

Pronóstico de bolsa de valores empleando técnicas inteligentes

Forecasting of Stock Exchange through Intelligent Techniques

ELIANA MIRLEDY TORO OCAMPO

Ingeniera industrial de la Universidad Tecnológica de Pereira y magíster en Ingeniería eléctrica de la misma Universidad. Docente catedrática en la Facultad de Ingeniería industrial de la Universidad Tecnológica de Pereira en el área de investigación operativa.
eliana@ohm.utp.edu.co

ALEXANDER MOLINA CABRERA

Ingeniero electricista y magíster en Ingeniería eléctrica de la Universidad Tecnológica de Pereira. Docente categoría Auxiliar del Programa de Ingeniería eléctrica de la misma Universidad, en el área de planeamiento.
almo@utp.edu.co

ALEJANDRO GARCÉS RUIZ

Ingeniero electricista y magíster en Ingeniería eléctrica de la Universidad Tecnológica de Pereira. Docente categoría Auxiliar del Programa de Ingeniería eléctrica de la misma Universidad, en el área de planeamiento.
alejandrog@utp.edu.co

Clasificación del artículo: reflexión

Fecha de recepción: 3 de agosto de 2005

Fecha de aceptación: 2 de junio de 2006

Palabras claves: pronóstico, redes neuronales, redes neurodifusas, lógica difusa, bolsa de valores, inteligencia artificial.

Key words: forecasting, neural networks, neurofuzzy networks, fuzzy logic, stock exchange, artificial intelligence.

RESUMEN

En este artículo se presenta un estudio comparativo entre la predicción de precios en bolsa de valores utilizando redes neuronales y neuro-difusas. Se muestra una metodología aplicable a la predicción del comportamiento de cualquier tipo de acción, basada en el cálculo preliminar de la correlación

entre el precio y otras variables de mercado. El pronóstico del valor de las acciones en la bolsa de valores incide en los procesos de toma de decisiones de las empresas u otros agentes del mercado afectados por su comportamiento. Los resultados obtenidos fueron satisfactorios en cuanto al porcentaje de error del valor estimado frente al valor real. Las técnicas inteligentes se muestran como

una herramienta interesante que está mostrando resultados promisorios y abre un abanico de posibilidades por explorar en el campo del pronóstico.

ABSTRACT

This paper shows a comparative study between forecasting of prices in stock exchange using neural and neurofuzzy networks. It is presented a methodology, usable to predict any kind of stock based

on previous calculations about correlation between stocks price and other variables of the market. Forecasting of prices in stock exchange affects the processes to make decisions of companies and other agents in the market who could be influenced by their behavior. The obtained results was satisfactory, referred to the mistake percentage of estimated values versus real values. Intelligent techniques are interesting tools which are showing promising results and open an spectrum of possibilities to study in forecasting area.

* * *

1. Introducción

Una de las mayores preocupaciones de quienes toman decisiones gerenciales es el comportamiento futuro del mercado. Cuando se tienen datos históricos de la variable bajo estudio, que permitan predecir el futuro, es posible proponer un modelo matemático representativo del proceso que luego puede emplearse para generar pronósticos. No obstante, las características atípicas de algunos fenómenos económicos impiden que la predicción se ajuste al comportamiento real del sistema.

Para obtener pronósticos pueden emplearse técnicas cualitativas o cuantitativas. En el primer caso, un pronóstico es casi siempre el resultado de una expresión de los juicios u opiniones de uno o más expertos (la técnica subjetiva); en el segundo caso se usan dos técnicas basadas en estadísticas convencionales (análisis de series de tiempo y de regresión). Hoy día puede identificarse una tercera alternativa, que combina técnicas cualitativas y cuantitativas: las redes neuronales y los sistemas difusos.

