

Modelado del comportamiento del tipo de cambio peso-dólar mediante redes neuronales diferenciales

Francisco Ortiz-Arango*

Agustín I. Cabrera-Llanos**

Fernando Cruz-Aranda***

Fecha de recepción: 27 de noviembre de 2011

Fecha de aceptación: 26 de diciembre de 2011

* Universidad Panamericana,
Escuela de Ciencias Económicas y Empresariales,
fortizar@up.edu.mx

** Instituto Politécnico Nacional,
Unidad Profesional Interdisciplinaria de Biotecnología,
aiclbuda@yahoo.com

*** Universidad Panamericana,
Escuela de Ciencias Económicas y Empresariales,
fcruz@up.edu.mx

RESUMEN

Las redes neuronales artificiales se han venido consolidando como una técnica confiable para analizar comportamientos de variables económicas y financieras. Sus primeros usos en las finanzas datan de inicios de la década de los 90's. A través de estos años su uso como herramienta de modelación y descripción de sistemas dinámicos no lineales en general, se ha ido consolidando como una técnica eficaz y relativamente rápida, gracias al gran desarrollo experimentado en los sistemas de cómputo.

En el presente trabajo se utiliza a las Redes Neuronales Diferenciales (RND) como herramienta de análisis y descripción del comportamiento del tipo de cambio entre el peso mexicano y el dólar estadounidense durante el periodo del 3 de enero de 2000 al 5 de octubre de 2011.

El empleo de esta técnica de uso común en el análisis de sistemas dinámicos complejos no lineales empleada en las áreas de ingeniería y biología, mostró un excelente desempeño en la descripción de la paridad peso-dólar desarrollada en este trabajo.

Clasificación JEL: C02, C45, G17.

ABSTRACT

Artificial neural networks have been consolidated as a reliable technique to analyze behaviors of economic and financial variables. Its first use in finance was on the early 90's. Through these years, its use as a tool for modeling and description of general nonlinear dynamical systems has been consolidated as an effective and relatively fast technique, thanks to the great development experienced in computer systems.

In this paper we use a Differential Neural Networks (DNN) as a tool of analysis and description of the behavior of exchange rate between the mexican peso and the U.S. dollar during the period from January 3 of 2000 to October 5 of 2011.

The use of this technique very common in the analysis of complex nonlinear dynamical systems in the areas of engineering and biology, showed an excellent performance in the description of the peso-dollar exchange developed in this work.

Classification JEL: C02, C45, G17.

1. Introducción.

El uso de las redes neuronales como metodología de descripción y análisis del comportamiento de sistemas no lineales se viene dando de manera sostenida con resultados muy favorables desde principios de la década de 1940 (McCulloch y Pitts 1943), sin embargo su aplicación para la descripción de variables y procesos de índole económica y financiera, tuvo que esperar alrededor de 50 años y a partir de entonces su uso ha tenido un gran éxito como técnica de estimación de funciones no lineales que se aplican en finanzas (Haykin 1999; McNellis 2005), por ejemplo, en la aproximación de precios de productos derivados (Hutchinson *et al* 1994); o para el diseño de un portafolio de inversión (Hung *et al* 1996), en éstas aplicaciones ha sido de utilidad para realizar una identificación de la serie de tiempo de los datos (Chen *et al* 2001; Refenes y Holt 2001). Recientemente, las redes neuronales también se están utilizando para modelar el comportamiento del mercado de tipo de cambio euro/dólar en Europa (Dunis, Laws y Sermpinis 2010). Una de las razones por la cual ha sido usada esta técnica es el hecho de que se puede extender su utilidad para servir como un sistema predictor con base en la información disponible en bases de datos tanto económicas como financieras (Kuan y Whitte 1994; Smith y Gupta 2000; Chen *et al* 2001; Refenes y Holt 2001).

En (Hann y Steurer 1996) se determina que si se utilizan datos mensuales del tipo de cambio, las redes neuronales no muestran mejora sobre modelos de tipo lineal, pero para datos semanales las redes neuronales son mucho mejores que los modelos de caminata aleatoria en el pronóstico del tipo de cambio del marco alemán y el dólar estadounidense.

Por otro lado (Hu Michael Y. y Zhang G. 1997) examinan los efectos del número de entradas y nodos ocultos así como el tamaño de la muestra de entrenamiento y la salida de la muestra mejorada. Utilizan el tipo de cambio de la libra y dólar estadounidense en su estudio. Encuentran que las redes neuronales superan a los modelos lineales, en particular cuando el horizonte en el pronóstico es corto. Además, el número de nodos de entrada tiene un gran impacto sobre la mejoría no así el número de nodos ocultos, mientras que un gran número de observaciones no reduce los errores de pronóstico.

En el documento de trabajo de (Zhang y Berardi 2001), se utilizan las redes neuronales para llevar a cabo pronósticos sobre el tipo de cambio entre la libra británica y el dólar estadounidense, en particular hace uso de una partición sistemática para construir conjuntos de redes neuronales. Encuentran que los modelos en conjunto de diferentes estructuras neuronales pueden mejorar en forma consistente las predicciones de una red única. Asimismo, muestran que las redes conjuntas basadas en diferentes particiones de datos son más eficientes que las desarrolladas con el conjunto de datos de entrenamiento completo en la predicción fuera de muestra.

