

DESEMPEÑO FINANCIERO DE LAS EMPRESAS: UNA PROPUESTA DE CLASIFICACIÓN POR RNA¹

FINANCIAL PERFORMANCE OF FIRMS: A PROPOSAL FOR CLASSIFICATION RNA

DESEMPENHO FINANCEIRO DAS EMPRESAS: UMA PROPOSTA DE CLASSIFICAÇÃO POR RNA

Oswaldo García Salgado²

Arturo Morales Castro³

CITATION

García, O. & Morales, A. (2016) Desempeño financiero de las empresas: una propuesta de clasificación por RNA. *Dimensión Empresarial*, 14(2), 11-23

JEL: C22, C45, C53, G10, G11 .

DOI: <http://dx.doi.org/10.15665/rde.v14i2.686>

RESUMEN

Mediante el uso de Redes Neuronales Artificiales [RNA] se propuso mejorar la precisión de clasificación de las empresas dentro de la Bolsa Mexicana de Valores [BMV], en específico del sector comercial en comparación con las técnicas de análisis discriminante múltiple [ADM] y los modelos logit. Se desarrollaron más de cincuenta arquitecturas neuronales, y la red neuronal artificial que resulto fue la de arquitectura MLP 6:12:2 basada en algoritmos de aprendizaje de retro-propagación hacia atrás. Los resultados encontrados con la técnica de RNA arrojaron que esta técnica tiene un mejor pronóstico de evaluación y de clasificación que la obtenida por los modelos Logit y las técnicas ADM.

Palabras clave: Mercados Financieros, Desempeño financiero, Modelo logit, Técnicas ADM, Redes Neuronales Artificiales.

1 Artículo de reflexión. Este documento se deriva de la investigación "Evaluación del desempeño financiero de empresas que cotizan en la BMV: Enfoque de redes neuronales", desarrollada en la Universidad Autónoma de Querétaro [UAQ], México, Querétaro, <http://www.uaq.mx/>. Desarrollada entre julio de 2012 y marzo de 2014. Fecha de recepción 28/03/2016. Fecha de aceptación 12/05/2016.

2 Profesor-investigador, Universidad Autónoma del Estado de México (UAEM) en la División de Posgrado e Investigación de la Facultad de Economía (FE), <http://www.uaemex.mx/> en México, Ciudad de México, Doctor en Administración por la FE-UAEM. Correo: oswgars@gmail.com

3 Profesor-investigador, División de Posgrado e Investigación de la Facultad de Contaduría y Administración de la Universidad Nacional Autónoma de México [FCyA-UNAM], México, Ciudad de México, <http://www.fca.unam.mx/>, Doctor en Ciencias de la Administración. Correo amorales@fca.unam.mx

ABSTRACT

By using artificial neural networks [ANN] it was proposed to improve the accuracy of classification of companies within the Bolsa Mexicana de Valores [BMV], specifically the commercial sector compared to multiple discriminant analysis techniques [MDA] and logit models. More than fifty neural architectures were developed, and artificial neural network that resulted was the MLP architecture 6: 12: 2 based learning algorithms retro-backpropagation. The results found with the technique [ANN] showed that this technique has a better prognosis assessment and classification obtained by ADM and logit techniques.

Keywords: Financial Markets, Financial Performance, logit model, ADM Techniques, Artificial Neural Networks.

RESUMO

Utilizando Redes Neurais Artificiais [RNA] foi proposto para melhorar a precisão da classificação das empresas na Bolsa Mexicana de Valores [BMV], especificamente o setor comercial em comparação com as técnicas de análise discriminante múltipla [ADM] e modelos logit. Mais de cinquenta arquiteturas neurais foram desenvolvidas, e rede neural artificial que resultou foi a arquitetura MLP 6: 12: 2, com base algoritmos de aprendizagem retro-backpropagation. Os resultados obtidos com a técnica de RNA mostraram que esta técnica tem um prognóstico melhor avaliação e classificação obtida pelos modelos logit e técnicas de ADM.

Palavras-chave: mercados financeiros, o desempenho financeiro, modelo logit, técnicas de ADM, Redes Neurais Artificiais.

1. INTRODUCCIÓN

Las Redes Neuronales Artificiales (RNA) son modelos matemáticos desarrollados con base en el funcionamiento de los sistemas nerviosos biológicos. De esta manera, se intenta contar con un sistema que imite el funcionamiento natural de las neuronas, es decir, que puedan “pensar” y “aprender” como el cerebro humano, el cual se puede ver como un conjunto interconectado de neuronas.

La primera interpretación matemática de las redes neuronales fue realizada en 1865 cuando Mach, un físico y filósofo austriaco, intentó explicar la interacción recíproca e inhibitoria de los elementos que rodean a la retina (Peel y Wilson, 1996). Los trabajos sobre el desarrollo de modelos matemáticos detallados comienzan desde hace más de cuarenta años, con los trabajos de McCulloch y Pitts (1943), Hebb (1949) y Rosenblatt (1959).