Las redes neuronales permiten plantear métodos de pronóstico tipo combinado; entre sus fortalezas se destaca la capacidad de manejar discontinuidades en la información; además, pueden procesar varias series de datos y cruzarlas entre sí. Los sistemas difusos representan el conocimiento utilizando

etiquetas o expresiones lingüísticas más fáciles de interpretar; sin embargo, su capacidad de aprendizaje es reducida. Las redes neurodifusas combinan en un sistema integrado estos dos elementos: redes neuronales y lógica difusa.

Con propósitos comparativos, en este artículo se muestra una aplicación de estos dos tipos de redes al pronóstico de precios en bolsa de valores de una acción. En la primera parte se describe las principales características del problema y su enfoque convencional; luego se hace una descripción de las técnicas de redes neuronales y neurodifusas, y finalmente se realiza la aplicación de estas dos técnicas al problema específico de predicción de precios y se muestran resultados comparativos.

2. Pronósticos y predicción de precios

Las decisiones gerenciales, rara vez, se toman sin contar con algún tipo de pronóstico; cuando éste se basa en técnicas subjetivas se utiliza el juicio personal y se hace uso de cualidades como la intuición, la opinión de un experto y la experiencia. Las técnicas más utilizadas son el grupo de expertos y el método Delphi [1].

En la obtención de pronósticos cuantitativos se usan dos metodologías basadas en estadísticas convencionales: los análisis de series de tiempo y de regresión. Una serie de tiempo estadística es un

conjunto de valores numéricos de una variable aleatoria a lo largo de un horizonte de tiempo y pueden ser de los siguientes tipos: modelo de nivel constante, de nivel constante con efectos estacionales y con tendencia lineal.

En el análisis de regresión, la variable que se va a pronosticar (dependiente) se expresa como una función matemática de otras variables (independientes). Este tipo de metodologías opera bien cuando el fenómeno en estudio presenta una tendencia de ajuste suave, es decir, cuando los datos en un intervalo no presentan cambios bruscos de pendiente.

Los sistemas inteligentes utilizan una combinación de las técnicas cuantitativas y cualitativas, lo que permite evaluar variables con tendencias fluctuantes; en esta situación, las demás metodologías no son tan efectivas, si se compara el error medio cuadrático entre ellas.

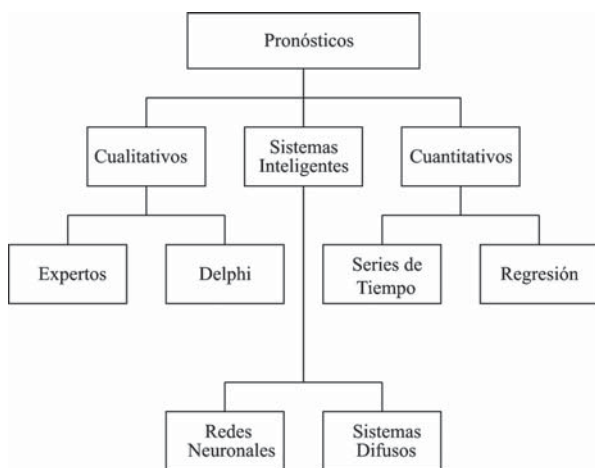


Figura 1. Tipos de predicción.

Los pronósticos deben obtenerse y analizarse con una perspectiva dinámica; asimismo, es preciso comparar los datos acumulados con sus pronósticos asociados; tales datos también pueden utilizarse para actualizar parámetros y redefinir el modelo, de acuerdo con la evolución de la variable a través del tiempo. El proceso es relevante en el ambiente empresarial porque con base en sus resultados se

diseñan políticas de comercialización, planeación financiera y de producción; de esta forma, el éxito o fracaso gerencial dependerá del grado de acierto de las predicciones realizadas.

