



http://www.economicas.uba.ar/institutos_y_centros/revista-de-investigacion-en-modelos-financieros/

UNA COMPARACIÓN DE REDES NEURONALES Y MODELOS ARCH-GARCH PARA PREDECIR VARIACIONES EN EL PRECIO DE ACCIONES. APLICACIÓN A UN CASO DE ACCIONES DE TELEFONÍA.

Juan Antonio DIP, Patricia Isabel ROMERO

Facultad de Ciencias Económicas, Universidad Nacional de Misiones. Av. Fernando "Tulo" Llamosas Km. 7,5. Miguel Lanús (CP N3304), Misiones, República Argentina
dip@fce.unam.edu.ar , romeropatricia89@gmail.com

Recibido: 06/2015

Aceptado: 11/2015

Palabras clave

Cambio climático
Valuación económica
Eventos extremos
Sequía
Soja.

Durante los últimos años se ha intentado contrastar la teoría de eficiencia de mercado, a partir de modelos más eficientes y exactos para predecir variaciones en los precios de los distintos instrumentos financieros. Actualmente existen dos vías para predecir dichas variaciones: modelos paramétricos y modelos no paramétricos. Dentro del primer grupo se encuentran diversos modelos estadístico-econométricos, mientras que dentro del segundo se encuentran técnicas de inteligencia artificial, como las redes neuronales y los algoritmos genéticos. La utilización de redes neuronales para la predicción del comportamiento de variables económicas ha aumentado en gran medida durante los últimos años. Este trabajo describe el diseño de soluciones para pronosticar el precio de la acción de la sociedad Telecom Argentina S.A., la cual cotiza en la Bolsa de Comercio de Buenos Aires, en el período 2005-2012 a partir del uso de la técnica de análisis de componentes principales. Se presentan resultados basados en modelos tradicionales *Arch-Garch* y en un sistema de redes *backpropagation*. Adicionalmente, se presenta una comparación entre las metodologías, teniendo en cuenta el grado de predicción logrado.

Copyright: Facultad de Ciencias Económicas

ISSN: 2250-6861

A COMPARISON OF NEURAL NETWORKS AND ARCH-GARCH MODELS TO PREDICT CHANGES IN SHARE PRICES. AN APPLICATION TO THE CASE OF STOCKS IN THE TELECOMUNICATIONS INDUSTRY

Juan Antonio DIP, Patricia Isabel ROMERO

*Facultad de Ciencias Económicas, Universidad Nacional de Misiones. Av. Fernando "Tulo" Llamosas Km. 7,5. Miguel Lanús (CP N3304), Misiones, República Argentina
dip@fce.unam.edu.ar, romeropatricia89@gmail.com*

ABSTRACT

Recibido: 06/2015

Aceptado: 11/2015

Keywords

Shares on the Stock Exchange,
Principal Component Analysis,
Arch-Garch Models,
Backpropagation Networks.

In recent years, there have been attempts to test the theory of market efficiency, using more efficient and accurate models to predict changes in the prices of various financial instruments. Actually there are two ways to predict such variations: parametric and non-parametric models. In the first group there are various statistical-econometric models, while in the second there are artificial intelligence techniques as neural networks and genetic algorithms. The use of neural networks for predicting the behaviour of economic variables has increased greatly in recent years. This paper describes the design of solutions to forecast the share price of Telecom Argentina SA, which is listed on the Stock Exchange of Buenos Aires, in the period 2005-2012 from the use of a technique called Principal Component Analysis. The results are presented based on traditional models Arch-Garch and backpropagation networks. Additionally, a comparison between the methodologies is presented, considering the degree of prediction achieved.

Copyright: Facultad de Ciencias Económicas

ISSN: 2250-6861

1. INTRODUCCIÓN

El mundo financiero ha sido de gran interés desde sus comienzos, haciendo que el estudio de la predictibilidad de los activos financieros sea un desafío interesante desde la misma época en que aparecieron estos mercados. Por otro lado, durante los últimos años se ha intentado contrastar la teoría de eficiencia de mercado, constituida como uno de los pilares del desarrollo moderno de las finanzas. Esta teoría afirma que *los precios de las acciones son el reflejo de toda la información disponible, por lo que ningún agente puede obtener retornos extraordinarios en los mercados de manera consistente*. Se podría resumir esta teoría en la siguiente frase *"cuanto más eficiente es el mercado, tanto más aleatorias serán las secuencias de precios"* (Pulido, 2006). Según (Roberts, 1967) existen tres tipos de eficiencia en los mercados: débil, semifuerte y fuerte, donde lo que difiere entre una y otra, es el tipo de información con la que cuentan los agentes.

En contraste a esta teoría, los entusiastas del análisis técnico del mercado financiero argumentan que los mercados serán todo lo aleatorio que se quiera, pero evidentemente tienen muy buena memoria (Perez Fernandez-Tenillado, 2010).

El mundo financiero ha experimentado una gran cantidad de cambios, impactando en la situación económica de los hogares e incrementando aún más los estudios acerca del mismo. Los economistas han estudiado e intentado comprender por qué se dan los movimientos en los precios en el mercado de la bolsa de valores, ya que las inversiones en este mercado están sujetas a riesgos, los rendimientos son variables y su existencia es incierta. Desde hace tiempo, los especialistas del mercado bursátil están buscando modelos más eficientes y exactos para predecir variaciones en los precios de los distintos instrumentos financieros acorde a las nuevas exigencias que presenta el mercado. Se ha presentado un proceso de perfeccionamiento y sofisticación de las herramientas empleadas para dichas predicciones, que tiene hoy en día una gran diversidad de posibilidades para este objetivo. Al presente, existe una amplia literatura sobre la predictibilidad de los mercados financieros y evolución de estrategias de negociación.

Actualmente existen dos vías para predecir series temporales: modelos lineales y modelos no lineales. Dentro del primer grupo se encuentran diversos modelos estadísticos y econométricos, mientras que dentro del segundo se encuentran técnicas de inteligencia artificial como las redes neuronales y los algoritmos genéticos (López-Ibor, 2008).

La utilización de técnicas de inteligencia artificial para predecir comportamientos de las diversas variables involucradas en el mercado bursátil, están siendo estudiadas, y en algunos casos, llevadas a la práctica en distintos países, en los últimos años. Parece ser un método eficaz y que representa una multitud de oportunidades (García, Jalal, & Otros, 2013).

La finalidad del desarrollo del presente trabajo es contrastar la teoría de eficiencia de mercado demostrando la posibilidad de predicción del precio de la acción de Telecom Argentina S.A. a partir de la utilización de un modelo econométrico ARCH y otro de redes neuronales de backpropagation (retropropagación hacia atrás). Así como también, realizar una comparación entre ambas metodologías utilizadas. La cotización de los precios de la acción de la compañía telefónica es diaria y abarca el período 2005-2012. (El tamaño de la muestra es de 1666 observaciones).

El trabajo es organizado de la siguiente manera: se presenta el marco teórico correspondiente y los antecedentes, la aplicación de las técnicas de estimación y finalmente las conclusiones del trabajo.

2. MARCO TEÓRICO Y ANTECEDENTES

El marco teórico se divide en tres partes: en la primera se hace referencia a todo lo concerniente a las acciones, en la segunda se explica la técnica PCA, mientras que en la tercera parte se analizan los métodos econométricos de la familia GARCH y el método de aprendizaje de las redes neuronales con propagación hacia atrás. La última sección presenta investigaciones similares en el área de estudio.

2.1. Acciones en la bolsa

La Bolsa de Comercio de Buenos Aires fue fundada el 10 de julio de 1854. Actualmente se define a la bolsa como el lugar o punto de encuentro institucionalizado donde se mercadean títulos o certificados de propiedad de determinados tipos de bienes y productos financieros (Perez Fernandez-Tenillado, 2010). En la bolsa se negocian activos financieros, dentro de los cuales existen dos grandes grupos:

- Activos financieros de renta fija: en este grupo se encuentran los títulos que suponen para el propietario un crédito frente al emisor. Estos producen un rendimiento fijo. Ejemplos de este grupo son los bonos, las obligaciones, los pagarés, etc.
- Activos financieros de renta variable: en este grupo se encuentran los títulos que suponen una participación en la propiedad de una sociedad. El rendimiento que estos producen es variable. Ejemplo de este grupo son las acciones.

