

Empresas exitosas y no exitosas que cotizan en la BMV del Sector Comercial: Una clasificación con Análisis Discriminante Múltiple, Modelos Logit y Redes Neuronales Artificiales

Oswaldo García Salgado*

Arturo Morales Castro**

Fecha de recepción: 30 de octubre de 2013

Fecha de aceptación: 26 de diciembre de 2013

* Universidad Autónoma del Estado de México,
Facultad de Economía.
oswgars@gmail.com

** Universidad Nacional Autónoma de México,
Facultad de Contaduría y Administración.
amorales@fca.unam.mx

RESUMEN

El presente estudio tiene el propósito de identificar las razones financieras que son determinantes para lograr el éxito financiero de las empresas que cotizan en la Bolsa Mexicana de Valores (BMV), en específico del sector comercial utilizando las técnicas de Análisis Discriminante Múltiple (ADM), el modelo Logit; y las Redes Neuronales Artificiales (RNA). Para ello se consideraron 24 empresas que pertenecían a este sector, tomando en cuenta para cada empresa 37 razones financieras - de liquidez, apalancamiento, solvencia, actividad, y rentabilidad - para el periodo comprendido entre 1995 y 2005. Se consideró como criterios de éxito financiero a aquellas empresas que crean valor teniendo crecimiento consecutivo por tres años en las utilidades netas, el precio del mercado y la Generación Económica Operativa.

Los hallazgos mostraron que los modelos paramétricos ADM y Logit, están limitados debido a sus supuestos estadísticos, en específico en la normalidad exigida en las variables exógenas, a diferencia de las RNA que no están sometidas a condiciones paramétricas, demostrando que aunque todas las razones financieras tienen una participación en la obtención del éxito financiero, existen algunas que influyen más que otras, y que al hacer uso de las RNA es posible considerar el total de las razones financieras, sin descartar ninguna.

Clasificación JEL: C45, G1 y G14

Palabras Claves: Razones financieras, desempeño financiero, redes neuronales artificiales,

Successful and unsuccessful companies from the Commercial Sector listed on the BMV: A classification with Multiple Discriminant Analysis, Logit Models and Artificial Neural Networks.

ABSTRACT

The aim of this study is to identify the financial ratios that are crucial for the financial success of the companies listed on the Mexican Stock Exchange (MSE) specifically from the commercial sector using Multiple Discriminant Analysis (MDA), Logit model, and Artificial Neural Networks (ANN) techniques. 24 companies belonging to this sector were considered, taking into account 37 financial ratios - liquidity, leverage, solvency, activity, and profitability - for each company in the period between 1995 and 2005. It was considered as a criteria of financial success the companies that create value and consecutive growth in three years in net incomes, the market price and Operative Economic Generation.

The findings showed that the parametric models MDA and Logit, are limited because of their statistical assumptions, specifically in normality required in the exogenous variables, unlike the ANN that are not subject to parametric conditions, showing that although all financial ratios have an interest in obtaining financial success, there are some that have more influence than others, and that in using ANN is possible to consider the total financial ratios, without discarding any.

JEL classification: C45, G1 and G14

Key words: Financial ratios, financial performance, artificial neural networks.

Introducción

En México, el entorno operativo para el sector comercial se ha vuelto menos favorable desde la crisis crediticia del 2008, la crisis económica del 2009 y la recesión prolongada de la economía mexicana. Esto ha provocado que las condiciones del mercado bursátil sean más difíciles. Por ello, los esfuerzos para predecir dificultades financieras han recibido considerable atención en la literatura financiera, la contabilidad y la auditoría durante más de medio siglo (Anandarajan *et al.*, 2001). Estudios previos indican que el desempeño financiero desde el enfoque de quiebras empresariales no es un evento inmediato, sino más bien un proceso que evoluciona a lo largo de un período considerable de tiempo, lo que proporciona una base para los intentos de predecir estas quiebras.

A la fecha, los modelos de predicción del desempeño financiero se han desarrollado principalmente para el sector manufacturero, y pocos estudios se han enfocado en otros sectores, como es el comercial. Sin embargo, las empresas en el sector comercial son muy vulnerables a los cambios económicos, especialmente en malas condiciones de mercado (Gu, 2002). El riesgo de una quiebra financiera o la poca capacidad de generar valor en el sector comercial de la Bolsa Mexicana de Valores requiere el desarrollo de modelos de predicción de desempeño con capacidad predictiva superior a los modelos tradicionales, (Kim y Gu, 2006 a y b).

En estudios realizados por Dimitras *et al.* 1996; Sirakaya *et al.* 2005; Wu *et al.* 2006, basándose en datos financieros de empresas del sector comercial, en específico restauranteras de Estados Unidos desarrollan modelos de redes neuronales artificiales (RNAs) para la predicción de quiebra. Como una técnica no paramétrica, el modelo de Redes Neuronales tiene la capacidad de predicción al clasificar a las empresas en quiebra en comparación con la regresión logística. Por otro lado, la técnica de RNA, determina razones financieras que la regresión logística no toma en cuenta.

En los trabajos realizados en México sobre desempeño financiero se encuentra el de Morales (2007), en el que se analiza este mismo sector, aplicando técnicas estadísticas basadas en modelación paramétrica como el Análisis Discriminante (ADM) y el modelo Logit. Sus resultados fueron que existen

seis razones financieras que determinan el éxito para el primer modelo, y siete para el segundo. Este autor consideró 37 razones financieras.¹

Esta investigación es una ampliación de dicho trabajo en el que se hace un comparativo de las mismas 37 razones financieras pero contrastando sus hallazgos con los obtenidos al aplicar Redes Neuronales Artificiales, debido a que esta técnica de inteligencia artificial ofrece un espectro más amplio de elección a diferencia de las técnicas paramétricas usadas por Morales (2007), que solo detectan aquellas razones financieras que cumplen con las pruebas estadísticas, en contraste las Redes Neuronales Artificiales detectan todas las razones financieras sin importar si cumplen con las pruebas estadísticas para determinar si las empresas son financieramente exitosas o no.

1. Revisión a la Literatura

Un método fundamental para comparar los diferentes modelos es calcular la tasa de precisión global de los modelos de predicción. Hay una serie de trabajos publicados sobre la predicción de empresas en quiebra, en la que utilizaron RNA, ADM y modelos logísticos, además de otros métodos de cálculos estadísticos. En uno de los primeros estudios, Hansen y Messier (1991) usan la RNA de retro propagación, la regresión logística, y los algoritmos genéticos para analizar su desempeño en informes publicados de empresas con problemas financieros del mercado financiero. Sus resultados explican que las redes neuronales artificiales superan a otros métodos. Fanning y Cogger (1994), comparan la capacidad de un procesador de algoritmo de red neuronal adaptativa generalizada del inglés *Generalized Adaptive Neural Network Algorithm* (GANNA), una RNA de retro propagación, la regresión logística, y un modelo basado en la teoría de juegos para clasificar a los bancos con problemas financieros. Sus resultados indican que el rendimiento de la RNA es un excelente clasificador comparado con las técnicas tradicionales.

Bell *et al.* (1997), utilizan una red neural de retro propagación para clasificar a los bancos, ya sea en quiebra o no quiebra. Comparan los resultados obtenidos por la RNA con un modelo logit con respecto a la precisión del desempeño y llegan a la conclusión de que tanto la RNA como los modelos logit se desempeñan igualmente bien en toda la gama de posibles valores del modelo de corte, pero la RNA tiene mejor precisión.

¹ Morales (2007) cita a Westwick (1987), con respecto a su metodología para seleccionar las razones financieras de su investigación.

Ala vez, Koh (2004) compara la utilidad de las redes neuronales, los árboles de decisión y la regresión logística para predecir el estado de continuidad de las actividades de una empresa. Los resultados de la clasificación indican que las técnicas de minería de datos, tales como las redes neuronales y los árboles de decisión son de gran alcance para el análisis de las complejas relaciones no lineales y la interacción, y por lo tanto, pueden complementar los métodos estadísticos tradicionales en la construcción de los modelos de predicción

Yildiz y Yezegel (2010) proponen una arquitectura Neuronal para predecir los rendimientos futuros en valores NYSE / AMEX / Nasdaq para el período 1990-2005, a través del análisis fundamental y los valores de retorno de la tecnología: considerando dieciocho razones financieras como nodos de entrada y los rendimientos de las acciones para un periodo adelantado de un año como nodo de salida. Estos investigadores, concluyen que las redes neuronales artificiales se destacan como una herramienta valiosa para el análisis fundamental y la previsión de rentabilidad de las acciones en los mercados de Estados Unidos de América.

