

REDES NEURONALES EN PREDICCIÓN DE MERCADOS FINANCIEROS: UNA APLICACIÓN EN LA BOLSA MEXICANA DE VALORES

NEURAL NETWORKS IN FINANCIAL MARKET PREDICTION: AN APPLICATION IN THE MEXICAN STOCK EXCHANGE

Miguel Alfonso Becerra Montañez

Universidad de Guanajuato
ma.becerramontanez@ugto.mx

Alejandro Ortega Hernández

Universidad de Guanajuato
a.ortega@ugto.mx

Jhon Alejandro Montañez Barrera

Universidad de Guanajuato
ja.montanezbarrera@ugto.mx

Sinai López Castillo

Universidad de Guanajuato
s.lopez.castillo@ugto.mx

Resumen

Desde la creación del mercado accionario, conocer las rentabilidades que ofrecen sus activos ha despertado interés tanto de inversionistas como investigadores. Actualmente, se encuentran múltiples aplicaciones documentadas que han intentado predecir acciones, índices u otros activos alrededor del mundo. Sin embargo, las aplicaciones en mercados emergentes y en particular el mexicano, es limitado y poco explorado. Este documento presenta una aplicación que predice las variaciones diarias de una de las empresas participantes en la BMV con un enfoque de análisis híbrido. Utiliza la capacidad de las redes Feed Forward y el algoritmo Backpropagation en problemas de predicción. La selección de variables de entrada a la red se realizó a través del ACP y el estadístico utilizado para medir la precisión de las predicciones es el MSE. Los resultados reflejan una importante contribución a la discusión de la posibilidad o no, de predecir estos activos en el corto plazo.

Palabra(s) Clave: ACP, Bolsa Mexicana de Valores, Mercado de valores, Predicción de mercados, RNA.

Abstract

Since creation of stock market, to know the returns offered by these assets has attracted interest from both investors and researchers. There are multiple documented applications that have tried to predict stocks, indexes or other assets around the world, however, applications in emerging markets as Mexican market, are limited and little explored. This document presents forecast of daily variations of one of companies participating in BMV uses the capacity of Feed Forwards ANNs and Backpropagation algorithm in prediction problems. The selection of input variables to the network was made through the PCA and the MSE statistic was used to measure accuracy of predictions. Results reflect an important contribution to the discussion of the possibility or not of predicting these assets in the short term.

Keywords: ACP, Market prediction, Mexican stock exchange, Stock market, RNA.

1. Introducción

Predecir los movimientos del mercado accionario, ha sido por años una tarea compleja que ha despertado el interés de investigadores e inversionistas alrededor del mundo. Estos, han intentado adelantarse a conocer los niveles de retorno y así, reducir el riesgo al que se enfrentan en las inversiones [Fernández y Zamorano, 2014]. Los mercados de capitales son espacios de fundamental importancia para el desarrollo de las economías y su buen manejo favorece la transición del ahorro a la inversión mediante la compra y venta de acciones [Charris-Fontanilla, 2016]. Estas acciones, son tan importantes que están influenciadas por variables económicas, sociales, políticas y culturales. Por lo tanto, resulta razonable considerar el valor de una acción en un instante no como una variable determinística sino como una variable aleatoria, considerando su trayectoria temporal como un proceso estocástico [Lamberton, 2007].

Gracias a la importancia económica y al interés de los inversionistas por anticiparse al mercado accionario, muchos investigadores han centrado sus esfuerzos en

comprender los fenómenos que influyen en la volatilidad de las acciones [Charris-Fontanilla, Parody-Camargo, & Causad-Rodriguez, 2016]. A pesar de los avances, se encuentra lejos de ser una línea de investigación agotada y aún hay mucho campo por explorar porque aún no existen técnicas consistentes que funcionen de forma sostenida [Gutpa, 2014]. La situación actual de las cotizaciones, ha puesto en evidencia la necesidad de especular los precios de acciones sobre la base de valores objetivos para evitar crisis económicas y mejorar los rendimientos de las inversiones [Iñíguez, 2003]. Respecto a la perspectiva teórica de la modelación y pronóstico de este tipo de series de tiempo financieras, se encuentran dos posturas populares. La primera, asume que el precio de un activo financiero cuenta con información suficiente y útil que lo hace susceptible a ser predecible, esto quiere decir que, su comportamiento pasado tiende a repetirse en el futuro [Murphy, 2000]. La segunda, la Hipótesis de Mercados Eficientes (HME), plantea que no es posible predecir precios futuros a partir de precios pasados. Asegura que los mercados son reflejo de toda la información disponible y no se puede seguir una regla de comercio que proporcione beneficios adicionales [Fama, 1964]. Aceptar la HME implicaría que es imposible obtener rendimientos superiores a los del promedio del mercado, situación que en la práctica ha sido rebatido pues inversores como Warren Buffet y Peter Lynch han logrado superar el promedio del mercado por más de 20 años.

