

Pronóstico de la volatilidad usando perceptrones multicapa con funciones adaptativas de activación

Volatility forecast using multilayer perceptrons with adaptive activation functions

Sarah Gutiérrez. Ing, Juan D. Velásquez. Ph.D & Carlos J. Franco. Ph.D
Facultad de Minas, Universidad Nacional de Colombia
sgutierd@unal.edu.co; jdvelasq@unal.edu.co; cjfranco@unal.edu.co

Recibido para revisión 13 de diciembre de 2010, aceptado 28 de junio de 2011, versión final 30 de junio de 2011

Resumen— Las redes neuronales artificiales han sido usadas exitosamente para la predicción de series de tiempo no lineales. En este artículo, se presenta una aproximación novedosa para modelar y pronosticar la volatilidad de una serie de tiempo financiera usando un perceptrón multicapa con una función adaptativa de activación; los parámetros del modelo son estimados maximizando el logaritmo natural de la función de verosimilitud de los residuos. Para garantizar que la varianza sea siempre cero o positiva, se impusieron algunas restricciones a la red neuronal artificial. Para evaluar habilidad predictiva de la aproximación propuesta, se compararon los pronósticos de un modelo ARCH y de la red neuronal; se encontró que la aproximación propuesta es capaz de pronosticar con mayor precisión la volatilidad que el modelo clásico.

Palabras Clave— ARCH no lineal, Modelos no lineales, Modelos de pronóstico, Heterocedasticidad, Modelos heterocedásticos condicionales, Precisión predictiva.

Abstract— Artificial neural networks has been used successfully for forecasting nonlinear time series. In this paper, we present a novel approach to forecast the volatility of financial time series using a multilayer perceptron with adaptive activation functions; model parameters are estimated by maximizing the natural logarithm of the residuals. To guaranty that the variance is always zero or positive, some restrictions are imposed to the neural network. For evaluating the predictive ability of the proposed approach, we compared the forecasts of an ARCH model and the neural network; we found that our approach is able to forecast with more accuracy the volatility that the classical model.

Keywords— Non-linear ARCH, Non-linear models, Forecasting models, Heteroscedasticity, Conditional heteroscedastic models, Predictive accuracy.

I. INTRODUCCION

Una de las más importantes aplicaciones de los modelos de redes neuronales artificiales (ANN, por su sigla en inglés) es la predicción de series de tiempo [1]. Su uso está fundamentado en la presencia de no linealidades desconocidas

en los datos que no pueden ser capturadas por las aproximaciones lineales tradicionales, haciendo que el pronóstico usando ANN sea más preciso cuando se compara con el obtenido usando la aproximación lineal clásica. En el caso general, el valor actual de la serie de tiempo se expresa como:

$$y_t = f(\Theta; \mathbf{x}_t) + \sigma \varepsilon_t \quad (1)$$

donde \mathbf{x}_t es un vector conformado por los valores pasados de la serie de tiempo que son observables en el instante t , es decir, $\mathbf{x}_t = [y_{t-1}, \dots, y_{t-p}]'$; y Θ es el vector de parámetros del modelo especificado por la función $f()$ que representa una ANN. Desde el punto de vista estadístico, las ANN se pueden entender como modelos no lineales en la media, cuyos residuos ($e_t = \sigma \varepsilon_t$) siguen una distribución normal con media cero y varianza (σ^2) desconocida; ε_t es una variable aleatoria que sigue una distribución normal con media cero y varianza unitaria. En este sentido, las ANN son equivalentes a los modelos no paramétricos de regresión múltiple no lineal [2]. Una de sus grandes bondades es que pueden aprender la relación existente entre y_t y \mathbf{x}_t a partir de los datos, aunque dicha relación sea desconocida.

Por otra parte, una de las principales temáticas de interés en finanzas computacionales es el pronóstico de los rendimientos, los cuales representan el logaritmo natural del cambio porcentual entre el precio actual y el precio anterior de un *commodity* (un bien físico o financiero):

$$r_t = \log\left(\frac{p_t}{p_{t-1}}\right) \quad (2)$$

En el trabajo seminal de Engle [3], el rendimiento actual es representado como:

$$r_t = c + e_t \quad (3)$$

donde c una constante y e_t es una variable aleatoria normal con varianza cambiante en el tiempo; e_t recibe, usualmente, el nombre de shock. Engle [3] demostró que r_t se caracteriza por:

- Presentar regiones de volatilidad similar.
- Tener una volatilidad que evoluciona continuamente en el tiempo.
- Presentar comportamientos diferentes de la volatilidad ante la subida o caída de los precios.