Por otra parte Roli (2012) realizó un estudio relacionado con la predicción financiera del Banco Indio HDFC (Housing Development Finance Corporation), mediante la construcción de un modelo BPNN del inglés (*Back Propagation Neural Network*). Para su arquitectura consideró 55 razones financieras de esta institución crediticia, dentro del periodo 2000-2008 y su objetivo era predecir el comportamiento de cada razón de 2009-2015, entrenando una red neuronal y obteniendo resultados con una alta predicción entre las razones financieras del 2009 y 2010. Roli (2012) concluye su investigación comentando que los modelos BNPP pueden ser utilizados como una herramienta de enlace entre el analista de riesgo de crédito y los responsables de las políticas de riesgo crediticio de los bancos.

Además, Ecer Faith (2013), desarrolló un modelo de red neuronal, con el propósito de identificar si los recursos de la empresa se utilizaban de manera eficiente, para las 500 principales empresas de Turquía entre 1993 a 2009. Para ello y para predecir el desempeño financiero de las empresas se tomaron en cuenta como variable dependiente a la utilidad antes de impuestos y como variables independientes las ventas totales, el capital social, los activos circulantes y fijos, la exportación, y el número de empleados. El estudio utilizó técnicas de inteligencia artificial como son los árboles de decisión, los modelos neuronales tipo perceptrón multicapa y las funciones de base radial todos ellos para poder predecir.

Lo anterior, mostró que los modelos de redes neuronales artificiales tienen un mejor rendimiento que los árboles de decisión en términos de sus tasas de precisión y que pueden ser utilizados para predecir el rendimiento financiero. Por otra parte, se encontró que los modelos perceptrón multicapas tenían mejor capacidad de predicción que las funciones de base radial; también se encontró que las RNA y los árboles de decisión tuvieron la capacidad de modelar con éxito las relaciones no lineales. Por ello el analizar el desempeño financiero a través del uso de las RNA es de interés para hacer estudios comparativos entre diferentes técnicas y en este caso para el área financiera de las empresas.

2. Fundamentos de las Redes Neuronales Artificiales (RNA)

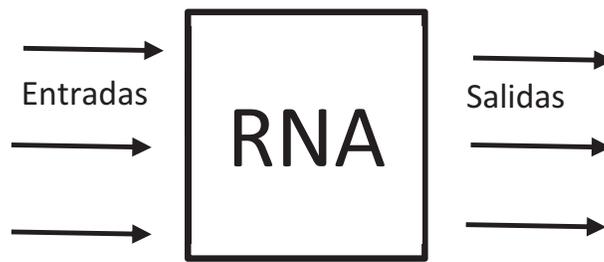
Las Redes Neuronales siguen el modelo de los métodos de procesamiento en paralelo del cerebro humano. El cerebro biológico se compone de miles de millones de elementos de procesamiento interconectados llamadas neuronas, que transmiten información y se fortalecen cuando el cerebro aprende. Una RNA es un modelo lógico matemático compuesto por varias unidades de cómputo interconectadas llamadas neuronas o nodos.

Cada nodo realiza una operación sencilla con una entrada seguida de una capa oculta para conectarse a través de una función de transferencia, y volverse a conectar a la capa oculta con la capa de salida que se envía con otra función de transferencia en secuencias. Este procesamiento en paralelo tiene ventajas en el análisis de datos, ya que el procesar la información de esta manera no solo permite aprender de los errores, sino que permite aprender de ejemplos, y reconocer patrones en los datos.

Estructura Perceptrón Multicapas (MLP)

Las RNA tienen diferentes estructuras y arquitecturas. En esta investigación se utilizó la RNA de tipo Perceptrón Multicapas creada por Rosenblatt (1958). Su forma de aprender es bajo un proceso de ajuste de las sinapsis de información inicial y al añadirse nueva información, ésta va reconociendo los pesos específicos que le corresponden a cada arquitectura al proponer diferentes funciones de transferencia. Una estructura simplificada de una RNA-MLP de este proceso se proporciona en la Figura 1.

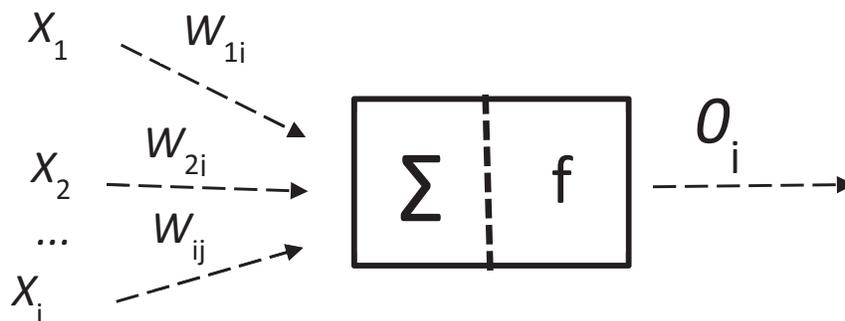
Figura 1. Estructura simplificada de una red neuronal artificial.



Fuente: Elaboración propia.

La estructura básica de la RNA consta de neuronas artificiales que se agrupan en capas. Una estructura de una neurona (*Perceptrón*) se presenta en la Figura 2.

Figura 2. Componentes de una Neuronal de tipo Perceptron.



Fuente: Elaboración propia.

Aquí se considera a X_1, X_2, \dots, X_i , como las variables de entrada de la neurona. Cada conexión tiene su peso unido a un peso específico llamado W_{ij} donde j es el número de las neuronas e i representa el i -ésimo elemento de entrada. Los pesos pueden ser tanto positivos como negativos. La neurona resume todas las señales que recibe multiplicando cada entrada por su peso asociado:

$$h_j = \sum (W_{ij} \cdot X_i) \quad (1)$$

El elemento Σ es a menudo llamado el nodo de suma. Esta salida h_j va a la siguiente etapa a través de una función de activación o función de transferencia:

$$O_j = f(h_j) = f\left(\sum (W_{ij} \cdot X_i)\right) . \quad (2)$$

La función de activación, en la mayoría de los casos, es una función continua, no lineal, entre valores de su imagen o contra dominio entre valores de 0 y 1, o en otros casos entre -1 y 1. La función de activación se elige de acuerdo a las necesidades específicas: la función más popular es la función sigmoidea o logística, como se muestra en la ecuación 3:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

y otra función muy utilizada son de tipo tangente hiperbólica:

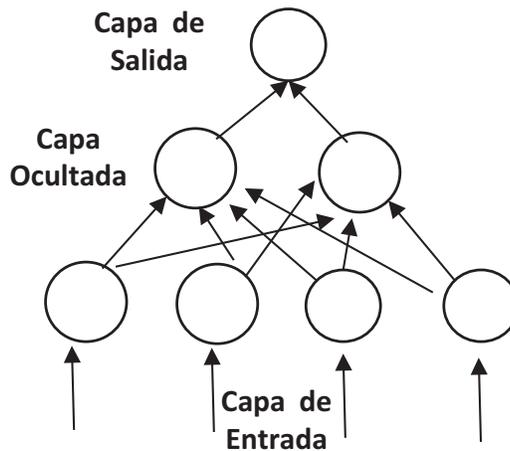
$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

Estas funciones son las más ampliamente utilizadas debido a su fácil diferenciación entre grupos, es decir funciones clasificadoras que permiten clasificar de manera adecuada. Aunque existen otras funciones que también son posibles, como son la función lineal o identidad, senusoidal, softmax, y los modelos de base radial entre otras.

Una estructura de varios *Perceptrones* y sus conexiones se llama Modelo *Perceptrón* Multicapa (MLP). Por lo general se compone de varias capas de neuronas. En la primera capa se recibe la información externa y se llama capa de entrada. La última capa es la capa de salida, donde se logra la respuesta al problema. Estas dos capas están separadas por una o más capas (llamadas capas ocultas). Si todos los nodos están conectados desde la parte inferior a las capas superiores, la RNA se llama una red conectada en capas y nodos.

La red se alimenta de información fluyendo hacia adelante (*feed forward*) para conocer su objetivo, y después de aprender, su alimentación regresa hacia atrás (*feed back*) para calibrar el modelo, a través de pesos específicos entre sus interconexiones. Existen otros tipos de RNA, pero esta investigación se centra en las RNA de tipo MLP que son de las más usadas para clasificar. La estructura de una RNA se proporciona en la Figura 3.

Figura 3. Red Neuronal Artificial de tipo MLP con aprendizaje feedforward típica.



Fuente: Elaboración propia.