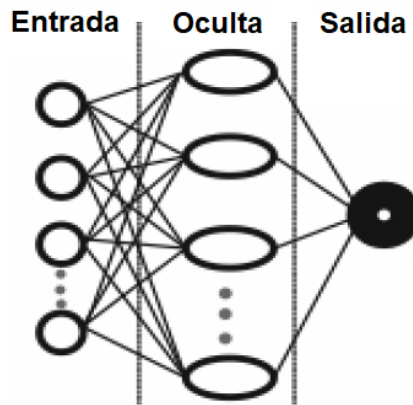
Existen dos enfoques con los que se pueden modelar los mercados accionarios: el análisis fundamental y el análisis técnico [Gupta, 2014]. El primero, es un enfoque numérico de series de tiempo que se basa en intentar estimar los valores que alcanzan las acciones con rendimientos pasados. El segundo, es un estudio de los factores que afectan la oferta y la demanda. Se realiza mediante el análisis, recopilación e interpretación de la información entregada por las empresas en sus informes, balances, declaraciones o noticias [Vui, Soon, On, Alfred & Anthony, 2013]. Los trabajos publicados hasta el momento recogen dichos enfoques de forma separada, empleando técnicas econométricas, estadísticas o computacionales y haciendo predicciones de corto, mediano o largo plazo.

El reto de predecir el comportamiento de los activos de las Bolsas de Valores, ha logrado que en las últimas décadas se publiquen múltiples estudios; los primeros

modelos empleados para la predicción de estas series de tiempo, fueron los lineales por su fácil interpretación. A principios de la década de 1980, los más usados para modelar el comportamiento accionario fueron los ARMA. Sin embargo, pasada la década se le da más importancia a la volatilidad de las acciones que a la media de los datos y ARCH y GARCH se hicieron populares [Alonso y Garcia, 2009]. En general, se han empleado modelos ARIMA como el presentado por [Ariyo, Adewumi & Ayo, 2014], de regresión múltiple como el desarrollado por [Forslund & Akesson, 2013], algoritmos genéticos como el mostrado por [Lakshman Naik, Ramesh, Manjula, & Govardhan, 2012] y, en la última década, con mayor frecuencia las aplicaciones con Redes Neuronales Artificiales (RNA) como la publicada por [Arrieta Bechara, Torres Cruz, & Velásquez Ceballos, 2009]. Los más exactos en la predicción han sido los que han usado metodologías computacionales como las RNA [Rao, Hule, Shaikh, Nirwan, & Daflapurkar, 2015]. En este sentido, [Arrieta Bechara *et al.*, 2009] empleó las RNA para el pronóstico de la acción de Suramericana de Inversiones SA, comparó los resultados con modelos econométricos, obteniendo mayor precisión en las predicciones diarias con RNA. Arrieta concluyó que la habilidad de las técnicas estadísticas se reduce a medida que las series de tiempo se hacen complejas mientras que las RNA con suficientes datos y una arquitectura adecuada son mucho más eficientes.

En general, las Redes Neuronales han sido usadas en la predicción de acciones, índices accionarios, futuros, materias primas y divisas. Los estudios han confirmado que el uso de redes Backpropagation (BP) son ideales en los pronósticos de corto plazo [Parody-Camargo, 2016]. Una RNA, es un conjunto de capas interconectadas que consta de una o más neuronas artificiales, tienen la capacidad de aprender, generalizar, encontrar patrones ocultos y procesar información eficientemente [Chang Sim Vui, 2013]. La arquitectura más popular en los problemas de predicción financiera ha sido con tres capas (entrada, oculta y salida) y se ha demostrado que aumentar el número de capas no resulta en mejoras significativas de las predicciones [Hagan, Demuth, & Hudson, 2014]. Un ejemplo de este tipo de red se puede apreciar en la figura 1. Entre las arquitecturas de RNA que se han desarrollado se encuentran:

- Redes Feed Forward (FF).
- Redes recurrentes.
- Redes de impulso.



Fuente: Elaboración propia.

Figura 1 Arquitectura de una Red Neuronal Artificial.