Por su parte, (Álvarez y Álvarez 2004), emplean un algoritmo genético y una red neuronal para anticipar el comportamiento del cambio semanal del yen y la libra respecto al dólar estadounidense. Asimismo, combinan los pronósticos obtenidos por medio de un algoritmo genético.

Por otro lado (Dunis y Williams 2002), realizaron una regresión con redes neuronales, para modelar y predecir el tipo de cambio euro-dólar, obteniendo mejores resultados que los que proporcionan los modelos ARMA. Posteriormente en (Dunis, Laws y Sermpinis 2010), emplean cuatro tipos de redes neuronales para modelar las transacciones y paridad entre el dólar y el euro, donde observaron que los mejores resultados que obtuvieron fueron aquellos en los que utilizaron Redes Neuronales de Orden Superior (HONN) por sus siglas en inglés, sin embargo esta técnica es bastante compleja tanto desde el punto de vista matemático como desde el punto de vista computacional.

Todos los trabajos mencionados previamente usan como base de funcionamiento a las redes neuronales artificiales discretas o clásicas, (a excepción del trabajo de Dunis, Laws y Serpinis de 2010), las cuales fundamentan su operación en el método de propagación hacia atrás en el proceso de llevar a cabo el cálculo de los pesos que permiten el aprendizaje de la red. Afortunadamente a fines de los 90's se desarrolló una clase de redes basadas principalmente en el uso de la teoría de estabilidad de Liapunov para el desarrollo de las leyes de aprendizaje, estas redes son llamadas Redes Neuronales Diferenciales o Dinámicas (Poznyak, Sánchez y Yu 2001), las cuales han tenido aplicaciones exitosas en campos como la biotecnología al hacer la estimación de variables en un proceso de fermentación (Cabrera-Llanos *et al* 2002; Cabrera-Llanos *et al* 2007), utilizando esquemas de observación y usando una técnica que ha sido llamada sensor virtual (Cabrera-Llanos *et al* 2007); en la estimación de dosis de fármacos para cáncer (Aguilar y Chairez 2006), al generar una señal de control en la dosificación de tal manera que el crecimiento de células cancerosas no sea grande.

En este artículo se presenta uno de los primeros trabajos en los que se utiliza un sistema de identificación basado en una red neuronal diferencial para analizar y describir la serie de tiempo de las cotizaciones del tipo de cambio del peso mexicano contra el dólar norteamericano, durante el periodo del 3 de enero de 2000 al 5 de octubre de 2011. Los resultados obtenidos muestran una precisión sorprendente en lo que se refiere a la reproducción del comportamiento de las paridades en el tipo de cambio peso-dólar, mediante el uso de la red neuronal diferencial que estimó y reprodujo la evolución del tipo de cambio entre el peso y el dólar a lo largo del periodo de tiempo señalado.

Este trabajo está organizado del siguiente modo: En la siguiente sección se describen brevemente los fundamentos de las Redes Neuronales Diferenciales (RND), así como la forma del identificador de estados a través de una RND, el cual constituye la parte fundamental para poder construir el modelo de identificación de la paridad peso-dólar a lo largo del periodo de tiempo estipulado. En la sección 3, se plantean los resultados y el análisis de éstos. En la sección 4 se presentan las conclusiones del trabajo. Finalmente se presenta un apéndice con el diagrama del algoritmo empleado, ejecutado en la plataforma de Matlab-Simulink.

2. Metodología

La identificación es una fase de suma importancia e interés para el análisis y control de los procesos o sistemas, ya que de ésta podemos obtener información inicial del comportamiento del sistema, es decir, podemos entre otras cosas identificar los parámetros de la estructura del sistema a estudiar y así poder diseñar un modelo que se comporte de manera muy semejante al sistema en cuestión. Lamentablemente al llevar a cabo la identificación, es difícil conocer si dentro de las mediciones exteriores que se pueden obtener del sistema, se presentan componentes debidas a perturbaciones externas o de tipo paramétrico, esto dificulta el proceso de identificación, sin embargo existen diferentes técnicas que nos ayudan a sortear estas dificultades. A continuación se lleva a cabo una descripción del proceso de construcción del identificador del sistema basado en una RND.

Red neuronal diferencial como identificador. En la identificación de un sistema, se asume que tanto los valores de entrada como los de salida pueden ser medidos, por lo que forman parte vital del entrenamiento de la red.

