


# Instrumento Novedoso de Predicción en Finanzas

María Eugenia Serrano Acevedo  
Jaime Ángel Rico Arias

## Introducción

El mercado accionario en Colombia ha ido creciendo en los últimos siete años, gracias a la fusión de las tres bolsas que existían hasta entonces, la Bolsa de Bogotá, la de Medellín y la de Cali. La dinámica de este crecimiento no ha alcanzado el estado esperado debido a muchos factores macroeconómicos y además la falta de herramientas de pronóstico que permitan disminuir el temor de los inversionistas por falta de conocimiento del movimiento del mercado. Las redes neuronales artificiales son una herramienta que puede facilitar la predicción de eventos futuros con un nivel de error menor al de otros métodos de pronósticos.

En este artículo describiremos una aplicación de las redes neuronales a la predicción de la rentabilidad de algunas acciones que cotizan en la bolsa de valores de Colombia, usando una red multicapa con algoritmo de aprendizaje *backpropagation*, mostrando que esta red presenta un error de pronóstico menor al de otros métodos tradicionales tales como ARIMA y regresión múltiple.



## Marco teórico

Las redes neuronales son modelos matemáticos multiparamétricos no lineales capaces de inducir una respuesta entre conjuntos de patrones de información.

Existen diferentes clasificaciones de las redes; una de ellas de acuerdo con su arquitectura y aprendizaje; dentro de esta podemos considerar las redes supervisadas, no supervisadas, clasificándose a su vez en realimentadas y unidireccionales<sup>1</sup>.

La red escogida para esta aplicación es una red supervisada y unidireccional llamada Perceptron multicapa con algoritmo *Backpropagation*, que permite aprender a través de un conjunto de ejemplos, aproximar relaciones no lineales, filtrar ruido en los datos, etc; siendo este un modelo adecuado para abordar datos reales, convirtiéndose en una nueva clase de funciones, que pueden usarse para aproximar o interpolar relaciones no lineales.

El sistema de entrenamiento de este tipo de aprendizaje consiste en iniciar con pesos sinápticos que pueden ser o no escogidos al azar; se introduce una base de datos ya establecida; después de insertarse un patrón a la entrada de la red éste se propaga desde la primera capa hacia las capas superiores procesando los datos por las diferentes capas para arrojar una salida; dicha respuesta se compara con la salida deseada o real y la diferencia que se obtiene de estas dos (error), se utiliza para ajustar los pesos de las capas de salida; el error luego se propaga hacia atrás por cada una de las capas que intervinieron en el proceso, ajustando y redistribuyendo los pesos de conexión de cada neurona hasta llegar a la capa de entrada, permitiendo que la red clasifique adecuadamente los patrones de entrenamiento y de esta manera procesar los datos nuevamente para arrojar una nueva salida. Este proceso se repite iterativamente hasta alcanzar el error deseado.

La correspondencia establecida se ha realizado entre las variables de la economía, del sector y de la empresa que afectan el precio y la rentabilidad de las acciones más bursátiles de la bolsa de valores de Colombia.

## Descripción de variables

La red multicapa con algoritmo *backpropagation* fue diseñada y entrenada a partir de una base de datos conformada por las acciones de Suramericana, Cementos Caribe, Coltabaco, Corfinsura, Grupo Aval, Valores Bavaria, Cementos Paz del Río, Nacional de Chocolates, Éxito, Argos, Bavaria, Banco de Bogotá y las variables Producto Interno Bruto (PIB), precio de la acción, Dividendo Yield, relación precio ganancia (RPG), Q-tobin, tasa de cambio representativa del mercado (TRM), índice general de la bolsa de valores de Colombia (IGBC), índice de precios al consumidor (IPC), oferta monetaria (M1), tasa de interés (DTF) en el periodo de enero del 99 a junio del 2005.

Para mostrar un ejemplo de los resultados obtenidos escogimos la acción de Bavaria.

## Identificación de la serie rentabilidad de Bavaria

En el gráfico N°1 podemos observar la rentabilidad de Bavaria desde enero de 1999 hasta junio del 2005.