Otras redes populares, han sido las redes multicapa, de base radial y de auto organización. En la predicción del mercado de valores las más comunes son las redes FF multicapa que emplean el algoritmo BP, en estas redes, la información se va moviendo en una sola dirección desde la capa de entrada hacia la capa oculta y posteriormente a la capa de salida. Después de comparar la salida de la red con un valor objetivo o meta, el error es propagado hacia atrás para ajustar los parámetros de la red, a este tipo de aprendizaje se le conoce como aprendizaje supervisado [Gupta, 2014].

El trabajo de investigación presentado en este documento desarrolla una aplicación para la predicción de los rendimientos que presenta la acción del grupo Alfa S.A.B de C.V (ALFAA) que cotiza en la Bolsa Mexicana de Valores (BMV) con un enfoque de corto plazo (diario). Se emplean Redes Neuronales multicapa FF con el algoritmo BP y se considera un análisis híbrido que integra tanto variables del análisis fundamental como del análisis técnico, partiendo del razonamiento que ambos análisis son considerados por los inversionistas en sus especulaciones.

Esta aplicación, pretende proveer una evidencia que indique a los inversionistas de la BMV, la posibilidad de emplear herramientas que faciliten el proceso de toma de

decisiones de inversión y pueda ser replicado en empresas de la industria bursátil como: fondos de inversión, calificadoras de valores, sociedades administradoras de inversión, proveedores de precios, sociedades fiduciarias O por *traders* de mercados descentralizados y de operación diaria como Forex. El valor teórico de esta aplicación se fundamenta en la integración de variables que se contemplan tanto en los análisis técnicos como en los fundamentales proponiendo un enfoque más robusto que los realizados hasta ahora. Las conclusiones aportan una base que soportará la aceptación o el rechazo de la HME desarrollada por Fama en 1964. Se espera que los resultados obtenidos se puedan replicar en otras aplicaciones con diversas acciones y BV alrededor del mundo.

2. Métodos

Esta metodología es una adaptación de la propuesta por [Vui *et al.*, 2013] que resulta de una recopilación de las pautas que diversos investigadores han aportado para guiar los experimentos predictivos con RNA, como puede apreciarse en la figura 2:

- *Selección de datos:* Para esta actividad se toman en cuenta series datos que se relacionan con las variaciones de la acción en estudio y son potenciales patrones de entrada a la RNA. Las series seleccionadas inicialmente fueron 392, estas incluyeron: divisas, índices de la bolsa de valores, materias primas, futuros y otros datos del análisis fundamental como indicadores financieros de la empresa Alfa SAB de CV e indicadores macroeconómicos, tabla 1. La selección de la acción de Alfa SAB de CV (AlfaA) obedeció a los criterios de: disponibilidad de la información, relevancia dentro de la BMV, sector industrial diversificado, impacto en la economía mexicana y relación con índices e indicadores. Además, porque hace parte del índice de Precios y Cotizaciones (IPC), principal índice accionario de la bolsa.
- *Organización y homogeneización de los datos:* Es común encontrar series de datos incompletas o de tamaños distintos por las diferencias en los tiempos de operación de los mercados, por esta razón, se requiere completarlas empleando técnicas estadísticas y ajustarlas a los periodos de operación de

la acción AlfaA. El estudio comprendió el periodo entre el 28/05/2015 y el 28/06/2018, los datos fueron descargados de INEGI y del portal financiero global Investing.com, se organizaron en Excel cronológicamente y los datos faltantes fueron estimados a través de la técnica de medias móviles. Esta técnica consiste en calcular el promedio aritmético a un subgrupo de observaciones previas al dato faltante y usarlo en su lugar [Andersson & Palm, 2009]. Aquellas series que presentaron un alto volumen de datos incompletos fueron descartadas y las que permanecieron se igualaron de acuerdo con el calendario de operación de la acción en estudio, de esta forma, se garantiza que las series tengan la misma longitud y las observaciones coincidan con las fechas de operación.



Fuente: Elaboración propia.

Figura 2 Metodología de la investigación.

Tabla 1 Serie de datos de entrada (potenciales).

Categoría	Series de datos	No. de series de tiempo
Tasas de cambio	Precio de cierre, apertura, máximo, mínimo.	122
Índices	Precio de cierre, apertura, máximo, mínimo, volumen.	115
Materias primas	Precio de cierre, apertura, máximo, mínimo, volumen.	30
Futuros	Precio de cierre, apertura, máximo, mínimo, volumen.	76
Macroeconómicos	Precio de cierre, apertura, máximo, mínimo.	10
Ratios financieros	Cubrimiento de intereses, reducción de la deuda, ingresos margen bruto, margen neto, margen de operación, prueba ácida, rentabilidad de fondos, rentabilidad operativa, utilidad por acción, ventas, flujo de caja.	39
Total		392

Fuente: Elaboración propia.