Sin embargo, cuando se pretende analizar un conjunto de datos con relaciones complejas y condiciones adicionales, la capacidad de procesamiento requerida se eleva considerablemente, lo cual ocasionó que los primeros intentos por utilizar este tipo de

modelos fueran abandonados debido a la limitada capacidad de los sistemas de cómputo disponibles en la época.

Fue hasta los años 80's cuando se retoma el interés por su empleo de forma más generalizada. Esto debido a los avances en la potencia de cálculo de las nuevas computadoras, aunado a un mayor conocimiento del funcionamiento del propio cerebro humano. Este nuevo interés se debió al desarrollo de algoritmos y nuevas topologías de red, nuevas técnicas de implementación de circuitos analógicos, algunas demostraciones intrigantes por parte de Sejnowski (1986) y Hopfield (1982), así como por la creciente fascinación por el funcionamiento del cerebro humano.

Las aplicaciones de las RNA en los negocios se dividen en dos principales categorías: clasificación y modelado (Peel, 1966). La clasificación se refiere a la forma de discriminar entre observaciones con características comunes en diferentes grupos, v. gr. predicción de fallas corporativas, asignación de créditos y clasificación de bonos. Por otra parte, el modelado consiste en simular el comportamiento o las reacciones de una entidad o variable dado un estímulo externo, basado en observaciones

pasadas. v. gr, predecir los movimientos de los precios de las acciones o fluctuaciones en el tipo de cambio.

El primer artículo sobre redes neuronales que considera información financiera fue realizado por White (1988), quien estudió la predicción de los precios de las acciones con un modelo de red neuronal. Posteriormente la predicción de la cotización de las acciones, del tipo de cambio y de otras variables económico-financieras ha sido uno de los temas más atractivos para los investigadores y analistas financieros.

Por lo anterior, el propósito de la presente investigación es que mediante el uso de redes neuronales artificiales se mejore la precisión de clasificación de las empresas que tienen mejor desempeño financiero y son exitosas dentro del Mercado Bursátil Mexicano, en específico del sector comercial en comparación con las técnicas de análisis discriminante y los modelos logit utilizadas por Morales (2007), para el periodo de 1990 a 2011.

2. REVISIÓN DE LA LITERATURA Y ESTADO DEL ARTE

El trabajo seminal en el uso de las redes neuronales para el pronóstico de series de tiempo fue la realizada por Halbert White (1988) quien fue el primero en utilizar las redes, motivado a encontrar regularidades no lineales en los movimientos del precio de las acciones. Básicamente su objetivo fue ilustrar como la búsqueda de estas regularidades podía aplicarse en particular a los rendimientos diarios de las acciones de IBM. Utilizando una sencilla red feedforward de tres capas (entrada, oculta y salida) pudo confirmar la potencia de esta metodología para las relaciones no lineales. A partir de esta investigación se comenzó a utilizar a las redes neuronales en el campo de las finanzas en diversos temas.

Tiempo después del trabajo de White (ibídem.) Altman, Marco y Varetto (Altman et al. 1994) realizaron en Italia pruebas de diagnóstico a empresas medianas y pequeñas para pronosticar dificultades financieras, excluyendo a las empresas con ventas por más de 60 millones de dólares, en un periodo

de 1985 a 1992. Utilizaron 404 compañías sanas y 404 con problemas financieros. Empleando análisis discriminante y redes neuronales para pronosticar aquellas empresas que tendrían problemas. Dentro de la muestra ambas tuvieron un desempeño similar, pero en cuanto a pronóstico, las redes neuronales probaron ser mejores que el análisis discriminante alcanzando un 94.7% de acierto.

Otra aplicación de las redes en finanzas es el trabajo hecho por Chiang, Urban y Baldrige (Chiang et al. 1996) quienes utilizaron redes para pronosticar el valor neto de los activos al final del año de fondos de inversión y compararon sus pronósticos con regresiones lineales y no lineales. Encontraron que las redes neuronales superan de sobremana a ambos tipos de regresiones, en especial cuando se encuentran con disponibilidad limitada de datos.

En cuanto a exclusivamente pronosticar series, las redes neuronales eran cada vez más socorridas, con la motivación de demostrar si eran superiores a otros métodos Hill, O'Connor y Remus (Hill et al. 1996) realizaron un ejercicio comparativo entre el desempeño de las redes neuronales artificiales y otros métodos de pronóstico: suavizamiento exponencial, método de Holt y procesos autorregresivo integrados de media móvil (ARIMA) por mencionar algunos. Utilizaron 104 series de tiempo con diferentes frecuencias: 65 series mensuales, 21 series trimestrales y 18 series anuales, encontraron que para las series mensuales y trimestrales las redes neuronales eran significativamente mejores que el resto. Para las series anuales no existió una gran diferencia, obteniendo así desempeños similares con el resto de los métodos.

Otros autores que han incursionado en la aplicación de las redes neuronales artificiales en las finanzas son: Dutta y Shekhar (1988), Bosarge (1989), Trippi (1990), Hawley, et. al. (1990), Salchenberger, Cinar y Cash (1992) y Tam y Kiang (1992).

