

# Congreso de Inteligencia Computacional Aplicada

**Mario M. Figueroa de la Cruz**

UTN – Facultad Regional Tucumán  
San Miguel de Tucumán – Tucumán Argentina (4000)  
mfiguero@gmail.com

and

**Pablo C. Rovarini Diaz**

UTN – Facultad Regional Tucumán  
San Miguel de Tucumán – Tucumán Argentina (4000)  
provarini@gmail.com

and

**Ignacio Ariel del Monte**

UTN – Facultad Regional Tucumán  
San Miguel de Tucumán – Tucumán Argentina (4000)  
ignaciodelmonte@gmail.com

and

**Claudia Inés Solorzano**

UTN – Facultad Regional Tucumán  
San Miguel de Tucumán – Tucumán Argentina (4000)  
Clausol2@yahoo.com.ar

## Abstract

This investigation project tries to demonstrate how through the use of systems based in Artificial Intelligence, like the Expert Systems and the Neuronal Nets, we can get to apply a prediction system on market trends that are constantly changing, just how the Financial Markets are. The investigation is centre on evaluating and analyzing first, to generate an application after, which will orientate a manager (person or system) to take the decisions trying to decrease the mistakes at the moment of making a transaction.

**Keywords:** Expert Systems, Neuronal Nets, Financial Markets

## Resumen

Este proyecto de investigación trata de demostrar como mediante la utilización de sistemas basados en Inteligencia Artificial como son los Sistemas Expertos y las Redes Neuronales, se puede llegar a implementar un sistema de predicción de tendencias en mercados continuamente cambiantes, como son los Mercados Financieros.

El enfoque de la investigación se centra en realizar evaluación y análisis para posteriormente generar una aplicación la cual orientara a un gestor (persona o sistema) el cual llevara a cabo la toma de decisiones tratando de disminuir los errores al llegar el momento de realizar una operación bursátil.

**Palabras claves:** Sistemas Expertos, Redes Neuronales, Mercado Financiero

## 3. Definición del Problema

El Mercado Financiero es un mecanismo el cual permite a los agentes económicos (personas físicas o sistemas) el intercambio de valores (papeles) o de materias primas (commodities) ambas por dinero. Este mercado al igual que todos los mercados conocidos, se ve modificado de forma dinámica y agresiva por factores como la oferta y la demanda. Particularmente en los Mercados Financieros, se modifica el precio o valor que puede tomar un papel (acciones) o materia prima que se esté comerciando.

En la actualidad los sistemas para predicción se emplean con frecuencia, los cuales permiten una visión general de los precios o valores futuros, basándose en la implementación de modelos matemáticos o estocásticos y

eventualmente de herramientas basadas en Inteligencia Artificial [4] [5] que permiten el análisis financiero (como ser osciladores, medias, análisis fundamental, entre otros). Este tipo de sistemas brinda a una persona o grupo de ellas el conocimiento con grados de exactitud elevados, hacia dónde oscilará el valor de un elemento financiero, permitiendo así obtener una toma de decisión más confiable.

Inmerso dentro de este gran mercado, se encuentran los indicadores bursátiles, quienes permiten determinar como se encuentra financieramente ese sector, ya que representa su comportamiento en general. En nuestro trabajo de investigación, utilizamos el Ibex - 35, perteneciente a la Bolsa de Madrid de España, ya que este indicador se encuentra dirigido principalmente a mercados estables.

Para poder determinar si un índice bursátil se encuentra en alza o baja, se analiza su tendencia. Se entiende por la tendencia de este, a la dirección de los precios de un valor en base a máximos y mínimos relativos, unidos entre sí según ciertas reglas, denominadas directrices. Una directriz une al menos dos puntos significativos de un valor, ya sean máximos o mínimos, indicando así la dirección del valor (Dow y Jones, 1896).