Muchos autores han tratado el tema de predicción de precios. En [2] se presenta una comparación entre redes neuronales y series de tiempo, concluyendo que las primeras presentan mejor desempeño, en especial cuando los datos históricos tienen algún grado de disturbio. En [3] se implementa una técnica neuro-difusa a la predicción de precios en la bolsa de energía; ella entregó mejores resultados, en comparación con técnicas como los «procesos *markovianos* de decisión» [4]; una posible explicación a este comportamiento es que el mercado de energía es altamente volátil y requiere de herramientas que incluyan aprendizaje y adaptación al fenómeno.

3. Redes neuronales

Se ignora bastante acerca de la forma en que el cerebro aprende a procesar la información; sin embargo se han desarrollado modelos que tratan de emular sus habilidades, denominados redes neuronales artificiales, cuya elaboración supone la deducción de los rasgos o características esenciales de las neuronas, sus conexiones y la implementación del modelo en un computador, para que pueda simularse. Estos modelos son idealizaciones burdas de las auténticas redes neuronales, pero resultan interesantes por su capacidad de aprendizaje [5]; las redes tienen múltiples aplicaciones en actividades como estudios de crédito, identificación de fallas en sistemas de potencia, análisis de series de tiempo y predicciones financieras, entre otras.

Las redes neuronales son grafos organizados por capas en cuyos vértices se procesa información, con un tipo de funciones matemáticas determinadas y con la característica de ser densamente interconectada. Una de tipo *FeedForward* o *BackPropagation* es mostrada a continuación.




Figura 2. Esquema de una red neuronal.

La red mostrada en la figura 2 se denota como n-h-s, esto es, una red neuronal que contiene n entradas, h neuronas en la capa oculta y s neuronas en la capa de salida. Esta estructura se puede modificar, de tal forma que contenga un número mayor de capas ocultas.

Las neuronas son representadas por círculos; los enlaces son la conexión entre neuronas y tienen un valor de castigo llamado peso. Tomando como referencia una capa intermedia se afirma que cada neurona es alimentada por las salidas de la capa anterior, ponderada por los pesos existentes entre capas. La red procesa información de arriba hacia abajo; primero toma las entradas a procesar y luego las propaga, haciendo uso de los pesos hasta llegar a la salida.

Los nodos de entrada reciben los valores a procesar x_j , con $j = 1, \dots, n$, las neuronas ocultas reciben las entradas x_j ponderadas por los pesos w_{ij} y bias b_i para generar las salidas y_i (salidas de cada neurona de la segunda capa) que se calculan como:

$$y_i = \phi_i \left(\sum_{j=1}^n w_{ij} x_j + b_i \right) \text{ con } i = 1, \dots, h \quad (1)$$

En (1):

$\phi_i(\cdot)$ es la función de transferencia de la neurona i .

Finalmente, los nodos de salida hacen la suma ponderada de las salidas de las neuronas ocultas y luego se aplica la función para obtener las salidas de la red neuronal, a saber:

$$y_s = \phi_s \left(\sum_{i=1}^h w_{si} y_i + b_s \right) \text{ con } s = 1, \dots, g \quad (2)$$

El entrenamiento, o proceso de aprendizaje de la red, es similar al aprendizaje humano. Consiste en modificar la intensidad del valor de las conexiones entre neuronas, esto es, modificar el valor de los pesos. Para este tipo de redes es iterativo y supervisado; esto último, hace referencia a que el entrenamiento se realiza basándose en unos conjuntos de referencia, entrada-salida, llamados patrones.

La red toma las entradas y las propaga, se obtiene la salida de la red y con ésta se calcula un error; luego el error es propagado hacia atrás, haciendo uso de las derivadas de las funciones de cada neurona [6]. Lo anterior constituye una iteración que se sigue ejecutando hasta cumplir un criterio de parada, que puede ser el cumplimiento de un error o el alcance de un número de iteraciones¹. Luego del proceso de entrenamiento o aprendizaje y conociendo los pesos fijos del grafo puede afirmarse que se cuenta con una estructura computacional capaz de reproducir el modelo para el cual fue entrenado.