El estudio de Shang-Wu (1999) emplea redes neuronales para realizar pronósticos y arbitraje sobre el futuro del índice

accionario del Nikkei, en donde de acuerdo con los resultados empíricos, las redes neuronales superaron al modelo ARIMA en las predicciones, así como también fue capaz de proporcionar al operador mayores ganancias por arbitraje que por los modelos tradicionales aun cuando se observa un menor intervalo de tiempo redituable.

El estudio de Zang y Berardi (2001), quienes utilizan redes neuronales para predecir el tipo de cambio entre la libra británica y el dólar estadounidense, específicamente utilizan un método de particionamiento sistemático para construir conjuntos de redes neuronales. Encuentran que la aproximación básica conjunta creada con arquitecturas de red entrenadas con diferentes pesos iniciales aleatorios no es efectiva para mejorar la precisión de la predicción, mientras que los modelos en conjunto de diferentes estructuras neuronales pueden mejorar de manera consistente las predicciones de una única red. Sus resultados también muestran que las redes conjuntas basadas en diferentes particiones de datos son más eficientes que aquellas desarrolladas con el conjunto de datos de entrenamiento completo en la predicción fuera de muestra.

El estudio de Medeiros, Veiga y Pedreira (2001), en el cual presentan y comparan diferentes alternativas para modelar y predecir series de tiempo del tipo de cambio mensual. Los modelos que proponen son autorregresivos de transición suave de neuro-coeficientes, lineales autorregresivos y de caminata aleatoria. Encuentran que la no linealidad sólo es relevante en algunos periodos de la serie, especialmente al inicio y al final de la muestra, que los modelos no lineales se desempeñan mejor solo en los casos en donde la linealidad esta uniformemente distribuida. También concluyen que no hay diferencias significativas con respecto a un modelo lineal actual.

El estudio de Collantes (2001) quien compara las metodologías Box-Jenkins, ARIMA y función de transferencia en dos aplicaciones, la primera, sobre la serie de tiempo del número de nacimientos mensuales ocurridos en España de enero 1960 a diciembre de 1999 y, la segunda sobre dos series de tiempo, el

gasto de publicidad mensual y el número de ventas mensuales, en donde se llegó a la conclusión de que la metodología ARIMA se puede utilizar como herramienta de preprocesamiento de datos, considerando como entradas a los retrasos involucrados en el modelo proporcionado por esa metodología, además de que los resultados de la predicción tanto dentro como fuera de muestra por parte de la red neuronal propuesta resultó ser superior a las otras metodologías.

El estudio de Haefke y Helmenstein (2002) en el que se presenta una estrategia de negocio que explota la diferencia en información que implican los principios de construcción de índices de mercado de diferentes acciones. Esto para ganar ventaja competitiva sobre otros participantes de mercado, empleando redes neuronales para predicciones de un día y generar señales de compra y venta de acuerdo a la regla de negociación. Para ilustrar como trabaja el sistema, se aplica al índice de comercio austriaco (ATX). Sus resultados muestran que las redes seleccionadas se desempeñan bien con respecto a R2, MSE y MAPE. Encuentran una relación positiva y significativa con los datos dentro de muestra, mientras que en algunos casos las correlaciones fuera de muestra no son significativas o tienen el signo incorrecto.

Por su parte, García (2003) diseña un modelo no lineal para el análisis y predicción de la serie de tiempo del precio externo del café colombiano utilizando redes neuronales artificiales en donde lo compara con un modelo clásico de predicción lineal ARIMA. La red utilizada utiliza una capa oculta, emplea el algoritmo de retropropagación y una función sigmoidea como función de activación de la red. Los resultados obtenidos indican que la varianza del error del modelo RNA es menor que el del modelo ARIMA aproximadamente en un 22%, por lo que el modelo de redes neuronales se considera mejor.

Stansell y Eakins (2004) proponen usar redes neuronales para predecir la dirección de cambio en índices de acciones de 19 sectores sobre un intervalo de cinco meses en el 2001 y de tres en el 2002. Los resultados fueron evaluados solamente en

términos de la dirección de cambio y también en términos del número de puntos ganados en el índice del sector. Concluyen que un inversionista puede obtener ventaja de la habilidad de predicción de las redes neuronales utilizando los datos económicos públicamente disponibles.

En lo que se refiere al tema de predictibilidad con RNA en las finanzas para México, se encontraron solo dos investigaciones Berumen (1998), y Pérez (1998), pero además estos estudios hacen referencia a la utilización de un software comercial o bien al desarrollo de un programa en lenguaje C++ para hacer predicciones del precio de las acciones, por lo que su objetivo no es conocer la predicción de la tendencia de los instrumentos financieros derivados.

3. MATERIALES Y MÉTODOS

El objetivo principal de este análisis se centra en la construcción de un modelo matemático basado en las Redes Neuronales Artificiales y la comparación con la técnica Z-score soportada por ADM y Logit para el análisis del desempeño financiero de las empresas exitosas del sector comercial que cotizan en la Bolsa Mexicana de Valores [BMV].