Siguiendo las ideas propuestas en (Cabrera-Lanos *et al* 2007), la descripción matemática de la red está dada por la siguiente ecuación diferencial:

$$\frac{d}{dt} \hat{x}_t = A \hat{x}_t + W_{1,t} \sigma(\hat{x}_t) + W_{2,t} \phi(\hat{x}_t) u_t \quad (1)$$

Donde : $\hat{x}_t \in \mathfrak{R}^n$ es el estado de la red neuronal, $u_t \in \mathfrak{R}^q$ es la entrada proveniente del modelo, $W_{1,t} \in \mathfrak{R}^{n \times k}$ es la matriz de pesos de la capa de estados de retroalimentación, $W_{2,t} \in \mathfrak{R}^{n \times r}$ es la matriz de pesos de la capa de entrada, $A \in \mathfrak{R}^{n \times n}$ es una matriz estable seleccionada por método de prueba y error, las funciones de activación $\sigma(\cdot) := [\sigma_i(\cdot)]_{i=1, \dots, n}^T$; $\phi(\cdot) := [\phi_{jk}(\cdot)]_{j=1, \dots, n; k=1, \dots, r}^T$ se encuentran compuestas por funciones sigmoideas en cada uno de sus elementos

$$\sigma_i^{-1}(\hat{x}_t) := a_{\sigma_i}^{-1} \left(1 + b_{\sigma_i} \exp \left(- \sum_{j=1}^n c_{\sigma_i} \hat{x}_t \right) \right)$$

$$\phi_j^{-1}(\hat{x}_t) := a_{\phi_j}^{-1} \left(1 + b_{\phi_j} \exp \left(- \sum_{j=1}^n c_{\phi_j} \hat{x}_t \right) \right) \quad (2)$$

Definiendo a $\Delta_t = x_t - \hat{x}_t$ como el error entre los estados del sistema original y los estados generados por la red neuronal diferencial considerada.

Los pesos de la red neuronal diferencial son ajustados por las siguientes ecuaciones matriciales diferenciales:

$$\dot{W}_{1,t} = -K_1 P \Delta_t \sigma^T(\hat{x}_t)$$

$$\dot{W}_{2,t} = -K_2 P \Delta_t \phi^T(\hat{x}_t) u_t^T \quad (3)$$

donde: $W_{1,0}$, $W_{2,0}$ son fijas.

Donde K_1 y K_2 son constantes por medio de las cuales se lleva a cabo el ajuste de los pesos y deben ser seleccionadas por el método de prueba y error. P es una matriz que proporciona la solución de una ecuación algebraica de Riccati descrita por:

$$A^T P + PA + PRP + Q = 0 \quad (4)$$

Donde se requiere que se cumplan los siguientes hechos:

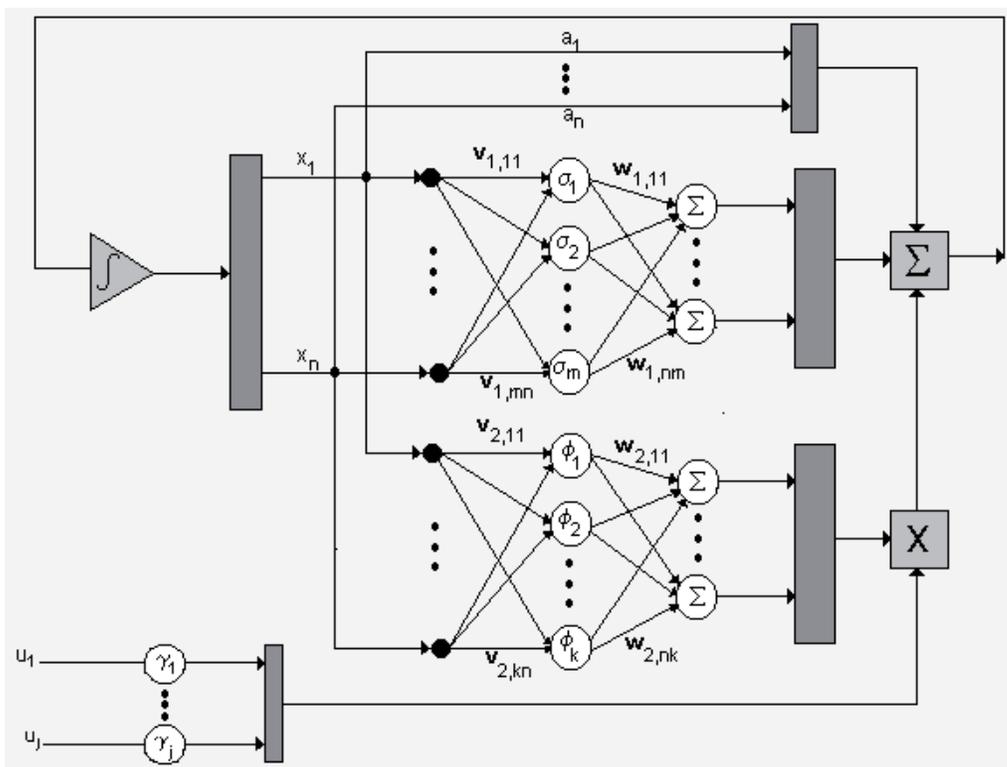
- Existe una matriz definida positiva Q_0 tal que la ecuación de Riccati tenga una solución positiva $P = P^T > 0$,
- Además se requiere que las matrices R y Q se encuentren descritas por:

$$R = \Lambda_f^{-1} + W_{1,t}^* \Lambda_\sigma^{-1} (W_{1,t}^*)^T + W_{2,t}^* \Lambda_\phi^{-1} (W_{2,t}^*)^T + K_1 \Lambda_1^{-1} K_1^T + K_2 \Lambda_2^{-1} K_2^T + \Lambda_{\xi,t}^{-1} \quad (5)$$

$$Q = D_\sigma + v_0 D_\phi + \Lambda_1 + Q_0$$

Para su mejor comprensión a continuación se muestra un diagrama general de la red neuronal diferencial como identificador.

