.57%), lo que representa un valor relativamente pequeño para modelos multivariados, aunque debe considerarse lo reducido del tamaño de la muestra de validación. Por otra parte, se confirma que el ajuste de datos realizado, según la industria, no generó un diferencial que represente una mejoría en la estimación. Otro aspecto interesante a señalar en este punto, es la alta tasa de *Error Tipo I* (42,86%), lo que no es buen indicativo, ya que es preferible que éste sea mínimo, debido a las consecuencias que genera en su utilización empírica.

Regresión Logística (LOGIT)

De acuerdo a la estimación realizada por este modelo, para los datos *no ajustados* y con un punto de corte igual a 0.5, se obtuvo la siguiente matriz de clasificación y predicción:

CUADRO 4
Matriz de clasificación y predicción con datos no ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
		GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ
GRUPO Q		37 88.10%	7 16.67%	5 71.43%	2 28.57%
GRUPO NQ		5 11.90%	35 83.33%	1 14.29%	6 85.71%
Agrupación correcta	<i>Clasificación</i>		<i>Predicción</i>		
	85.71% = (72/84)		78.57% = (11/14)		

Para el caso de la muestra de *datos ajustados* la matriz con un punto de corte de 0.5, corresponde a:

CUADRO 5
Matriz de clasificación y predicción con datos ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
		GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ
GRUPO Q		34 80.95%	8 19.05%	5 71.43%	2 28.57%
GRUPO NQ		6 14.29%	36 85.71%	0 0%	7 100%
Agrupación correcta	<i>Clasificación</i>		<i>Predictión</i>		
	83.33% = (70/84)		85.71% = (12/14)		

El desempeño de ambos modelos, en cuanto a su capacidad total de clasificar correctamente los datos no es muy distinto, sin embargo se producen diferencias en cuanto a la clasificación errónea. El *Error Tipo I* es superior para el modelo de *datos ajustados*, con un diferencial de 2.38 puntos porcentuales (19.05%-16.67%), ocurriendo lo mismo para el *Error Tipo II* en donde el modelo de datos *no ajustados* es inferior en 2.39 puntos porcentuales (14.29%-11.90%). Lo anterior indica que, aunque existen diferencias en cuanto a la clasificación errónea, éstas son pequeñas. Sin embargo, en este estudio es conveniente establecer nuevamente que un modelo con un menor *Error Tipo I* es más confiable que un modelo con menor *Error Tipo II*. Esto se debe a que clasificar a una empresa quebrada en no quebrada, produce efectos más negativos a la hora de utilizar esta herramienta en la práctica, como por ejemplo en la clasificación de riesgo, de la cual depende la concesión de préstamos que podrían quedar impagos.

Con respecto al desempeño predictivo de los modelos LOGIT, se tiene que aunque éste es superior para el modelo de datos ajustados, la diferencia viene dada por un error que representa 7.14 puntos porcentuales (85.71%-78.57%). Debe tomarse en cuenta lo reducido de la muestra de validación, lo que permite establecer que ambos modelos son buenos predictores de quiebra empresarial para datos que se encuentran fuera de la muestra.

Redes Neuronales (RN)

La estimación realizada por el modelo “Back-Propagation”, para los datos *no ajustados* y con un punto de corte igual a 0.5, se obtuvo la siguiente matriz de clasificación:

CUADRO 6
Matriz de clasificación y predicción con datos ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
		GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ
GRUPO Q		42 100%	0 0%	7 100%	0 0%
GRUPO NQ		0 0%	42 100%	1 14.29%	6 85.71%
Agrupación correcta	<i>Clasificación</i>		<i>Predicción</i>		
	100% = (84/84)		92.86% = (13/14)		

Para el caso de la muestra de *datos ajustados* la matriz de clasificación, con un punto de corte de 0.5, corresponde a:

CUADRO 7
Matriz de clasificación y predicción con datos ajustados

		GRUPO ESTIMADO POR EL MODELO			
		Muestra de Estimación		Muestra de Validación	
		GRUPO Q	GRUPO NQ	GRUPO Q	GRUPO NQ
GRUPO Q		41 97.62%	1 2.38%	6 71.43%	1 28.57%
GRUPO NQ		3 7.32%	39 92.86%	0 0%	7 100%
Agrupación correcta	<i>Clasificación</i>		<i>Predicción</i>		
	95.24% = (80/84)		95.86% = (13/14)		

Los modelos RN mostraron el mejor desempeño, en cuanto a clasificación y predicción de quiebra empresarial. Aunque debido al alto número de iteraciones que se debieron efectuar para la convergencia de la red, lo que produjo un aparente sobreentrenamiento de ésta, se logró un aprendizaje muy eficiente (debido a la óptima arquitectura utilizada), lo que se refleja en las altas tasas de aciertos. Es así como para el modelo de datos *no ajustados* se obtuvo un 100% en la clasificación y para el modelo de *datos ajustados* se alcanzó el 95.24%. En el caso de la capacidad predictiva de ambos modelos, ésta fue muy alta, demostrando que el modelo RN es un excelente predictor para datos extrapolados, es decir, los que se encuentran fuera del conjunto de entrenamiento, con un 92.86% para los datos *no ajustados* y un 95.86% para los datos *ajustados*.