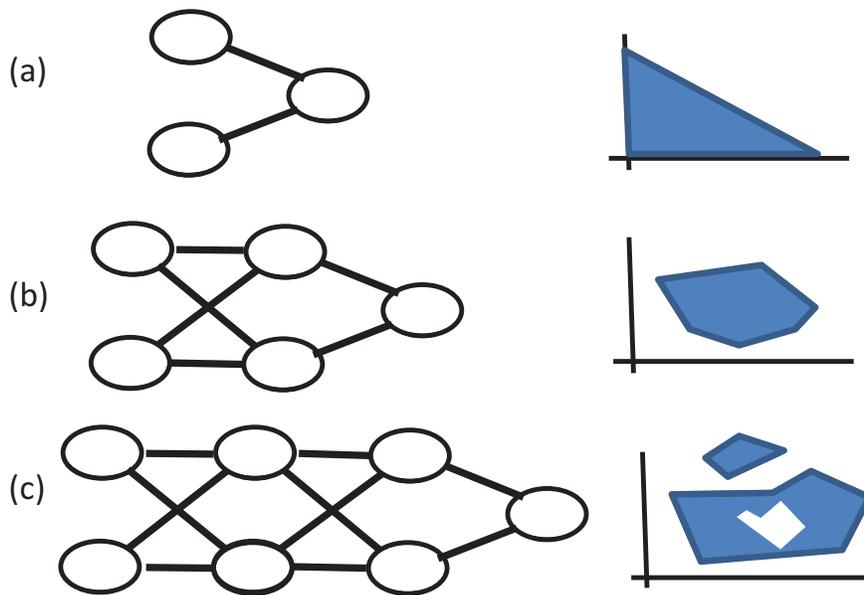
La cantidad de neuronas en cada capa puede tener diferentes características específicas y el número de capas ocultas puede ser también de cero a decenas o más según los objetivos específicos del diseñador de la red. La estructura de la RNA de tipo MLP depende de la naturaleza de todos los datos específicos.

El algoritmo de retro propagación es importante ya que su fin es encontrar los pesos más apropiados W_{ij} , que la RNA requiere para el procedimiento de aprendizaje. El aprendizaje supervisado es el tipo más común. La idea de este algoritmo es ajustar los pesos de una manera que se determiné un valor predicho d_i determinado por las funciones de transferencia y compararlo con un valor real y_i , donde el error debe ser reducido entre la salida deseada y el objetivo y se determina de la siguiente manera:

$$E = \frac{1}{2} \sum (y_i - d_i)^2 \quad (5)$$

En una red neuronal se exhiben algunas habilidades estadísticas en función de su arquitectura, especialmente, cuando se enfrenta con un problema de clasificación si una entrada debe ser clasificada de clase A o B. Una red neuronal que tiene función de transferencia y un nivel umbral de conexión se puede utilizar para separar el espacio de decisión en dos categorías con una línea (Ver Figura 4.a). Una red neuronal con dos niveles de conexión puede separar el espacio de entrada al abrir planos cóncavos convexos o cercanos (Ver Figura 4.b). Si la red neuronal tiene niveles de conexión de árbol, tiene la capacidad para separar el espacio de entrada en un número de planos abiertos o cerrados (Ver Figura 4.c) (Bishop, 1997).

Figura 4. Arquitectónicas de una RNA MLP según sus capas ocultas debido a la dificultad de clasificación de grupos.



Las redes neuronales pueden presentar una cierta capacidad de estadística de acuerdo con sus estructuras. (a) La red neuronal consiste sólo en una capa de entrada y una de salida y se puede separar el espacio de entrada en dos grupos lineales. (b) La red neuronal consta de una capa oculta se puede separar el espacio de entrada para cóncava cerrada y la grupos convexos. (c) La red neuronal consiste de más de una capa oculta y se puede separar el espacio de entrada para muchos grupos abiertos y cerrados.

Fuente. Elaboración propia basada en Bishop (1997).

En esta investigación se utilizó el tipo de red neuronal Perceptrón Multicapas, en donde se tomaron como capa de entrada a 37 razones financieras que son los nodos y como capa de salida se consideró al desempeño financiero de las empresas del sector comercial clasificadas como exitosas o no exitosas. La red planteada tuvo como propósito aprender y determinar qué razones financieras llevaban a clasificar a las empresas como exitosas o no exitosas financieramente hablando.

3. Metodología utilizada

El objetivo principal de este análisis se centró en conocer si las técnicas paramétricas ADM y Logit consideraban a las mismas razones financieras que la técnica de las Redes Neuronales Artificiales para determinar si una empresa era exitosa o no financieramente.

Para el desarrollo de este análisis se hizo un comparativo de los hallazgos obtenidos por Morales (2007), y se agregó el análisis de la información con la técnica de Redes Neuronales Artificiales. Para dicho análisis, el modelo neuronal utilizó arquitecturas que tomaron en cuenta a todas las razones financieras —37 razones financieras—, a diferencia de los modelo ADM y Logit, que por sus características estadísticas² deben de excluir variables o razones financieras que no les permiten validar cada modelo, que es lo que hace diferente a la técnica de Inteligencia artificial, pues toma en cuenta todos los factores si es que así lo desea el diseñador de la red.

La metodología empleada en esta investigación comprendió las etapas siguientes:

1. Conformación de la base de datos, compuesta por 24 empresas que cotizan en la Bolsa Mexicana de Valores pertenecientes al sector comercial.
2. Obtención de 37 razones financieras que miden el desempeño empresarial en base a su clasificación de liquidez, apalancamiento, solvencia,

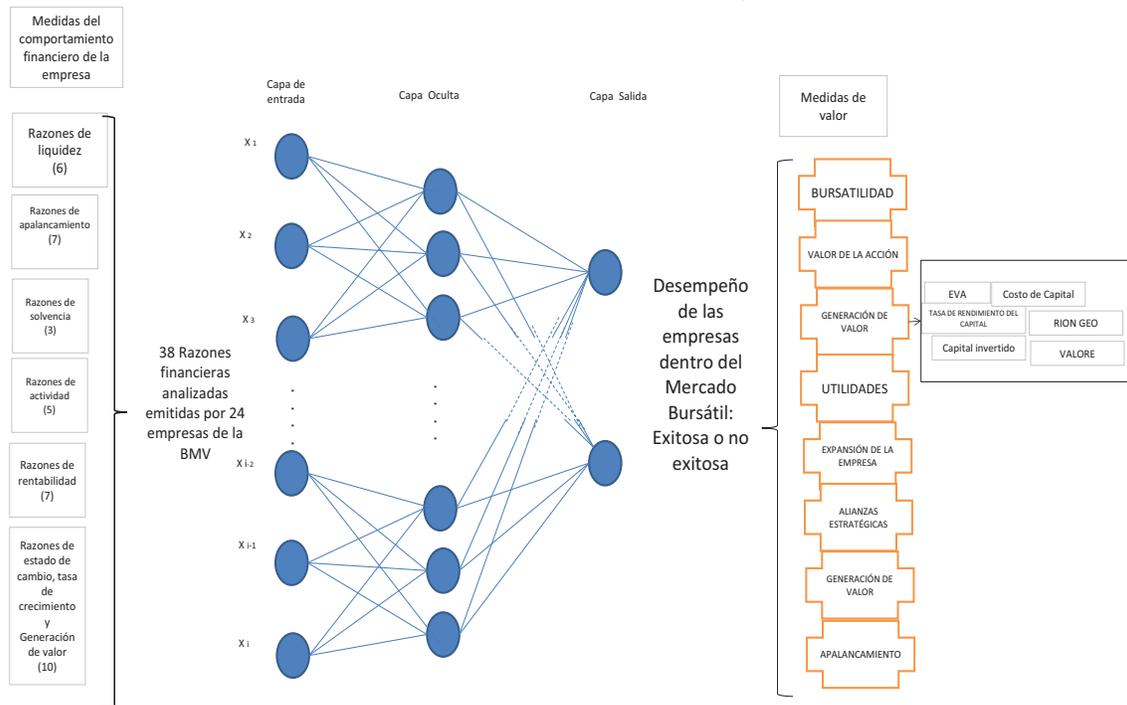
² Se refiere a que los modelos deben considerar proporcionalidades entre grupos casi iguales, deben de pasar pruebas de inferencia como la lambda de Wilks, M de Box, y prueba de matrices no singulares en el modelo discriminante; y además encontrar rotaciones que maximicen la diferencia entre grupos (Varimax). Para los modelos Logit deben considera las pruebas de los coeficientes de la función de clasificación de Fisher y descomposición de Matrices de Varianzas y Covarianzas, además de la prueba LR.

Y por último el comportamiento de las variables exógenas deben pasar la prueba K-S de normalidad.

actividad, rentabilidad, tasas de crecimiento y generación de valor. En el periodo comprendido de 1995 a 2005 con periodicidad anual. Se consideraron estas porque fueron las que se pudieron deducir de los estados financieros reportados por la BMV.