¹ Si bien estos dos criterios de parada son los más comunes, no son los únicos.

Una característica de las redes neuronales es la aproximación de funciones no-lineales; por tanto, es factible utilizarlas para predecir el precio de las acciones en la bolsa de valores. Si se utiliza la información histórica del mercado e información interna de la compañía de interés, la red puede encontrar una relación no lineal entre las variables seleccionadas [7].

En los últimos años las técnicas de inteligencia artificial han mostrado un notable desempeño en el área de la predicción, convirtiéndose en una temática en constante evolución. En [8] se muestra un modelo híbrido entre las redes neuronales y los modelos ARIMA², que presenta mejor desempeño que estos últimos por sí solos. En [9] se presenta una técnica combinada entre redes neuronales y algoritmos genéticos; esta metodología híbrida se emplea debido a que las redes neuronales muestran inconsistencias cuando procesan información con «ruido». En [10] se demuestra la superioridad de las redes neuronales frente a los modelos ARIMA en la predicción de precios futuros en mercados agrícolas.

Con base en lo anterior, para la presentación de la experiencia base de este artículo se hizo el proceso de selección de patrones de aprendizaje estableciendo el nivel de correlación entre las posibles variables de entrada y su efecto en la salida esperada, se realizó el entrenamiento y luego se implementó la red para la predicción, como se explicará en la sección 5.

4. Sistemas neurodifusos

Este tipo de sistemas identifican las reglas lógicas difusas y ajustan las funciones de pertenencia en forma automática y simultánea [5]. Así, ellos combinan el procedimiento de aprendizaje supervisado para construir los nodos de reglas y entrenar las funciones de pertenencia.

² ARIMA significa Modelos Autorregresivos de Medias Móviles.

4.1. Lógica difusa

Es una rama de la inteligencia artificial que permite procesar información, cuando se manejan términos inexactos, imprecisos o subjetivos. De manera análoga al funcionamiento del cerebro humano, es posible ordenar un razonamiento basado en reglas imprecisas y en datos incompletos; para ello se definen conjuntos difusos, en los cuales un elemento puede pertenecer parcialmente a varios conjuntos.

Definido sobre un universo U , un conjunto difuso D puede ser el siguiente:


$$D = [20\%/1, 50\%/4, 100\%/7] \quad (3)$$

La nomenclatura significa que el elemento 1 pertenece en un 20% al conjunto D (y por tanto pertenece en un 80% al complemento de D), en tanto que el elemento 4 pertenece en un 50% y el elemento 7 en un valor de 100%.

Algunas características de los conjuntos difusos son:

- La función de pertenencia asociada puede tener cualquier valor entre 0 y 1.
- Un elemento puede pertenecer (parcialmente) a un conjunto difuso y simultáneamente pertenecer (parcialmente) al complemento de dicho conjunto.
- Las fronteras del conjunto son difusas; existen elementos en las fronteras mismas, y estos pueden pertenecer simultáneamente a dos conjuntos.

Por ejemplo, supóngase que se desea clasificar a un grupo de deportistas según su estatura en tres conjuntos: bajos, medianos y altos. En conjuntos concretos una opción sería: se considera «bajo» si su estatura es inferior a 1,6 m, «mediano» si se ubica en el rango [1,6-1,80], y «alto» si la estatura es $\geq 1,8$ m. Si se opta por efectuar la clasificación con conjuntos difusos no se percibirían fronteras claras, pues ellas permitirían cambios graduales en la clasificación. Un deportista con 1,63 m. de estatura tendría un valor de pertenencia al conjunto denominado bajo (0,8) y un valor de pertenencia al conjunto denominado mediano (0,2).



Gráfica 1. Funciones de pertenencia en conjuntos difusos.