Conclusiones

De acuerdo con los hallazgos de la investigación, se establece la superioridad del *Modelo de Redes Neuronales* (RN), en cuanto a capacidad de clasificación y predicción de la quiebra de empresas en Chile, sobre los *Modelos de Regresión Logística* (LOGIT) y *Análisis Discriminante* (ADM). Cabe destacar que estos últimos, a diferencia de las RN permiten explicar el fenómeno, lo que se traduce en la identificación de aquellas variables que mejor explican el tema en cuestión. La elección del modelo “Back Propagation” de RN, es sin duda un gran avance en el estudio de los fracasos empresariales en Chile.

Cabe resaltar, también, que los mejores resultados en los tres modelos utilizados se obtuvieron de la base de datos *no ajustada*, lo que implica que el ajuste realizado no aportó mejoras en la estimación. Se postula para posteriores estudios, el mejoramiento del factor de ajuste utilizado en esta investigación. Una situación similar ocurrió con las variables macroeconómicas las cuales tuvieron una mínima significancia individual en todos los modelos resultantes, incluyéndose en algunos sólo por su aporte a la significancia global de los modelos.

Otro de los aspectos a concluir se refiere a la significancia obtenida por las variables. En este sentido, las variables más importantes

MODELOS DE CLASIFICACIÓN Y PREDICCIÓN DE QUIEBRA DE EMPRESAS

fueron las de endeudamiento y tamaño. Las variables de liquidez no fueron tan relevantes en los tres modelos analizados, lo que significa que si una empresa tiene problemas de liquidez en el corto plazo, no representa necesariamente peligro para su futuro desarrollo o permanencia en el tiempo.

Los Modelos ADM y LOGIT, entregan herramientas estadísticas que permiten visualizar la significancia individual de las variables. Sin embargo, el modelo “Back Propagation” de *Redes Neuronales* (RN), por su naturaleza no proporciona dichos elementos de análisis.

Finalmente, se hace hincapié en el hecho de que los modelos utilizados en esta investigación, deben ser constantemente actualizados, revisados y recalibrados para sus futuras aplicaciones, con el objetivo de conservar su buen desempeño. También se deja abierta la posibilidad de la creación de un modelo híbrido que tenga la capacidad de explicar, clasificar y predecir la quiebra empresarial, todo en una sola aplicación que combine técnicas estadísticas y de inteligencia artificial como redes neuronales y sistemas de inducción de árboles de decisión.

Bibliografía

- Almeida F.; Siqueira J. Comparação entre regressão logística e redes neurais na previsão de falência de bancos brasileiros. *Artículo*. Terceiro Congresso Brasileiro de Redes Neurais, 4. Florianópolis. pp.1-6. 1997.
- Altman E.. Financial Ratios. Discriminant analysis and prediction for corporate bankruptcy. *The Journal of Finance*, September 1968.
- _____. *Corporate Financial Distress: A Complete Guide to Predicting, Avoiding, and Dealing With Bankruptcy risk of Corporation*. New York: John Wiley Interscience. 1993.
- Aroca, P.; Romani, G. Impacto de la Administración Financiera en la Probabilidad de Quiebra de Empresas. *Artículo*. Publicado en el XVI Encuentro Nacional de Escuelas y Facultades de Administración y Economía , ENEFA 99. pp. 411- 422. 1999.
- Avellaneda, C. *Diccionario Bilingüe de Términos Financieros*. Universidad de Bogotá. Editorial Mc Graw – Hill. Colombia. 1996.
- Barandiarán, R. *Diccionario de Términos Financieros*, Cuarta Edición. México: Trillas. 1996.
- Basch, M. y Montenegro, C. Aplicación de modelos estadísticos multivariados a la predicción de quiebra de empresas latinoamericanas. *Paradigmas en administración*. Universidad de Chile. Facultad de Ciencias Económicas y Administrativas. N°14 Primer Semestre 1989.
- Beaver, W. H. Financial Ratios as predictors of failure - Empirical Research in Accounting. *Selected Studies*. Chicago University,1967.
- Becerra, R. Predecir la pertenencia de una empresa a grupos con el Análisis Discriminante. *Artículo*. Disponible en Internet:
<http://www.siempre.unizar.es/ciberconta/600.htm>.1998.
- Bolten, S. E. *Administración Financiera*, Segunda Edición. México: Limusa.1990.
- Bonsón, E.; Escobar, T. Y Martín M.: Sistemas de Inducción de Árboles de Decisión. *Artículo*. Disponible en Internet: <http://ciberconta.unizar.es/Biblioteca/0007/arboles.html>. 1996
- Boritz, J. E.; Kennedy, D.B.; De Miranda E Alburquerque, A. *Predicting Corporate Failure Using a Neural Network Approach*. Intelligent Systems in Accounting, Finance and Management School of Accountancy, Canadá. John Wiley & Sons, Ltda., Vol, 4: 95-111. 1995.
- Brealey, R.; Myers, S.C. *Fundamentos de Financiación Empresarial*, Cuarta Edición. España: McGraw Hill. 1997.
- Cortina, A.; Moya, M. *Análisis descriptivo de índices financieros y predicción de quiebra en las Sociedades Anónimas Chilenas*. Tesis de Título, Pontificia Universidad Católica de Chile, Escuela de Ingeniería. Chile, 1980.