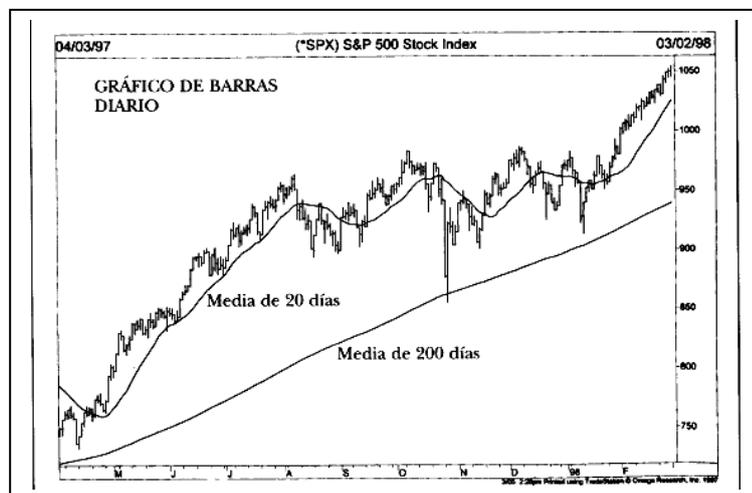
Como herramienta financiera se investiga la **Media Móvil**, debido a que este indicador técnico, en el ámbito financiero, es versátil y se encuentra muy difundido.

### 3.1 Aplicación de la Media Móvil

La Media Móvil empleada en los mercados financieros, “**persigue tendencias**” por ello su propósito es dar a conocer e indicar que ha comenzado una tendencia, o bien que ha finalizado. Esto significa que indica, en forma de una curva, variaciones que tiene dicha tendencia. No es un líder, ya que no se anticipa al mercado, sino reacciona ante este.

Este mecanismo que propicia la media móvil, sirve entonces para seguir al mercado e indicar si su tendencia o sentido se mantendrá. Por su naturaleza, va por detrás de la línea del mercado. Existen distintos defasajes cronológicos de acuerdo a la cantidad de elementos que se promedien, esto implica que si tomamos una media de 20 días, esta se encuentra siguiendo a la tendencia real muy de cerca, distinto a si la media es de 200 días.

En el mercado financiero existen diversos precios a tener en cuenta, como por ejemplo el precio de cierre, el precio de apertura, etc. Estos precios varían de acuerdo a el espacio de tiempo que decidamos tomar.



Para nuestro análisis emplearemos La Media Móvil Suavizada Exponencialmente (MMSE) [2], ya que es la más adecuada porque posee características de los dos tipos de medias móviles, estas son:

- Asigna una carga mayor a los elementos más recientes (media ponderada).
- Aunque le asigne mayor carga a los precios o elementos recientes, también contempla toda la información (precios más antiguos).

Fig. 1 – Comparación de tipos de Media Móvil aplicada a un índice bursátil.

### 4.1 Algoritmos de Resolución

Las Redes Neuronales Artificiales (RNA) forman parte de una tecnología de procesamiento de información que surge a raíz de los últimos desarrollos en software computacional aplicados al área de inteligencia artificial. Representan una herramienta muy innovadora para simular y analizar sistemas de relaciones complejas y cambiantes.

Las RNA son modelos matemáticos desarrollados con base en el funcionamiento de los sistemas nerviosos biológicos. De esta manera, se intenta contar con un sistema que imite el funcionamiento natural de las neuronas, es decir, que puedan “pensar” y “aprender” como el cerebro humano, el cual se puede ver como un conjunto

interconectado de neuronas. Desde hace unos años se comenzó a emplear las redes neuronales para la predicción de series de tiempo [2]. En el ámbito financiero se trata de series temporales [2] donde se vio la posibilidad de incursionarlo, permitiendo así obtener predicciones sobre ciertos mercados [1].

#### 4.2 Estructura de las Redes Neuronales Artificiales

Una RNA se compone de un conjunto masivamente paralelo de unidades de proceso muy simples y es en las conexiones entre estas unidades donde reside la inteligencia de la red. Biológicamente, un cerebro aprende mediante la reorganización de las conexiones sinápticas entre las neuronas que lo componen. De la misma manera, las RNA tienen un gran número de procesadores virtuales interconectados que de forma simplificada simulan la funcionalidad de las neuronas biológicas. El elemento básico dentro de una RNA es la neurona artificial también denominada Perceptron la cual posee características que le permiten realizar tareas elementales.