3. Determinación de los tres indicadores financieros que miden el desempeño financiero empresarial por los accionistas para clasificar a las empresas exitosas y no exitosas. Los indicadores fueron a) variación en el valor de la acción, b) Utilidades netas en los últimos 5 años y c) Generación Económica Operativa.
4. Establecimiento de los criterios de entradas y salidas para la construcción de los diferentes modelos (ADM, Logit y RNA MLP). En donde las entradas fueron las razones financieras y la salida el criterio de desempeño (exitosa y no exitosa).³ Ver Figura 5.

Figura 5. Conceptualización de la RNA para determinar las empresas exitosas o no exitosas del sector comercial de la BMV.



Fuente: Elaboración propia.

³ Las empresas exitosas de la BMV del Sector Comercial, según el criterio de Morales (2007), fueron aquellas que: a) Tuvieron crecimiento en el valor de la acción en los últimos cinco años, b) Su capacidad de Generar Valor Económica Operativa de manera positiva durante los últimos cinco años y c) La capacidad de Generar

5. Se analizaron los resultados entre los diferentes modelos planteados.
6. Se compararon las razones financieras que determinó cada modelo, para comprobar si existía similitud en la determinación de las razones financieras, o había diferencia.

4. Resultados y Discusión

Las empresas que fueron consideradas en este estudio se muestran en la tabla siguiente:

Tabla 1. Empresas del Sector Comercio de la BMV que participaron en el estudio.

Clave de BMV	NOMBRE DE LA EMPRESA	Clave de BMV	NOMBRE DE LA EMPRESA	Clave de BMV	NOMBRE DE LA EMPRESA
ALMACO	COPEL S.A. DE C.V.	ECE	ECES.A.DEC.V.	GPH	GRUPO PALACIO DE HIERRO, S.A. DE C.V.
ALSEA	ALSEA S.A. DE C.V.	EDOARDO	EDOARDOS S.A DE C.V.	LIVERPOOL	EL PUERTO DE LIVERPOOL, S.A. DE C.V.
BEVIDES	FARMACIAS BENAVIDES S.A. de C.V.	ELEKTRA	GRUPO ELEKTRA S.A. DE C.V.	MADISA	MAQUINARIA DIESEL, S.A. DE C.V.
CNCI	UNIVERSIDAD CNCI S.A. DE C.V.	FRAGUA	CORPORATIVO FRAGUA	MARTI	MARTIN S.A. DE C.V.
COLLADO	G. COLLADO S.A. DE C.V.	GCORVI	GRUPO CORVI S.A. DE C.V.	GSANBOR	GRUPO SANBORNS S.A. DE C.V.
COMERCI	CONTROLADORA COMERCIAL MEXICANA S.A. DE C.V.	GFAMSA	GRUPO FAMSA, S.A. DE C.V.	SAB	GRUPO CASA SABA, S.A. DE C.V.
DERMET	DERMET DE MÉXICO S.A. DE C.V.	GIGANTE	GRUPO GIGANTE S.A. DE C.V.	SORIANA	ORGANIZACIÓN SORIANA, S.A. DE C.V.
DOCUFOR	DOCUFORMAS S.A. DE C.V.	GOMO	GRUPO COMERCIAL GOMO, S.A. DE C.V.	WALMEX	WALMART DE MEXICO, S.A. DE C.V.

Fuente: Elaboración propia basada en la información de Morales (2007).

Utilidades Netas de manera positiva en los últimos cinco años en forma constante. Y las empresas No Exitosas fueron las que no cumplieron con estos criterios.

Una vez determinadas las emisoras que conforman el sector comercial se procedió a determinar las razones financieras, clasificadas en seis grupos de razones, obtenidas de la información de la BMV. Esto se muestra en la Tabla 2.

Tabla 2. Clasificación de las Razones financieras consideradas en el estudio.

Razón financiera	No.	Relación Contable	Razón financiera	No.	Relación Contable	
LIQUÍDEZ	1	Activo Circulante Pasivo Circulante	SOLVENCIA	14	Intereses Pagados Resultado de Operación	
	2	Activo Circulante Activo Total		15	Pasivo Largo Plazo Activo Fijo	
	3	Activo Circulante Pasivo Total		16	Ventas Netas Pasivo Total	
LIQUÍDEZ	4	Efectivo e Inver. Temporales Pasivo Circulante	ACTIVIDAD	17	Ventas Netas Activo Total	
	5	Activo Circulante e Invent. Pasivo Circulante		18	Ventas Netas Activo Fijo	
	6	Variación Flujo Efectivo Pasivo Total		19	Costo Ventas Inventarios	
	7	Pasivo Total Activo Total		20	Cuentas por Cobrar (Ventas/360)	
	8	Intereses Pagados Pasivo con Costo		21	360/Días de ventas por cobrar	
APALANCAMIENTO	9	Pasivo Mon .Ext. Pasivo Total	ACTIVIDAD	22	Resultado Neto Ventas Netas	
	10	Capital Contable Activo Total		RENTABILIDAD	23	Resultado Neto Activo Total
	11	Pasivo circulante Activo Total			24	Resultado Neto Capital Contable
	12	Pasivo Total Capital Contable			25	Resultado Neto Activo Fijo
13	Ventas Netas Capital de Trabajo	26	Resultado Operación Activo Total			
ESTADO DE CAMBIOS, TASAS DE CRECIMIENTO Y GENERACIÓN DE VALOR	29	Flujo Derivado Resultado Neto Ventas Netas	RENTABILIDAD	27	Dividendo Efectivo Resultado Ejerc. Ant.	

	30	Flujo Derivado cambios Capital Trabajo Ventas Netas		28	CIF Resultado Neto
	31	Rec. Generados (Utilizados) Operación Intereses Pagados		34	Adquisición Inm. Planta y Equipo Recursos Generados (Utilizados) Act. Inversión
	32	Financiamiento Ajeno Recursos Generados (Utilizados) Financiamiento	ESTADO DE CAMBIOS, TASAS DE CRECIMIENTO Y GENERACIÓN DE VALOR	35	Cash Flow Operativo Pasivo Total
	33	Financiamiento Propio Recursos Generados (Utilizados) Financiamiento		36	Cash Flow Operativo Pasivo Circulante
				37	EVA (Valor Económico Agregado)
				38	GEO (Generación Operativa Neta)

Fuente: Elaboración propia basada en la información de Morales (2007).

Para la realización de los modelos ADM y Logit se usó el software SPSS v. 17 y para la construcción de la Red Neuronal Artificial se utilizó el Software NN. 4.0.

En la Tabla 3 se muestran las razones que se consideraron para los modelos ADM y Logit, que permitieron clasificar a las empresas exitosas y no exitosas. Considerándose como exitosas a aquellas que cumplieron con las tres condiciones del desempeño financiero; *a*) variación en el valor de la acción, *b*) Utilidades netas en los últimos 5 años y *c*) Generación económica operativa.

En la Tabla 3 se presentan en la primera columna las variables consideradas en el modelo multivariado como exógenas. En la columna dos y tres se muestra el número de razón financiera que se determinaron en los modelos ADM y Logit. En la Columna cuatro se muestra la Razón financiera que considero el modelo de acuerdo a su numeración en la Tabla 2 y la columna cinco reporta a que grupo de Análisis financiero pertenece la razón respectiva. Estas variables conforman los modelos ADM y Logit que se mencionan a continuación.

Tabla 3. Razones Financieras usadas para el modelo ADM y el modelo Logit que determinan las empresas exitosas o no exitosas del sector comercial de la BMV.

Nombre de la variable	Número de Razón financiera de acuerdo al modelo		Relación contable	Grupo al que pertenece la razón financiera
	Análisis Discriminante Múltiple. (ADM)	Logit		
Variable	Puntuación discriminante Z	Puntuación discriminante L		
Capacidad de clasificación				
X1	2	2	Activo Circulante / Activo Total	Liquidez
X2	3		Activo Circulante / Pasivo Total	Liquidez
X3	4	4	(Efectivo e Inversiones Temporales) / Pasivo Circulante	Liquidez
X4		5	(Activo Circ.-Inventarios) / Pasivo Circulante	Liquidez
X5	18	18	Ventas Netas / Activo Fijo	Actividad
X6	19	19	Costo Ventas / Inventarios	Actividad
X7		21	360 / Días de ventas por cobrar	Actividad
x8	26	26	Resultado Operación / Activo Total	Rentabilidad

Fuente: Elaboración propia basada en la información de Morales (2007).