A partir de la representación anterior, Engle [3] desarrolló el modelo de heterocedasticidad condicional autorregresiva (ARCH, por su sigla en inglés) que permite representar dichas características de la volatilidad; en los modelos ARCH, los cambios temporales de la varianza σ_t^2 son descritos en función de los shocks pasados de la serie:

$$\sigma_t^2 = \omega_0 + \sum_{p=1}^P \alpha_p e_{t-p}^2 \quad (4)$$

Donde ω_0 es una constante positiva y α_p son los coeficientes de ponderación de los shocks pasados (también positivos). A partir de este trabajo seminal, se dio origen a toda una línea de trabajo sobre el modelado y la predicción de la volatilidad condicional en series de tiempo, en los que se destacan los aportes de Bollerslev [4], Nelson [5] [6] y Glosten, Jagannathan y Runkle [7], entre otros.

A partir de la interpretación matemática de las ANN dada en (1), es fácilmente demostrable que las ANN pueden ser aplicadas a la predicción de los rendimientos:

$$r_t = f(\Theta; \mathbf{x}_t) + a_t \quad (5)$$

con $\mathbf{x}_t = [r_{t-1}, \dots, r_{t-p}]'$, y que ellas podrían dar cuenta de la relación no lineal entre r_t y sus valores pasados (r_{t-p}), pero no de la dinámica de σ_t^2 [8] [9]. Sin embargo, si se observa que σ_t^2 es una serie de tiempo [véase (4)] cuyo valor actual es función de los shocks pasados elevados al cuadrado, e_{t-p}^2 , entonces, una ANN podría ser utilizada para representar relaciones más complejas (y desconocidas) que la representada por el modelo ARCH (4).

Consecuentemente con lo anterior, se han reportado muchas investigaciones en la literatura sobre el modelado y pronóstico de la volatilidad usando redes neuronales y otros tipos de modelos no lineales; una revisión detallada es presentada en [10]. Por ejemplo, pueden generarse modelos híbridos al combinar las redes neuronales con los modelos clásicos de volatilidad [11]. Igualmente, las redes neuronales pueden ser usadas para combinar los pronósticos de la volatilidad de varios modelos clásicos alternativos [12] [13]. Otra aproximación consiste en usar las redes neuronales para combinar la información proveniente de distintas variables de mercado con

el fin pronosticar la volatilidad [14] [15]. Dada la existencia de relaciones no lineales, también otros tipos de modelos no lineales han sido considerados para el pronóstico de la volatilidad [16].

El objetivo de este artículo es evaluar la precisión de las ANN tipo perceptrón multicapa, que utilizan una función adaptativa de activación, para pronosticar la volatilidad de una serie de tiempo respecto a un modelo ARCH. Una de las principales diferencias de este trabajo con muchos otros de la literatura es que los parámetros del perceptrón multicapa son estimados maximizando la función de verosimilitud de los residuales y no mediante la minimización de la suma de los residuos al cuadrado; en el caso tradicional, ambas optimizaciones son equivalentes cuando la varianza de los residuos es constante, pero, no es el caso en esta investigación. Como caso de aplicación se usó la serie de rendimientos mensuales de los precios de la acción de Intel Corporation para el periodo de Enero de 1973 a Diciembre de 2003.

El trabajo está organizado de la siguiente manera: En la Sección 2, se realiza una corta presentación de la forma tradicional en que se modela la volatilidad. Seguidamente, se hace un desarrollo conceptual sobre el modelado de la volatilidad por medio de un perceptrón multicapa. Posteriormente, se presenta un caso de aplicación en la Sección 4. Finalmente, las conclusiones son expuestas en la Sección 5.

II. MODELADO CLÁSICO DE LA VOLATILIDAD

En esta sección se presenta una discusión sobre el concepto de no linealidad y el modelado y pronóstico de la volatilidad.