- *Preprocesamiento de los datos*: Garantizar la estacionalidad de las series de tiempo y eliminar las tendencias son requisitos fundamentales en los modelos paramétricos y de predicción, por esta razón se usaron series de retornos simples en lugar de series de precios, pues presentan mejores propiedades estadísticas [Andersson & Palm, 2009], para lo cual fue aplicada ecuación 1.


$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}} \quad (1)$$

En donde: R_t Retorno simple.

P_t Precio del día t

P_{t-1} Precio del día anterior a t

Así mismo, los datos fueron estandarizados para que estos entraran en el dominio activo de la función de transferencia Tansig, es decir, que oscilaran en un rango de -1 y 1, como se aprecia en la figura 3.



$$y = \text{tansig}(v) = \frac{2}{1 + e^{2v}} - 1$$


Figura 3 Función de transferencia.

Para ello se empleó un escalado lineal calculado con la ecuación 2. Los resultados de este preprocesamiento, son series sin tendencia, varianza constante y al menos débilmente estacionarias, todas estas, condiciones ideales para el desarrollo del modelo de predicción [Monsalve & Harmath, 2015].

$$\hat{y}_t = 2 \left[\frac{y_t - \min(Y)}{\max(Y) - \min(Y)} \right] - 1 \quad (2)$$

En donde: \hat{y}_t Valor t de la serie Y transformado
 y_t Valor t de la serie Y
 $\min(Y)$ Valor menor de la serie Y
 $\max(Y)$ Valor mayor de la serie Y

Este proceso fue realizado para la totalidad de las series de tiempo presentadas en la tabla 1. El efecto en las series del preprocesamiento puede verse en la figura 4.



Fuente: Elaboración propia.

Figura 4 Transformación de series de precios en series de rendimientos.


- Selección de variables de entrada: De las 392 series, fue necesario depurar aquellas que presentaran alta correlación entrada-entrada porque aportarían poca o nula información adicional a la red y dificultarían su aprendizaje [Andersson & Palm, 2009], por esta razón, se realizó un análisis de correlación entre las series y se eliminaron aquellas que presentan correlaciones superiores a 0,85. En la tabla 2 se presenta una porción de la matriz de correlaciones de las 392 series de tiempo, los valores sombreados representan las correlaciones altas e indican la necesidad de eliminar alguna de las variables correlacionadas. A continuación, se ejecutó un Análisis de Componentes Principales (ACP) para reducir el problema dimensional y facilitar el aprendizaje de la red.

Tabla 2 Fragmento de matriz de correlaciones (criterio para depurar series de datos)