Una de las piezas esenciales del engranaje del capitalismo es la existencia de sociedades anónimas cuyas acciones se pueden comprar o vender a terceros en la bolsa de valores. Las acciones se intercambian en las bolsas de valores y las negocian firmas de corretaje inscritas en ellas. En las bolsas, el encuentro entre vendedores y compradores lo realizan los especialistas. La labor de estos últimos es encontrarles un vendedor a los que desean comprar una acción o un paquete de acciones, y un comprador a los que quieren vender una acción o un paquete de acciones (Llano Ferro, 2001).

Herramientas de Análisis

Existen dos grandes grupos de herramientas utilizados por los analistas para intentar prever el movimiento de los mercados. El primero de estos corresponde a lo que se denomina análisis fundamental, que hace uso de datos relativos a la economía general, datos socio-políticos, estados financieros de las empresas, datos del sector económico en el que operan, estudios de mercado, etc. El segundo grupo es el análisis técnico, el cual se basa en el hecho de que el propio mercado es el que proporciona la mejor información sobre la evolución futura que tanto él como los títulos que lo integran pueden tener (Crespo, 2007).

2.2. Análisis de componentes principales (pca)

Es uno de los métodos de análisis más difundidos, que permite la estructuración de un conjunto de datos multivariados obtenidos de una población, cuya distribución de probabilidad no necesita ser conocida (Pia, 1986). El análisis de componentes principales (PCA) puede disminuir el efecto de redundancia o dispersión de los fenómenos observados originalmente mediante la obtención de nuevas características con poca pérdida de información. Esta reducción de variables, además de crear nuevas características para el análisis, permite el desarrollo de modelos de pronóstico donde el trabajo de cómputo se disminuye notablemente (Colmenares, Orlandoni, Borges, & Otros, 2006).

Los objetivos de esta técnica son:

- Generar nuevas variables que puedan expresar la información contenida en el conjunto original de datos.
- Reducir la dimensionalidad del problema que se está estudiando, como paso previo para futuros análisis.
- Eliminar algunas de las variables originales si ellas aportan poca información, cuando sea posible (Pia, 1986) (Engle, 2004).

El análisis de componentes principales tiene como objetivo la reducción de la dimensionalidad de datos multivariantes.

2.3. Modelos ARCH

Generalmente las series financieras no presentan una varianza o variabilidad constante, por lo que las estructuras lineales son incapaces de explicar determinados aspectos que se encuentran presentes en las series financieras, como ser:

- Leptocurtosis: Es más apuntalada que una distribución normal (en una distribución normal es igual a 3).
- Volatilidad de los mercados financieros que aparecen por rachas. Altos retornos suelen ir seguidos de altos retornos y viceversa.
- Asimetría: La volatilidad aumenta más cuando hay caídas de precios que cuando hay aumentos. (García M. , 2011)

Por otro lado, en una serie financiera la varianza presenta las siguientes características:

- Comportamiento auto-regresivo: la variabilidad actual suele depender del comportamiento volátil que hubo en el pasado reciente.
- Contagio: los periodos en los que la volatilidad es alta suele mantenerse en el tiempo, lo mismo ocurre en periodos de baja volatilidad.
- Asimetría: las caídas son más intensas y bruscas que las subidas.

Los precios de las acciones sufren altibajos a lo largo del tiempo, por lo que la rentabilidad de las mismas posee una estructura temporal muy relacionada entre sí. Por ello se debe considerar a la volatilidad como una serie temporal.

Así, (Fuglewski, 1997, págs. 79-80) define a la volatilidad de la siguiente manera:

“ Volatility as the term is used in practice, does not refer to a single parameter, but to a set of related concepts. In a option pricing model, volatility is the square root of the average variance of the return on the underlying asset over every instant of the option's remaining lifetime. An options market maker, on the other hand, may use the term to mean the variability of return over the immediate short run. But much of the time, when the market maker uses the term volatility he actually means implied volatility. By contrast, a risk manager for a financial institution may calculate volatility in order to estimate the probability distribution for the value of a borrower's collateral at the maturity of a loan, and from that, her firm's exposure to the risk of default.....”

Para el caso que nos compete, la volatilidad es una medida del riesgo que se deriva de los cambios en la rentabilidad de las acciones.

Por lo tanto, una definición ajustada sobre volatilidad podría ser: “*La volatilidad es una medida de la intensidad de los cambios aleatorios o impredecibles en la rentabilidad o en el precio de un título. En la representación gráfica de una serie histórica de rendimientos, se asocia la volatilidad con la amplitud de las fluctuaciones del rendimiento, tanto es que se consideren en valor absoluto como en desviaciones alrededor de un valor medio*”.

Ederigton y Guan (2004), muestran que la forma más simple de pronosticar la volatilidad de los retornos diarios de un activo financiero a futuro, es la desviación estándar muestral o la varianza de los retornos de su pasado reciente¹.

Como se definió anteriormente, en las series de activos financieros se observa que existe un exceso de curtosis involucrada en la presencia de la volatilidad. Además presentan conglomerados de volatilidad “volatility clusters”², entendiéndose que, si la volatilidad es elevada en un periodo, tiende a seguir siéndolo; si es baja, tiende a seguir siendo baja en el periodo siguiente. También el comportamiento de las series de volatilidades es diferente, según lleguen al mercado buenas o malas noticias, ésta es una evidencia del comportamiento asimétrico de la serie.

Habiendo definido lo que es la volatilidad, se establece que la misma es un concepto de relevancia en el mundo de las finanzas, ya que al llevar a cabo la medición de los riesgos del mercado se debe estimar los parámetros de volatilidad. Existen diferentes tipos de modelos no lineales, entre ellos los más populares son los modelos de la familia ARCH que se utilizan para predecir la volatilidad. Estos determinan un patrón de comportamiento estadístico para la varianza, donde la información pasada de una variable y su volatilidad son factores que explican su comportamiento presente y, por tanto, podrá ser extrapolado a futuro.

El modelo ARCH fue inventado por el ganador del premio nobel de economía Robert Engle en la London School of Economics, en 1979. Su objetivo era encontrar un modelo que pudiese evaluar la validez de una conjetura realizada por Milton Friedman (1977), según la cual una de las principales causas de los ciclos económicos era el carácter impredecible de la inflación. Así Engle (1982) introduce una nueva clase de procesos estocásticos llamados modelos ARCH, en los cuales la varianza condicionada a la información pasada no es constante, y depende del cuadrado de las innovaciones pasadas. La idea de Engle fue comprobar que la incertidumbre cambiaba con el tiempo, o como él mismo dice “los econométricos llaman a esto heterocedasticidad” (Engle, 2004).

La especificación GARCH fue propuesta por Bollerslev (1986), quien formula la dependencia serial de la volatilidad e incorpora las observaciones pasadas a la volatilidad futura. Nelson (1991), propone los modelos EGARCH, en el cual formula el efecto apalancamiento. Glosten (1993), extiende el modelo GARCH con el efecto de apalancamiento a otro modelo llamado GRJ. Este modelo viene a ser la versión asimétrica del modelo GARCH. Jorion (1988) introduce la noción de “*Jump Specification*” en un modelo GARCH y luego muchos trabajos han desarrollado la dinámica de estos modelos.

Finalmente, Engle, Focardi y Fabozzi (2007), argumentan que los modelos ARCH, GARCH y los modelos de volatilidad estocástica, constituyen las principales herramientas para modelar y pronosticar a la volatilidad

La variedad de modelos ARCH se desarrolló en gran medida en el campo de las finanzas, debido a que los efectos riesgo/rendimiento tienen una importancia primordial y se dispone de datos de

¹ Si $R_t = \ln(P_t/P_{t-1})$, representa los retornos diarios de un activo financiero y calculada bajo un proceso de capitalización continua, la varianza histórica $VAR(n)$, sobre n periodos históricos, se define como $Var(n)_t = 1/n \sum_{j=0}^{n-1} r_{t+j}^2$ con $j=0, \dots, (n-1)$ y $r_{t+j} = R_{t+j} - \mu$, donde μ es el retorno esperado.

² Ver Engle, Focardi y Fabozzi (2007); “ARCH/GARCH Models in Applied Financial Econometrics”.

frecuencia diaria o incluso intra-diaria, que permiten hacer predicciones de volatilidad con precisión (Engle, 2004).