Una serie de tiempo es una secuencia cronológica de observaciones de una variable [17]:

$$\dots, y_1, y_2, \dots, y_T, \dots \quad (6)$$

El objetivo fundamental del análisis de dicha secuencia es establecer las relaciones de dependencia entre y_t y un vector de variables explicativas \mathbf{x}_t , el cual puede estar formado por observaciones rezagadas de y_t , y por variables exógenas que explican el comportamiento de la serie de tiempo. En el modelado, se busca comprender y analizar la dinámica de la evolución histórica bajo el cumplimiento estricto de los supuestos que se usaron para derivar el modelo considerado, mientras que en el pronóstico, prima la capacidad para predecir sus valores futuros $y_{T+1}, y_{T+2}, \dots, y_{T+H}$, donde H se conoce como horizonte de pronóstico.

Se dice que el modelo que representa la dinámica de y_t es lineal si puede representarse como

$$y_t = [\psi_0 \Theta'] \begin{bmatrix} 1 \\ \mathbf{x}_t' \end{bmatrix} + e_t \quad (7)$$

Si $\mathbf{x}_t = [y_{t-1}, \dots, y_{t-p}]'$, entonces (7) puede escribirse como:

$$y_t = e_t + \psi_0 + \sum_{p=1}^P \psi_p y_{t-p} \quad (8)$$

En otras palabras, el modelo definido en (8) es lineal, si y_t puede expresarse como una combinación lineal de sus valores pasados más una variable aleatoria ($e_t = \sigma \mathcal{E}_t$) con varianza constante. Un modelo es no lineal cuando no se cumple la definición anterior.

Los rendimientos financieros, r_t , son un tipo particular de series de tiempo que se obtienen a partir de los precios históricos de un activo [véase la Ecuación (2)], los cuales podrían ser pronosticados usando (8):

$$r_t = e_t + \psi_0 + \sum_{p=1}^P \psi_p r_{t-p} \quad (9)$$

Pero uno de los supuestos para que la Ecuación (9) sea adecuada, es que en la práctica, e_t siga efectivamente una distribución normal con media cero y varianza constante y desconocida σ^2 .

Engle [3], al verificar el supuesto anterior en series reales de rendimientos financieros, encontró que la varianza de los residuos e_t no es constante sino que cambia en el tiempo, proponiendo el modelo definido en (4) para representar dicha dinámica. Este hallazgo dio origen a toda una gama de modelos para representar la dinámica de la volatilidad.

Diferentes variaciones y extensiones han sido propuestas para el modelo ARCH de Engle [3]. Ellas están motivadas en que la dinámica de la varianza no es adecuadamente representada por el modelo ARCH, y que existen comportamientos determinísticos que son ignorados por el modelo. Por ejemplo, Bollerslev [4] generaliza el modelo ARCH al considerar que la varianza no es solamente función de los shocks pasados, sino también función de las varianzas pasadas:

$$\sigma_t^2 = \omega_0 + \sum_{i=1}^p \alpha_i e_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (10)$$

Al suponer otras ecuaciones para representar la dinámica de la varianza, se obtiene toda una amplia gama de modelos para representar la dinámica de la varianza.

III. MODELADO DE LA VOLATILIDAD USANDO UN PERCEPTRÓN MULTICAPA

Una ANN es una representación matemática de las redes de neuronas del cerebro humano; un perceptrón multicapa es un tipo de red neuronal donde la señal de entrada se propaga hacia la salida sin que exista ningún tipo de realimentación.

Su representación pictórica, en el contexto de la predicción de series de tiempo, es presentada en la Figura 1. El modelo está

conformado por una capa de entrada, con un nodo (cuadrado) por cada elemento del vector $\mathbf{x}_t = [y_{t-1}, \dots, y_{t-p}]'$; una capa oculta con tres neuronas de procesamiento; y una capa de salida con una única neurona que entrega el valor de y_t . El modelo contiene una neurona adaptativa notada por la letra B , que no tiene entradas y que genera un pulso unitario.