Figura 1. Esquema de una red neuronal diferencial.

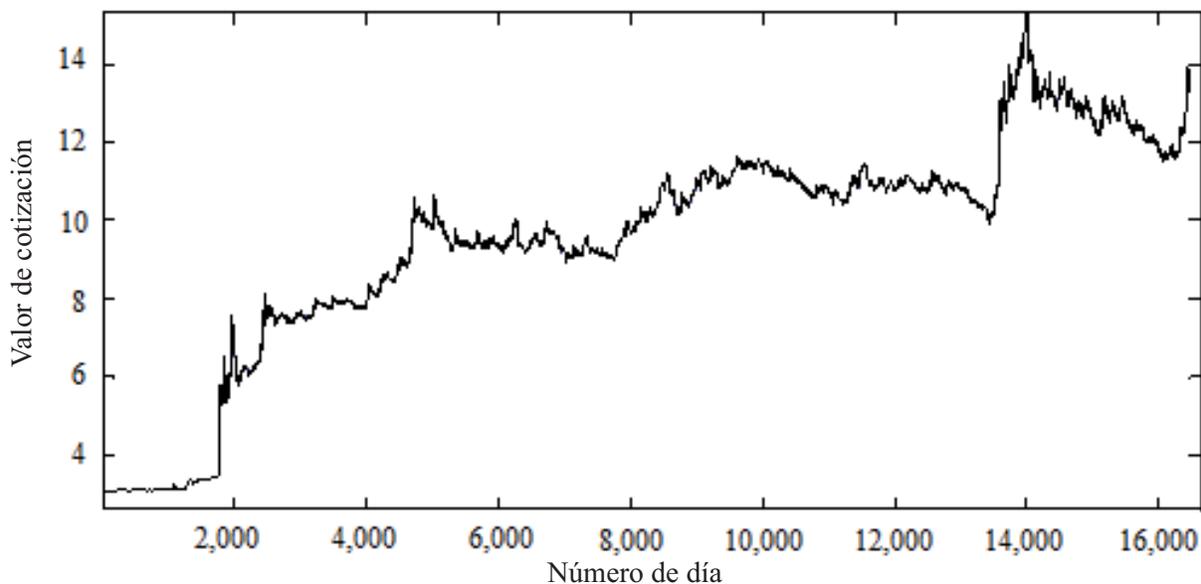


3. Resultados

La identificación de la evolución de la paridad peso-dólar y la evolución de la red se muestran en las Gráficas 1 a 5, donde se observa que las trazas de los estados real y generado con la red neuronal diferencial se encuentran muy cercanas entre sí, esto nos está indicando que el desempeño de la red es muy bueno pues logra reproducir con gran aproximación a la serie real de la paridad peso-dólar, esto se comprueba con el análisis de errores mediante la integral del error cuadrático medio y como muestra se tomaron los errores absolutos entre la paridad real y la estimada durante el periodo del 1 de septiembre al 5 de octubre de 2011 y cuyos resultados se muestran en la Gráfica 6.

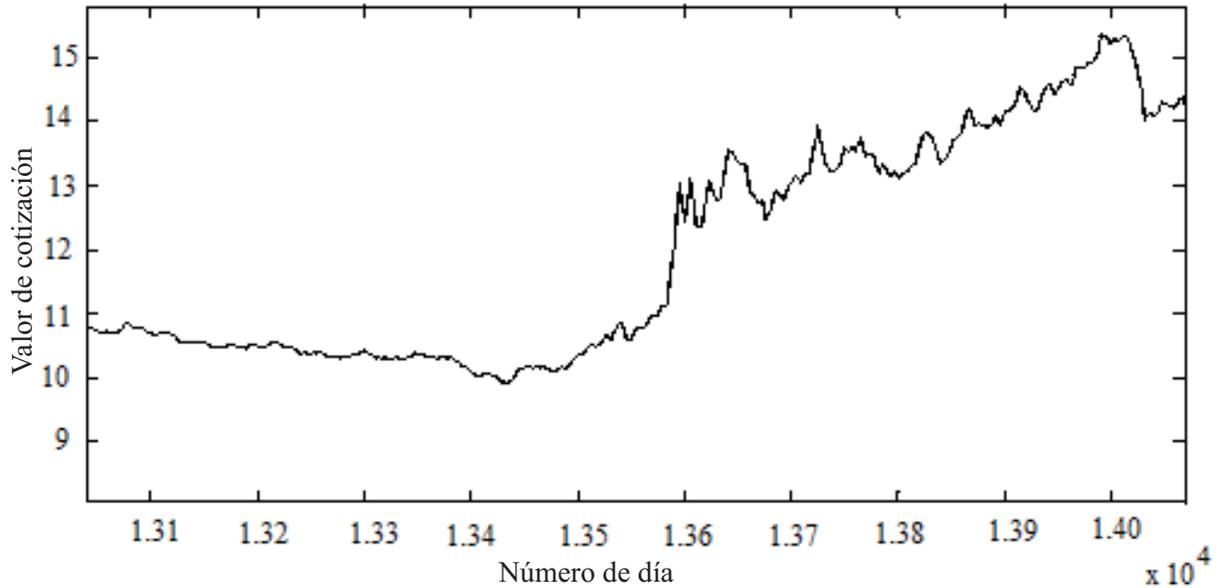
Como podemos ver en las Gráficas 1 y 2 es imposible detectar la diferencia entre los valores reales y los valores generados con la red, por lo cual en la Figura 3 se recurrió a una ampliación de un sector a casi diez veces para poder distinguir las mínimas diferencias existentes entre los valores reales y los generados con la RND.