Cabe señalar que para poder desarrollar este análisis se consideró la misma base de datos, la misma periodicidad,

los mismos criterios de desempeño financiero, y las mismas razones obtenidas en los tres modelos de predicción.

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 [véase Tabla 1], 2. Obtención de 38 razones financieras que miden el desempeño empresarial en base a su clasificación de liquidez, apalancamiento, solvencia, actividad, rentabilidad, estado de cambios, tasas de crecimiento y generación de valor. En el periodo comprendido de 1990 a 2011 con periodicidad anual [véase tabla 2], 3. Determinación de siete indicadores financieros que miden el desempeño empresarial para clasificar a las empresas exitosas y no exitosas. Los indicadores fueron a) bursatilidad, b) variación en el valor de la acción, c) Generación Económica Operativa, d) Utilidades en los últimos 5 años, e) Expansión de la empresa de acuerdo al mercado, f) Existencia de alianzas estratégicas [véase tabla 3], 4. Establecimiento de los criterios de entradas y salidas para la construcción de los diferentes modelos (ADM, logit y RNA). En donde las entradas serán las razones financieras y la salida el criterio de desempeño (exitoso y no exitoso); para la determinación de estos modelos se hizo uso del software SPSS v. 20, aplicando metodologías de análisis multivariado, y para el diseño de la arquitectura de la red como lo establece en el cuadro 1.

Cuadro 1. Ocho Pasos a Seguir en la Construcción de una RNA

Paso 1	Elección de Variable	
Paso 2	Recolección de Datos	
Paso 3	Pre-proceso de Datos	
Paso 4	Sets de Entrenamiento, Prueba y Validación	
Paso 5	Arquitectura de las Redes Neuronales	Número de Capas Ocultas
		Número de Neuronas Ocultas
		Número de Neuronas de Salida
		Funciones de Activación
Paso 6	Criterios de Evaluación	

Paso 7	Entrenamiento de la Red Neuronal	Número Máximo de Iteraciones
		Factor de Aprendizaje y Momentum
Paso 8	Implementación	

Fuente: García y Morales (2016).

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	ECE S.A. de C.V.	GPH	GRUPO PALACIODE 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 S.A.B. de C.V.	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: García y Morales (2016). Basado en la Bolsa Mexicana de Valores (2016), en <https://www.bmv.com.mx/>

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

Razón financiera	No.	Relación Contable	Razón financiera	No.	Relación Contable
LIQUÍDEZ	1	<u>Activo Circulante</u> <u>Pasivo Circulante</u>	SOLVENCIA	14	<u>Intereses Pagados</u> <u>Resultado de Operación</u>
	2	<u>Activo Circulante</u> <u>Activo Total</u>		15	<u>Pasivo Largo Plazo</u> <u>Activo Fijo</u>
	3	<u>Activo Circulante</u> <u>Pasivo Total</u>		16	<u>Ventas Netas</u> <u>Pasivo Total</u>
	4	<u>Efectivo e Inver. Temporales/</u> <u>Pasivo Circulante</u>	ACTIVIDAD	17	<u>Ventas Netas</u> <u>Activo Total</u>
	5	<u>Activo Circulante e Invent./</u> <u>Pasivo Circulante</u>		18	<u>Ventas Netas</u> <u>Activo Fijo</u>
	6	<u>Variación Flujo Efectivo/</u> <u>Pasivo Total</u>		19	<u>Costo Ventas</u> <u>Inventarios</u>
APALANCAMIENTO	7	<u>Pasivo Total</u> <u>Activo Total</u>		20	<u>Cuentas por Cobrar</u> <u>(Ventas/360)</u>
	8	<u>Intereses Pagados</u> <u>Pasivo con Costo</u>		21	<u>360/Días de ventas por cobrar</u>
	9	<u>Pasivo Mon .Ext.</u> <u>Pasivo Total</u>		RENTABILIDAD	22
	10	<u>Capital Contable</u> <u>Activo Total</u>	23		<u>Resultado Neto</u> <u>Activo Total</u>
	11	<u>Pasivo circulante</u> <u>Activo Total</u>	24		<u>Resultado Neto</u> <u>Capital Contable</u>
	12	<u>Pasivo Total</u> <u>Capital Contable</u>	25		<u>Resultado Neto</u> <u>Activo Fijo</u>
	13	<u>Ventas Netas</u> <u>Capital de Trabajo</u>	26		<u>Resultado Operación</u> <u>Activo Total</u>
ESTADO DE CAMBIOS, TASAS DE CRECIMIENTO Y GENERACIÓN DE VALOR	29	<u>Flujo Derivado Resultado Neto</u> <u>Ventas Netas</u>	27		<u>Dividendo Efectivo</u> <u>Resultado Ejerc. Ant.</u>
	30	<u>Flujo Derivado cambios Capital Trabajo</u> <u>Ventas Netas</u>	28	<u>CIF</u> <u>Resultado Neto</u>	
	31	<u>Rec. Generados (Utilizados) Operación</u> <u>Intereses Pagados</u>	ESTADO DE CAMBIOS, TASAS DE CRECIMIENTO Y GENERACIÓN DE VALOR	34	<u>Adquisición Inm. Planta y Equipo</u> <u>Recursos Generados (Utilizados) Act. Inversión</u>
	32	<u>Financiamiento Ajeno</u> <u>Recursos Generados (Utilizados) Financiamiento</u>		35	<u>CashFlow Operativo/</u> <u>Pasivo Total</u>
	33	<u>Financiamiento Propio</u> <u>Recursos Generados (Utilizados) Financiamiento</u>		36	<u>CashFlow Operativo</u> <u>Pasivo Circulante</u>
				37	<u>EVA (Valor Económico Agregado)</u>
		38		<u>GEO (Generación Operativa Neta)</u>	