En esta investigación se usó un perceptrón multicapa cuya función de activación es adaptativa (aMLP, por su sigla en inglés), representado matemáticamente como:

$$y_t = \beta_* + \sum_{h=1}^H \beta_h \cdot g \left[\omega_h + \sum_{i=1}^P \alpha_{i,h} y_{t-i} \right]^{M_h} + \sigma \cdot \mathcal{E}_t \quad (11)$$

donde:

- β_* es el peso de la conexión de la neurona adaptativa a la neurona de salida.
- β_h es el peso asociado a la conexión entre cada neurona h de la capa oculta y la neurona de salida.
- ω_h representa el peso de las conexión que van de la neurona adaptativa hasta cada neurona h de la capa oculta.
- $\alpha_{i,h}$ corresponde a los pesos entre cada entrada i y la neurona h en la capa oculta.
- H representa el número de neuronas en la capa oculta.
- P es el número de rezagos considerados.
- $g()$ es la función de activación de las neuronas de la capa oculta.
- M_h es un parámetro que permite adaptación a nivel de la función de activación [18]

Consecuentemente con [18], se usó la función sigmoidea:

$$g(u) = \left[\frac{1}{1 + \exp(-u)} \right] \quad (12)$$

para la activación de las neuronas de la capa oculta. La función de identidad $g(u) = u$ fue utilizada para la activación de la neurona de la capa de salida.

Para poder usar un aMLP para el modelado y pronóstico de la volatilidad bastaría realiar los siguientes reemplazos en (11):

$$\begin{aligned} y_t &= \sigma_t^2 \\ y_{t-i} &= e_{t-i}^2 \end{aligned} \quad (13)$$

No obstante, es necesario imponer las siguientes restricciones para garantizar que siempre se cumpla que $\sigma_t^2 > 0$:

- Sólo se pueden usar funciones de activación cuyo dominio sea siempre positivo, esto es, $g(u) \geq 0, \forall u$, tal como la función sigmoidea definida en (12).
- Los parámetros β_* y β_h deben ser positivos para que su suma sea siempre positiva. Para facilitar el proceso de estimación de los parámetros del modelo, estos se cambian por sus versiones al cuadrado.

Así, el modelo propuesto en esta investigación es el siguiente:

$$\sigma_t^2 = \beta_*^2 + \sum_{h=1}^H \beta_h^2 \cdot g \left[\omega_h + \sum_{i=1}^P \alpha_{i,h} e_{t-i}^2 \right]^{M_h} \quad (14)$$




Figura 1. Perceptrón multicapa con tres neuronas en la capa oculta y una salida.

IV. CASO DE APLICACIÓN

En esta sección se presentan e interpretan los resultados obtenidos al pronosticar la serie de rendimientos mensuales de los precios de la acción de Intel Corporation [8]. La serie tiene un total de 372 observaciones para el periodo comprendido entre enero de 1973 y diciembre de 2003. La traza en el tiempo de los rendimientos es presentada en la Figura 2.

A. Modelo ARCH

Tsay [8] postula que la dinámica de la serie puede ser representada por un modelo ARCH de orden 3, cuya ecuación es:

$$\sigma_t^2 = \omega_0 + \omega_1 \cdot e_{t-1}^2 + \omega_2 \cdot e_{t-2}^2 + \omega_3 \cdot e_{t-3}^2 \quad (15)$$

donde el error o shock e_t está definido como:

$$e_t = r_t - c \quad (16)$$

En (16), c una constante arbitraria y r_t el rendimiento de la acción en el mes t . Tsay [8] estimó los parámetros del modelo

definido por (15) y (16) sobre el 100% de los datos, obteniendo:

$$e_t = r_t - 0.0171 \quad (17)$$

$$(18)$$

$$\sigma_t^2 = 0.0120 + 0.1787e_{t-1}^2 + 0.0772e_{t-2}^2 + 0.0572e_{t-3}^2$$

Ya que el objetivo de este trabajo es analizar la capacidad de predicción de la volatilidad, la muestra fue dividida en dos partes: la información entre enero de 1973 y diciembre de 2001 (348 datos) fue utilizada para la estimación de los parámetros de todos los modelos considerados; la información restante fue utilizada para evaluar la capacidad de predicción. Se consideraron 2 horizontes de pronóstico: un horizonte de 12 meses (enero de 2002 a diciembre de 2002) y un horizonte de 24 meses (enero de 2002 a diciembre de 2003).