La Función ADM (Z) para el periodo de 1995 a 2005 está dada por la siguiente expresión:

$$\begin{aligned}
 Z = & -2.814 + 5.772 \left(\text{Activo Circulante} / \text{Activo Total} \right) - 0.822 \\
 & \left(\text{Activo Circulante} / \text{Pasivo Total} \right) + 0.581 \left(\text{Efectivo e Inversiones} \right. \\
 & \left. \text{Temporales} \right) / \text{Pasivo Circulante} - 0.174 \left(\text{Activo Circ.-Inventarios} \right) / \\
 & \text{Pasivo Circulante} + 0.078 \left(\text{Costo Ventas} / \text{Inventarios} \right) + \quad (6) \\
 & 15.223 \left(360 / \text{Días de ventas por cobrar} \right)
 \end{aligned}$$

Por otra parte, el modelo logit (L) para la misma investigación en el mismo periodo está dado por la siguiente expresión:

$$L = -8.435 + 13.022 (\text{Activo Circulante} / \text{Activo Total}) + 1.08 (1 \text{ Efectivo e Inversiones Temporales} / \text{Pasivo Circulante}) - 1.246 (\text{Activo Circ.-Inventarios} / \text{Pasivo Circulante}) - 0.456 (\text{Ventas Netas} / \text{Activo Fijo}) + 0.203(\text{Costo Ventas} / \text{Inventarios}) + 0.008 (360 / \text{Días de ventas por cobrar}) + 24.787 (\text{Resultado Operación} / \text{Activo Total}) \quad (7)$$

5. Diseño de la Red Neuronal

Los modelos multivariantes clasificadores analizados hasta el momento han sido aplicados para poder predecir el desempeño de las empresas del sector comercial de la BMV; pero en esta etapa se comparara con un modelo de inteligencia artificial, para conocer si existe diferencias en encontrar otras razones financieras que no determinaron los modelos anteriores, o por otro lado, las RNA; también detectan las mismas razones financieras. Esto permitirá de alguna manera conocer si hay diferencias en la determinación de las empresas exitosas y no exitosas debido a la técnica utilizada; y por qué no hay diferencia o por que sí.

Para ello, se realizaron un total de quince⁴ arquitecturas para la construcción de la Red neuronal buscada. La condición de esta Red neuronal fue que la arquitectura buscada considerara las 37 razones financieras tomadas en cuenta en la investigación, con el propósito de conocer la sensibilidad que tiene cada una de ellas para cumplir su objetivo con respecto al criterio de exitosa o no exitosa en cuanto a su desempeño financiero. El criterio para determinar la arquitectura adecuada en la investigación se fundamentó en los siguientes aspectos: *a)* que la RNA tuviese la mayor capacidad en clasificar correctamente a las empresas exitosas y no exitosas, *b)* que la RNA convergiera adecuadamente y no entrara en un sobre entrenamiento, *c)* que esta red tuviese el mínimo número de nodos en la capa oculta de la arquitectura de la Red, *d)* que las funciones de transferencia estuviesen entre las funciones de tipo lineal, idéntica, softmax, logística, exponencial, sinusoidal, tangente hiperbólica, lognormal, y funciones de base radial.

Como ya se mencionó, las RNA's consideradas en esta investigación fueron Redes Neuronales Artificiales de tipo perceptrón multicapas, y se consi-

⁴ En el Anexo I se presentan las diferentes arquitecturas neuronales planteadas en este trabajo.

deraron arquitecturas con dos o tres capas ocultas; con la capacidad de clasificar las emisoras exitosas y no exitosas por arriba del 90%. Estas RNA se entrenaron con el 70% de la base de datos para su aprendizaje, y el 30% para comprobar la capacidad de verificación con los datos reales. La base de datos estuvo conformada por 8,8800 datos (24 empresas del sector pertenecientes a la BMV del sector comercial que cotizaron de 1995-2005 x 37 razones financieras por un periodo de 10 años).

El algoritmo de entrenamiento se fundamentó en modelos iterativos BFGS,⁵ con un nivel de decaimiento de 0.05. La mejor Red Neuronal Artificial se consideró bajo tres criterios. El primero por el porcentaje de clasificación que tiene la red para determinar exitosa y no exitosa. El segundo por la parsimonia de las capas ocultas, y el último la sencillez de la función de transferencia.

El modelo Neuronal encontrado para esta investigación fue una RNA que tiene una arquitectura MLP 37-10-2, es decir 37 variables de entrada (en este caso las razones financieras), una capa oculta con diez nodos, y dos nodos de salida que fueron el desempeño financiero con el criterio de exitosas y no exitosas con una precisión del 95% (clasificando el 100% en el entrenamiento de su aprendizaje, y 89.8% en su etapa de verificación). En la Tabla 4 se muestra el resumen de esta RNA.

En la Tabla 4 se aprecia que las funciones de transferencia entre los nodos de entrada y la oculta determinaron que una función logística es la apropiada.

Tabla 4. Resultados de la RNA que mejor clasifica a las empresas del Sector Comercial de la BMV 1995.

Número de corrida	Arquitectura de la red	Desempeño del enfren.	Desempeño de la preba	Algoritmo del enfrentamiento	Función de terror	Activación de la capa oculta	Activación de la capa de salida
10	MLP 37-10-2*	100.00000	89.83051	BFGS 57	Entropia	Logistica	Softmax

* Nivel de predicción del 95.0%

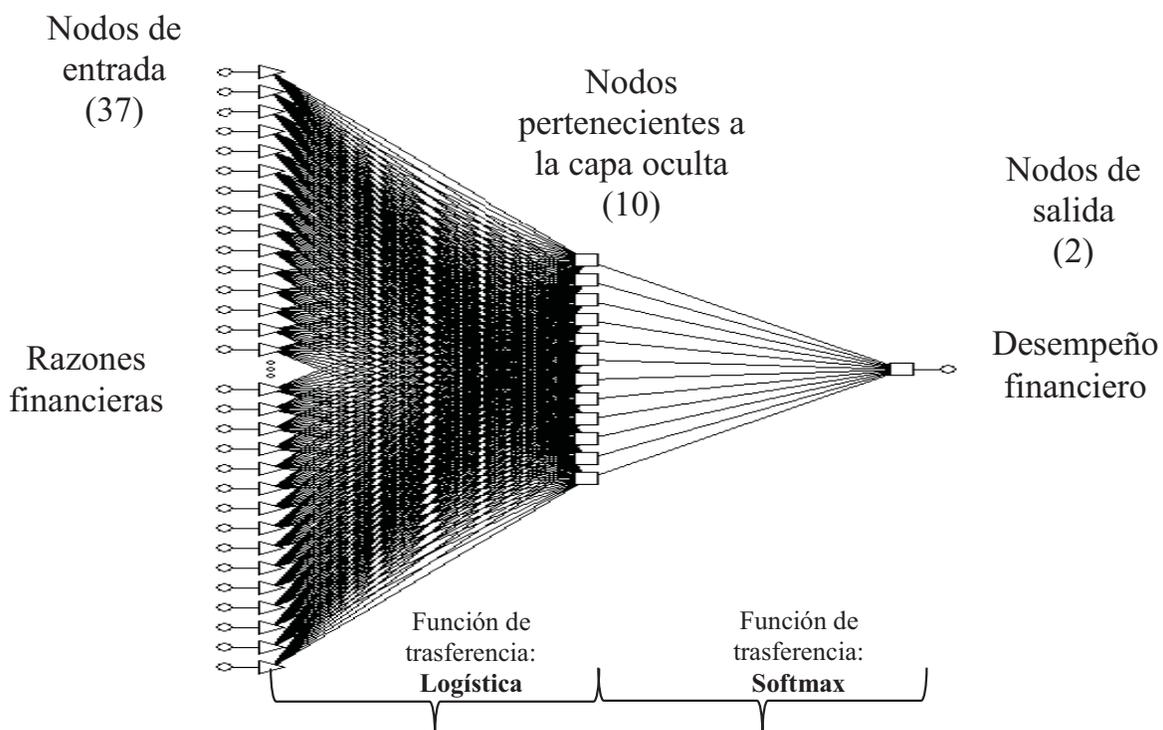
Fuente: Elaboración propia basada en los resultados de la construcción de la RNA.

⁵ Método Numérico denominado Broyden – Fletcher – Goldfarb – Shanno (BFGS) que permite optimizar el error entre los datos reales y los del modelo propuesto, sin someterlo a ninguna restricción para problemas de funciones no lineales.

da, mientras que para la función de transferencia entre la capa oculta y la de salida, el modelo considero una función de tipo *softmax*; comprobando con estas funciones que las relaciones entre las variables de entrada y de salida son topológicamente no lineales. Es decir, mientras que en los modelos multivariantes como son los ADM y Logit, los grupos se clasifican bajo un enfoque de algebra lineal mediante estadística gaussiana, en las redes neuronales se clasifican mediante aprendizaje de funciones de transferencia no lineal y sin las condiciones de normalidad en las variables de análisis, lo que hace que la topología, es decir, los espacios vectoriales de las variables sean más complejos en su arquitectura matemática pero más precisos en su clasificación.