#### 4.3 La Neurona Artificial

Si denotamos con la letra X a las fuentes de información que depositan los datos en la neurona, así tendremos de X1 a Xn a las fuentes que se tengan. Los pesos de ponderación que llevara la relevancia de importancia de la información para la neurona se denotan con la letra W (que al igual que X van de 1 a N).

Al llegar a la neurona todos los datos de las informaciones ponderados por sus pesos se suman. Esto es lo que se denomina la “Regla de Propagación”. La fórmula que se empleara es la suma de todas las entradas ponderadas que toma el nombre de *Potencial Sináptico*.

$$H_i(t) = \sum_{j=1}^N X_j \times W_j$$

Siendo:

$H_i(t)$  = Potencial Sináptico del a Neurona i en el momento t.

$X_j$  = La entrada de datos procedente de la fuente de información j.

$W_j$  = El peso sináptico asociado al valor  $X_j$ .

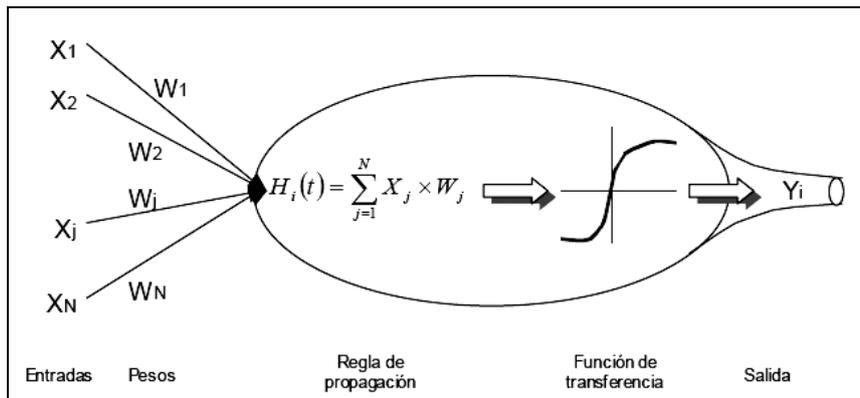


Fig. 2 - Estructura gráfica de una neurona artificial

Cuando el resultado de la Regla de Propagación supera un cierto número, denominado umbral, entonces la neurona se activa y dicho número se introduce en una función denominada “Función de Transferencia”. La cual se representa:

$$H_i(t) > \phi \text{ entonces } f[H_i(t)]$$

La función de activación típica utilizada, es la Función Sigmoidea.

La salida de esta función siempre será continua en el rango entre cero y uno. Con esta función se puede utilizar datos continuos y digitales, proporcionando salidas continuas únicamente.

$$F(x) = \frac{1}{1 + e^{-x}}$$

Siendo  $x = H_i(t)$

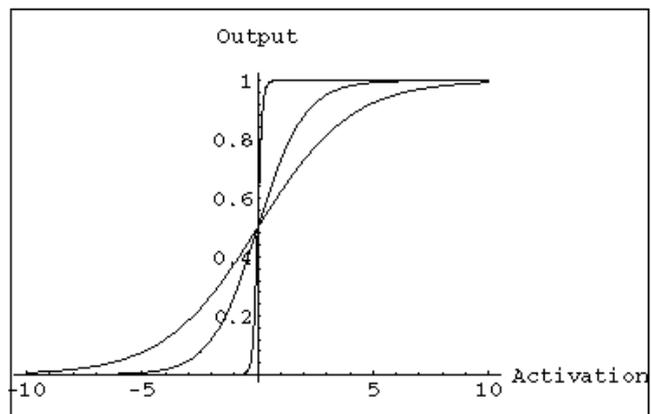


Fig. 3 - Función Sigmoidea.

#### 4.4 Redes Neuronales Multicapas - Backpropagation

Las neuronas se agrupan para realizar cálculos lógicos en redes. Estas redes se componen de capas. Una red Perceptron Multicapa o MLP (Multi Layer Perceptron) es una red de varias capas, por lo general de tres capas, (entrada – oculta – salida), la cual utiliza en su capa oculta, funciones de transferencia. Dichas funciones, empleadas en la capa de salida pueden ser Lineales o Sigmoideas dependiendo de lo que se necesite.

- Capa de Entrada (ingreso de los datos).
- Capa Oculta de datos (procesamiento de los datos).
- Capa de Salida (resultados).