Los conjuntos difusos permiten definir sub-conjuntos, de tal manera que cualquier elemento pueda pertenecer a ellos en diferentes grados. Las reglas difusas permiten procesar relaciones entre variables y producir una salida borrosa o difusa; a partir de ésta última pueden proporcionarse cantidades binarias y continuas, como el estado de un interruptor o una cantidad de dinero.

Una regla difusa consiste en una serie de antecedentes y consecuentes. Por ejemplo, para el pronóstico de precios de la acción estudiada es posible plantear lo siguiente:

***IF** el día es lunes **AND** cotización del dólar es alta **THEN** el precio de la acción es bajo.*

4.2 Sistema ANFIS

En este artículo se trabajó con la arquitectura ANFIS³. Estos sistemas utilizan un mecanismo de inferencia tipo Sugeno [11].⁴

Las reglas para un sistema neurodifuso están expresadas como:

$$\alpha_i = \text{IF } X_1 \text{ es } A_1 \text{ AND } X_2 \text{ es } A_2 \text{ then } Z_i = w_1 A_1(X_1) + w_2 A_2(X_2)$$

³ ANFIS significa «sistema de inferencia difusa basado en una red adaptativa».

⁴ Una red adaptativa es una estructura de varias capas del tipo de propagación hacia adelante, en la que cada nodo realiza una función particular con las señales de entrada así como los parámetros asociados a ese nodo.

El operador lógico «AND» puede modelarse mediante cualquier norma-T continua y diferenciable [11], por ejemplo:

$$\alpha_i = A_1(X_1) \wedge A_2(X_2) \quad (4)$$

En este caso el producto se elige como norma T. Generalizado para varias entradas se tiene:

$$\alpha_i = \prod A_i(X_i) \quad (5)$$

La salida total del sistema corresponde a la defusificación de las diferentes reglas:

$$Y = \frac{\sum w_j \cdot \alpha_j}{\sum \alpha_j} \quad (6)$$

En la figura 3 se muestra el esquema general de un sistema ANFIS. La primera capa corresponde a las entradas; la segunda aplica las funciones de inferencia, que en este caso son campanas de Gauss expresadas como:

$$A_i(x) = e^{-\left(\frac{\mu_i - x}{\sigma_i}\right)^2} \quad (7)$$

Los parámetros de entrenamiento son las medias de cada una de las funciones de pertenencia (μ_i), las desviaciones correspondientes (σ_i) y los pesos (w_j) de cada una de las reglas.




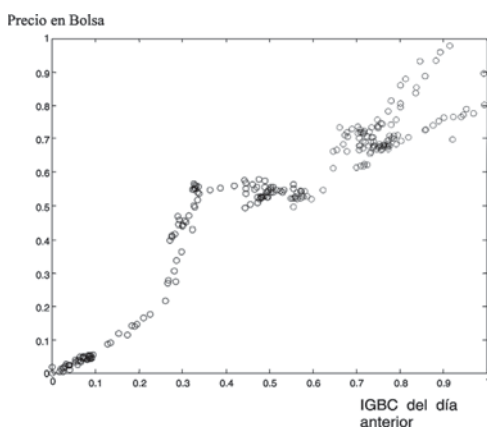
Figura 3. Sistema ANFIS

La tercera capa calcula la intensidad de disparo de la regla asociada; las salidas de las neuronas están dadas por la ecuación 5. La cuarta capa corresponde a la defusificación de los niveles de disparo, como se expresa en la ecuación 6.

3. Experimentación

Se realizó un estudio estadístico del precio de acción en la bolsa de valores de una empresa del sector financiero (Corfinsura S.A.)⁵ y se determinó su correlación con otras variables de mercado. Para determinar las variables de entrada se evaluaron varias opciones que pudiesen repercutir directamente sobre el pronóstico; en el proceso se descartaron aquellas que no tenían correlación con el fenómeno en estudio. Así, el procedimiento aplicado fue el siguiente: para el mismo periodo de tiempo se observó el comportamiento del precio de la acción en bolsa, la tasa representativa del mercado (TRM), el índice general de la Bolsa de Valores de Colombia⁶ (IGBC), la tasa de depósitos a término fijo de 90 días (DTF90) y el valor del euro; el cálculo de los coeficientes de correlación respectivos demostró la gran dispersión con los datos del euro y la DTF90, luego estas variables no fueron tenidas en cuenta.