El modelo ARCH(3) definido por (15) y (16) fue recalculado usando solo los datos de entrenamiento. Para estimar sus parámetros, se maximizó el $\log L$ [8]:

$$\max \log L = - \sum_{t=4}^T \log \sigma_t^2 - \sum_{t=4}^T \frac{e_t^2}{\sigma_t^2} \quad (19)$$

El modelo encontrado fue el siguiente:

$$e_t = r_t - 0.0245 \quad (20)$$

$$(21)$$

$$\sigma_t^2 = 0.0106 + 0.3273e_{t-1}^2 + 0.0661e_{t-2}^2 + 0.0399e_{t-3}^2$$

B. Perceptrón Multicapa

En este caso, se utilizó el modelo definido por las ecuaciones (3) y (14) para modelar la dinámica de los rendimientos. El aMLP usa las mismas entradas del modelo ARCH; se consideraron modelos que tienen desde 1 hasta 4 neuronas en la capa oculta (parámetro H).

Los parámetros se estimaron maximizando el logaritmo natural de la función de verosimilitud ($\log L$) para la muestra de estimación (348 datos) usando la ecuación (19).

La capacidad de predicción de los modelos ARCH y aMLP, para las muestras de estimación y pronóstico, fue evaluada usando la sumatoria de los errores al cuadrado:

$$SSE = \sum_{i=n}^N |e_i^2 - \sigma_i^2|^2 \quad (22)$$

y la sumatoria del valor absoluto de los errores:

$$SAE = \sum_{i=n}^N |e_i^2 - \sigma_i^2| \quad (23)$$

Se encontró que el $\log L = 221,45$ para el modelo ARCH

estimado para la muestra de calibración de los parámetros. En contraste, dicho estadístico fue de 221,82 ; 227,65 ; 234,40 y 234,40 para los aMLP con $H = 1, 2, 3$ y 4 respectivamente, siendo superior en todos los casos considerados. Esto permite concluir que la ANN considerada es superior en términos de que los residuos normalizados siguen una distribución más similar a una normal estándar que el modelo ARCH. En relación al valor de $\log L$, los modelos ARCH y aMLP ($H = 1$) no son significativamente diferentes, pero si para los modelos aMLP con $H = 2$ y $H = 3$. Finalmente, no fue posible encontrar un aMLP con $H = 4$ con un $\log L$ superior al aMLP con $H = 3$.

En la Tabla I se presentan los errores obtenidos para todos los modelos considerados. Se encontró que el aMLP con $H = 3$ se ajusta mejor a las muestras de calibración y pronóstico que los demás modelos considerados. De esta forma, se presenta

una reducción del SSE del 9,6%, 15,2% y 10,9% respecto al modelo ARCH para las muestras de calibración y de pronóstico a 12 y 24 meses respectivamente. Estos resultados permiten corroborar que efectivamente el modelo aMLP capturó con mayor precisión la dinámica de los datos.

Tabla I. Estadísticos de ajuste.

Modelo	Calibración	Pronostico	Pronóstico
	SSE (SAE)	$H = 12$ SSE (SAE)	$H = 24$ SSE (SAE)
ARCH	0,5053 (6,4482)	0,0223 (0,3501)	0,0256 (0,5121)
aMLP ($H = 1$)	0,4847 (6,2805)	0,0218 (0,3413)	0,0254 (0,5082)
aMLP ($H = 2$)	0,4714 (6,1008)	0,0199 (0,3138)	0,0242 (0,5104)
aMLP ($H = 3$)	0,4568 (6,0222)	0,0189 (0,2925)	0,0228 (0,4846)
aMLP ($H = 4$)	0,4568 (6,0224)	0,0289 (0,2925)	0,0228 (0,4846)




Figura 2. Rendimientos mensuales de la acción de Intel Corporation entre enero de 1973 y diciembre de 2003.