		ALFA						Real Brasileño/MXN			
		Último	Apertura	Máx	Min	m	Vol	Cierre	Apertura	Máxima	Mínimo
ALFA	Último	1									
	Apertura	0,995	1								
	Máximo	0,998	0,998	1							
	Mínimo	0,998	0,997	0,9972	1						
	Pendiente	0,081	0,015	0,0447	0,0559	1					
	Vol	-0,052	-0,056	-0,044	-0,067	-0,011	1				
Real Brasileño/MXN	Cierre	-0,661	-0,662	-0,664	-0,658	-0,02	0,0996	1			
	Apertura	-0,664	-0,666	-0,668	-0,661	-0,014	0,096	0,996288	1		
	Máximo	-0,658	-0,660	-0,662	-0,656	-0,023	0,1011	0,997875	0,997731	1	
	Mínimo	-0,669	-0,670	-0,672	-0,666	-0,018	0,0931	0,998155	0,998309	0,996821	1
Peso Chileno/MXN	Cierre	-0,016	-0,015	-0,013	-0,014	-0,016	-0,005	0,042277	0,03753	0,04056	0,039698
	Apertura	-0,013	-0,018	-0,015	-0,017	0,0252	0,0358	0,05003	0,042261	0,047812	0,044181
	Máximo	-0,020	-0,023	-0,02	-0,022	0,0065	0,0219	0,065311	0,056457	0,062528	0,059349
	Mínimo	-0,763	-0,761	-0,763	-0,761	-0,017	-0,007	0,739056	0,743594	0,741246	0,742852
Yuan Chino/MXN	Cierre	-0,616	-0,615	-0,613	-0,62	-0,012	-0,036	0,590785	0,590001	0,595526	0,586069
	Apertura	-0,613	-0,615	-0,612	-0,617	0,0213	-0,041	0,587584	0,59175	0,592986	0,585535
	Máximo	-0,608	-0,608	-0,605	-0,613	-0,01	-0,03	0,589761	0,590171	0,597261	0,584531
	Mínimo	-0,628	-0,629	-0,627	-0,632	0,0074	-0,046	0,594783	0,597175	0,59893	0,592997
EURO/MXN	Cierre	-0,806	-0,804	-0,804	-0,808	-0,025	-0,03	0,670097	0,670842	0,671199	0,67172
	Apertura	-0,802	-0,802	-0,801	-0,803	0,0022	-0,032	0,667869	0,672244	0,669719	0,671326
	Máximo	-0,798	-0,797	-0,797	-0,801	-0,023	-0,024	0,668194	0,66967	0,671528	0,66914
	Mínimo	-0,811	-0,811	-0,811	-0,813	-0,008	-0,037	0,671219	0,674271	0,672056	0,674927
Rupee India/MXN	Cierre	-0,734	-0,733	-0,734	-0,736	-0,024	0,0451	0,856555	0,855324	0,858477	0,853557
	Apertura	-0,733	-0,734	-0,734	-0,735	0,0031	0,0394	0,853615	0,856672	0,856241	0,852908
	Máximo	-0,728	-0,728	-0,728	-0,731	-0,021	0,0497	0,854025	0,854138	0,85842	0,850738
	Mínimo	-0,742	-0,742	-0,743	-0,743	-0,009	0,0371	0,857654	0,859125	0,859076	0,857221
MXN/Peso Argentino	Cierre	-0,768	-0,765	-0,768	-0,765	-0,027	-0,106	0,38719	0,391262	0,38605	0,396387
	Apertura	-0,772	-0,768	-0,772	-0,769	-0,036	-0,117	0,391672	0,394586	0,39025	0,400395
	Máximo	-0,765	-0,762	-0,765	-0,763	-0,031	-0,102	0,385085	0,388482	0,384052	0,393608
	Mínimo	-0,774	-0,771	-0,774	-0,771	-0,028	-0,12	0,393246	0,397051	0,391196	0,402794

Fuente: Elaboración propia.

- Construir el modelo y selección de la mejor arquitectura: Los datos son divididos en tres grupos: entrenamiento, validación y pruebas (figura 5).



Fuente: Elaboración propia.

Figura 5 División de datos.

Durante estas etapas fue necesario realizar un proceso de experimentación apoyado por el software Matlab y su Toolbox, en este, se combinaron el número de entradas y de neuronas en la capa oculta. Una vez realizados los

experimentos, se seleccionó la arquitectura que presentó un mejor rendimiento de predicción, medido con los estadísticos MSE y la tasa de aciertos en las tres etapas.

- *Evaluación de Resultados:* La fase final consistió en expresar las conclusiones sobre las medidas de rendimiento (MSE y Tasa de Aciertos) obtenidas y con mejores resultados, analizar la utilidad de las predicciones y establecer consideraciones para futuras investigaciones.

3. Resultados

La ejecución del ACP, con el fin de reducir el problema de la dimensionalidad para agilizar el aprendizaje de la red, se realizó con el criterio de Kaiser, el cual indica que se deben preservar los factores cuyos valores propios sean mayores a uno porque estos contribuyen con una unidad de varianza a la varianza total. El resultado del ACP fue la extracción 19 componentes que explican el 83.5% de la varianza total del modelo, la tabla 3 presenta el resultado del ACP expresado en los valores propios de cada componente.

Tabla 3 Valores propios y varianza total explicada.

No.	Valores propios		
	Total	% varianza	% acumulado
1	17.864	19.004	19.004
2	12.483	13.280	32.285
3	6.695	7.122	39.407
...
18	1.038	1.104	82.431
19	1.001	1.064	83.495
20	0.939	0.999	84.492
...
93	-1.10E-13	-1.10E-13	100
94	-1.20E-13	-1.21E-01	100