Lo que destaca a esta Red Neuronal de otras, es su método de aprendizaje. Este es el denominado “*Retropropagación*” o hacia atrás, mas conocidas como BackPropagation (BP).

EL algoritmo de aprendizaje Backpropagation es una especificación del algoritmo LMS (Least Mean Square), en donde ambos realizan su labor en la actualización de los pesos y ganancias con base en el error cuadrático medio. Una BP trabaja en redes neuronales supervisadas, por ello es que necesita un conjunto de entrenamiento que le describa cada salida y su valor asociado.

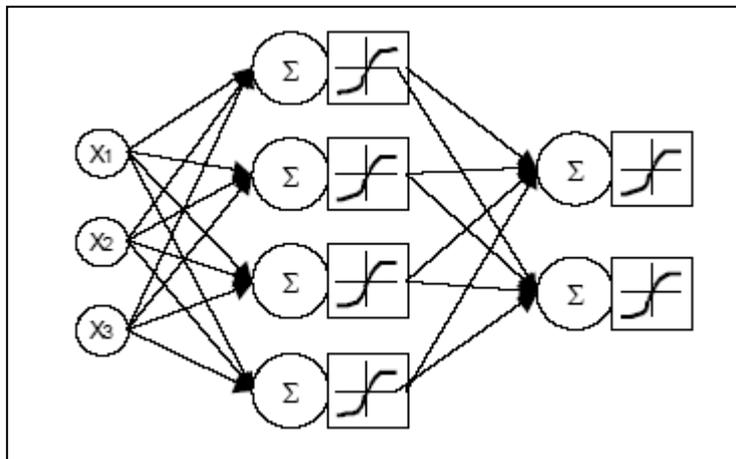


Fig. 4 - Representación de una red neuronal

Cada una de estas capas contendrá un número de neuronas en función al diseño que haya decidido el experto y del tipo de trabajo que realice la red.

Todas las neuronas que poseen una capa se conectan con todas las neuronas de la siguiente capa. Por ello, cuando una neurona de una capa anterior obtiene un dato lo envía a todas la neuronas de la capa siguiente, una vez sucedido esto, el resultado es ponderado por cada neurona por el peso sináptico.

#### 5.1 Redes Neuronales Aplicadas a Finanzas

En el campo de las aplicaciones de las redes neuronales para la predicción sobre índice bursátiles teniendo en consideración las series de tiempo [3] [4] [5], nos basamos en las teorías de Kaastra y Boyd [1], empleando una Red Neuronal Backpropagation para la implementación. Los pasos son los siguientes:

- Selección de la variable
- Recolección de datos
- Procesamiento de datos
- Conjunto de entrenamiento, de testeo y de validación
- Paradigmas de la red neuronal
  - Numero de capas ocultas*
  - Numero de neuronas ocultas*
  - Numero de neuronas output*
  - Funciones de transferencia*
- Entrenamiento de la red neuronal
- Criterio de evaluación
- Implementación

#### 5.2 Selección de Variables

Determinar qué variables de entrada son importantes en el pronóstico de series de tiempo es un tema crítico. En este caso, el interés en la predicción involucra emplear como entradas datos técnicos en lugar de fundamentales por las características mismas de la investigación. La forma más simple de modelar redes neuronales involucra emplear

valores retrasados de la variable dependiente o sus primeras diferencias como entradas. Generalmente, en las aplicaciones en mercados accionarios y de derivados es más probable de usar datos diarios en el diseño de una red neuronal como un componente de todo un sistema completo. Sin embargo, también es posible emplear datos semanales o mensuales como entradas de la red en el caso de que se requiera formular una estrategia diferente que involucre intervalos de tiempo mayores.

### 5.3 Recolección de Datos

Empleando la media a 18 días suavizada exponencialmente [2] [3] se genera un vector el cual posee dicha muestra. Además se determina el retraso de las entradas, para esto se aplica un Autocorrelograma, quien determina el numero de retrasos que mejor se ajustan a las muestras tomadas.