Definición de un modelo ARCH

Como se describió anteriormente, el modelo ARCH busca capturar los clusters de volatilidad observada en las series económico-financieras. Un modelo ARCH de orden q o ARCH(q), se define de la siguiente manera:

$$r_t = f(\Phi, \Omega_{t-1}) + u_t, \quad u_t \sim N(0, \sigma_t^2) \quad (1)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 u_{t-2}^2 + \dots + \alpha_p u_{t-p}^2 \quad (2)$$

Donde r_t es la variable de interés, f es una función de Φ (vector de parámetros) y Ω_{t-1} el conjunto de información disponible en $t-1$.

La varianza debe ser positiva y en consecuencia, todos los coeficientes de la ecuación de la varianza $\alpha_i \quad i = 1, \dots, q$ deben ser positivos.

Existe un test de "efectos ARCH" para constatar si existen o no efectos de tipo ARCH. La prueba de hipótesis para este test es la siguiente:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_q = 0 \quad (\text{No hay efectos ARCH}) \quad (3)$$

$$H_1: H_0 \text{ falsa (al menos un } \alpha_i \text{ es distinto de 0)}$$

2.4. Redes Neuronales

Estructura de un Sistema Neuronal Artificial

Los sistemas de redes neuronales imitan la estructura hardware del sistema nervioso, con la intención de construir sistemas de procesamiento de la información paralelos, distribuidos y adaptativos, que puedan presentar un cierto comportamiento inteligente (de Brío & Sanz Molina, 2007).

Las redes neuronales artificiales buscan copiar la estructura de las redes neuronales biológicas con el objeto de alcanzar una funcionalidad similar. Las redes pretenden emular:

- Paralelismo de cálculo.
- Memoria distribuida.
- Adaptabilidad al entorno.

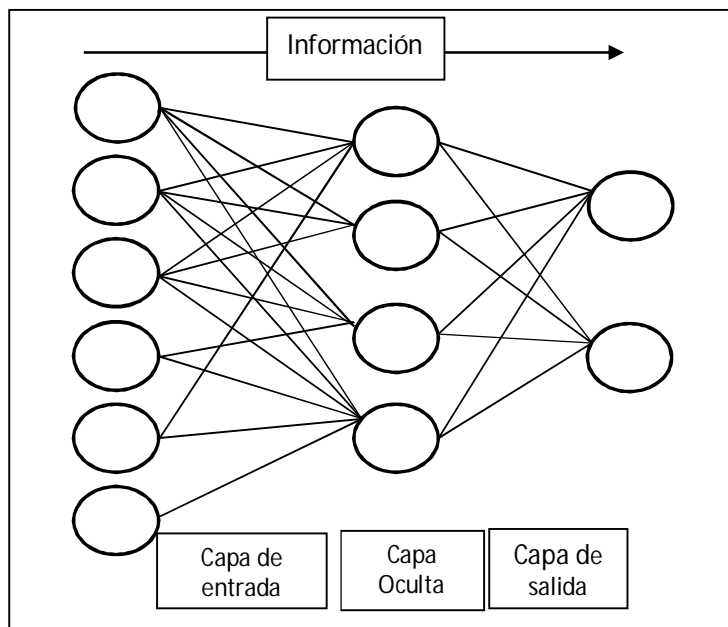
Las redes neuronales artificiales constan de un gran número de características que se asemejan a las del cerebro. Algunos de los ejemplos corresponden a la capacidad de aprender de la experiencia, la generalización de casos anteriores a nuevos, abstracción de características esenciales a partir de entradas que representan información irrelevante, etc.

Elementos de una red neuronal artificial

Las redes neuronales son modelos que intentan reproducir el comportamiento del cerebro, realizando una simplificación, averiguando cuales son los elementos relevantes del sistema (Hilera González, 2000). Los elementos que componen una red neuronal artificial son:

- Unidades de proceso: hacen referencia a las neuronas que tendrá la red. Existen tres tipos de unidades, las de entrada que son aquellas que reciben señales desde el entorno, las de salida que son las que envían la señal fuera del sistema, y las ocultas que son aquellas cuyas entradas y salidas se encuentran dentro del sistema. Se las puede ver gráficamente en la Figura 3.
- Estado de activación: el estado de una neurona varía en el tiempo, por lo cual cada neurona está caracterizada, en cualquier momento, por un valor numérico denominado valor o estado de activación. Hay dos posibles estados, reposo y excitado, donde a cada uno se les asigna un valor. A su vez, los valores de activación pueden ser discretos o continuos.
- Función de transferencia: las neuronas están unidas por conexiones, cada una emite señales a las neuronas conectadas a su salida. A su vez, cada neurona tiene asociada una función de salida que transforma el estado actual de activación a una señal de salida, es decir que esta función hace referencia a la función de salida de la neurona. Existen distintos tipos de funciones de transferencia, las más usuales son escalón, lineal y mixta, sigmooidal y gaussiana.

Figura 1. Unidades de proceso de una red neuronal



Fuente: Elaboración propia en base a (Russel & Norvig, 2004)

- Conexiones entre neuronas: las conexiones que unen a las neuronas tienen asociado un peso, que es el que hace que la red aprenda. Si este peso es positivo significa que la interacción entre las neuronas de esa conexión es excitadora; en cambio si es negativo la

sinapsis será inhibitoria. Por otro lado, si el peso es cero se supone que no hay conexión entre ambas neuronas.

- Función o regla de activación: es una regla que combina las entradas con los pesos de las conexiones, con el estado actual de la neurona para producir un nuevo estado de activación.
- Regla de aprendizaje: como el conocimiento se encuentra en el peso de las conexiones, se dice que se aprende modificando los valores de los pesos de la red.
- Representación vectorial: en algunos modelos de redes neuronales, se utiliza la forma vectorial como herramienta de representación de algunas magnitudes.

Conexiones entre neuronas

Respecto a la forma de las conexiones entre las neuronas, existen distintos tipos de redes neuronales:

- Redes con conexiones hacia adelante o feedforward: en este tipo de redes todas las señales neuronales se propagan hacia adelante a través de capas de la red. No existen conexiones hacia atrás y normalmente tampoco autorrecurrentes.
- Redes con conexiones hacia adelante y hacia atrás o feedforward/feedback: en este tipo de redes circula información tanto hacia adelante como hacia atrás durante el funcionamiento de la red.

En este trabajo se utilizan redes neuronales con propagación hacia atrás, que pertenecen al grupo de las redes neuronales con conexiones hacia adelante. En estos tipos de redes las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a la red, y envían las señales de salida a una capa posterior, más cercana a la salida de la red (Hilera González, 2000). Se ha optado por elegir este tipo de red neuronal ya que es una excelente técnica para la predicción de series temporales. Se ha utilizado en varios estudios de variables económicas de otros contextos, dando muy buenos resultados. Como por ejemplo para el pronóstico de ventas (Nojek & Otros, 2003); o para un caso particular de la acción Suramericana de Inversiones S.A. (Arrieta Bechara, Torres Cruz, & Velásquez Ceballos, 2009).

El método backpropagation (propagación del error hacia atrás) está basado en la generalización de la regla delta, el cual a pesar de sus limitaciones, ha ampliado de forma considerable el rango de aplicaciones de las redes neuronales (Valencia Reyes, Yañez Marquéz, & Sánchez Fernández, 2006). Al igual que el perceptron, ADALINE y MADALINE, esta red se caracteriza por tener una arquitectura en niveles y conexiones estrictamente hacia adelante entre las neuronas y utiliza aprendizaje de tipo supervisado.

El algoritmo de las redes backpropagation es una generalización del algoritmo Least Mean Square (LMS), donde llevan a cabo la actualización de los pesos mediante el error medio cuadrático. Además utiliza una superficie de error que está asociada a la propia red, buscando el estado de mínimo error posible a través del camino descendente de la superficie del error.

Esta red tiene la capacidad de auto adaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones dados como ejemplo y sus salidas correspondientes. Esto posibilita que después del entrenamiento, se reconozca a nuevos vectores de entrada con ruido o incompletos, dando una salida activa si la nueva entrada es parecida a las presentadas durante el aprendizaje. Esta característica importante, que se exige a los sistemas de aprendizaje, es la capacidad de generalización, entendida como la facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento (Hilera González, 2000).