Fuente: García y Morales (2016). Basado en la Bolsa Mexicana de Valores (2016), en <https://www.bmv.com.mx/>

Tabla 3 Relación de las dimensiones de eficiencia financiera para considerar a las empresas exitosas y no exitosas del sector comercial de la BMV para el periodo de 1990 a 2011.

Empresa	Bursatilidad	Crecimiento del valor de las acciones en veces	Generación Economica Operativa (GEO)	Utilidades últimos 5 años	Expansión Empresa	Alianzas estrategicas	Apalancamiento o promedio	Éxito con todos los criterios	Aumento valor acción, GEO, Utilidades, Expansión empresa	Éxito por utilidades
ALMACO	Nd	19.58	0.04	SI	SI	NO	0.48	NO	SI	SI
ALSEA	Baja	1.87	0.04	SI	SI	SI	0.35	NO	SI	SI
BEVIDES	Baja	0.12	-0.04	NO	SI	SI	0.58	NO	NO	NO
CNCI	Baja	0.07	-0.08	NO	SI	NO	0.44	NO	NO	NO
COLLADO	Minima	0.71	0.01	SI	SI	NO	0.61	NO	SI	SI
COMERCI	Alta	1.48	-0.02	SI	SI	SI	0.44	NO	NO	SI
DERMET	Minima	0.11	-0.13	NO	SI	NO	0.62	NO	NO	NO
DOCUFOR	Nd	Nd	0.04	NO	SI	NO	0.65	NO	NO	NO
ECE	Baja	0.04	-0.28	NO	SI	NO	0.75	NO	NO	NO
EDOARDO	Minima	0.47	-0.13	NO	SI	NO	0.29	NO	NO	NO
ELEKTRA	Alta	1.68	0.08	SI	SI	NO	0.80	NO	SI	SI
FRAGUA	Media	2.48	0.27	SI	SI	NO	0.48	NO	SI	SI
GCORVI	Baja	0.28	-0.01	SI	SI	NO	0.63	NO	NO	SI
GFAMSA	Nd	1.81	0.00	SI	SI	NO	0.64	NO	NO	SI
GIGANTE	Media	0.20	-0.09	SI	SI	SI	0.41	NO	NO	SI
GMARTI	Baja	1.91	0.00	SI	SI	NO	0.44	NO	SI	SI
GOMO	Minima	0.05	-0.18	NO	SI	NO	0.48	NO	NO	NO
GPH	Minima	1.12	-0.02	SI	SI	NO	0.38	NO	NO	SI
LIVEPOL	Baja	1.49	0.01	SI	SI	NO	0.33	NO	SI	SI
MADISA	Minima	2.29	0.03	SI	SI	NO	0.64	NO	SI	SI
SAB	Baja	2.14	0.05	SI	SI	SI	0.56	NO	SI	SI
GSANBOR	Baja	9.28	0.01	SI	SI	NO	0.47	NO	SI	SI
SORIANA	Alta	3.56	0.01	SI	SI	NO	0.33	NO	SI	SI
WALMEX	Alta	3.62	0.08	SI	SI	SI	0.32	SI	SI	SI

Los modelos determinados en esta investigación fueron:

- Para la función discriminante múltiple (ADM) para el periodo de 1990 a 2011 se determinó que el modelo que clasifica a las empresas como exitosas y no exitosas dentro del sector comercial es la expresión matemática siguiente:

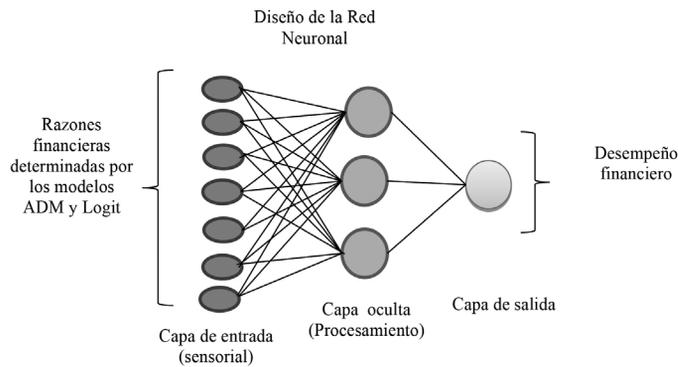
$$Z = -0.967 + 2.108 x_1 - 0.841 x_2 + 0.318x_3 - 0.097 x_4 + 0.023 x_5 + 14.466 x_6$$