El motivo de emplear los mencionados retrasos como entrada en la red neuronal, se debe a que los datos inicialmente no se encuentran al mismo momento en que se los toma, sino que estos tuvieron algún tipo de error en su cálculo. Segundo porque permiten agilizar el tiempo de entrenamiento y prueba al cual se someten dentro de la red. La forma en la cual estarán dispuestos, es en una matriz donde, la primera columna se considerará como el objetivo, mientras que las demás columnas serán las correspondientes a los retrasos hasta un máximo de  $r$ , el cual será fijado de acuerdo a los criterios mencionados en la determinación de las entradas.

$$B_r = \begin{bmatrix} a_{t-n} & 0 & 0 & \dots & 0 \\ a_{t-n+1} & a_{t-n} & 0 & \dots & 0 \\ a_{t-n+2} & a_{t-n+1} & a_{t-n} & \dots & 0 \\ \dots & \dots & \dots & \dots & \dots \\ a_{t-2} & a_{t-3} & a_{t-4} & \dots & a_{t-r-2} \\ a_{t-1} & a_{t-2} & a_{t-3} & \dots & a_{t-r-1} \\ a_t & a_{t-1} & a_{t-2} & \dots & a_{t-r} \end{bmatrix}$$

Donde:

$n$ , es el número total de elementos de la serie  
 $r$  es el número de retrasos

### 5.4 Preprocesamiento de los Datos

El preprocesamiento de datos se refiere al hecho de analizar y transformar las variables de entrada y salida para minimizar interferencias, enfatizar relaciones importantes, detectar tendencias, y aplanar la distribución de la variable para ayudar a la red neuronal en el aprendizaje de patrones relevantes. Como las redes neuronales son buscadores de patrones, la representación de los datos es crítica en el diseño de una red exitosa. Las variables de entrada son raramente ingresadas a la red en su forma original. Los datos deben ser uniformizados entre los límites inferior y superior de la función de transferencia (generalmente entre 0 y 1 ó -1 y 1).

Dos de las transformaciones de datos más comunes tanto en métodos tradicionales como en redes neuronales es tomar las primeras diferencias y calcular el logaritmo natural de la variable independiente.

La primera diferenciación es para quitar tendencias lineales en los datos. La transformación logarítmica es útil para datos que pueden tomar valores muy pequeños o muy grandes y que están caracterizados por una distribución de cola extendida. Las transformaciones logarítmicas también convierten las relaciones multiplicativas o de razones en aditivas lo cual simplifica y mejora el entrenamiento de la red.

Otra transformación de datos muy popular es la que emplea las razones de las variables de entrada. Tales razones resaltan las relaciones importantes al mismo tiempo que se conservan los grados de libertad debido a que se necesitan menos neuronas para generar las variables independientes.

La formula empleada para este preprocesamiento es:

$$z_t = \frac{2y_t - (y_{\max} + y_{\min})}{y_{\max} - y_{\min}}$$

Donde:

$y_t$ : valores originales de la serie de tiempo  
 $y_{\max}$ : valor máximo de la serie de tiempo  
 $y_{\min}$ : valor mínimo de la serie de tiempo  
 $z_t$ : serie de tiempo transformada en valores entre -1 y 1

### 5.5 Conjuntos de Entrenamiento y Prueba

Comúnmente el conjunto de los datos, se emplea dividiéndolo en dos grupos, el grupo de Entrenamiento y el grupo de Prueba. Estos grupos permiten entrenar la red empleando el algoritmo Backpropagation; mientras que el conjunto de Prueba permite corregir y comprobar el entrenamiento. Muchas veces se utiliza además, un tercer

conjunto que es el de validación, para la comprobación final de la red, donde los datos empleados son los más recientes consecuentemente al último valor de la muestra.

Para el entrenamiento se destinó el 80% de la muestra, mientras que para la Prueba el 20% restante. El conjunto de validación debe consistir en las más recientes y contiguas observaciones. Se debe procurar no usar el conjunto de validación como conjunto de testeo tras ejecutar repetidamente pasos de series de entrenamiento-testeo-validación y adaptar las variables de entrada basadas en la actuación de la red en el conjunto de validación.

### 5.6 Topología de la Red Neuronal Experta Financiera

Existen diversas formas de determinar la arquitectura a seguir para desarrollar una red neuronal de predicción, cabe destacar que se emplea en la mayoría de los casos redes con algoritmos de entrenamiento Backpropagation.