Graficando el precio de la acción normalizado contra el IGBC y la TRM del día anterior⁷ se encontró una correlación más estrecha entre ellas (ver gráfica 2).



Gráfica 2. IGBC contra precio en bolsa.

⁵ Los datos de la compañía pueden consultarse en la página de Internet:

<http://www.corfinsura.com/espanol/home/home.asp>

⁶ La Bolsa de Valores de Colombia es la plataforma única que desde el año 2001 administra los mercados accionario, cambiario, de derivados y de renta fija en Colombia.

⁷ Teniendo en cuenta que se pretende realizar una predicción.

Con resultado, los datos de entrada para el entrenamiento de las redes se definieron así: a) IGBC del día anterior⁸; b) TRM del día anterior; valor de la acción en bolsa del día anterior; c) valor de la acción en bolsa dos días atrás.

El precio de la acción en bolsa se considera una variable estocástica de características dinámicas. Por tanto, se diseñó una red entrenada bajo un esquema de «ventana móvil»; los n datos anteriores al día de predicción se emplean para entrenar la red y predecir el dato $N+1$.

5.1 Predicción usando redes neuronales

La red neuronal diseñada cuenta con una capa de entrada, una de salida y dos intermedias, como se muestra en la figura 4.

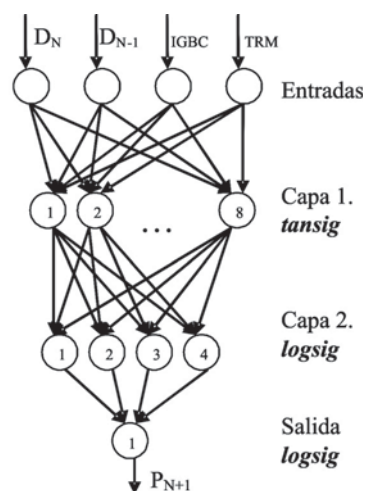


Figura 4. Modelo de la red neuronal empleada.

⁸ El IGBC es relevante en el comportamiento accionario, ya que contiene información consolidada sobre volumen y frecuencia de las transacciones accionarias. Se calcula con base en: a) liquidez o rotación de la acción; b) frecuencia de negociación; c) cantidades diarias transadas en el año inmediatamente anterior al cálculo del índice para la canasta elegida; d) valor nominal de la acción en cada periodo de tiempo. Para calcular este índice se elige un conjunto de acciones denominado «canasta», que deben cumplir con un mínimo de rotación en el último semestre mayor o igual a 0,5%, y frecuencia de negociación en el trimestre inmediatamente anterior superior al 40%.

Para probar la eficiencia del algoritmo se utilizaron los datos de acciones diarias de la empresa *Corfinsura* disponibles en [12]. La red se entrenó con n datos y se comprobó su capacidad para predecir el dato $N+1$. El error está definido como:

$$E_{rr} = D_{N+1} - P(D_N, D_{N-1}, IGBC_N, TRM_N) \quad (8)$$

En (8):

Err: Error de predicción para el día $N+1$

D_{N+1} : Precio de la acción en bolsa para el día $N+1$.

D_N : id. para el día N

D_{N-1} : id. para el día $N-1$

$IGBC_N$: Índice general de la bolsa de Colombia para el día N .

TRM_N : Tasa representativa del mercado para el día N .

P : Función de predicción entrenada.

De los N_T datos totales se toman n datos consecutivos para predecir el dato $N+1$.



Figura 5. Algoritmo de entrenamiento y predicción.