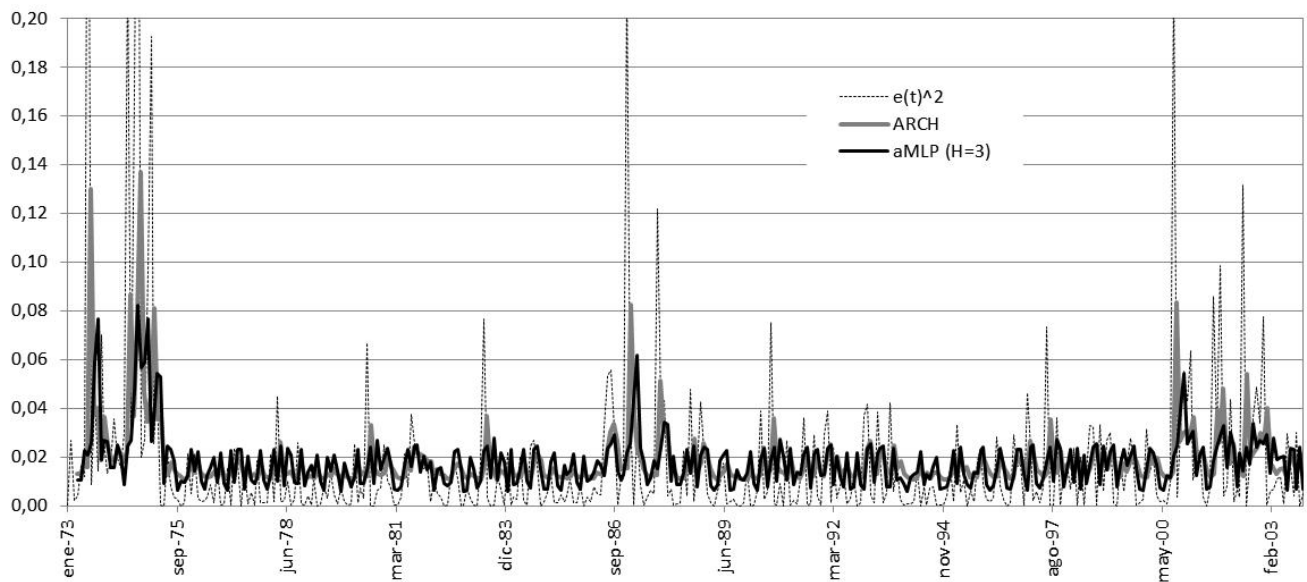


Figura 3. Pronóstico de la volatilidad para los modelos considerados

Respecto a los resultados anteriores, es necesario resaltar que la maximización del $\log L$, busca que la distribución de los residuos normalizados e_t / σ_t sea lo más cercana posible a una distribución normal estándar, pero, ello no es equivalente a minimizar el error de pronóstico de la volatilidad.

En la Figura 3, se comparan los pronósticos obtenidos con los modelos considerados. Se observa que el modelo ARCH presenta una mayor fluctuación en función de los shocks pasados, y que reacciona tardíamente a los puntos de volatilidad más alta. El pronóstico del aMLP ($H = 3$) es más estable y pareciera que predice mejor los picos de volatilidad; igualmente, su pronóstico no es tan sensible a entradas con valores muy altos, tal como se aprecia en las regiones siguientes a la ocurrencia de shocks importantes.

Ambos modelos (ARCH y MLP), son incapaces de pronosticar los valores más bajos de la volatilidad.

En la Figura 4 se presentan los pronósticos de los modelos ARCH y MLP como una función de los shocks reales al cuadrado. En esta Figura, el pronóstico perfecto corresponde a la línea con 45 grados de inclinación. Se observa que:

- Para valores bajos de e_t^2 (lado izquierdo de la abscisa), el modelo ARCH tiende a producir estimados más altos de la volatilidad que el MLP. Se nota que el modelo ARCH tiende a producir pronósticos más bajos de la volatilidad que el MLP.
- El mejor desempeño del MLP es debido a que sus pronósticos tienden a estar más cerca de la línea hipotética de 45 grados, especialmente para valores altos; estos fueron marcados con óvalos en la Figura 4.

IV. CONCLUSIONES

En este artículo se evaluó la capacidad de una red neuronal artificial para pronosticar la volatilidad de una serie de tiempo y fue comparada contra los métodos tradicionales.




Figura 4. Relación entre el pronóstico y los valores reales.

El primer aporte de este trabajo, es introducir variaciones a la configuración de la red neuronal artificial para garantizar que siempre los pronósticos de la volatilidad son positivos.

El segundo aporte es la comparación del pronóstico para una serie real, donde se demuestra que el modelo propuesto puede generar pronósticos más precisos que los modelos tradicionales.

Como trabajo futuro, es necesario indagar sobre otras medidas de error que permitan obtener mejores pronósticos con la red neuronal. Este hecho se debe a la observación de que el ajuste del MLP es influenciado por la magnitud del error de ajuste, y consecuentemente, es más importante pronosticar de forma precisa las volatilidades altas.