En la Figura 6 se muestra un diagrama de la arquitectura neuronal MLP 37-10-2. En este caso como la capa oculta tiene menor número de nodos que las de entrada, muestra que el modelo no es complejo, pero el comportamiento en las funciones de transferencia muestra que muchos de los nodos de entrada son no lineales, esto indica que las variables de entrada que son las

Figura 6. Diagrama de RNA MLP 37-10-2 para determinar las empresas exitosas o no exitosas del sector comercial de la BMV.



Fuente: Elaboración propia.

razones financieras no tienen un comportamiento con características de distribución normal y que bajo modelos paramétricos, estas razones financieras serían descartadas, mientras que el modelo neuronal tiene la capacidad de considerarlas, y así dar a conocer con mayor precisión cuales son las razones financieras que realmente son determinantes para el desempeño financiero exitoso o no de una empresa.

En la Tabla 5 se muestra el análisis de sensibilidad de las 37 razones financieras consideradas por la RNA determinadas en este trabajo.

Tabla 5. Nivel de sensibilidad que tiene la Red Neuronal con el desempeño financiero.

Sensitivity analysis for DESEMPEÑO (BASE DATOS ACCIONES COMERC BMV 1995-2005)

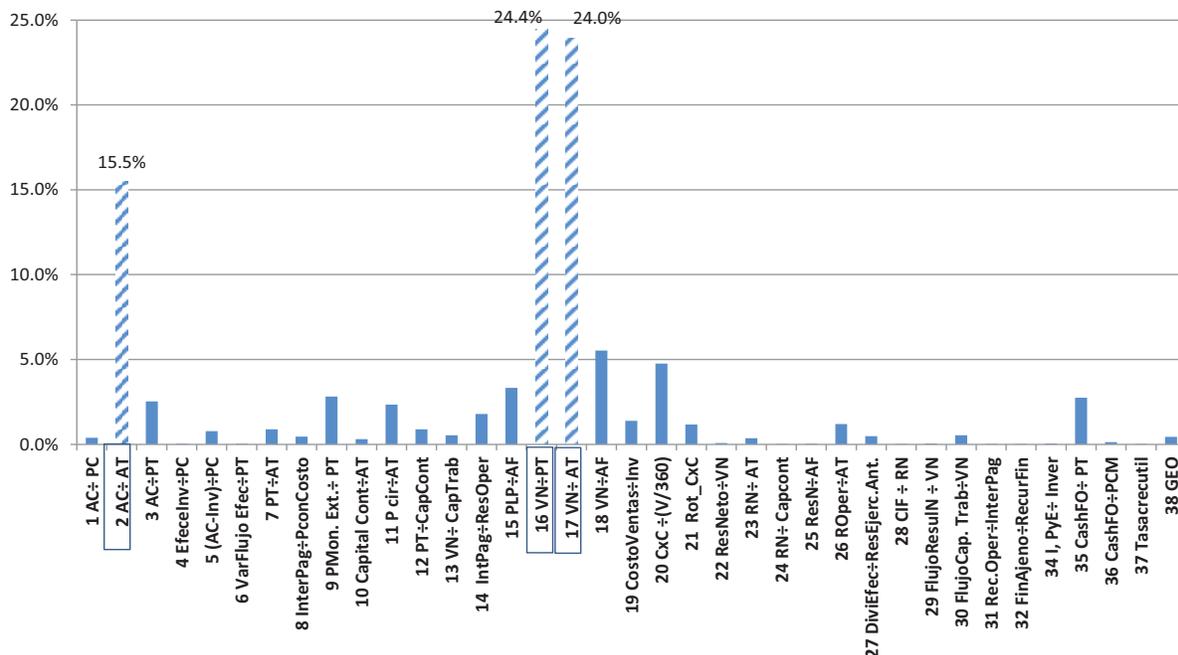
Networks/ Variable	10.MLP 37-10-2	Ponderación	Networks/ Variable	10.MLP 37-10-2	Ponderación
1 AC+ PC	24.49168	0.4%	20 CxC +(V/360)	298.2641	4.8%
2 AC+ AT	971.4288	15.5%	21 Rot_CxC	73.51641	1.2%
3 AC+PT	158.8398	2.5%	22 ResNeto+VN	5.184025	0.1%
4 EfecelInv+PC	2.013849	0.0%	23 RN+ AT	22.68604	0.4%
5 (AC-Inv)+PC	48.65535	0.8%	24 RN+ Capcont	1.003922	0.0%
6 VarFlujo Efec+PT	2.491939	0.0%	25 ResN+AF	1.884999	0.0%
7 PT+AT	55.84084	0.9%	26 ROper+AT	75.13386	1.2%
8 InterPag+PconCosto	28.60636	0.5%	27 DivEfec+ResEjerc.A	30.50380	0.5%
9 PMon. Ext.+ PT	176.5400	2.8%	28 CIF + RN	1.156101	0.0%
10 Capital Cont+AT	18.92683	0.3%	29 FlujoResulN + VN	3.066914	0.0%
11 P cir+AT	146.8014	2.3%	30 FlujoCap. Trab+VN	33.92957	0.5%
12 PT+CapCont	55.72065	0.9%	31 Rec. Oper+InterPag	1.007220	0.0%
13 VN+ CapTrab	33.68205	0.5%	32 FinAjeno+RecurFin	1.076281	0.0%
14 IntPag+ResOper	112.5981	1.8%	34 I, PyE+ Inver	2.998009	0.0%
15 PLP+AF	208.5688	3.3%	35 CashFO+ PT	172.1478	2.7%
16 VN+PT	1533.334	24.4%	36 CashFO+PCM	8.508987	0.1%
17 VN+ AT	1503.321	24.0%	37 Tasacreutil	1.456515	0.0%
18 VN+AF	347.0782	5.5%	38 GEO	27.36544	0.4%
19 CostoVentas+Inv	86.59802	1.4%			

Fuente: Elaboración propia.

Como se puede apreciar en la tabla anterior, la Red Neuronal MLP 37-10-2, tiene tres razones financieras que son muy sensibles en la determinación del éxito y no éxito empresarial para el sector comercial de la BMV. Estas razones son por orden de sensibilidad en su ponderación en el modelo, comenzando por la razón 16 que es la relación entre Ventas Netas entre Activo Total (VN /AT) con una sensibilidad del 24.4%; seguido por la Razón 17 que es la relación entre Ventas Netas entre Pasivo Total (VN / PT) con una sensibilidad en el modelo del 24.0%; y por último la Razón 2 con un nivel de sensibilidad en el modelo de 15.5% que es la relación entre Activo Circulante y Activo Total.

Por lo anterior, se puede decir que al conocer el comportamiento de estas tres razones financieras se conoce el 63.9% del comportamiento del modelo neuronal, es decir que para que las empresas alcancen el éxito o el no éxito empresarial es importante analizar estas tres razones, pues aunque se tenga la información de las 34 razones restantes, esto solo representa el 36%. En la Figura 7 se muestra una gráfica que muestra el nivel de sensibilidad de las 37 razones financieras analizadas.

Figura 7. Diagrama de RNA MLP 37-10-2 para determinar las empresas exitosas o no exitosas del sector comercial de la BMV.



Fuente: Elaboración propia.

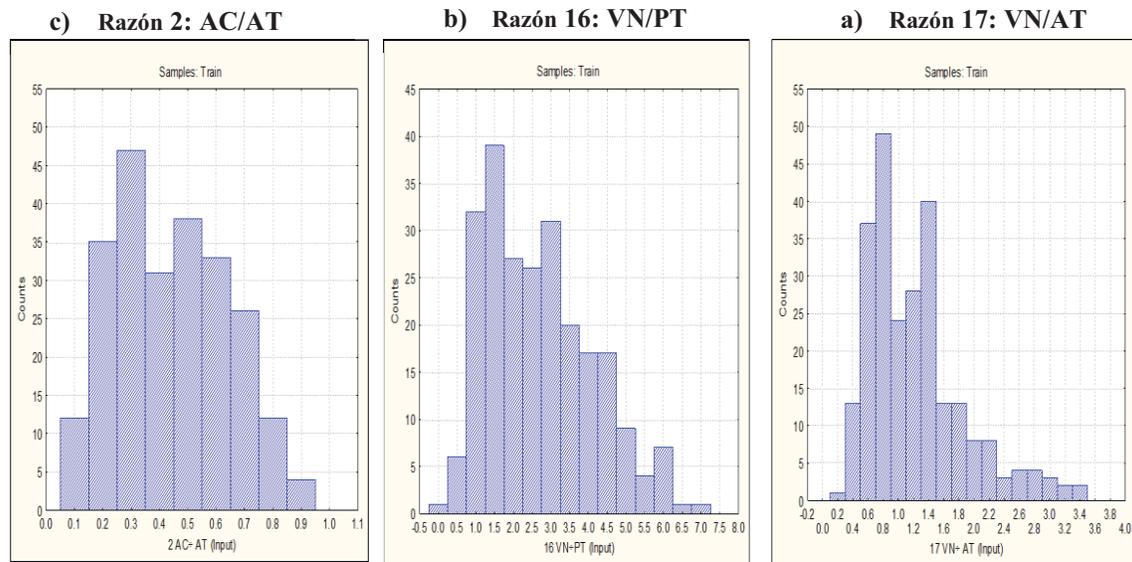
En el gráfico anterior se aprecia con mayor detalle la magnitud de sensibilidad que tienen las 37 razones financieras para la RNA MLP 37-10-2.

