

Arquitectura multi-agente con redes neuronales artificiales para el análisis de acciones en la bolsa de valores de Colombia

Multi-agent architecture with artificial neural networks for the analysis of shares in the colombian stock exchange

Jessie Steve Camargo Cantillo, Julio cesar Munera Loaiza, Fabian Alberto Polo Viana & Paola Sánchez Sánchez

{jcamargo32, jmunera1, fpolo6} @unisimon.edu.co – {psanchez9} @unisimonbolivar.edu.co

Universidad Simón Bolívar, Barranquilla-Colombia.

Resumen

En este artículo se desarrolla la implementación de una plataforma para el análisis de acciones en la bolsa de valores de Colombia, que además provee una recomendación de que y cuando invertir, para que los inversionistas puedan decidir dónde invertir su dinero en determinado momento. Esto se realiza a través de la integración de metodologías para el análisis de series de tiempo, modelos de redes neuronales y sistema multi-agentes. Los resultados obtenidos muestran que los parámetros relacionados con la información tienen un significativo impacto para la predicción de las variables y de esta manera poder advertir la evolución y el comportamiento de valores futuros de las acciones, para lo cual se hace uso de múltiples tecnologías y lenguajes de programación, que permiten la integración de los agentes y la red neuronal. En general, el objetivo del presente trabajo es ofrecer una sugerencia sobre el comportamiento de cada una de las acciones, basándose solo en datos cuantitativos, como resultado de un proceso coordinado por agentes inteligentes que cumplen determinadas tareas, los cuales se comunican con una plataforma de redes neuronales y con un sistema de base de datos

Palabras clave:

Agentes inteligentes, Series de tiempo, Red neuronal artificial, predicción, Acciones, Bolsa de valores de Colombia

Abstract

This paper develops the implementation of a platform for the analysis of shares in the stock exchange of Colombia, which also provides a recommendation of what and when to invest, so that investors can decide where to invest their money at a certain time. This is done through the integration of methodologies for the analysis of time series, models of neural networks and multi-agent system. The obtained results show that the parameters related to the information have a significant impact for the prediction of the variables and in this way to be able to warn the evolution and the behavior of future values of the actions, for which use is made of multiple technologies and languages of programming, which allow the integration of agents and the neural network. In general, the objective of this paper is to offer a suggestion about the behavior of each one of the actions, based only on quantitative data, as a result of a process coordinated by intelligent agents that fulfill certain tasks, which communicate with a platform of neural networks and with a database system.

Key words:

Intelligence Agents, Time Series, Artificial Neural Network, prediction, Stocks, Colombian Stock Exchange

Introducción

Los economistas desde hace tiempo han intentado comprender los movimientos de los índices bursátiles, que reaccionan a diversos factores [1]. En la actualidad, existen dos tendencias principales de análisis: El análisis fundamental y análisis técnico, utilizados para analizar los diversos cambios y riesgos de las acciones. Estas tendencias son complementarias, pero se diferencian notablemente una de la otra [2].

El análisis fundamental, determina el valor real del título bursátil, llamado valor fundamental, y que no tiene porque corresponder con el valor de mercado. Para ello se realiza un estudio en profundidad de la empresa, del sector al que pertenece y de los países en los que opera.

El análisis Técnico que es en el cual se enmarca el presente artículo de investigación, trata de una serie de herramientas estadísticas para estudios a corto y medio plazo, estudia las gráficas del valor de la acción y el volumen de negociación, basándose en una serie de premisas:

- Los movimientos del mercado lo descuentan todo.
- Los precios se mueven por tendencias.
- La historia se repite [3].

La predicción del mercado de valores puede clasificarse en sistemas complejos y de gran importancia, donde numerosos métodos se han propuesto para proveer recomendaciones con un determinado grado de precisión, Sin embargo, el dominio del mercado de valores es dinámico e impredecible. Varios Estudios de investigación se han realizado para predecir el mercado, utilizando diferentes técnicas que van desde análisis estadísticos, análisis técnico, análisis fundamental, entre otros, obteniendo diferentes resultados. Aun así, Estas técnicas no pueden proporcionar un análisis en profundidad, por lo tanto, no soy muy efectivos a la hora de predecir los precios del mercado de valores [4].

De tal manera que la creación de un sistema que permita brindar recomendación al momento de la compra o venta de acciones siempre ha sido un tema de gran interés [1] y para lograr objetivos de predicción se han utilizado técnicas representativas como son: Redes neuronales, Programación no lineal, Agentes predictivos, Sistemas dinámicos, Algoritmos difusos, entre otros [5].

Para el estudio e implementación del sistema, se analizó cada acción desde un enfoque de series de tiempo, con el fin de modelar su comportamiento. Posteriormente se utilizó una sencilla arquitectura multi-agente, la cual consta de un conjunto de agentes que interactúan para llevar a cabo una serie de tareas de forma distribuida [6]. De igual manera se utiliza el modelo

de red neuronal en cada serie de tiempo para el pronóstico de las acciones tomando como referente los movimientos de Ecopetrol, Grupo Sura, Grupo Argos, Grupo Aval y Bancolombia, de las cuales se toma los precios de cierre diarios en los últimos seis meses, determinando el posterior análisis estadístico. Teniendo siempre presente, que la predicción de series de tiempo con redes neuronales ha sido aceptada por su capacidad de generalización y ajuste. Sin embargo, se deben tener en cuenta un gran número de factores importantes para la construcción de un modelo de red neuronal, para no conducir a resultados inconsistentes [7].