Gráfica 1. Valores reales y estimados con la red neuronal de la paridad peso-dólar, considerando toda la serie de datos.



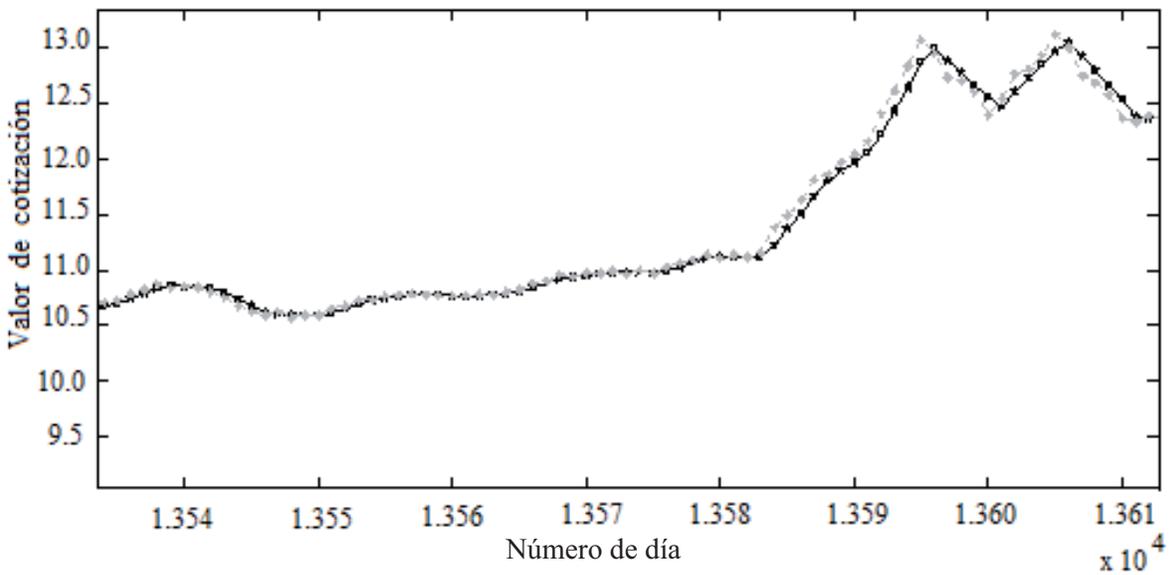
Fuente: Elaboración propia.

Gráfica 2. Valores reales y estimados con la red neuronal de la paridad peso-dólar, considerando un acercamiento que muestra el periodo de enero a diciembre de 2008.



Fuente: Elaboración propia.

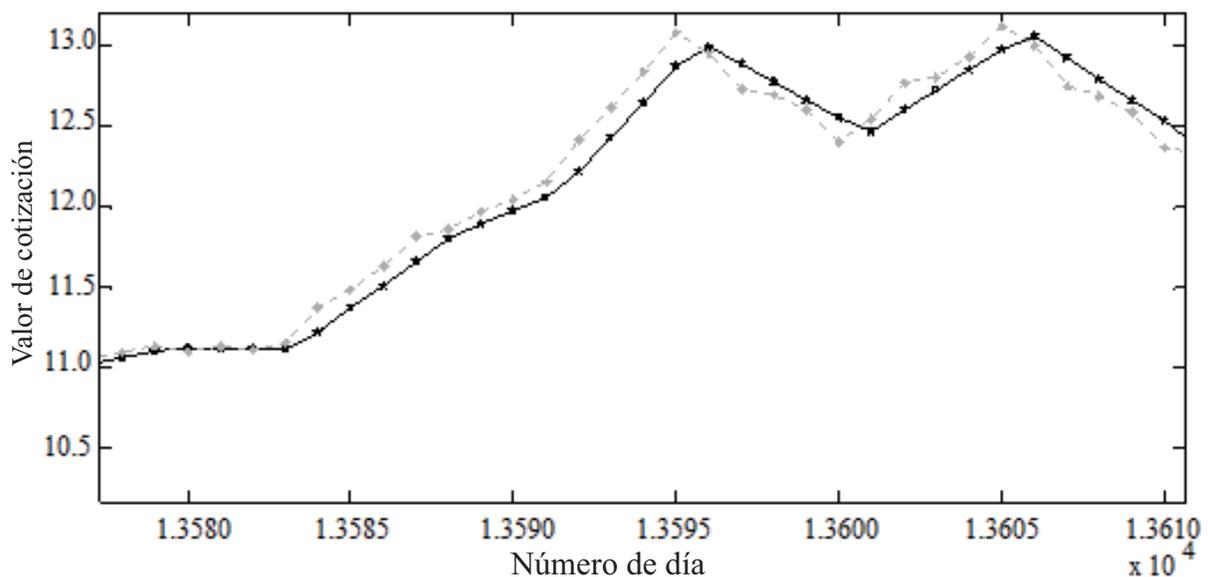
Gráfica 3. Acercamiento de valores reales y estimados con la red neuronal de la paridad peso-dólar, que amplifica el periodo de finales de 2008 periodo de alta volatilidad cambiaria.