- Para el modelo logit que clasifica a las empresas como exitosas y no exitosas está dado por la expresión matemática siguiente:

$$Z = -1.3998 + 3.3105 X_1 + 0.5085X_2 - 0.6697 X_3 - 0.1618 X_4 + 0.04757X_5 + 0.000019 X_6 + 13.99887 X_7$$

- Para la RNA, se diseñó una red neuronal artificial de auto propagación multicapas de aprendizaje *feedback*, proponiendo como entrada la información contable de la empresa representada en las razones financieras tomadas en cuenta por los dos modelos anteriores con la intención de comparar las metodologías y sus resultados. Por otro lado, la información de salida para la red neuronal fue el desempeño de la empresa dentro del sector comercial medido mediante las siete dimensiones mencionadas en la tabla 3, que determinan si estas empresas son exitosas o no, dentro del sector comercial de la Bolsa Mexicano de Valores. Esta conceptualización se muestra de manera esquemática en la figura 1.

Figura 1. Conceptualización de la RNA para determinar el desempeño financiero de las empresas del sector comercial de la BMV.



Fuente: García y Morales (2016). Basado en la Bolsa Mexicana de Valores (2016), en <https://www.bmv.com.mx/>

4. RESULTADOS

Se desarrollaron un poco más de cincuenta arquitecturas neuronales, mediante la utilización del software SNN v.4.5; con el propósito de encontrar la arquitectura neuronal que mejor determinara el desempeño de las empresas del sector comercial, tomando en cuenta el nivel de sensibilidad que tienen estas

razones en la determinación del éxito de la simulación.

La red neuronal artificial que tuvo mayor eficiencia fue la de arquitectura MLP 6:12:2 (Multilayer Perceptron de una capa oculta) con 6 razones financieras de entrada, 12 nodos ocultos y dos de salida, que son el éxito o fracaso en el desempeño financiero de las empresas del sector comercial que cotizan en la BMV como se aprecia en la Tabla 4.

Las capas ocultas tienen una función de transferencia entre la de entrada y la oculta de tipo logístico, mientras que las capas ocultas y la de salida tienen una función de tipo softmax. Esta red neuronal artificial obtuvo una tasa de clasificación de 91.158% en su fase de entrenamiento, y de 85.544% en la comprobación de esta clasificación, esto nos da una precisión del 90.3% en la determinación del desempeño exitoso o no de las empresas del sector comercial que cotizan en la BMV.

En la tabla 5 se presenta el análisis de sensibilidad que tiene el modelo neuronal. En él, se aprecia la influencia que tiene cada razón financiera sobre el desempeño financiero. La razón financiera 19 (Costo de venta entre Inversión) y la razón financiera 2 (Activo circulante entre Activo total) son las que presentan mayor sensibilidad al medir el éxito o no éxito del grupo de empresas analizadas.

Tabla 4 Resumen de la actividad de la RNA obtenida de la Base de Datos de Acciones del Sector Comercial pertenecientes a la BMV 1990-2011.

Núm. de RNA	Nombre de la Red	Desempeño de la red en etapa de entrenamiento	Desempeño de la red en etapa de comprobación	Algoritmo de entrenamiento	Evaluación del error	Activación de la capa oculta	Activación hacia la capa de Salida
8	MLP 6-12-2	91.15854	85.5443	BFGS 66 ⁴	Entropía	Logística	Softmax

Fuente: García (2015) y Morales (2015). Basada en los resultados obtenidos del entrenamiento de la RNA Neuronal Multilayer Perception (NMLP) con arquitectura 6: 12: 2

⁴ Método Broyden - Fletcher - Goldfarb - Shanno (BFGS), que es un método numérico basado en la iteración de Newton para una resolución de optimización no lineal sin restricciones.

Tabla 5 Peso y grado de importancia de las razones financieras que determinan el desempeño financiero de las empresas que pertenecen al sector comercial de la BMV para el periodo 1990-2011

Análisis de Sensibilidad para la base de datos : DESEMPEÑO DE LA ACCIONES DEL SECTOR COMERCIAL PERTENECIENTES A LA BMV: 1990-2011)						
Orden de importancia en la sensibilidad	1	4	6	2	3	5
Razón financiera	2 AC÷ AT	3 AC÷PT	4 EfeceInv÷PC	18 VN÷AF	19 CostoVentas÷Inv	26 ROper÷AT
8.MLP 6-12-2	12.86578	5.249325	1.527529	8.405727	6.32765	3.364224
% de importancia sobre la sensibilidad del modelo	34%	14%	4%	22%	17%	9%

Elaboración Propia: Basada en los resultados obtenidos del entrenamiento de la RNA Neuronal Multilayer Perceptron (NMLP) con arquitectura 6: 12: 2

Por lo tanto, la capacidad de predicción del desempeño financiero que tiene la red neuronal en general, es decir, para clasificar a las empresas exitosas y a las no exitosas es del 91.15% en el entrenamiento.