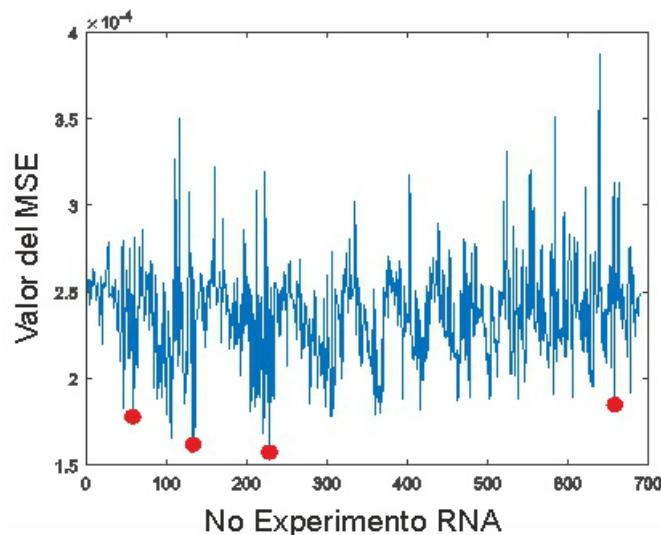
Fuente: Elaboración propia.

Después de realizar las combinaciones lineales de las componentes, para extraer los 19 factores que sirvieron como entradas a la red, se procede con el entrenamiento y la experimentación. Se utilizó una red multicapa FF, entrenada bajo

el algoritmo BP y constó de tres capas (entrada, oculta y de salida), la elección de esta arquitectura obedece a que su uso está ampliamente respaldado por trabajos como [Andersson & Palm, 2009]; [Constantinou et al., 2012]; [Moghaddam et al., 2016]; [Munasinghe, 2015]; [Sim Vui et al., 2013]; [Vaisla & Bhatt, 2010]. Se empleó un aprendizaje supervisado, lo que significa que se proporcionó a la red una salida esperada (Objetivo) para que sus parámetros (pesos sinápticos y bias) se ajustaran hasta que las salidas se aproximaran al objetivo. La salida esperada fueron los rendimientos diarios de la acción presentadas en el periodo de estudio.

El algoritmo de optimización empleado, fue el de gradiente decreciente, su uso se justifica en la capacidad que tiene para predecir problemas económicos o financieros y por su habilidad de generalizar modelos de series de tiempo no lineales [Arrieta Bechara et al., 2009]. En total se probaron 689 Redes FF con la ayuda de un código desarrollado en Matlab que agilizó el proceso experimental. Los resultados de los 689 experimentos en la etapa de entrenamiento en términos del Error Cuadrático Medio (MSE) se presentan en la figura 6. El cálculo del MSE se realizó mediante la expresión presentada en la ecuación 3.

$$MSE = \frac{1}{n} \sum_{i=1}^n (f_i - y_i)^2 \quad (3)$$



Fuente: Elaboración propia.

Figura 6 MSE de las redes neuronales entrenadas.

En donde: n Número de datos
 f Valor pronosticado del modelo
 y Valor real comparado

Del total de los experimentos, fue necesario extraer aquellas redes que en sus etapas de entrenamiento, validación y pruebas obtuvieran los mismos resultados o resultados próximos porque no necesariamente la red que presente el menor MSE en la etapa de entrenamiento, es la que tiene mejor desempeño en el pronóstico. La razón, es que pudo haber existido un sobreajuste, es decir que la red aprendió bien del conjunto de datos de entrenamiento, pero es incapaz de generalizar el modelo [Gupta, 2014]. Las mejores arquitecturas por su proximidad en los valores de entrenamiento, validación y pruebas se presentan en la tabla 4.

Tabla 4 Arquitecturas con mejores rendimientos en los pronósticos.


No. RNA	MSE entrenamiento	MSE pruebas	% aciertos dirección	Arquitectura	
				Neuronas en capa oculta	Días (entradas)
367	0.00017978	0.00018284	73.3%	5	58
394	0.00018786	0.00018955	70%	6	24
478	0.00018872	0.00018951	66.67%	8	13
566	0.00021348	0.00021582	66.67%	10	28

Fuente: Elaboración propia.

Aquella red que presentó el mejor rendimiento en la predicción de los rendimientos diarios de la acción, fue la red 367. En la figura 7 se presentan las predicciones de los rendimientos realizados por esta red y se contrastan con los valores reales del periodo. Se observan algunas desviaciones significativas, sin embargo, la gráfica logra de alguna manera simular el comportamiento de los rendimientos sin llegar a la precisión. Otro aspecto que se analizó, fue si la red logró predecir la dirección que tomó la acción, esto es, si la acción subió o bajó de precio, la red logró hacerlo en el 73.3% de las oportunidades, siendo un resultado importante para este tipo de problemas.