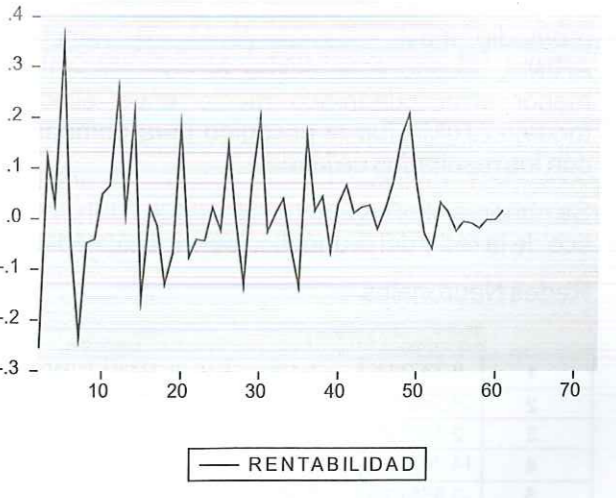


Gráfico N°1

Esta serie es estacionaria. Para verificar esto se aplicó la prueba de raíz unitaria.

<sup>1</sup> Martín del Brío, Bonifacio, Sanz Molina, Alfredo. Redes Neuronales y Sistemas Difusos. Segunda Edición. Editorial Alfaomega. 2002.

Null Hypothesis: RENTABILIDAD has a unit root  
 Exogenous: Constant  
 Lag Length: 0 (Automatic based on SIC, MAXLAG=10)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-8.194953	0.0000
Test critical values:		
1% level	-3.546099	
5% level	-2.911730	
10% level	-2.593551	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(RENTABILIDAD)  
 Method: Least Squares  
 Date: 01/27/03 Time: 16:55  
 Sample(adjusted): 3 61  
 Included observations: 59 after adjusting endpoints

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RENTABILIDAD(-1)	-1.022765	0.124804	-8.194953	0.0000
C	0.022436	0.013602	1.649521	0.1045
R-squared	0.540905	Mean dependent var		0.004642
Adjusted R-squared	0.532850	S.D. dependent var		0.150897
S.E. of regression	0.103135	Akaike info criterion		-
				1.672237
Sum squared resid	0.606304	Schwarz criterion		-
				1.601812
Log likelihood	51.33099	F-statistic		67.15725
Durbin-Watson stat	1.904830	Prob(F-statistic)		0.000000

Tabla N°1

Se puede observar un t estadístico de -8,19, el cual es mayor que los valores críticos al 90%, 95% y 99%, lo que nos indica que existe evidencia muestral con un nivel de confianza del 99% que la serie es estacionaria; por tanto, no tiene raíz unitaria. Para la predicción de la rentabilidad de la acción escogida a la base de datos se le aplicaron los modelos tradicionales de pronóstico como promedio móvil, suavizamiento exponencial y ARIMA, siendo este último el que presentó el menor error cuadrático medio entre ellos. El modelo ARIMA fue el escogido para compararlo con los resultados de la red.

Se observan los siguientes resultados del pronóstico de la red y del pronóstico del modelo ARIMA.

Redes Neuronales

	Rent. Real	Rent. Pronos	Error	MSE
1	9,23271%	-1,12%	-10,35271%	0,010718
2	24,35928%	-0,73%	-25,08928%	0,062947
3	2,44769%	-0,16%	-2,60769%	0,000680
4	14,26756%	0,59%	-13,67756%	0,018708
5	-3,85513%	1,51%	5,36513%	0,002878
6	5,84629%	2,53%	-3,31629%	0,001100
7	5,69111%	3,53%	-2,16111%	0,000467
8	-4,52658%	4,39%	8,91658%	0,007951
9	7,65474%	5,03%	-2,62474%	0,000689
10	8,85861%	5,46%	-3,39861%	0,001155
11	13,21039%	5,72%	-7,49039%	0,005611
12	-3,24494%	5,89%	9,13494%	0,008345
			MSE	1,01%