- A. Determinación de las entradas: Las entradas se determinan de acuerdo a los retrasos marcados por el autocorrelograma, obteniendo heurísticamente y por pruebas, 17 neuronas en la capa de entrada.
- B. La red es totalmente conectada en donde la salida de cada neurona se conecta a la neurona de la capa siguiente.
- C. La Red es del tipo unidireccional o perceptrón multicapas, es decir una red con conexiones que pasan las salidas en una única dirección a las neuronas de la capa siguiente.
- D. Número de neuronas en la capa oculta: se obtiene utilizando métodos heurísticos y de pruebas de distintas posturas de acuerdo a experimentos anteriores.
- E. Puntos de transferencia o activación: Se emplea funciones del tipo Tangente Hiperbólica para la conexión de las neuronas de la capa oculta.
- F. Números de salidas: Se plantea una salida.
- G. Función de transferencia o activación para la capa de salida: Lineal.

### 5.7 Algoritmo de Entrenamiento

Se emplea el algoritmo de Backpropagation, la red neuronal se entrena en particular con el algoritmo Levenberg-Marquardt de Matlab basado en Backpropagation, ya que es el método más rápido para entrenar redes de hasta varios cientos de pesos.

### 5.8 Criterio de Evaluación

Se emplearán dos criterios por motivos de contrastar los datos obtenidos en relación de los datos generados, uno es el de minimización de la suma de los cuadrados, estará dirigido a probar el comportamiento de la red esto es el error de entrenamiento y prueba. El otro error es el denominado MAPE (Error Porcentual Medio Absoluto), se destina a controlar los resultados obtenidos con respecto a los resultados de predicción obtenidos.

### 5.9 Implementación

Por medio de la ecuación de predicción definida por la red neuronal, se obtiene el valor de la predicción en el tiempo  $t + 1$ . Se calcula entonces el error de generalización.

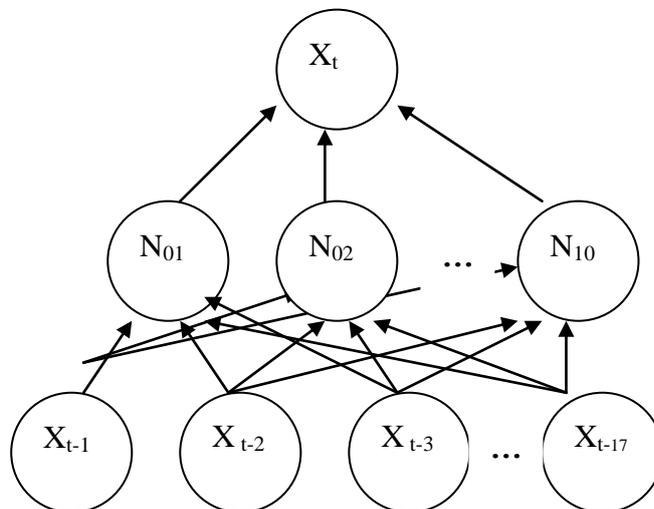


Fig. 5 - Representación de la Red Diseñada

## 6. Simulación

Mediante el empleo de las ecuaciones mencionadas anteriormente, se tratan a la serie temporal [2] para poder suavizar los datos que servirán de entrada a la red neuronal [3]. Quedando los datos de la forma que lo indica la Fig. 6. Se emplea la media móvil suavizada exponencialmente de 18 días, con un coeficiente  $\alpha = 0,3$  tratando de que este siga de forma adecuada la tendencia real de los precios de cierre.