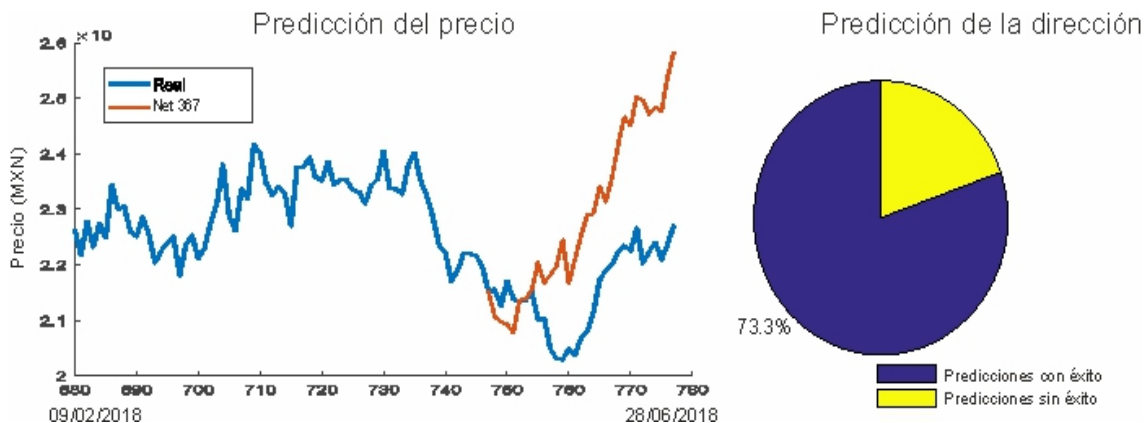
Una vez, convertidos estos pronósticos de rendimientos a pronósticos de precios, se observan las desviaciones de la predicción, si bien no existe una alta precisión,

si se puede observar que la red logra capturar la tendencia del periodo de pronóstico de AlfaA, es importante resaltar que se presentan únicamente los 30 datos finales porque en la etapa experimental se evidencia que es el periodo en el que la red puede presentar resultados con desviaciones mínimas ya que al aumentar el periodo de predicción, las diferencias se amplían dada la acumulación del error día tras día. Esta situación sugiere que para resultados más confiables se deben considerar periodos de tiempo cortos en la predicción como se ve en la figura 8.



Fuente: Elaboración propia.

Figura 7 Proyecciones de los rendimientos acción AlfaA (Pronósticos).



Fuente: Elaboración propia.

Figura 8 Proyecciones de los pronósticos en series de precios y tasa de aciertos en la dirección.

4. Discusión

Los resultados demuestran que es posible predecir la dirección de la acción con un 73.3% de aciertos, esto es un resultado importante, teniendo en cuenta que proveería al inversionista algún grado de certidumbre en sus inversiones. Se encontró que la precisión de las predicciones reduce pasados 30 días por lo que es ideal re-entrenar la Red Neuronal con regularidad para mantener el rendimiento de pronóstico. En cuanto a las predicciones de los rendimientos de AlfaA, el MSE presentó un valor de 0.00018 para la mejor red. En este punto es importante resaltar que las variaciones de la acción en estudio oscilan entre -0.04 y 0.05, por lo que este valor de MSE no es un resultado confiable para predecir los rendimientos. Sigue siendo un desafío predecir la magnitud de la ganancia o pérdida que podría obtener un inversionista.

Al convertir la serie de rendimientos pronosticada a una serie de precios, es posible observar que la red generalizó con éxito la tendencia de la acción, si bien no se predice con exactitud, demuestra que si es posible aproximarse a los resultados en periodo de tiempo cortos. Se puede inferir que, con alguna otra configuración de variables y arquitecturas, o inclusive con otro tipo de red, se podrían obtener resultados más exactos.

Finalmente, los resultados de esta investigación, aportan evidencias al debate mundial centrado en la posibilidad o no, de predecir mercados financieros en el corto plazo. Desde el punto de vista de los investigadores, los resultados reflejan una posibilidad de acercarse a los comportamientos del mercado mediante el uso de técnicas de análisis de datos y de inteligencia artificial. El éxito de los resultados dependerá de la disponibilidad y calidad de la información relacionada. En futuras investigaciones se pretende mejorar la precisión de las predicciones a través del diseño de nuevos modelos de predicción, profundizando aún más en las variables que podrían afectar a la acción en específico. Es posible que algunas de las variables seleccionadas, hayan entorpecido el proceso de aprendizaje y no hayan aportado información relevante. También, se considera emplear un tamaño de muestra más amplio, otras redes y diferentes algoritmos de aprendizaje para medir su incidencia en los resultados.