Fases del Funcionamiento

El funcionamiento de este tipo de red consiste en dos fases:

- Primera fase: se aplica un patrón de entrada como estímulo para la primera capa de las neuronas de la red, se va propagando a través de todas las capas superiores hasta generar una salida, se compara el resultado obtenido en las neuronas de salida con la salida que se desea obtener y se calcula el error para cada neurona de salida.
- Segunda fase: se transmiten hacia atrás los errores calculados en la fase anterior, partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida, recibiendo el porcentaje de error aproximado a la participación de la neurona intermedia en la salida original. Este procedimiento se repite capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aportación relativa al error total. Se reajustan los pesos de conexión de cada neurona, teniendo en cuenta el valor del error recibido, de manera que en la siguiente vez que se presente el mismo patrón, la salida esté más cercana a la deseada, es decir el error disminuya (Russel & Norvig, 2004).

2.5. Investigaciones aplicadas

Las investigaciones aplicadas se han concentrado, no solamente en aplicar las técnicas de redes neuronales, sino en comparar la predicción de estos modelos respecto a los resultados que arrojan las técnicas convencionales de modelización en econometría. Así Pérez Ramírez & Campo (2005) analizan las acciones de Bavaria (02/01/2001 hasta el 21/04/2005) haciendo uso de la plataforma matlab. Presentan una metodología completa destinada a identificar, estimar y analizar modelos de series de tiempo haciendo uso de procedimientos estadísticos tradicionales y de manera alterna, un sistema neuronal apropiado. Se hizo uso de un modelo TARCH (heterocedasticidad condicional autorregresiva por tramos) y respecto a la red neuronal se usó una de tipo lineal. Luego de realizar un análisis comparativo entre ambas metodologías, concluye que la implementación del sistema neuronal propuesto obtiene resultados que superaron a los obtenidos por los métodos estadísticos empleados. Siguiendo en la misma línea Arrieta Bechara, Torres Cruz, & Velásquez Ceballos (2009) realizan predicciones sobre el comportamiento de mercado de la acción de SURAMINV (Suramericana de Inversiones S. A.) desde junio 2002 hasta marzo 2008. Utilizan un modelo de regresión con procesos AR(1), MA(1) y MA(6), y respecto a la red neuronal se usó una red de tipo *feedforward*. Obtuvieron evidencia a favor de la utilización de modelos econométricos y de inteligencia artificial construidos a partir de componentes principales, los cuales permiten lograr predicciones sobre el comportamiento diario de la acción de SURAMINV, contrastando la hipótesis de la teoría de eficiencia débil de mercado. El trabajo va más allá que otros desarrollados sobre el tema, en el sentido de que más que lograr un buen pronóstico *in sample* busca obtener resultados *out of sample*, controlando de esta manera la existencia de data snooping y, por tanto, suministrando información que puede ser aprovechada en estrategias de negociación. Se observó un mejor resultado por parte de la red neuronal al momento de analizar datos *out of sample*.

En Argentina, Maradona (2007), entrena una red neuronal con el fin de predecir el índice Merval en Argentina y comparar su desempeño con el de un camino aleatorio. Utiliza una red neuronal de tipo recurrente (Total-Recurrent) con dos capas ocultas. El algoritmo de aprendizaje es el de optimización de Powells. El autor resalta que si bien la red ha servido para captar una parte importante de la dinámica logrando un nivel de ajuste satisfactorio en el horizonte de estimación,

Lo cierto es que si el objetivo es predecir su comportamiento, nuestras redes evidencian menos capacidad que la que se obtiene de la aplicación de un modelo lineal (camino aleatorio). Resalta la condición de resultado preliminar de su investigación. Años más tarde, Benedetti et.al. (2011), vuelven a utilizar un modelo de redes neuronales artificiales para predecir el Merval, sofisticando el mismo mediante el incremento de la cantidad de insumos. Con esta sofisticación, las autoras aseguran que el desempeño en la predicción del Merval a través de las redes neuronales mejora significativamente. Además muestran que sus resultados son robustos a varias especificaciones de la red: ventana de tiempo, cantidad de nodos, restricciones en los inputs y testeo en base separadas al entrenamiento.

3. RESULTADOS

3.1. Tratamiento de los datos – Análisis de componentes principales (pca)

Las variables de entrada utilizadas para la predicción de las Acciones de Telecom en el período 2005-2012, dentro de la red neuronal son descriptas en el anexo 1. Las mismas son tratadas especialmente para evitar ciertos problemas que ocasionan el valor de las mismas, al momento de calcular los componentes principales. Cuando las escalas de medida de las variables son muy distintas, la maximización que se lleva a cabo en el proceso de PCA, dependerá decisivamente de estas escalas de medida, en el que las variables con valores más grandes tendrán mayor peso en el análisis. Para resolver este problema, se procede a estandarizar las variables antes de calcular los componentes, así de esta manera las magnitudes de los valores numéricos de las variables serán similares. Por otro lado, si los cambios de las variables son muy distintos, las que posean mayor varianza van a influir más en la determinación del primer componente principal; este inconveniente también se resuelve estandarizando las variables, ya que las varianzas son la unidad, y las covarianzas son los coeficientes de correlación.

Se puede advertir en el anexo 1 que los valores de las 86 variables de entrada son muy diversos entre sí. Esto motivó a proceder con la estandarización de todas las variables mediante la siguiente fórmula (Yao & Tan), que permite escalar los datos para el rango de [-1, 1].:

$$Nm = \frac{2*Y-(Max+Min)}{Max-Min} \quad (4)$$

Donde Y hace referencia al valor original, mientras que Max y Min representan el valor más grande y el más pequeño de la variable respectivamente. De esta manera, se evitan los problemas que puede llegar a traer la gran diversidad de las escalas de medida de las variables, así como las variabilidades de estas, a la maximización que lleva a cabo la técnica de PCA. Una vez estandarizados todos los datos, se utiliza la técnica PCA para disminuir la cantidad de variables de entrada. Para esto se usa el software XLSTAT. En la Tabla 1 podemos ver la salida de este software para las variables correspondientes a Telecom Argentina S.A.

Tabla 1. Salida PCA para Telecom Argentina S.A.

	F1	F2	F3	F4	F5	F6
Valor propio	32,942	17,251	7,810	5,378	4,067	2,952
Variabilidad (%)	38,755	20,295	9,188	6,327	4,784	3,473
% acumulado	38,755	59,050	68,238	74,565	79,350	82,823
	F7	F8	F9	F10	F11	F12
Valor propio	1,911	1,512	1,382	1,171	1,006	0,937
Variabilidad (%)	2,248	1,779	1,626	1,377	1,183	1,102
% acumulado	85,071	86,850	88,476	89,854	91,037	92,139

Fuente: Elaboración propia.

El ítem "% acumulado" representa el porcentaje total de variabilidad que se obtiene utilizando esa cantidad de componentes principales; a medida que aumenta la cantidad de componentes principales este porcentaje se hace mayor. Se puede observar que con 10 componentes principales se rescata el 89% de información que representan la totalidad de variables originales. Por lo que se decide utilizar como variables de entrada para la red neuronal los primeros 10 componentes, considerando que se está manteniendo un porcentaje significativo de la información brindada por las variables originales.

Los componentes principales elegidos como variables de entrada para la red neuronal, pasan por un proceso de estandarización de igual manera que las 86 variables originales. Esto se lleva a cabo ya que facilita el aprendizaje de la red, la convergencia hacia el error aceptable, así como su posterior predicción. El propósito de esta normalización es modificar los niveles de las entradas a un valor razonable. Sin tal transformación, el valor de la salida puede ser demasiado grande para que la red maneje, especialmente cuando hay una gran cantidad de capas involucradas en la estructura de la red (Yao & Tan).

3.2. Modelando la volatilidad. Modelos ARCH

Se analizaron diversos modelos de regresión de la familia ARCH, en los cuales se fue modificando la incorporación o no de los procesos AR(p), MA(p), para la estructura de la media, mientras que para la ecuación de la varianza se tuvo en cuenta los modelos ARCH, GARCH y EGARCH.

Fase de entrenamiento

El modelo elegido entre todos los estimados ha sido un modelo ARMA(1,1) ARCH(2). La variable SALIDA representa la cotización diaria en la Bolsa de la acción de Telecom Argentina S.A. El resultado de la estimación se muestra a continuación. Además se puede observar el correlograma de los residuos en el anexo 2.