MODELOS DE CLASIFICACIÓN Y PREDICCIÓN DE QUIEBRA DE EMPRESAS

- Chávez, G. Historia de tres regímenes de quiebra. *Management en Finanzas*. 1998.
- Episcopos, A. Artificial Neural Networks In Financial Economics. *Artículo*. Disponible en Internet: <http://www.compulink.gr/users/episcopo/tutorial.html>. 1996.
- Gallizo, J. L.; Serrano, C. Las Redes Neuronales Artificiales en el Tratamiento de la Información Financiera. *Artículo*. Disponible en Internet: <http://ciberconta.unizar.es/Biblioteca/0004/SerGall96.html>. 1998.
- Gentry, J.; Newbold, P.&Whithford, D. Classifying Bankrupt Firms with Founds Flow Components. *Journal of Accounting Research*. Vol.23. N°1 Spring 1985.
- Gloubus, G.& Grammatikos. The success of bankruptcy prediction models in Greece, *Studies in Bankruptcy and Finance*, Vol.7,1988.
- Golinski, G. Bankruptcy Prediction Using Neural Networks. *Artículo*. Disponible en Internet: <http://www.stern.nyu.edu/~sjournal/articles/golinski.htm>. 1998.
- Grice, J.S. Examination of Bankruptcy Prediction Models. Sensitivity to Selected Financial Ratios. *TSU Business and Economic Review*. January 1998.
- Hair, J.; Anderson, R.; Tatham, R. *Multivariate Data Analysis*, Second Edition. U.S.A.: Macmillan. 1987.
- Huberty, C. *Applied Discriminant Analysis*. Georgia: John Wiley & Sons Inc. 1994.
- Jiménez, P. *Control de Gestión*. Chile: Editorial Jurídica Conosur. 1996
- Lawrence, S.; Y Haley, CH. *Administración Financiera*. México: McGraw Hill. 1984.
- Matias, A.; Siqueira J. Risco Bancário: Modelo de previsão de Insolvência de Bancos no Brasil. *Rausp Revista de Administração*.Vol 31. 1996.
- Mora, A. Los Modelos de Predicción del Fracaso Empresarial: Una Aplicación Empírica del Logit. *Artículos Doctrinales. Revista Española de Financiación y Contabilidad*. Vol. XXIII. N°78. 1994.
- Narvaez, L.A. Predicción de la Quiebra de Empresas. *Apuntes*. Universidad Austral de Chile. Master en Administración de Empresas. Valdivia. Junio 1994.
- Ohlson, J. Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research*. Vol.18 N°1. Spring 1980.
- Platt, Platt & Gunnar. Bankruptcy Discrimination With Real Variables. *Journal of Business Finance and Accounting*, 21 (4), June 1994.
- Pappoullas,C.& Theodossiou. Corporate Failure Prediction Models for Greece. *Working Paper*, City University of New York, 1987.

- Robertson, T.; Kennedy, J. Prediction of Consumer Innovators: Application of Multiple Discriminant Analysis. *Journal of Marketing Research*. Vol.5. U.S.A.: American Marketing Association. Febrero de 1968.
- Sandoval, R. *Derecho Comercial*. Cuarta Edición. Chile: Editorial Jurídica de Chile. 1995.
- Sarle, W.S. Introduction of Neural Network. *Newsgroup*. Disponible en Internet: <ftp://ftp.sas.com/pub/neural/FAQ.html>. 1997.
- Theodosiou, P. Failure prediction Models in Greece. *Journal of Business Finance & Accounting*, 1991.
- Van Horne, J.C. & Wachowicz. *Fundamentos de Administración Financiera*, Octava Edición, México: Prentice Hall Hispanoamericano S.A., 1994.
- Weston, F. y Brigham, E. *Fundamentos de Administración Financiera*, Décima Edición, México: McGraw Hill, 1994.
- Weston, F. y Copeland, E.. *Fundamentos de Administración Financiera*, Volumen II, Novena Edición, México: McGraw Hill, 1995.
- Weston, F.; Copeland, T. *Finanzas en Administración*, Novena Edición, Volumen I. México: McGraw Hill. 1996.