Para conocer el comportamiento de distribución que tiene cada una de estas tres razones financieras, se le aplicó la prueba K-S,⁶ con el propósito de demostrar que los modelos paramétricos, en este caso el modelo ADM y Logit, no consideran del todo las razones financieras más sensibles para deter-

⁶ Prueba Kolmogorov- Smirnov, es una prueba no paramétrica que se utiliza para determinar la bondad de ajuste de dos distribuciones de probabilidad entre sí.

minar el desempeño financiero, sino que solo consideran aquellas que cumplen las condiciones que le solicitan para realizar el modelo, en este caso la normalidad. En la figura 8 se puede apreciar el histograma de estas razones.

Figura 8. Histogramas de las razones financieras más sensibles determinada por la RNA MLP.



Fuente: Elaboración propia.

Al realizarse la prueba K-S, la única que cumplió con la prueba de normalidad fue la Razón 2, por lo que los indicadores financieros denominados Razón 16 y Razón 17 no cumplieron con esta condición, motivo por el cual los modelos ADM y Logit no los consideraron. En la tabla 6 se puede apreciar las variables o razones financieras que consideraron cada uno de los tres modelos analizados en esta investigación.

Como se puede apreciar en la Tabla 6, las razones financieras del modelo ADM y Logit consideraron casi las mismas razones financieras. El Modelo ADM toma en cuenta seis razones financieras, mientras que el modelo Logit considera siete. El modelo Neuronal de RNA considero 37 razones financieras, pero las más sensibles en la determinación fueron tres, marcadas con un círculo para poder identificarlas con mayor rapidez, como se muestra en la quinta columna de la Tabla 6.

Al comparar los tres modelos, se aprecia que el modelo ADM y Logit difieren en poco, pero entre los dos modelos anteriores y la RNA existen diferencias muy marcadas, porque solo coinciden en una de las tres razones

Tabla 6. Comparación de las razones financieras que fueron determinados por los modelos ADM, Logit y la RNA MLP para determinar las empresas exitosas o no exitosas del sector comercial de la BMV.

Medidas del comportamiento empresarial financiero	Modelos Analizados			
	Razones financieras	ADM	Logit	RNA
Razones de Liquidez	1 AC÷ PC			✓
	2 AC÷ AT	●	●	●
	3 AC÷PT	●		✓
	4 EfecInv÷PC	●	●	✓
	5 (AC-Inv)÷PC		●	✓
	6 VarFlujo Efec÷PT			✓
	Razones de Apalancamiento	7 PT÷AT		
8 InterPag÷PconCosto				✓
9 PMon. Ext.÷ PT				✓
10 Capital Cont÷AT				✓
11 P cir÷AT				✓
12 PT÷CapCont				✓
13 VN÷ CapTrab				✓
Razones de Solvencia	14 IntPag÷ResOper			✓
	15 PLP÷AF			✓
	16 VN÷PT			●
Razones de actividad	17 VN÷ AT			●
	18 VN÷AF	●	●	✓
	19 CostoVentas÷Inv	●	●	✓
	20 CxC ÷(V/360)			✓
	21 Rot_CxC		●	✓
Razones de Rentabilidad	22 ResNeto÷VN			✓
	23 RN÷ AT			✓
	24 RN÷ Capcont			✓
	25 ResN÷AF			✓
	26 ROper÷AT	●	●	✓
	27 DivEfec÷ResEjerc.Ant.			✓
	28 CIF ÷ RN			✓
	Razones de estado de cambio, de crecimiento y Generación de valor	29 FlujoResulN ÷ VN		
30 FlujoCap. Trab÷VN				✓
31 Rec. Oper÷InterPag				✓
32 FinAjeno÷RecurFin				✓
34 I, PyE÷ Inver				✓
35 CashFO÷ PT				✓
36 CashFO÷PCM				✓
37 Tasacreutil				✓
38 GEO				✓
Nivel de clasificación		78%	81%	95%

Nota: ✓ significa que es una razón financiera que toma en cuenta el modelo.

Fuente: Elaboración propia.

financieras que el modelo Neuronal determinó como de mayor sensibilidad, que fue la Razón 2 conocida como Activo Circulante entre Activo Total, mientras que la Razón 16 y la Razón 17 no fueron tomadas en cuenta por los otros modelos.

Esto confirma la hipótesis planteada en esta investigación, ya que los modelos paramétricos solo determinan variables exógenas que cumplen con la normalidad dejando afuera aquellas que no cumplen este criterio, haciendo que estos modelos estén limitados al momento de considerar factores que son determinantes para describir las causas de un fenómeno, mientras que las Redes Neuronales Artificiales no están limitadas por estos supuestos, haciendo que esta técnica tenga ventajas sobre los modelos paramétricos.

6. Discusión sobre los resultados

En el análisis de sensibilidad determinada por la Red Neuronal Artificial Multicapas de Retropopagación con arquitectura 37:10:2 muestra que hay tres razones que son fundamentales para obtener el objetivo de estas empresas que son la Razón 2 definida como la relación entre Activo Circulante / Activo Total perteneciente a razones de Liquidez, la razón 16 perteneciente a razones de Solvencia que es definida como la relación de Ventas Netas / Pasivo Total, y la razón financiera de Actividad que es definida como la relación entre Ventas / Activo Total. Estas razones financieras se muestran en la Tabla 7.

Tabla 7. Razones financieras que tienen mayor sensibilidad a la RNA MLP para determinar el desempeño de Éxito y No éxito en la BMV.

Razón 2	Razón 16	Razón 17
$\frac{AC}{AT}$	$\frac{VN}{PT}$	$\frac{VN}{AT}$

Fuente: Elaboración propia.

En la Tabla 8, mediante la técnica de Redes Neuronales se puede deducir que hay cuatro elementos de los Estados Financieros —Activos Totales, Activo Circulante, Ventas Netas y Pasivos Totales— que son determinantes para que las empresas de la BMV del Sector comercial tengan éxito dentro de este mer-

cado. Elementos que no podrían ser deducidos con las técnicas Discriminante Múltiple y Logit.

Realizando un análisis de cada una de las razones utilizadas, y analizando los parámetros correspondientes a cada una de ellas, se puede ver que en la segunda columna se encuentran los indicadores que muestran que la empresa es exitosa y en la tercera columna se encuentran los parámetros que determinan que una empresa no es exitosa.

Con este estudio se demuestra que al igual que trabajos realizados por Hansen y Messier (1991); Fanning y Cogger (1994); Bell *et al.* (1997); Koh (2004); Yildiz y Yezegel (2010); Roli (2012), y Ecer Faith (2013); que las RNA Perceptrón Multicapas son modelos con alta capacidad para poder clasificar a las empresas en sus desempeños financieros, basándose en sus razones financieras.

Tabla 8. Parámetros de las razones financieras más sensibles para determinar su desempeño de las empresas de la BMV del sector comercial.

		Parametros del Desempeño	
Razón financiera	Relación	Exitosa	No exitosa
Razón 2	AC/AT	≤ 0.31	≥ 0.62
Razón 16	VN/PT	≥ 4.19	≤ 3.06
Razón 17	VN/AT	≥ 1.76	≤ 0.96

Fuente: Elaboración propia.

A diferencia de estos estudios, este modelo no trata de encontrar quiebras financieras como los trabajos de Hansen y Messier (1991) y Fanning y Cogger (1994), que pretendían clasificar el desempeño financiero que provocaban la quiebra financiera. Sino que el enfoque de este trabajo fue determinar el desempeño de generación de valor dentro del mercado bursátil.

Y aunque Roli (2012) realiza un estudio con 55 razones financieras para una institución crediticia de la India, superando la cantidad de razones financieras, de la presente investigación; este trabajo compara todo el sector comercial de un mercado bursátil. Además de que Roli (2010) utiliza las redes neuronales con el propósito de analizar cada razón como una serie de tiempo, y no como un clasificador de empresas al medir su desempeño.

La mayoría de los trabajos analizados en la revisión a la literatura fueron comparados con modelos Logit, árboles de decisión, modelos discriminante y modelos basados en teoría de juegos, y en todos los casos demostraron que esta técnica es una alternativa para poder medir el desempeño financiero de las empresas con mayor potencialidad, pero solo mostrando en sus respectivos casos el poder predictivo o clasificatorio.