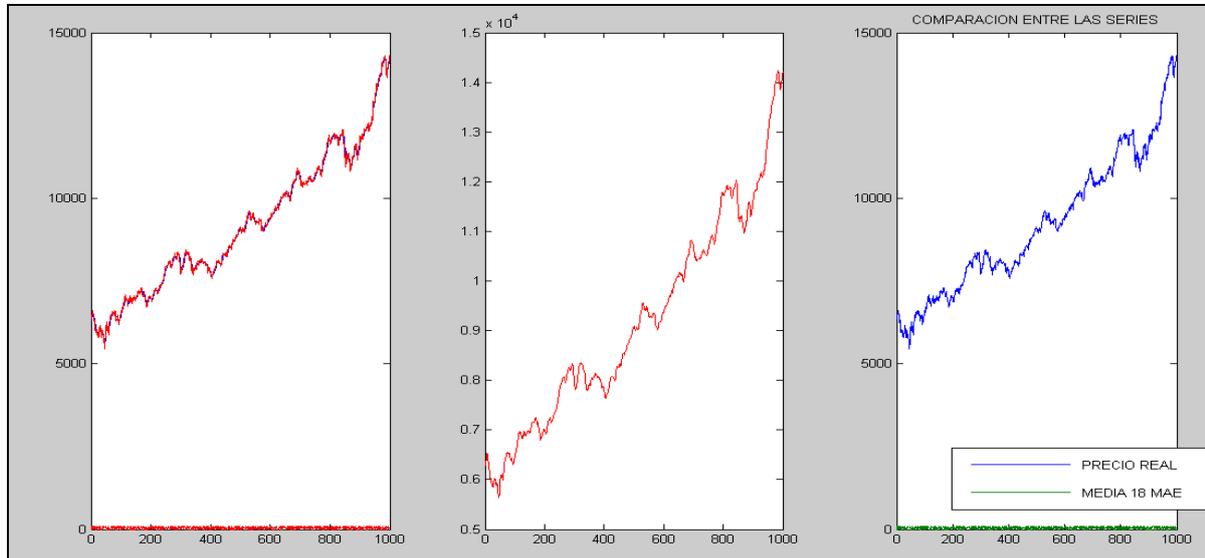


Fig. 6 - Comparación entre la Media18 y el Precio Real de Mercado.

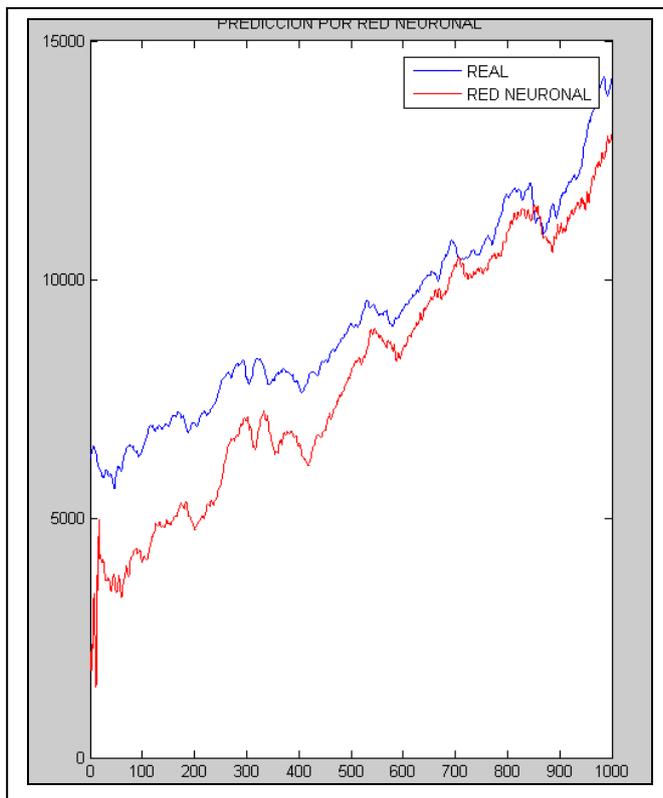


Fig. 7 - Error de predicción del 97% de la Red Neuronal Experta

## 7. Conclusiones

Las Redes Neuronales, han tomado una gran importancia en el ámbito financiero [4] [5], debido a su gran versatilidad para la predicción de series temporales [2], queda demostrado que se puede emplear para este fin.

A continuación se alimenta la red con los datos reservados para realizar el testeo. El objeto de esto es comparar la respuesta con los últimos precios que realmente hubo en el mercado para cada una de esas referencias. Para comprobar el grado de predicción del modelo utilizamos el coeficiente de correlación. Este coeficiente entre los resultados obtenidos en el test y los resultados reales es del 81%, un valor muy aceptable teniendo en cuenta las definiciones expuestas por Kaastra y Boyd [1], para la realización de predicciones en Mercados Financieros mediante el uso de Redes Neuronales.