Fuente: Elaboración propia.

A continuación se observa cómo la red logra reproducir muy bien las variaciones tanto suaves como abruptas del tipo de cambio, lo cual puede apreciarse de manera más clara en las Gráficas 4 y 5, en las que se presentan acercamientos considerables durante el periodo de alta volatilidad cambiaria a finales de 2008. De hecho es posible distinguir cómo la red “atrapa” de manera casi inmediata las variaciones tanto de crecimiento como de decrecimiento en la paridad entre las dos monedas.

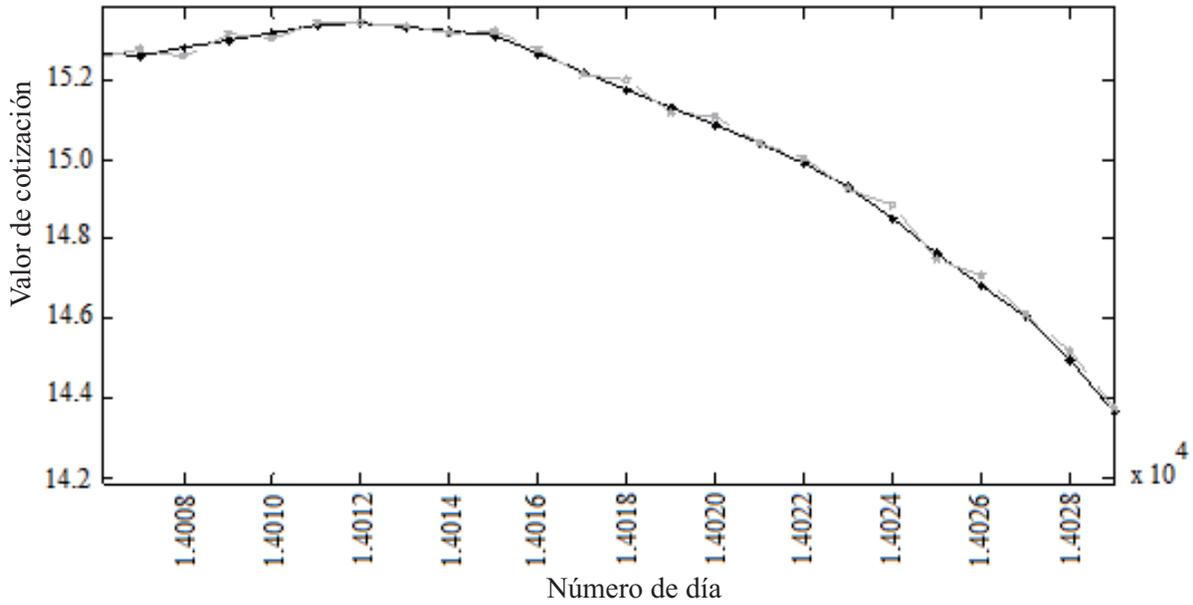
Gráfica 4. Acercamiento de valores reales y estimados con la red neuronal de la paridad peso-dólar, considerando la semana de mayor volatilidad cambiaria a fines de 2008.



Fuente: Elaboración propia.

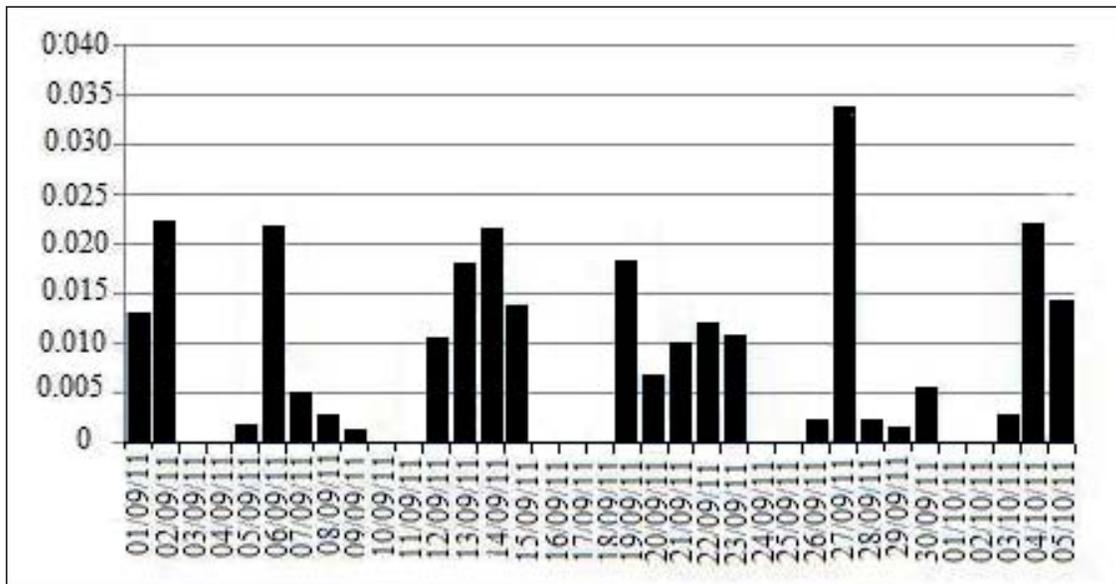
Ahora en la Gráfica 6, se muestran los errores absolutos entre los valores reales del tipo de cambio respecto de los valores generados por la RND. Se puede apreciar que dichos errores fluctúan entre 0.0011 hasta 0.033 pesos por dólar. Al considerar el cociente de los errores absolutos mostrados en la Gráfica 6 divididos entre sus correspondientes valores reales del tipo de cambio se obtiene un error porcentual, el cual es menor según se aprecia en la Gráfica 7, en este caso su variación va de 0.000088% el menor, hasta 0.0025% el mayor. De este modo podemos decir que el uso de las RND son una excelente alternativa para la descripción del comportamiento de la paridad peso-dólar.