5. DISCUSIÓN

Si bien ya existen estudios sobre este tema (específicamente el de Morales [2007]), los resultados obtenidos difieren al aplicar RNA, ya que al incorporar esta técnica se da más robustez a la clasificación de las empresas exitosas o no exitosas. Ya que, como menciona Kamruzzaman (2006), aunque las redes neuronales fueron inicialmente desarrolladas como un modelo para simular la inteligencia humana en la máquina, estas tienen una excelente capacidad para aprender la relación entre la asignación de entrada-salida de un determinado conjunto de datos sin ningún conocimiento o suposiciones sobre la distribución estadística de los datos, a diferencia de las técnicas tradicionales que necesitan forzosamente tener ciertos criterios basados en parámetros de distribución normal.

Los resultados encontrados con la técnica de redes neuronales artificiales (RNA) arrojaron que esta técnica tiene un mejor pronóstico de evaluación y de clasificación que la obtenida por las técnicas ADM y Logit como se muestra en la Tabla 6.

Como se puede apreciar en la tabla 6., el modelo neuronal mejora la capacidad de predicción y clasificación en la determinación del desempeño de las empresas de la Bolsa Mexicana de Valores.

6. CONCLUSIONES

Los resultados encontrados con la técnica de redes neuronales artificiales (RNA) arrojaron que esta tiene un mejor pronóstico de evaluación y de clasificación que la obtenida por las técnicas ADM y Logit. Después de realizar un análisis de 50 arquitecturas y analizar sus supuestos, se encontró que una de las mejores arquitecturas neuronales es una MLP 6:12:2, es decir una red perceptron multicapa con 6 razones financieras, siendo tres de liquidez, dos de actividad y una de ciclo; con doce nodos

Tabla 6. Resumen de la matriz de precisión en clasificación del Desempeño Financiero de las empresas del Sector Comercial para la BMV, en la que compara las metodologías ADM, Logit y RNA para el periodo de 1990-2011.

Modelo	Precisión en la clasificación del Desempeño Financiero de las empresas		Total de aceptabilidad en la evaluación del desempeño
	Exitosa	No exitosa	
ADM*	81.38%	51.45%	66.80%
Logit*	80.30%	54.0%	68.80%
RNA	90.44 %	91.67%	91.15%

Fuente: García (2015) y Morales (2015). Basada en los resultados obtenidos del entrenamiento de la RNA Neuronal MultilayerPerceptron (NMLP) con arquitectura 6: 12: 2

en una capa oculta, y dos que clasifican a las empresas como exitosas y no exitosas. Las capas ocultas tuvieron una función de transferencia de tipo logística entre la capa de entrada y la oculta, mientras que entre la capa oculta y la de salida la función de transferencia fue de tipo softmax.

Con esta investigación se pretende hacer una contribución al uso de nuevas metodologías sobre estudios realizados para determinar el desempeño financiero de las empresas que cotizan en la BMV.

Para finalizar, se puede decir que la técnica de RNA permite a los analistas financieros, inversionistas y a todos aquellos involucrados en la medición del desempeño financiero tener una herramienta no tradicional que da mayor certidumbre en la toma de decisiones relacionadas con este sector y esta bolsa. Cabe señalar que los hallazgos encontrados en este estudio pueden servir como base para estudios futuros con otros sectores y otras bolsas.

REFERENCIAS

Alquicira, S. (2001), *Redes Neuronales Artificiales aplicadas a la detección de enfermedades cardiovasculares (rótula ventricular aguda y angina de pecho)*. México: UNAM, Facultad de Contaduría y Administración. Tesis de Licenciatura en Informática.

Altman, E., G. Marco y F. Varetto. (1994), Corporate Distress Diagnosis: Comparisons Using Linea Discriminant Analysis and Neural Networks (The Italian Experience). *Journal of Banking and Finance*, Vol. 18, No. 3, pp. 505-529.

Bribiesca, G. (2006). *Redes Neuronales Artificiales para la toma de decisiones: El Caso de tutores del Programa de Posgrado en Ciencias de la Administración*. México: UNAM, Programa de Posgrado en Ciencias de la Administración. Tesis de Doctorado en Ciencias de la Administración.

Berumen, G. (1998), *La teoría del caos y las redes neuronales aplicadas a las finanzas*, Tesis de maestría en ingeniería económica y financiera, México: Universidad La Salle.

Bosarge, W. (1989), *A Non Random Walk Down Wall Street*. USA: Princeton University Press, pp. 45.

Chiang, W., T. Urban y G. Baldrige. (1996). A Neural Network Approach to Mutual Fund Net Asset Value Forecasting. *International Journal of Management Science*, Vol.24, No. 2, pp.205-215.

Collantes, J. V. (2001), *Predicción con redes neuronales: Comparación con las metodologías de Box y Jenkins*, Tesis de maestría. Universidad de los Andes.

Dutta, S. y Shekbar, S. (1988), "Bond Rating: A Non-conservative Application of Neural Networks", Proceedings of the IEEE International Conference on Neural Networks, pp. II443-II450.

García, I. (2003), Análisis y predicción de la serie de tiempo del precio externo del café colombiano utilizando redes neuronales artificiales, *Revista de la Facultad de Ciencias*, Pontificia Universidad Javeriana, Vol. 8, pp. 45-50.