Tabla 2a


Arima

	Rent. Real	Rent. Pronos	Error	MSE
1	9,232708%	2,7567%	-6,4760%	0,004194
2	24,359281%	1,5052%	-22,8541%	0,052231
3	2,447695%	-2,0714%	-4,5191%	0,002042
4	14,267558%	4,4169%	-9,8507%	0,009704
5	-3,855129%	1,9934%	5,8485%	0,003421
6	5,846292%	2,2978%	-3,5485%	0,001259
7	5,691110%	1,9123%	-3,7788%	0,001428
8	4,526583%	0,8105%	5,3371%	0,002848
9	7,654744%	2,8092%	4,8455%	0,002348
10	8,858611%	2,0626%	6,7960%	0,004619
11	13,210395%	2,1564%	-11,0540%	0,012219
12	-3,244941%	2,0377%	5,2826%	0,002791
			MSE	2,73%

Tabla 2b

Como podemos ver, el error cuadrático medio dado por la red es de 1,01% en un periodo de pronóstico de un año y el del modelo ARIMA es de 2,73%. Esto nos indica que con la red se puede obtener un mejor pronóstico en un horizonte temporal de un año, como se puede apreciar en la siguiente gráfica.

Gráfica rentabilidad para Bavaria pronosticada por la red



Gráfica N°2

En la gráfica N°2 podemos observar en la línea azul el comportamiento de la rentabilidad de la acción de Bavaria en el periodo de enero de 1999 a junio del 2005 y en rojo observamos la predicción realizada por la red neuronal creada, vemos como el pronóstico de la red se aproxima a los datos reales.

Lo mismo se pudo observar con las otras 11 acciones trabajadas; esto nos lleva a concluir que las redes neuronales artificiales son una herramienta que puede facilitar la predicción de

eventos futuros con un nivel de error menor al de otros métodos de pronósticos, permiten describir una serie temporal sin necesidad de preocuparnos por problemas de multicolinealidad ni tener que especificar previamente el tipo de relación funcional entre variables.

Las RNA se usan para pronosticar tendencias de mercado con alta volatilidad cuyas variables obedecen a comportamientos no lineales y también pueden realizar predicciones financieras a partir de series de datos históricos como por ejemplo: índices financieros, cotizaciones de bolsa, etc... Su fortaleza está en que las RNA se pueden entrenar para resolver problemas donde no existen modelos matemáticos para la predicción de mercados financieros, como en aquellos en donde existen correlaciones complejas entre los diferentes valores y pueden estar influenciados por sucesos que no están contemplados o de los que no se dispone de información suficiente.

Entre algunas de las tantas aplicaciones en la Ingeniería Financiera se tienen:

- Predicción de índices
- Detección de fraudes
- Riesgo crediticio
- Predicción de la rentabilidad de las acciones
- Concesión de préstamos (Perfil del cliente)
- Análisis fundamental y técnico
- Estimación de beneficios
- Predicción de quiebra de empresas

- Calificación de activos financieros
- Clusters del movimiento de precios de los valores.

Referencias Bibliográficas:

Martín del Brio, Bonifacio y Sanz Molina, Alfredo. Las redes neuronales y sistemas difusos. Segunda Edición. Alfaomega. 2002.

Hilera González, José Ramón y Martínez Hernando, Víctor José. Redes Neuronales artificiales. Fundamentos, modelos y aplicaciones. Alfaomega.2000.

Haykin, Simon. Neural Network. A comprehensive Foundation. Second Edition. Prentice Hall.

Isasi Viñuela, Pedro. Redes neuronales artificiales. Un enfoque práctico. Primera edición. Pearson, Prentice Hall. 2004.

Deboeck, Guido y Kohonen, Teuvo. Visual Exploration in Finance with Self-organizing Maps. Springer Finance. Second edition. 2000.

McNelis, Paul D. Neural Networks in Finance, Gaining predictive edge in the market. Ed. Elsevier Academic Press. Primera edición. 2005.

Shadbolt, Jimmy y Taylor, John G. Neural Networks and the financial markets. Predicting, Combining and Portfolio Optimisation. Ed. Springer. Primera Edición. 2002.