Gráfica 5. Acercamiento de valores reales y estimados con la red neuronal de la paridad peso-dólar, considerando 4 días de máxima volatilidad cambiaria a la baja en 2008.



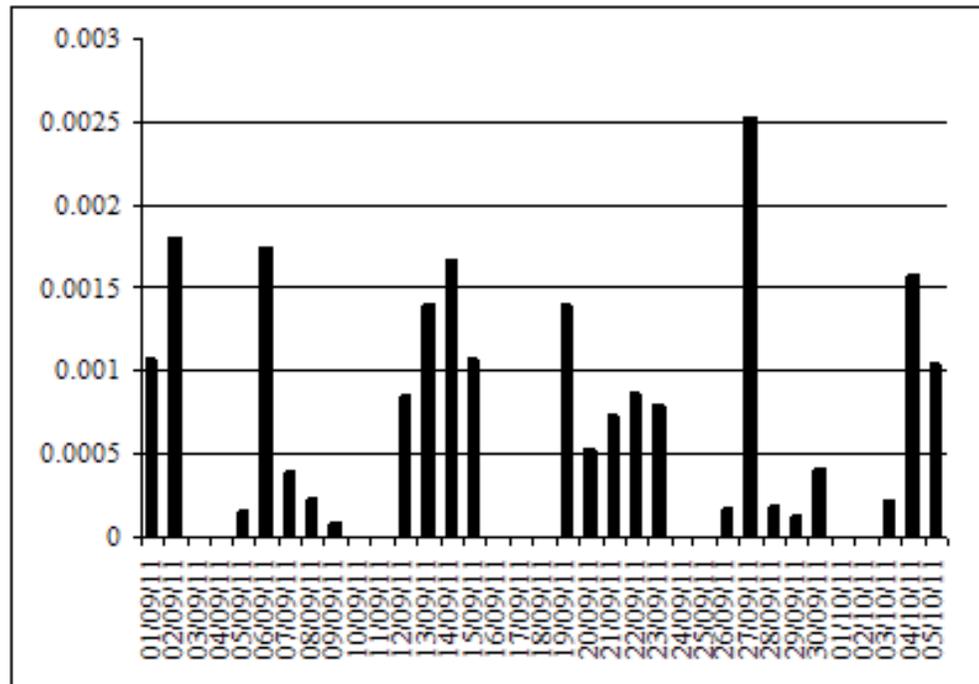
Fuente: Elaboración propia.

Gráfica 6. Errores absolutos entre los valores reales y estimados por la RND de la cotización peso-dólar del 1 de septiembre al 5 de octubre de 2011.



Fuente: Elaboración propia.

Gráfica 7. Errores porcentuales entre los valores reales y estimados por la RND de la cotización peso-dólar del 1 de septiembre al 5 de octubre de 2011. (medidos como el cociente del error absoluto y la paridad real).



Fuente: Elaboración propia.

4. Conclusiones

En el presente artículo se puede apreciar que un sistema de identificación basado en redes neuronales diferenciales muestra un excelente desempeño como elemento de descripción del comportamiento de un sistema dinámico, esta situación permite considerar el uso de estas redes como una herramienta viable, útil y robusta para lograr una descripción precisa del comportamiento de las variables que interactúan en un sistema dinámico compuesto de variables financieras, en el cual se logra que el error de aproximación tienda a cero.

En particular, el tratar de describir el comportamiento del tipo de cambio entre el peso mexicano y el dólar estadounidense se observó que la RND, logró describir de manera muy precisa los valores del tipo de cambio entre estas dos monedas, incluso en periodos de alta volatilidad.

Lo anterior demuestra que las redes neuronales diferenciales, se pueden constituir en un futuro próximo en una de las herramientas más usadas y so-

bre todo confiables para realizar trabajos de descripción de sistemas económicos y financieros, que deben ser tratados como sistemas dinámicos.

La metodología basada en la red neuronal diferencial, mostró que aún en cambios abruptos, como los experimentados en periodos de alta volatilidad cambiaria, logró “capturar” de manera casi inmediata y precisa dichas variaciones y tendencias, aunque fueran de muy corta duración.