Tabla 2. Modelo ARMA (1,1) ARCH(2)

Variable dependiente: D(LOG(SALIDA))


Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000894	0.000593	1.507621	0.1317
AR(1)	0.954831	0.050868	18.77074	0.0000
MA(1)	-0.952948	0.052343	-18.20569	0.0000
Variance Equation				
C	0.000317	2.73E-05	11.59984	0.0000
RESID(-1)^2	0.300476	0.108182	2.777516	0.0055
RESID(-2)^2	0.275459	0.054446	5.059269	0.0000

Fuente: Elaboración propia.

Los errores son robustos y corregidos por el método de Bollerslev-Wooldridge.

La figura 2 muestra el comportamiento de la salida otorgada por el modelo descrito anteriormente (SALIDAF) y la salida real (SALIDA). Se puede observar que si bien la precisión no es exacta, el modelo se ajusta en gran medida a los datos reales.

Figura 2 Salida del Modelo ARCH(2) vs Salida Real



Fuente: Salida Software Eviews.

Fase de Evaluación

Luego se lleva a cabo una etapa de estimación, donde se procede a separar los datos en dos partes:

- Datos *in sample*: son los primeros 1416 datos los cuales representan el 85% de los datos totales. Estos datos se utilizarán para llevar a cabo la estimación del modelo de regresión elegido.

- Datos *out of sample*: son los últimos 250 datos los cuales representan el 15% de los datos totales. Estos datos no estarán incluidos a la hora de llevar a cabo la estimación del modelo, sino que se utilizarán los mismos para realizar la predicción a partir del modelo de regresión elegido.

Los resultados de la estimación del modelo de regresión elegido haciendo uso de solamente el 85% de los datos puede visualizarse en la siguiente tabla. Mientras que el correlograma de los residuos pueden observarse en el anexo 3.

Tabla 3. Modelo ARCH(2)- Estimación IN SAMPLE

Variable dependiente: D(LOG(SALIDA))
n=1416

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001477	0.000543	2.720416	0.0065
AR(1)	0.812309	0.185315	4.383399	0.0000
MA(1)	-0.825460	0.180488	-4.573501	0.0000
Variance Equation				
C	0.000300	3.02E-05	9.924909	0.0000
RESID(-1)^2	0.316477	0.118934	2.660947	0.0078
RESID(-2)^2	0.324646	0.061718	5.260146	0.0000

Fuente: Elaboración propia.

Una vez calculado el modelo se procede a llevar a cabo la predicción/pronóstico de los datos que no fueron incluidos en la etapa anterior. Se muestran dos opciones: un pronóstico estático (se utilizan los valores verdaderos de las variables rezagadas) y un pronóstico dinámico (se utiliza el valor estimado y no el valor real del periodo precedente). El resultado del pronóstico dinámico de esta estimación, se muestra en la figura 3, donde SALIDA es el valor real de los datos y SALIDAF es la predicción realizada por el modelo.

Figura 3. Estimación del Modelo ARCH(2) vs Salida Real-Método Dinámico



Fuente: Elaboración propia.

Se puede observar que el modelo ARCH propuesto no ajusta correctamente cuando se pronostica con datos fuera de la muestra. Sin embargo, si se observan los anexos 4, 5 y 6 se puede constatar que a medida que aumenta el plazo en la estimación el modelo ARCH se aleja de los valores reales. Por otra parte, si se utiliza el método estático para realizar la estimación, este se ajustaría mejor como muestra la figura 4.

Figura 4 Estimación del Modelo ARCH(2) vs Salida Real-Método Estático



Fuente: Elaboración propia.

En base a lo anterior, se puede intuir que los pronósticos dinámicos dependen de ciertos supuestos que son muy difíciles de proyectar con precisión durante un período prolongado en el tiempo.

3.3. Red neuronal

Fase de entrenamiento

La programación de la red neuronal es llevada a cabo mediante el uso de la librería Encog. Se llevaron a cabo una serie de pruebas, intentando encontrar una configuración de la estructura de la red, que permita cumplir con los objetivos planteados. Luego de analizarlas a cada una, se eligió la configuración que se detalla en la Tabla 4. A continuación se presentan dos tipos de redes.

La red uno tiene como variable de salida el valor de la acción original del día siguiente sin ningún tipo de manipulación, mientras que la red número dos posee como variable de salida la variación que sufrirá el valor de la acción el día siguiente, es decir que si el precio de la acción en un tiempo $t=1$ es igual a 2,35 y en el tiempo $t=2$ es igual a 3,40, entonces la salida de la red dos para el tiempo $t=2$ será de 1,05. De esta manera, la red uno utiliza un rango de valores de la variable de salida igual a [3.15;21.53], mientras que la red dos usa un rango de [-1.61;1.32] lo que permitirá a la red lograr un porcentaje de aciertos mejor. A su vez, ambas redes tienen como variables de entrada los diez componentes principales estandarizados en etapas anteriores.

Se utilizaron los siguientes parámetros de aprendizaje, los cuales fueron elegidos luego de la realización de las diversas pruebas.

Tabla 4. Parámetros utilizados en el entrenamiento

Parámetro	Valor
Factor de Aprendizaje	0.001
Factor Momento	0.05
Iteración Máxima	10000000
Error Aceptable	0.00001
Número de Capas Ocultas	3
Cantidad de Neuronas Capa Oculta 1	5
Cantidad de Neuronas Capa Oculta 2	3
Cantidad de Neuronas Capa Oculta 3	2

Fuente: Elaboración propia.

El número de neuronas en la capa de salida es siempre igual a uno; mientras que en la capa de entrada es de 10. Respecto a la función de activación de las neuronas de salida, se ha decidido elegir la de tipo lineal, ya que tiene como rango todos los valores reales. Para las neuronas de entrada y de la capa oculta se ha optado por elegir la función de activación tangente hiperbólica.

Como condición de paro del algoritmo de aprendizaje se utilizaron dos opciones:

1. Alcanzar el máximo de iteraciones.
2. Alcanzar el error global aceptable.


En la etapa de entrenamiento se utilizan el 100% de los datos para el entrenamiento y para la evaluación del desempeño de la red. Debido a la existencia de una gran diversidad en los valores de esta salida, se considera acierto un valor que esté a ± 0.5 del valor original. En la Tabla 5 se puede observar el error global mínimo alcanzado por las redes y sus respectivos porcentajes de aciertos, además se puede ver la precisión que poseen ambas redes para ajustarse a los datos reales en la figura 5.

Tabla 5 Resultados del entrenamiento de las redes

Red	Error global mínimo alcanzado	Porcentaje de aciertos
Red Uno	0,181534534	80,07%
Red Dos	0,059606629	93,75%

Fuente: Elaboración propia.

Figura 5. Salida de las Redes Uno y Dos vs Salida Real



Fuente: Elaboración propia.

Fase de evaluación

En primer lugar, se lleva a cabo el entrenamiento de la red, pero sólo con el 85% de los datos para luego realizar el correspondiente test con el 15% restante. Se ha optado por elegir para entrenar la red los primeros patrones, ya que se trata de una serie temporal, y el factor tiempo es de gran relevancia para el problema en cuestión. Es decir que las pruebas se efectuaron con los últimos patrones.

Se ha utilizado la misma configuración en las redes y las condiciones de paro que en la fase de entrenamiento.


Los resultados obtenidos para las pruebas de ambas redes pueden resumirse en la Tabla 6. Los resultados de la red dos son considerados óptimos para los objetivos que se buscan en el presente trabajo. Se puede ver como el porcentaje de acierto se ha mantenido respecto a lo que mostraba la Tabla 5. Sin embargo la red uno no tuvo un buen desempeño a la hora de trabajar con datos *out of sample*, lo cual puede ser debido al rango de valores de variable de salida que maneja esta red. En la figura 6 se tiene una imagen representativa de la fase de evaluación.

Tabla 6. Resultados de la evaluación de las redes

Red	Error global mínimo Alcanzado	Porcentaje de Aciertos
Red Uno	6,10822269	10,41%
Red Dos	0,74582963	85,60%

Fuente: Elaboración propia.

Figura 6. Salida de las redes uno y dos vs salida real-evaluación



Fuente: Elaboración propia.

3.4. Comparación de resultados

Comparación In Sample

En la Figura 7 podemos ver el comportamiento de las predicciones tanto para los modelos ARMA (1,1) - ARCH(2) como para ambas redes neuronales. Se puede resaltar que tanto la red dos como el modelo con pronóstico estático se ajustan muy bien a los datos. Sin embargo al evaluar los errores, el modelo ARCH con pronóstico estático posee un error promedio menor que sus competidores, por lo que tendría una mejor performance dentro de la muestra.