En la labor de predicción se mantiene constante la topología de la red. No obstante, ésta debe ser re-entrenada de manera que las tendencias y correlaciones sean actualizadas y así obtener predicciones más precisas. Los resultados obtenidos se muestran en la sección 6, comparados con los obtenidos empleando una red neurodifusa.

5.2. Predicción usando una red neurodifusa.

La red neurodifusa tiene características similares a la red neuronal en cuanto a la composición de la capa de entrada y la salida, así como de los datos de entrenamiento.

La topología de la red fue mostrada en la figura 3; sólo varían el número de funciones de pertenencia por cada entrada, pues en este caso se usaron cuatro campanas de Gauss. Esto representa 256 reglas de inferencia, que corresponden a cuatro datos de entrada por cuatro funciones de pertenencia.

6. Resultados


A continuación se muestran los resultados obtenidos empleando la red neuronal; como indicador de error se utilizó la diferencia entre el valor estimado y el valor real (error residual para cada una de los períodos de entrenamiento). Como lenguaje de programación se utilizó Matlab 6.

Número de patrones de entrenamiento	Error promedio (%)	Desviación estándar (%)
5 días	-0,77	2,13
10 días	-0,72	3,40
15 días	-1,44	3,72
20 días	-1,17	3,29
30 días	0,48	3,81
40 días	-0,86	3,56

Tabla 1. Resultados usando redes neuronales.

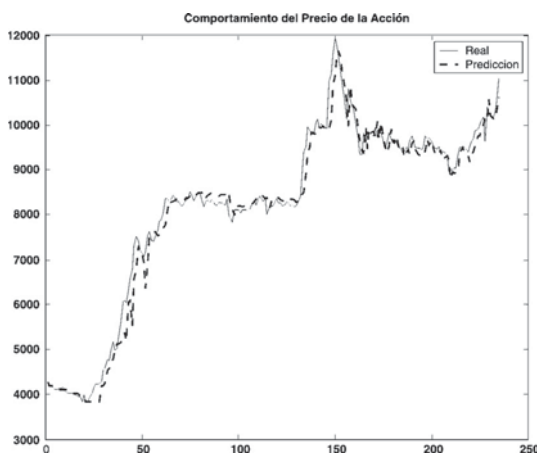
Como puede observarse, los mejores valores de predicción se produjeron con un entrenamiento de 5 días. Los datos de entrenamiento son 245, por lo que el número de puntos de comprobación en la

predicción es de 240. El histograma del error, expresado en unidades monetarias, se muestra a continuación.



Gráfica 3. Histograma del error en unidades monetarias para una predicción con 5 días de entrenamiento.

Como era de esperarse, por la acción de la ley fuerte de los grandes números, la distribución resultante del error tiene una tendencia normal con una desviación estándar de \$ 154,79 (equivalente al 2,13%) y un error promedio de \$ -37.83. El sistema propuesto tiene una alta confiabilidad, dado que la mayor parte de los resultados se encuentran dentro de la zona interna de la campana de Gauss. El comportamiento general de la predicción se muestra en la gráfica 4.



Gráfica 4. Validación de la predicción con una red neuronal con respecto a datos reales.

Los resultados obtenidos usando una red neurodifusa se presentan a continuación.

N (días de entrenamiento)	Error promedio (%)	Desviación estándar (%)
5	-0,13	8,82
10	-0,12	8,91
15	-0,13	9,01
20	-0,14	9,11
30	-0,16	9,32
40	0,14	9,46

Tabla 2. Resultados obtenidos empleando una red neurodifusa.

Puede observarse que la red neuronal tiene un mayor grado de acierto que la neurodifusa aunque el error promedio de ésta última pueda ser menor. Los datos de desviación son más importantes que los valores de error promedio, dado que la desviación estándar puede medir el grado de seguridad y la capacidad de acierto en las predicciones de la red.