Se contempla como trabajo futuro el ampliar la funcionalidad de la red para convertirla en un sistema de predicción a corto plazo para el tipo de cambio peso-dólar, considerando los cambios necesarios en la red.

Bibliografía

- Aguilar, N., Cabrera A. e I. Chairez (2006). Neuro tracking control for immunotherapy cancer treatment. IJCNN '06 International Joint Conference on Neural Networks. IEEE. Vancouver, BC, pp. 5316-5323.
- Álvarez-Díaz M. y A. Álvarez (2004). “Predicción no-lineal de tipos de cambio. Aplicación de un algoritmo genético”. *Economía aplicada*. Universidad de Zaragoza. Vol. XII, núm. 35. España, otoño, pp. 55-64.
- Andrew, W.L., J.M. Hutchinson y T. Poggio (1994). “A nonparametric approach to pricing and hedging derivative securities via learning networks”. *The journal of finance*. The American Finance Association. Vol. 49, núm. 3. EU, pp. 851-889.
- Cabrera-Llanos, A.I., A. Poznyak, T. Poznyak y J. Aranda (2002). “Identification of a fed-batch fermentation process: computational and laboratory experiments”. *Bioprocess and biosystems engineering*. Springer. Vol. 24, núm. 5. Nueva York (EU), enero, pp. 319-327.
- _____, T. Poznyak y J. Aranda. (2007). Estimating the trehalose cytoplasmic content during a baker’s yeast. 10th International Symposium on Computer Applications on Biotechnology. Cancún, México, IFAC press.
- _____ y M.G.R.S. (2007). “Soft sensors in biotechnology process”. Version en español. *Superficies y vacío*. Vol. 20, núm. 2, pp. 1-5 .
- _____, F. Ortiz-Arango (2012). “Pronóstico de rendimiento del IPC mediante el uso de redes neuronales diferenciales”. Por publicarse en *Contaduría y Administración*.
- Chen, X., R. Jeffery y R.N. Swanson (2001). “Semiparametric ARX neural network models with an application to forecasting inflation”. *IEEE Transactions on*

- neural networks. IEEE Computational Intelligence Society. Vol. 12, núm. 4. pp. 674-683.
- Dunis, C.L., J. Laws, G. Sermpinis (2010). "Modeling and trading the EUR/USD exchange rate at the ECB fixing". *European journal of finance*. Taylor & Francis. Vol. 16, núm. 6. Reino Unido, pp. 541-560.
- _____ y W. Mark (2002). "Modeling the EUR/USD exchange rate: do neural network models perform better?". *Derivatives use, trading & regulation*. Vol. 8, núm. 3, pp. 211-239.
- Hann Tae, H. y E. Steurer (1996). "Much ado about nothing? Exchange rate forecasting: neural networks vs. linear models using monthly and weekly data". *Neurocomputing*. Elsevier. Holanda, pp. 323-339.
- Haykin, S. (1999). *Neural Networks a comprehensive foundation*. EU, Prentice Hall.
- Hu, M.Y. y G. Zhang (1997). "Neural network forecasting of the British Pound/US Dollar Exchange rate". *Omega*. Elsevier. Vol. 26, núm. 4. Holanda, agosto, pp. 495-506.
- Hung, S.Y., T.P. Liang y V.W. Chi Liu (1996). "Integrating arbitrage pricing theory and artificial neural networks to support portfolio management". *Decision support systems*. Elsevier. Vol. 18, núms. 3-4. Holanda, noviembre, pp. 301-316.
- Kuan, C.-M. y H. White (1994). "Artificial neural networks: an econometric perspective". *Econometric reviews*. Taylor & Francis. Vol. 13, núm. 1. Reino Unido, pp. 1-91.
- McNelis, P.D. (2005). *Neural networks in finance: gaining predictive edge in the market*. Holanda, Elsevier, Academic Press.
- Poznyak, A.S., E.N. Sánchez. y W. Yu (2001). "Differential neural networks for robust nonlinear control". World Scientific.
- Refenes, A.P.N. y W.T. Holt (2001). "Forecasting volatility with neural regression: a contribution to model adequacy". *IEEE Transactions on neural networks*. IEEE Computational Intelligence Society. Vol. 12, núm. 4. pp. 850-865.
- Smith, K.A. y J.N.D. Gupta (2000). "Neural networks in business: techniques and applications for the operations researcher". *Computer & operation research*. Elsevier. Vol. 27, núms. 11-12. Holanda, pp.1023-1044.
- Yu, Lean, S. Wang y K.K. Lai (2007). *Foreign exchange rate forecasting with artificial neural networks*. EU, Springer.
- Zhang, G.P. y V.L. Berardi (2001). "Time series forecasting with neural network ensembles: an application for exchange rate prediction". *Journal of the operational research society*. Macmillan. Vol. 52, núm. 6. Reino Unido, junio, pp. 652-664.

Apéndice

A continuación se presenta el diagrama con el algoritmo de la red neuronal diferencial empleado en la plataforma de Matlab-Simulink.

Figura 2. Diagrama de la red neuronal diferencial.