A diferencia de los trabajos mencionados, esta investigación, demuestra el potencial que tiene sobre técnicas multivariadas, como son los modelos Logit y discriminante, ya que como modelos clasificadores del desempeño financiero, estos consideraran solamente razones financieras que tengan un comportamiento gaussiano, y descartan las variables (o razones financieras) que no tengan estas características, dejando fuera muchas razones que por su naturaleza no se comporten así. Por lo anterior, al no depender de estas características las RNA pueden contribuir a la toma de decisiones del analista financiero al considerar razones financieras de todo tipo, y otras variables no tan solo de valor numérico, sino de tipo ordinal y en su caso hasta nominal.

Conclusiones

El objetivo de esta investigación fue determinar si los modelos de Redes Neuronales Artificiales de tipo MLP —basados en inteligencia artificial—, determinan las mismas razones financieras que los modelos de tipo paramétrico que permiten clasificar el desempeño financiero de las empresas del sector comercial de la BMV, en exitosas y no exitosas, como son las técnicas ADM y Logit,

Se concluye en esta investigación que entre estas técnicas existen diferencias en la determinación de las razones financieras que permiten medir el desempeño financiero en exitoso y no exitoso ya que los modelos ADM y Logit se limitan a considerar solo indicadores o razones financieras que tienen comportamiento de distribución normal, excluyendo a las que no cumplen con estos supuestos; limitando con ello severamente la determinación de los factores reales en el logro de los objetivos, que en este caso es el éxito empresarial en este mercado.

Para el caso que se analiza, se puede apreciar que los modelos ADM y Logit, no detectan que la Razón 16 dada por las Ventas Netas entre Pasivo Total, ni tampoco la Razón 17 que está dada entre las Ventas Netas entre Activo Total, son determinantes para conocer si una empresa es exitosa o no dentro del Sector Comercial de la Bolsa Mexicana de Valores. Y esto se comprueba con el

poder de clasificación que tiene cada una de las técnicas pues el modelo ADM y Logit clasifican con una precisión del 78% y 81%; mientras que el modelo de la RNA MLP clasifica con una precisión del 95%.

Con lo anterior, se puede afirmar que los modelos de Redes Neuronales Artificiales, son una alternativa que permite a los analistas financieros, a los administradores, a los accionistas y a los involucrados en este sector, contar con una herramienta que les da mayor certidumbre para la toma de mejores decisiones financieras y por ende de éxito o no éxito en cuanto al desempeño financiero de las empresas que administran.

Referencias bibliográficas

- Anandarajan , M., Lee, P. and Anandarajan, A. (2001). "Bankruptcy Prediction of Financially Stressed Firms: An Examination of the Predictive Accuracy of Artificial Neural Networks". *International Journal of Intelligent Systems in Accounting, Finance and Management* 10 (2): 69–81.
- Bell, T. (1997). "Neural Net or the Logit Model? A Comparison of Each Model's Ability to Predict Commercial Bank Failures". *Intelligent Systems in Accounting, Finance, and Management*, 249–264.
- Bishop; C. (1997). *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford, 1997, p. 123.
- Dimitras, A. I., Zanakis, S. H. and Zopounidis, C. (1996). "A Survey of Business Failures with an Emphasis on Prediction Methods and Industrial Applications". *European Journal of Operational Research* 90 (3): 487–513.
- Fanning, K. and K. Cogger. (1994). "A Comparative Analysis of Artificial Neural Networks Using Financial Distress Prediction. *International Journal of Intelligent Systems in Accounting*". *Finance & Management*. Volume 3. Number 4. December. 241-252.
- Ecer, Faith (2013). "Artificial Neural Networks In Predicting Financial Performance: An Application For Turkey's Top 500 Companies". *Economic Computation & Economic Cybernetics Studies & Research*. 2013, Vol. 47 Issue 2, p103-114.
- Gu, Z. (2002). "Analyzing Bankruptcy in the Restaurant Industry: A Multiple Discriminant Model". *International Journal of Hospitality Management* 21 (1): 25–42.
- Hansen, J. V. and. Messier, W. F. (1991). "Artificial Neural Networks: Foundations and Application to a Decision Problem". *Expert Systems With Applications: An International Journal*: 135-141.

- Kim, H. and Gu, Z. (2006a). "A Logistic Regression Analysis for Predicting Bankruptcy in the Hospitality Industry". *The Journal of Hospitality Financial Management* 14 (1): 17-34 .
- _____ (2006b). "Predicting restaurant bankruptcy: A logit model in comparison with a discriminant model". *Journal of Hospitality & Tourism Research* 30 (4): 474-493.
- Koh, H. (2004). "Going Concern Prediction Using Data Mining Techniques". *Managerial Auditing Journal*, 462-476.
- Morales, J. (2007). "Razones financieras que describen y clasifican a las empresas financieramente exitosas del sector comercial que cotizan en la Bolsa Mexicana de Valores". Tesis Doctoral, Universidad Autónoma de México.
- Roli, P. (2012). "Forecasting Financial Ratios for Credit Lending in Banks using Artificial Neural Network". *A case study of HDFC Bank*. *Department of Management Studies, Maulana Azad National Institute of Technology, Bhopal (M.P.), India*. Vol. 5. p.41-54.
- Rosenblatt, F. (1957). "The Perceptron: A Perceiving and Recognizing Automaton". Report 85-460-1, *Cornell Aeronautical Laboratory*.
- _____ (1958). "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain". *Psychological Review*, Vol 65(6), Nov 1958, 386-408.
- Sirakaya, E., Delen, D. and Choi, (2005). "Forecasting Gaming Referenda". *Annals of Tourism Research* 32 (1): 127-149.
- SPSS. (2007). *SPSS Neural Networks 17.0*. Chicago, IL.: SPSS Inc
- Westwick, C.A. (1987): *Manual para la aplicación de los ratios de gestión*, España, Edit Deusto.
- Wu, W., Lee, V. C. S. and Tan, T. Y. (2006). "Data Preprocessing and Data Parsimony in Corporate Failure Forecast Models: Evidence from Australian materials industry". *Accounting and Finance* 46 (2): 327-345.
- Yildiz, B; y Yezegel; A. (2010). *International Journal of Business & Finance Research*. (IJBFR). 2010, Vol. 4 Issue 1, p149-158. 10p.

ANEXO I

Arquitecturas Neuronales analizadas con alto desempeño en la clasificación en las empresas Exitosas y No exitosas del Sector Comercial de la BMV para el período de 1995-2005.

Número	Arquitectura RNA	Desempeño entrenamiento (%)	Desempeño de comprobación (%)	Algoritmo de Entrenamiento	Función de Error	Activación capa Oculta	Activación Capa Salida
1	MLP 37-14-2	94.44444	81.35593	BFGS 28	Entropy	Logistic	Softmax
2	MLP 37-23-2	90.07937	81.35593	BFGS 29	Entropy	Tanh	Softmax
3	MLP 37-18-2	96.82540	88.13559	BFGS 47	SOS	Logistic	Identity
4	MLP 37-10-2	98.41270	83.05085	BFGS 35	Entropy	Logistic	Softmax
5	MLP 37-9-2	99.20635	83.05085	BFGS 44	Entropy	Logistic	Softmax
6	MLP 37-16-2	67.46032	77.96610	BFGS 12	Entropy	Exponential	Softmax
7	MLP 37-22-2	97.22222	81.35593	BFGS 39	Entropy	Tanh	Softmax
8	MLP 37-11-2	96.82540	84.74576	BFGS 53	SOS	Logistic	Exponential
9	MLP 37-23-2	99.20635	81.35593	BFGS 43	Entropy	Tanh	Softmax
10	MLP 37-10-2	100.00000	89.83051	BFGS 57	Entropy	Logistic	Softmax
11	MLP 37-11-2	97.61905	84.74576	BFGS 58	SOS	Logistic	Logistic
12	MLP 37-9-2	80.95238	81.35593	BFGS 19	SOS	Tanh	Logistic
13	MLP 37-8-2	88.49206	81.35593	BFGS 31	SOS	Logistic	Logistic
14	MLP 37-16-2	96.82540	88.13559	BFGS 49	SOS	Logistic	Tanh
15	MLP 37-13-2	86.50794	77.96610	BFGS 59	SOS	Exponential	Logistic

Nota: La arquitectura sombreada fue la RNA Perceptrón Multicapas considerada en esta investigación por su capacidad de clasificación, su menor número de nodos en la capa oculta, su capacidad de no sobre entrenamiento, y que sus funciones de transferencias son fáciles de desarrollar.

Fuente: Elaboración propia basado en los resultados de las diferentes arquitecturas propuestas.