Los errores en la estimación IN SAMPLE de cada modelo, se describen en la siguiente Tabla 7.

Tabla 7 Errores In Sample de los Modelos ARCH y Redes

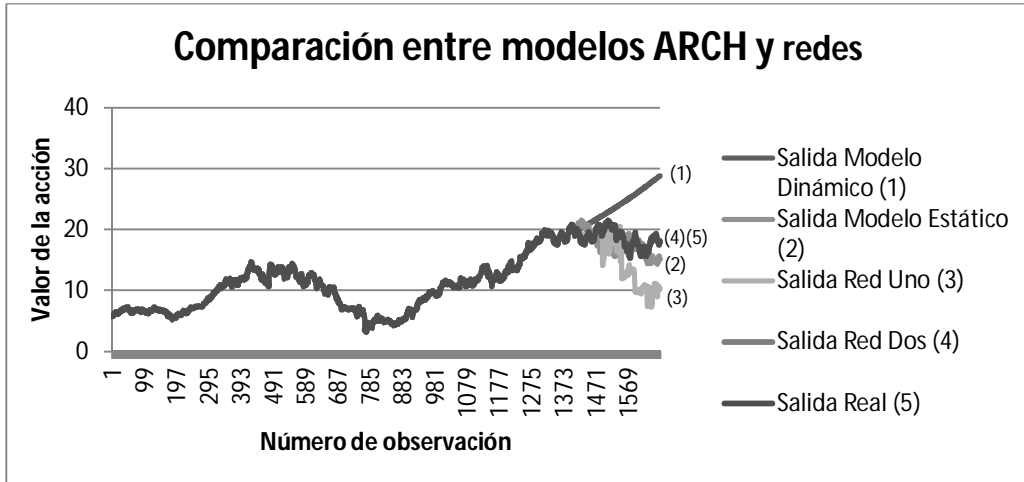
Método	Modelo ARCH		Red uno	Red dos
	Modelo ARCH dinámico	estático		
Error mínimo	0,00	0,00	0,00	0,00
Error máximo	29,77	1,16	1,61	1,27
Error promedio	10,58	0,04	0,33	0,17
% de Aciertos	13,08%	99,29%	80,07%	93,75%

Fuente: Elaboración propia.

Comparación Out of Sample


Cuando se trabaja con datos *out of sample*, es notable como la red dos tiene un ajuste casi exacto, mientras que la red uno no. Por el lado de los modelos, se observa que el modelo con pronóstico estático posee una aproximación bastante acertada a la salida real, sin embargo el modelo con pronóstico dinámico no. Se puede visualizar mejor el comportamiento de la etapa de evaluación en la figura 8.

Figura 7. Salidas del modelos ARCH y las redes



Fuente: Elaboración propia.

Figura 8 Salidas Evaluación-Modelos ARCH y Redes



Fuente: Elaboración propia.

En la tabla siguiente se puede ver una comparación de los errores obtenidos por las diferentes metodologías propuestas.

Tabla 8. Comparación de errores – (out of sample)

Método	Modelo ARCH dinámico	Modelo ARCH estático	Red uno	Red dos
Error mínimo	0,47	0,02	0,00	0,00
Error máximo	11,57	5,13	11,36	1,61
Error promedio	5,56	2,21	3,87	0,27
% de Aciertos	1,2%	10,4%	12%	85,60%

Fuente: Elaboración propia.

Como puede observarse, la red dos comete un error como máximo de 1.61 a la hora de predecir el valor de la acción, seguido por el modelo ARCH estático con un valor de 5,13; mientras que la red uno y el modelo de regresión llegan a cometer un error máximo mucho más elevado, 11.36 y 11.57 respectivamente. Además, al ver el error promedio que cometen cada uno de los métodos, se puede decir que la red neuronal dos en promedio comete errores de menor magnitud a la hora de llevar a cabo la predicción. Cabe resaltar que se debe tener en cuenta la trayectoria de los pronósticos respecto a la serie real y las formas convencionales de asimetría, curtosis y desvío estándar de los mismos.

4. CONCLUSIONES

El trabajo ha descrito el diseño de soluciones para pronosticar el precio de la acción de la sociedad Telecom Argentina S.A, la cual cotiza en la Bolsa de Comercio de Buenos Aires, en el periodo 2005-2012 a partir del uso de la técnica de análisis de componentes principales, modelos tradicionales Arch-Garch y un sistema de redes backpropagation. Se presentó en extenso, la metodología del funcionamiento de redes neuronales y una clasificación general de los modelos tradicionales que se utilizan en econometría. Cabe resaltar que la decisión de aplicar alguno de estos métodos dependerá de la experiencia del investigador respecto al conocimiento de la técnica elegida, dado que redes neuronales presenta una dificultad superior respecto a la involucrada en los modelos tradicionales. Esto último muchas veces requiere la necesidad de una mayor sofisticación de la red, incorporando una mayor cantidad de variables que expliquen el precio de la acción, así como también considerar una mayor cantidad de filtros, de nodos etc. Al analizar los porcentajes de aciertos y los errores de las cuatro propuestas de este trabajo se ha concluido en que el modelo ARMA(1,1) – ARCH(2) ha mostrado un mejor desempeño dentro de la muestra (*in sample*). Este modelo ha obtenido un porcentaje de aciertos del 99.29% y ha cometido un error promedio de 0.04 .

Por otro lado, se establece que la red 2 ha sido la que mejor ha estimado el precio de la acción fuera de la muestra (*out of sample*). Debido al hecho de que esta red ha obtenido un porcentaje de aciertos igual al 85.60% y ha alcanzado un error promedio de 0.27. Esto implica que las redes son aproximadoras de funciones universales, logrando modelar de mejor manera la tendencia. Con los resultados expuestos anteriormente, se puede concluir que las redes neuronales de retro propagación hacia atrás han manifestado su utilidad a la hora de trabajar con variables económicas e índices bursátiles, demostrando resultados aceptables. Se considera una buena opción a tener en cuenta como modelo de predicción del comportamiento de los precios de las acciones.

Sin embargo, respecto a contrastar la teoría de la eficiencia de los mercados, este trabajo no es concluyente sobre la existencia de una eficiencia débil. Si bien las redes neuronales tuvieron un buen desempeño al momento de predecir los valores de la acción de Telecom S.A., este no fue

perfecto. Por otro lado, las redes neuronales propuestas no han logrado superar en su totalidad al modelo de la familia ARCH elegido, ya que en la comparación *in sample* el modelo ARCH demostró un mejor resultado. Sería apresurado afirmar que la Hipótesis de los Mercados Eficientes no se cumple debido al logro de un porcentaje de aciertos alentador para una sola sociedad que cotiza en la Bolsa de Buenos Aires. Se alienta a una mayor investigación del uso de redes neuronales en el mercado financiero, pues no existen muchos antecedentes en nuestro país.

REFERENCIAS BIBLIOGRÁFICAS

- Arrieta Bechara, J. E., Torres Cruz, J. C., & Velásquez Ceballos, H. (2009). *Predicciones de modelos econométricos y redes neuronales: el caso de la acción de suraminv*. Medellín, Colombia: Universidad de Medellín.
- Benedetti, F., Baigún, A., & Yanguas, M. (2011). *Predicciones de Series de Tiempo con Redes Neuronales: Trading usando el Índice Merval*. Buenos Aires: Reporte Técnico-Universidad de San Andrés.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heterocedasticity. *Journal of Econometrics*.
- Bolsa de Comercio de Buenos Aires. (2004). *Acciones: Requisitos para la oferta pública y cotización en Bolsa*. Buenos Aires, Argentina: BCRA.
- Colmenares, G., Orlandoni, G., Borges, R., & Otros, y. (2006). *Modelos estadísticos multivariantes de pronóstico y de clasificación no paramétricos para el análisis de riesgo bancario*. Bucaramanga, Colombia: XVI Simposio de Estadística.
- Crespo, P. (2007). *Invertir y Ganar en la bolsa*. Buenos Aires, Argentina: Gestión 2000.
- De Brío, B. M., & Sanz Molina, A. (2007). *Redes Neuronales y Sistemas Borrosos*. México.
- Engle, F. R. (1982). Autoregressive Conditional Heterocedasticity whit Estimates of the Variance of United Kindgdom Inflation. *Econométrica*.
- Engle, R. (2004). Riesgo y Volatilidad: Modelos Econométricos y Práctica Financiera. *Revista Asturiana de Economía*, 221-252.
- Engle, R., Focardi, S., & Fabozzi, F. (2007). ARCH/GARCH Models in Applied Financial Econometrics. *JWPR026-C114-NP*.
- Flores López, R., & Fernández Fernández, J. M. (2008). *Las redes neuronales artificiales. Fundamentos teóricos y aplicaciones prácticas*. España: Netbiblo.
- Fuglewski, S. (1997). Forecasting Volatility. *Financial Markets, Institutions and Instruments*, 28(1).
- García, M. (2011). *Introducción a la Econometría Financiera. Modelos ARCH*. Madrid: Cátedra de econometría dinámica y financiera. UC3M.
- García, M. C., Jalal, A. M., & Otros. (2013). *Métodos para predecir índices bursátiles*. Medellín: Revista Ecos de Economía.
- Gil Zapata, M. M., & Pérez Ramírez, F. O. (2005). Análisis y predicción de la acción de la empresa Acerías Paz del Río utilizando un modelo GARCH(1,1) y redes neuronales artificiales. *Revista Ingenierías Universidad de Medellín*, 83-97.
- Glosten, L., Jagannathan, R., & Runkle, D. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *Journal of Finance*, 48(5).
- Hilera González, J. R. (2000). *Redes neuronales artificiales: Fundamentos, modelos y aplicaciones*. México.