Se emplea como segundo método de verificación, el MAPE (Error Porcentual Medio Absoluto), el cual mide el error de predicción que se tiene. El cual muestra un error entre los valores de un 1 %.

$$\text{MAPE} = 0.0112$$

Sin embargo una de sus grandes limitaciones es el uso de su arquitectura de forma generalizada. En este trabajo de investigación se brinda la metodología para la obtención de un análisis de tendencia, la cual se logra de forma clara permitiendo apreciar que el índice Ibex – 35, tuvo en dicho periodo una tendencia alcista.

El punto más relevante en cuanto al diseño de una arquitectura para una red neuronal experta en finanzas será la entrada que se escoja para la red, como también el tratamiento que se genere en los datos, debido a que esto no solo optimiza el cálculo de la red sino que mejora el tiempo de aprendizaje de la misma.

El funcionamiento de esta red así como también cualquier herramienta financiera empleada para seguimiento de tendencias en una serie temporal [2] [3] puede ser aplicado correctamente siempre y cuando nos encontremos en un mercado que posea una tendencia o un marca inicial, esto implica que no se puede aplicar dichos estudios a mercados cuyo rumbo sea inestable con alzas y bajas constantes y con un nivel elevado de volatilidad.

Si bien se empleo la teoría de base expuesta por Kaastra y Boyd [1] para la creación de redes neuronales [4] en predicción, podría plantearse una metodología con otros parámetros y arquitecturas diferentes [6], modificando la red neuronal empleado DAN (Dynamic Architecture for Artificial Neural Networks).

La evolución de esta Red Neuronal es poder incorporar un sistema experto de nueva generación, el cual permita determinar correctamente las entradas de la red, que para un caso generalizado, se emplean correlogramas parciales y totales, permitiendo de esta manera un uso ampliado de mayor cobertura a los índices bursátiles.

## Referencias

- [1] Kaastra y Boyd (1996). Designing a neural network for forecasting financial and economic time series. Neurocomputing.
- [2] Chatfield (1994). Times series analysis, forecasting and control. New Jersey, USA: Prentice Hill.
- [3] Faraway y Chatfield (1998). Times series forecasting with neural Networks: a comparative study using the airplane data. Applied Statistic.
- [4] Hill O'Connor y Remus (1996). Neural Networks models for time series forecasts. Management Science.
- [5] Collantes Duarte (2001). Predicción de redes neuronales: comparación con las metodologías de box Jenkins. Universidad de los Andes, Venezuela.
- [6] Velásquez Henao (2006). Modelado del índice de tipo de cambio real colombiano usando redes neuronales artificiales. Colombia.

## Anexo1 – Autores

### **Mg. Ing. Mario Marcelo Figueroa de la Cruz**

Prof. Cursos de Posgrado en Telecomunicaciones y Arq. de Redes de Telecomunicaciones Avanzadas – UTN FRT  
Prof. de las Cátedras de Base de Datos y Seminario de Integración – Mag. en Sistemas de Información – UTN FRT  
Prof. Adjunto de la Cátedra de Nuevas Tecnologías de Redes WAN – Ing. en Sistemas de Información – UTN FRT  
JTP de la Cátedra de Inteligencia Artificial – Ingeniería en Sistemas de Información – UTN FRT  
mfiguero@gmail.com

### **MSc. Ing. Pablo Cesar Rovarini Diaz**

Prof. Titular de la Cátedra de Proyectos – Ingeniería en Sistemas de Información – UTN FRT  
Prof. Titular de la Cátedra de Inteligencia Artificial – Ingeniería en Sistemas de Información – UTN FRT  
provarini@gmail.com

### **AUS Ignacio Ariel Del Monte**

Analista Universitario de Sistemas  
Alumno de 5° año de la carrera de Ingeniería en Sistemas de Información – UTN FRT  
ignaciodelmonte@gmail.com

### **Prof. Claudia Inés Solórzano**

Especialista en Sistemas Humanos  
Miembro del grupo de investigación sobre Redes Sociales SECyT– UTN FRT  
Clausol2@yahoo.com.ar