García, J. (2009). *Redes Neuronales Artificiales para el pronóstico del PIB: México, 1980.1-2008.3*. México: UNAM, Facultad de Economía División de Estudios de Posgrado. Tesis de Maestría en Economía.

García, M. (1996). *Redes Neuronales Artificiales: Aplicación en el diagnóstico diferencial de la demencia vascular y tipo Alzheimer*. México: UNAM, Facultad de Ingeniería División de Estudios de Posgrado. Tesis de maestría en Ingeniería Eléctrica.

Haefke, C. y Helmenstein, C. (2002), Index Forecasting and Model Selection, *International Journal of Intelligent Systems in Accounting, Finance and Management*, Abr/Jun, 11, 2, ABI/INFORM Global, pp. 119-135.

Hawley, D. et al. (1990). Artificial Neural Systems. A new Tool for Financial Decision-Making, *Financial Analysts Journal*, pp. 90-113.

Hebb, D.O. (1949). *The Organization of Behavior*. Nueva York: John Wiley & Sons.

Hill, T., O'connor, M. y Remus, W. (1996), Neural Network Models for Time Series Forecasts, *Management Science*, Vol. 42, No. 7, pp. 1082-1092.

Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. USA, *Proc. Natl. Acad. Sci*, vol. 79, April. pp. 2554-2558.

Kamruzzaman, J., Begg, R. & Sarker, R. (2006). *Artificial Neural Networks in Finance and Manufacturing*. NY: Idea Group Publishing.

Makridakis, S., et al., (1982), The Accuracy of Extrapolation (Time Series) Methods: Results of a Forecasting Competition, *Journal of Forecasting*, 1, pp. 111-153.

McCulloch, W. S. & Pitts, W. (1943). A Logical Calculus of the Ideas Imminent in Nervous activity, *Bulletin of Mathematical Biophysics*, Vol. 5, pp. 115-133.

Medeiros, M., Veiga, A. y Pedreira, C. (2001), Modeling Exchange rates: Smooth Transitions, *Neural Networks, and Linear Models*, *IEEE Transactions on Neural Networks*, Vol. 12, No. 4, julio, pp. 755-764.

Melchor, A. (2010). *Uso de las Redes Neuronales Artificiales para el Pronóstico de la Inflación*. México: UNAM, Facultad de Ciencias. Tesis de Actuaría.

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 Nacional Autónoma de México.

Peel, M. & Wilson, N. (1996). Neural network simulation: A new approach to risk assessment and business forecasting. *Management Research News*, Vol. 19, No. 6, ABI/INFORM Global, pp. 50-54.

Pérez, G. (1998), *Las redes neuronales artificiales: una herramienta cibernética para la estimación de precios en el mercado de productos derivados*, Tesis de licenciatura en Ingeniería en cibernética y ciencias de la computación, México: Universidad La Salle.

Rosenblatt, R. (1959). *Principles of Neurodynamics*, Nueva York: Spartan Books.

Salchenberger L., Cinare., y Lash. (1992). Neural Networks: a new tool for predicting thrift failures, *Decision Sciences*, Vol 23. pp. 899-916.

Shang-Wu, Y. (1999), Forecasting and Arbitrage of the Nikkei Stock Index Futures: An Application of backpropagation Networks, *Asia-Pacific Financial Markets*, diciembre, No. 6, pp. 341-354.

Sejnowski, T. y Rosenberg, C. R. (1986). *NETtalk: A Parallel Network That Learns to Read Aloud*. Technical Report JHU/EECS-86/01, Johns Hopkins Univ.

Stansell, S. y Eakins, S. (2004), Forecasting the direction of change in sector stock indexes: An application of neural networks, *Journal of Asset Management*, jun, 5, 1. ABI/INFORM Global, pp. 37-48.

Tam, K. Y. y Kiang, M. Y. (1992), Predicting Bank Failures: A Neural Network Approach. *Management Science*, Vol. 38, No. 7,

pp. 926-947.

Trippi, R. (1990), *Intelligent Systems for Investment Decision Making. Managing Institutional Assets*, USA: Fabozzi, pp. 251.

Torres, I. (2007). *Pronósticos en el mercado de derivados utilizando redes neuronales y modelos ARIMA: Una aplicación al Cete de 91 días en el MexDer*. México: UNAM, Programa de Posgrado en Ciencias de la Administración. Tesis de Maestría en Finanzas.

White, H. (1988). *Economic prediction using neural networks: The case of IBM daily stock returns*, USA, IEEE International Conference on Neural Networks, pp. 451-459.

Yu, L., S. Wang, W. Huang y K. Lai (2007). Are Foreign Exchange Rates Predictable? A Survey from Artificial Neural Networks Perspective? *Scientific Inquiry*, Vol.8, (2), pp. 207-228.

Zhang, G. P. y Berardi, V. L. (2001), Time series forecasting with neural network ensembles: an application for exchange rate prediction, *Journal of the operational research society*, 52, pp. 652-664.