REFERENCIAS

- [1] Zhang, G., B. Patuwo and M. HU (1998), "Forecasting with artificial neural networks: the state of the art", *International Journal of Forecasting* 14: 35–62.
- [2] Sarle, W. (1994), Neural networks and statistical models, in S. Institute, ed., 'Proc. of the 19th Annual SAS Users Group Int. Conference.', pp. 1538–1550.
- [3] Engle R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of United Kingdom inflations. *Econometrica* 50: 987–1007.
- [4] Bollerslev T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics* 31: 307–327.
- [5] Nelson D. B. (1990). Stationarity and persistence in the GARCH(1,1) model. *Econometric Theory* 6: 318–334.
- [6] Nelson D. B. (1991). Conditional heteroscedasticity in asset returns: A new approach. *Econometrica* 59: 347–370.
- [7] Glosten L. R., Jagannathan R., Runkle D. E. (1993). On the relation between the expected value and the volatility of nominal excess return on stocks. *Journal of Finance* 48: 1779–1801.
- [8] Tsay R. S. (2010). *Analysis of Financial Time Series*. Third Edn. Wiley-Interscience..
- [9] Frances, P.H.; van Dijk, D. (2003), *Nonlinear time series models in empirical finance*. Cambridge University Press.
- [10] Poon, S.-H., Granger, C.W.J. (2003), Forecasting volatility in financial markets: a review. *Journal of Economic Literature* 26: 478-539.
- [11] Donalson, R.G. Kamstra, M. (1997). An artificial neural network-GARCH model for international stock return volatility. *Journal of Empirical Finance*, 4: 17-46
- [12] Hu, M.Y.; Tsoukalas, C. (1999), Combining conditional volatility forecast using neural networks: an application to the EMS exchange rates. *Journal of International Financial Markets, Institutions and Money*, 9: 407-422.
- [13] Tseng, C.-H.; Cheng, S.T.; Wang, Y.-H. y Peng, J.-T. (2008), Artificial neural network model of the hybrid EGARCH volatility of the Taiwan stock index option prices. *Physica A* 387: 3192-3200.
- [14] Hamid, S.A.; Iqbal, Z. (2004), Using neural networks for forecasting volatility of S&P 500 Index futures prices. *Journal of Business Research* 57: 1116-1125
- [15] Malliaris, M.; Salchenberger, L. (1996), Using neural networks to forecast the S&P 100 implied volatility. *Neurocomputing*, 10 (2): 183-195.

- [16] Taylor, J.W. (2004), Volatility forecasting with smooth transition exponential smoothing. *International Journal of Forecasting* 20: 273-286.
- [17] Bowerman B., O'Connell R. (1993), *Forecasting and time series: an applied approach* (3^a. Ed.), California: Duxbury Press.
- [18] Chandra, P.; Singh, Y. (2004), "An activation function adapting training algorithm for sigmoidal feedforward networks". *Neurocomputing*, 61: 429-437.

Universidad Nacional de Colombia Sede Medellín Facultad de Minas

120 años 
TRABAJO Y RECTITUD

Escuela de Ingeniería de Sistemas

Misión

La misión de la Escuela de Ingeniería de Sistemas es fomentar y apoyar la generación o la apropiación de conocimiento, la innovación y el desarrollo tecnológico en el área de ingeniería de sistemas e informática sobre una base científica, tecnológica, ética y humanística.



Visión

La formación integral de profesionales desde el punto de vista científico, tecnológico y social que les permita adoptar, aplicar e innovar conocimiento en el campo de los sistemas e informática en sus diferentes aspectos, aportando con su organización, estructuración, gestión, planeación, modelamiento, desarrollo, procesamiento, validación, transferencia y comunicación; para lograr un desempeño profesional, investigativo y académico que contribuya al desarrollo social, económico, científico y tecnológico del país.



Escuela de Ingeniería de Sistemas
Dirección Postal:
Carrera 80 No. 65 - 223 Bloque M8A
Facultad de Minas. Medellín - Colombia
Tel: (574) 4255350 Fax: (574) 4255365
Email: esistema@unalmed.edu.co
<http://pisis.unalmed.edu.co/>