- Hotelling, H. (1933). *Analysis of a Complex of Statistical Variables Into Principal Components* (Vol. 24). Journal of Educational Psychology.
- Jorion, P. (1988). On jump processes in the foreign Exchange and stock markets. *Review of Financial Studies*, 1(4), 427-445.
- Llano Ferro, L. F. (2001). *Aproximación a Wall Street: Una introducción a los mercados de capitales y consejos prácticos sobre como invertir en la bolsa*. Bogotá, Colombia.
- López-Ibor, J. H. (2008). *Sistema de inversión en bolsa a corto plazo*. Madrid, España: Universidad Pontificia Comillas ICAI-ICADE.
- Macchi, J. A., Schamann, E. M., & Otros. (1998). *La inversión bursátil*. Buenos Aires, Argentina: Tesis.
- Maradona, G. (2007). Resultados de una aproximación preliminar a la predicción de series financieras utilizando redes neuronales. *Reunión Anual de la Asociación Argentina de Economía Política*.
- Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. Rosario, Argentina: Universidad Tecnológica Nacional-Facultad Regional Rosario.
- Monsegny, M., & Cepeda Cuervo, E. (2008). Modelos ARCH, GARCH y EGARCH: aplicaciones a series financieras. *Cuadernos de Economía*, V(XXVII).
- Nojek, S., & Otros. (2003). *Pronóstico de Ventas: Comparación de predicción basada en redes neuronales versus método estadístico*. Buenos Aires, Argentina: Instituto Tecnológico de Buenos Aires.
- Pearson, K. (1901). *On lines and planes of closest fit to systems of points in space* (Vol. 2). Philosophical Magazine.
- Peña, D. (2002). *Análisis de datos multivariantes*. España: Mc GrawHill.
- Perez Fernandez-Tenillado, R. (2010). *Teoría y práctica de la bolsa*. España: Diaz de Santos.
- Pérez Ramírez, F. O., & Campo, J. P. (2005). ARIMA, ARCH, GARCH y Redes Neuronales: Modelos para pronosticar series de tiempo financieras. *Componentes Electrónicas Ltda-Universidad El Bosque*.
- Pia, L. E. (1986). *Análisis Multivariado: Método de Componentes Principales*. Coro, Falcón, Venezuela: Universidad Nacional Experimental Francisco de Miranda.
- Pulido, A. (2006). *Guía para usuarios de predicciones económicas*. Madrid, España: ECOBOOK: Editorial del Economista.
- Roberts, H. (1967). Statistical versus clinical prediction of the stock market. *Unpublished manuscript*.
- Russel, S., & Norvig, P. (2004). *Inteligencia Artificial: un enfoque moderno*. Madrid, España.
- Valencia Reyes, M. A., Yañez Marquéz, C., & Sánchez Fernández, L. P. (2006). *Algoritmo Backpropagation para Redes Neuronales: conceptos y aplicaciones*. México: Instituto Politécnico Nacional. Centro de Investigación en Computación.
- Yao, J., & Tan, C. L. (s.f.). *Guidelines for Financial Forecasting with Neural Networks*.

ANEXOS

Anexo 1 Estadísticos de las variables de entrada

	Variables				
	<i>Cierre del día</i>	<i>Variación %</i>	<i>Apertura</i>	<i>Máximo</i>	<i>Mínimo</i>
<i>Máximo</i>	21,53	19,79	21,38	21,53	21,15
<i>Mínimo</i>	1,48	-25,09	1,47	1,51	1,44
<i>Promedio</i>	10,38	0,14	10,38	10,51	10,23
<i>Desvío</i>	5,18	2,69	5,18	5,23	5,12
			<i>Liquidez Corriente</i>		
	<i>Volumen Nominal</i>	<i>Monto Negociado</i>	<i>Nivel General</i>	<i>Industrias</i>	<i>Servicios Públicos</i>
<i>Máximo</i>	4134987,00	31855709,00	192,90	186,52	97,29
<i>Mínimo</i>	5214,00	59074,00	54,64	89,40	22,90
<i>Promedio</i>	346424,15	3131579,62	120,64	133,50	69,40
<i>Desvío</i>	435373,13	3199408,63	34,26	25,86	17,94
	<i>Liquidez Corriente</i>	<i>Liquidez seca</i>			
	<i>Otros</i>	<i>Nivel General</i>	<i>Industrias</i>	<i>Servicios Públicos</i>	<i>Otros</i>
<i>Máximo</i>	261,56	142,27	145,52	92,37	157,40
<i>Mínimo</i>	15,80	42,20	65,09	21,93	14,35
<i>Promedio</i>	106,89	87,59	94,09	65,29	84,10
<i>Desvío</i>	77,63	25,06	22,55	17,17	49,32
	<i>Capital de trabajo/activos corriente</i>				<i>Deudas Corrientes/PN</i>
	<i>Nivel General</i>	<i>Industrias</i>	<i>Servicios Públicos</i>	<i>Otros</i>	<i>Nivel General</i>
<i>Máximo</i>	48,16	46,39	-2,79	61,77	104,84
<i>Mínimo</i>	-83,01	-11,85	-336,67	-533,05	17,67
<i>Promedio</i>	10,34	22,43	-60,84	-76,81	37,88
<i>Desvío</i>	25,92	14,13	69,97	141,48	17,50
	<i>Deudas Corrientes/PN</i>			<i>Deudas no corrientes/PN</i>	
	<i>Industrias</i>	<i>Servicios Públicos</i>	<i>Otros</i>	<i>Nivel General</i>	<i>Industrias</i>
<i>Máximo</i>	85,10	269,98	26,94	69,84	76,43
<i>Mínimo</i>	18,68	41,35	1,28	14,20	13,99
<i>Promedio</i>	40,64	82,30	12,52	44,72	51,34
<i>Desvío</i>	13,89	47,60	7,58	13,80	15,40
	<i>Deudas no corrientes/PN</i>			<i>Deudas Totales/PN</i>	
	<i>Servicios Públicos</i>	<i>Otros</i>	<i>Nivel General</i>	<i>Industrias</i>	<i>Servicios Públicos</i>
<i>Máximo</i>	164,77	43,09	168,66	159,05	340,73