Finalmente, vale mencionar que el tiempo de entrenamiento de una red neuronal es de unos cuantos minutos (1-5 min), mientras que una red neurodifusa puede tardar algunas horas en su entrenamiento (3-10 h).

7. Conclusiones

- Antes de aplicar cualquier herramienta de predicción es necesario hacer un análisis de los datos disponibles, para determinar correlación con la variable en estudio.
- Es necesario calibrar la cantidad de datos de entrada. Demasiada información puede hacer lento el proceso de entrenamiento, o usar información redundante que no aporta en el mejoramiento de la calidad de la respuesta.
- La característica dinámica de la variable en estudio hace necesario actualizar los datos de

- entrada y re-entrenar la red para obtener pronósticos con un nivel de confianza adecuado.
- La calidad de los resultados depende de la información disponible. Puede suceder que algún agente de la bolsa de valores tenga información privilegiada que le permita mejorar su capacidad de tomar posiciones ante otros inversionistas que no cuentan con esta información.
- Un criterio de parada eficiente es aquel que no exige un error cercano a cero; un error pequeño lleva a memorizar, mas no a generalizar.
- Con base en la experiencia aquí presentada las redes neuronales presentan un mejor desempeño que las redes neurodifusas. Asimismo, el tiempo de cálculo de las primeras es mucho menor.

AGRADECIMIENTOS

Los autores expresan sus agradecimientos a la Universidad Distrital Francisco José de Caldas por facilitar los medios para esta publicación, y al Grupo de Investigación en Planeamiento de Sistemas Eléctricos de la Universidad Tecnológica de Pereira por su constante apoyo.

Referencias bibliográficas

- [1] Hiller F., Loebberman G. (1997) *Introducción a la investigación de operaciones*, McGraw-Hill, 6ª. ed., México 1997.
- [2] Guoqiang, P. (2001) *An Investigation of Neural Networks for Linear Time-series Forecasting*. En: *Computer & Operation Research* 28, pp. 1183-1202.
- [3] Mattson Keith, C. (2001) *Modeling Market Pricing in a Competitive Environment Using Adaptive Fuzzy Inference Systems*. Thesis for the degree of Master of Science in Electrical Engineering. University of Washington.
- [4] Song H., Liu C., Lawarrée J. and Dahlgren, R. (2000) *Optimal Electricity Supply Bidding by Markov Decision Process*. IEEE Trans. Power Systems, Vol. 15, Núm. 2, pp. 618-624.
- [5] Hilera, J y Martínez, V. (2000) *Redes neuronales artificiales: fundamentos, modelos y aplicaciones*. Alfaomega Grupo Ed., S.A. México.
- [6] Tutorial de redes neuronales. Disponible en Internet: <http://ohm.utp.edu.co/paginas/docencia/neuronales/>
- [7] Delgado, A. (1998) *Inteligencia artificial y minirobots*. Ecoe Ediciones, Bogotá.
- [8] Guoqiang, P.Z. (2003) *Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model*. In: *Neurocomputing* núm. 50, pp. 159-175.
- [9] Kyoung-Jae, Kim. (2006) *Artificial Neural Networks with Evolutionary Instance Selection for Financial Forecasting*. In: *Expert Systems with Applications* num. 30, p. 519-526.
- [10] Nowrouz et al. (1996) *A Comparison of Artificial Neural Network and Time Series Models for Forecasting Commodity Prices*. In: *Neurocomputing* núm. 10, pp. 169-181.
- [11] Jang J.R, Sun S., Mizutani E. (1997) *Neuro-fuzzy and Soft Computing: a Computational Approach to Learning and Machine Intelligence*. Prentice Hall, USA.
- [12] Corporación Financiera Nacional y Suramericana S.A. Corfinsura. Disponible en Internet: <http://www.corfinsura.com/espanol/home/home.asp>
<http://www.corfinsura.com/espanol/home/home.asp>