5. Bibliografía y Referencias

- [1] Alonso, Julio Cesar, and Juan Carlos García. (2009) ¿Qué tan buenos son los patrones del IGBC para predecir su comportamiento? *Estudios Gerenciales* 25(112): 13-36.
- [2] Andersson, Magnus, and Johan Palm. (2009). *Forecasting the Stock Market: A Neural Network Approach*. Malardalen University.
- [3] Ariyo, Adebisi A., Adewumi O. Adewumi, and Charles K. Ayo. (2014). Stock Price Prediction Using the ARIMA Model. In 2014 16th International Conference on Computer Modelling and Simulation, IEEE, 106-12.
- [4] Arrieta Bechara, Jaime Enrique, Juan Camilo Torres Cruz, and Hermilson Velásquez Ceballos. (2009). Predicciones de Modelos Económicos y Redes Neuronales: El Caso de La Acción de Suraminv. *Semestre Económico* 12(25): 95-109.
- [5] Charris-Fontanilla, Arturo, Edder Parody-Camargo, and Edwin Causad-Rodríguez. (2016). Aplicación Del Modelo Estocástico Winer Gaus Para la predicción del precio de acciones del Mercado Bursátil Colombiano. In XXI Congreso Internacional de Contaduría, Administración e Informática, Ciudad De México: Scielo, 20.
- [6] Eugene, Fama. (1965). The Behavior of Stock-Market Prices. *The Journal of Business* 38(1): 34-105.
- [7] Fernández, Rodrigo, and Pablo Zamorano. (2014). Modelos Predictivos de Índices Bursátiles Relevantes Para La Economía Chilena. Universidad de Chile.
- [8] Forslund, Gustaf, and David Akesson. (2013). Predicting Share Price by Using Miltiple Linear Regression. KTH Royal Institute of Technology.
- [9] Gupta, Abhishek. (2014). A Survey on Stock Market Prediction Using Various Algorithms. *International Journal Computer Technology and Applications* 5(April): 530-533.
- [10] Hagan, Martin T, Howard Demuth, and Mark Hudson. (2014). *Neural Network Design*. 2nd Ed. Frisco Tx: Martin Hagan.

- [11] Iñíguez, Raul. (2003). Aplicación de Los Modelos de Feltham-Ohlson Para La Predicción de Los Beneficios y La Valoración de Las Acciones. Universidad de Alicante.
- [12] Lakshman Naik, R, D Ramesh, B Manjula, and A Govardhan. (2012). Prediction of Stock Market Index Using Genetic Algorithm. *Computer Engineering and Intelligent Systems* 3(7).
- [13] Lamberton, Darmien. (2007). Introduction to Stochastic Calculus Applied to Finance. 2nd Ed. ed. Taylor & Francis Group. New York, NY, USA: Chapman and Hall.
- [14] Moghaddam, Amin Hedayati, Moein Hedayati Moghaddam, and Morteza Esfandyari. (2016). Predicción Del Índice Del Mercado Bursátil Utilizando Una Red Neuronal Artificial. *Journal of Economics, Finance and Administrative Science* 21(41): 89-93.
- [15] Monsalve, Abelardo, and Pedro Harmath. (2015). Introducción al análisis de series de tiempo con aplicaciones a la economía y finanzas. 1st Ed. ed. Escuela Venezolana de Matemáticas. Caracas: Ediciones IVIC.
- [16] Murphy, John J. (2000). Análisis Técnico de Los Mercados Financieros. 1st Ed. New York, NY, USA: Prentice Hall.
- [17] Parody-Camargo, Edder, Arturo Charris-Fontanilla, and Rafael García-Luna. (2016). Modelo log-normal para predicción del precio de las acciones del sector bancario. *Dimensión empresarial* 14: 137-49.
- [18] Rao, A., et al. (2015). Survey: Stock Market Prediction Using Statistical Computational Methodologies and Artificial Neural Networks. *International Research Journal of Engineering and Technology* (08).
- [19] Sim Vui, Chang et al. (2013). IEEE International Conference on Control System, Computing and Engineering, 2013 A Review of Stock Market Prediction with Artificial Neural Network (ANN). Penang: IEEE.
- [20] Vui, Chang Sim et al. (2013). A Review of Stock Market Prediction with Artificial Neural Network (ANN). In International Conference on Control System, Computing and Engineering, Penang: IEEE, 477-82.