Mínimo	43,09	0,19	36,01	44,40	90,40
Promedio	95,17	8,62	82,60	92,06	177,53
Desvío	32,19	11,70	26,15	23,56	59,59
	Deudas Totales/PN	Precio/Ganancia			
	Otros	Nivel General	Industrias	Servicios Públicos	Financiero
Máximo	46,60	38,91	35,81	56,42	26,45
Mínimo	5,96	0,00	0,00	0,00	0,00
Promedio	20,86	12,37	10,16	13,19	10,57
Desvío	12,69	6,69	4,40	9,97	7,17
	Precio/Ganancia	Precio/Valor libros			
	Otros	Nivel General	Industrias	Servicios Públicos	Financiero
Máximo	594,52	2,47	2,15	2,31	2,67
Mínimo	0,00	0,95	0,59	0,61	0,36
Promedio	26,44	1,70	1,40	1,51	1,51
Desvío	61,87	0,42	0,39	0,39	0,57
	Precio/Valor libros	Utilidad/PN			
	Otros	Nivel General	Industrias	Servicios Públicos	Financiero
Máximo	3,94	21,31	27,21	31,83	26,67
Mínimo	0,84	-23,64	-3,66	-45,98	-35,52
Promedio	2,60	12,27	15,60	7,30	10,03
Desvío	0,80	8,31	6,24	14,88	15,85
	Utilidad/PN				
	Otros	IPC	PBI	Consumo privado	Consumo público
Máximo	24,63	141,51	8418,90	7618,80	2543,40
Mínimo	-21,44	65,70	2024,30	776,80	122,90
Promedio	13,68	101,27	4893,21	3805,23	1087,98
Desvío	8,92	21,08	1546,96	1603,26	469,25
	Inversión Bruta Interna Fija	Exportaciones	Importaciones	Saldo Comercial	Deuda Externa Pública
Máximo	479963,68	318608,15	63763,83	121793,96	100593,60
Mínimo	228595,88	153188,34	29350,74	27659,22	56113,81
Promedio	368161,23	241315,38	45749,18	79742,98	70055,56
Desvío	65478,81	42892,08	8649,12	23753,15	11058,74
	Deuda Externa Privada	Deuda Total	Desempleo %	Tipo de Cambio	Capitalización Bursátil
Máximo	64030,06	163210,47	17,80	4,52	2269008777930,86

Mínimo	42322,80	104468,83	6,70	2,75	343263864654,00
Promedio	51969,31	127712,15	9,57	3,48	1398296271931,84
Desvío	6312,39	15945,40	3,03	0,49	541160442893,10
	Dividendos a pagar	Merval	Merval 25	Bolsa	Indice de Liquidez
Máximo	915474310,00	87,59	78,11	78,11	1,11
Mínimo	0,00	4,42	4,24	2,52	0,18
Promedio	308190921,85	28,06	25,98	24,99	0,70
Desvío	395196755,40	12,24	11,02	11,02	0,23
	Indice de Solvencia	Indice inmovilización	Indice de Rentabilidad	Activo Corriente	Activo No Corriente
Máximo	1,28	0,84	0,81	5826000000,00	10755000000,00
Mínimo	0,07	0,61	-2,99	1476000000,00	6525000000,00
Promedio	0,66	0,74	0,15	2851920626,63	7810183289,82
Desvío	0,39	0,06	0,61	1055097693,64	1199212889,86
	Total Activo	Pasivo Corriente	Pasivo no Corriente	Total Pasivo	Patrimonio Neto
Máximo	15815000000,00	11656000000,00	4931000000,00	11999000000,00	8875000000,00
Mínimo	8375000000,00	1493000000,00	308000000,00	5058000000,00	811000000,00
Promedio	10662103916,45	4645900783,29	1949422976,50	6595323759,79	3939158224,54
Desvío	1883722272,79	2434159733,83	1275318910,96	1751625147,66	2100222715,59
	Resultado Ordinario	Resultado Extraordinario	Resultado Neto	Indice de Endeudamiento	Capital de Trabajo
Máximo	3774000000,00	1319000000,00	2422000000,00	14,80	567000000,00
Mínimo	-5673000000,00	-1352000000,00	4354000000,00	0,78	-9564000000,00
Promedio	979952480,42	-299109138,38	680843342,04	2,65	-1793980156,66
Desvío	1488868705,18	454745139,84	1079547218,02	2,78	2532978256,74
	Indice de Recursos Propios	Inflación	Tasa de Interes	Riesgo Pais	FED
Máximo	0,56	3,35	25,41	7004,00	5,41
Mínimo	0,06	-0,86	2,59	185,00	0,06
Promedio	0,36	1,26	9,71	1320,20	1,91
Desvío	0,15	0,78	3,72	1699,18	2,06
	Dow Jones				
Máximo	21,53				
Mínimo	1,48				
Promedio	10,38				
Desvío	5,18				

Fuente: Elaboración propia.

Anexo 2 Correlograma de los residuos modelo ARMA(1,1) Arch(2)

Sample: 3 1666

Included observations: 1664

Q-statistic probabilities
adjusted for 2 ARMA
term(s)

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.038	0.038	2.4561	
		2	0.036	0.035	4.6227	
		3	-0.043	-0.046	7.7369	0.005
		4	0.039	0.042	10.328	0.006
		5	-0.053	-0.054	15.108	0.002
		6	-0.015	-0.015	15.463	0.004
		7	0.022	0.030	16.241	0.006
		8	-0.010	-0.018	16.397	0.012
		9	-0.002	0.000	16.404	0.022
		10	-0.033	-0.032	18.229	0.020
		11	0.009	0.007	18.360	0.031
		12	0.008	0.013	18.456	0.048
		13	0.010	0.005	18.613	0.068
		14	-0.005	-0.004	18.660	0.097
		15	0.020	0.017	19.321	0.113
		16	-0.050	-0.052	23.454	0.053
		17	-0.040	-0.035	26.081	0.037
		18	-0.042	-0.033	28.988	0.024
		19	0.041	0.040	31.795	0.016
		20	0.003	0.004	31.810	0.023
		21	-0.007	-0.015	31.893	0.032
		22	0.030	0.032	33.405	0.030
		23	0.037	0.030	35.665	0.024
		24	0.047	0.045	39.439	0.013
		25	-0.031	-0.030	41.019	0.012
		26	0.011	0.003	41.224	0.016
		27	0.003	0.007	41.235	0.022
		28	0.039	0.036	43.822	0.016
		29	0.011	0.020	44.033	0.021
		30	-0.033	-0.041	45.907	0.018
		31	0.034	0.039	47.891	0.015
		32	-0.009	-0.008	48.031	0.020
		33	0.014	0.011	48.368	0.024
		34	-0.004	0.000	48.391	0.032
		35	0.001	-0.012	48.394	0.041
		36	-0.026	-0.019	49.565	0.041


Fuente: Elaboración propia.

Anexo 3 Correlograma de los residuos – Estimación IN SAMPLE

Autocorrelation		Partial Correlation		AC	PAC	Q-Stat	Prob	
				1	0.043	0.043	2.6013	
				2	0.049	0.048	6.0625	
				3	-0.028	-0.032	7.1737	0.007
				4	0.052	0.052	10.958	0.004
				5	-0.035	-0.036	12.670	0.005
				6	-0.015	-0.018	12.999	0.011
				7	0.015	0.024	13.330	0.020
				8	-0.005	-0.010	13.367	0.038
				9	0.000	0.002	13.367	0.064
				10	-0.055	-0.053	17.610	0.024
				11	0.005	0.006	17.649	0.039
				12	0.023	0.030	18.404	0.049
				13	0.027	0.021	19.433	0.054
				14	0.012	0.013	19.641	0.074
				15	0.028	0.022	20.757	0.078
				16	-0.040	-0.047	23.067	0.059
				17	-0.060	-0.057	28.222	0.020
				18	-0.036	-0.026	30.122	0.017
				19	0.028	0.033	31.263	0.019
				20	0.006	0.006	31.307	0.027
				21	0.009	0.008	31.414	0.036
				22	0.041	0.042	33.807	0.027
				23	0.052	0.046	37.762	0.014
				24	0.066	0.062	44.074	0.003
				25	-0.017	-0.022	44.475	0.005
				26	0.006	-0.008	44.518	0.007
				27	0.002	-0.002	44.527	0.009
				28	0.050	0.045	48.186	0.005
				29	0.018	0.029	48.644	0.006
				30	-0.042	-0.046	51.256	0.005
				31	0.026	0.033	52.202	0.005
				32	-0.013	-0.009	52.436	0.007
				33	0.008	0.004	52.524	0.009
				34	-0.010	-0.003	52.659	0.012
				35	0.025	0.009	53.580	0.013
				36	-0.030	-0.034	54.884	0.013

Fuente: Elaboración propia.

Anexo 4 Estimación a 10 días con Modelo ARCH(2) – Pronóstico dinámico



Fuente: Elaboración propia.

Anexo 5 Estimación a 30 días con Modelo ARCH(2) –Pronóstico dinámico



Fuente: Elaboración propia.

Anexo 6 Estimación a 60 días con Modelo ARCH(2)-Pronóstico dinámico



Fuente: Elaboración propia.