Este trabajo está organizado de la siguiente manera. En la sección uno, se modelan los datos de las acciones con el modelo Autorregresivo Integrado de Media Móvil (ARIMA). En la sección dos se organiza y representa la arquitectura del modelo propuesto. Posteriormente en la sección tres, se realizan los ejercicios de predicción y comparación.

Trabajos realizados para predecir índices bursátiles

Existe una amplia gama de sistemas y algoritmos evolutivos, algunos basados en sistemas computacionales que se han dedicado al estudio y aplicación de sistemas de predicción mostrando su interés en el campo de combinar sistemas basados en agentes múltiples para realizar diferentes tareas.

Propuesta de arquitectura BNNMAS de cuatro capas la predicción. Utilizando un enfoque de agentes múltiples y autónomos, con tareas independientes, utilizado métodos de procesos de forma paralela, como normalización datos, selección de retraso de tiempo y selección de características [6].

Estudio de redes neuronales como modelos para el pronóstico de series de tiempo, cuya investigación comparan el método de Box-Jenkins contra el método de red neuronal para memoria a largo y corto plazo, Indicando con determinados experimentos que, para series de tiempo con memoria larga, Ambos métodos produjeron resultados comparables. Sin embargo, para series con memoria corta las redes superaron al modelo de Box-Jenkins. Porque las redes neuronales se pueden construir fácilmente para el pronóstico de pasos múltiples [8].

En este artículo se propone e implementa un modelo de combinación entre el Modelo de Markov Oculto (HMM), Red Neural Artificial. Works (ANN) y Algoritmos Genéticos (GA por sus siglas en inglés) para pronosticar el comportamiento del mercado financiero [9].

Presentación de un enfoque híbrido, donde se combina el uso de las variables de análisis técnico y las variables de análisis fundamental de los indicadores del mercado de valores para la predicción del precio futuro de las acciones con el fin de mejorar los enfoques existentes [4].

Trabajo para evaluar el rendimiento de los modelos autorregresivos como el promedio de redes neuronales recurrentes ARMA NN.

Trabajo para modelar la variación de las series de tiempo y pronosticar tipo de cambio colombiano, a través de la comparación de rendimiento, entre el modelo Autorregresivo Integrado de Media Móvil (ARIMA) y modelos de redes neuronales recurrentes (ARMA-NN) [10].

Trabajo de entorno multi-agente inteligente e innovador, utilizando Java Agent Development Environment (JADE), para proporcionar un servicio integrado y una plataforma inteligente basada en agentes en el entorno de comercio electrónico [11].

En este trabajo se desarrolló un sistema multi-agente, que incorpora diferentes aspectos relacionados con la información, como son: El comportamiento de los comerciantes en el mercado, la confiabilidad de la información, la penetración o accesibilidad de la información entre los diferentes comerciantes, y la percepción o impacto de la información por parte de los comerciantes. Donde realizaron extensas simulaciones basadas en agentes para analizar el efecto de la información relacionada parámetros en los comportamientos de los comerciantes, basados en la estrategia de inteligencia cero [12].

En este documento, se desarrolló un sistema basado en reglas difusas tipo Takagi – Sugeno – Kang (TSK) para la predicción del precio de las acciones. Este modelo aplica el índice técnico como las variables de entrada. El modelo está basado en las Acciones de la Bolsa de Taiwán (TSE). En las pruebas, el modelo ha pronosticado con éxito la variación del precio para las acciones de diferentes sectores con una precisión cercana al 97.6% en el índice TSE [13].

Trabajo que presenta un modelo del índice español Ibx 35 basado en técnicas analíticas y estadísticas, elaborado a partir de los datos de cierre semanales del mercado desde el 1 de enero de 1998 hasta el 31 de diciembre de 2012, donde se aplicaron para la elaboración del modelo las técnicas matemáticas como son: La modelización econométrica clásica, es decir, el ajuste de curvas por regresión y, por otro lado, las técnicas estadísticas de análisis y modelización de series temporales mediante el modelo ARIMA [2].

Análisis técnico

El análisis de los mercados financieros, o análisis bursátil, consiste en el estudio de los activos del mercado financiero. Con el cual se puede obtener información sobre la evolución y las cotizaciones anticipadas de las acciones en estudio, de forma que se puedan realizar operaciones de compra y venta en bolsa que arrojen beneficios [14].

“El análisis técnico es el estudio de los movimientos del mercado, principalmente mediante el uso de gráficos, con el propósito de pronosticar las futuras tendencias de los precios”

[3]. Este permite identificar fenómenos de la serie de tiempo financiera y agrupar el conjunto de observaciones sobre una variable específica, que generalmente es espaciada en el tiempo [15].

Una serie de tiempo es una secuencia de valores de datos ordenados de acuerdo con el tiempo, las cuales son resultado de mediciones de algunos datos físicos [8]. Estas mediciones permiten realizar un estudio sobre las variables en los últimos seis meses de cada una de las acciones nombradas, mediante el modelo ARIMA.

Modelo autorregresivo integrado de medias móviles (arima)

Al igual que existen modelos para procesos estacionarios, también existen modelos para procesos no estacionarios, que mediante diferenciación pueden llegar a serlo. A estos procesos se les denomina Autorregresivos Integrados de Medias Móviles (ARIMA) o modelos de Box-Jenkins por sus precursores. Estos procesos se dividen en regulares y estacionales. Los procesos ARIMA regulares explican aquellas series que tienen tendencia y son de tipo ARMA aplicados a la serie diferenciada para eliminar su tendencia. Su notación es ARIMA (p,d,q), siendo d las diferencias regulares tomadas, p el orden del proceso autorregresivo y q el orden del proceso de media móvil. Por otro lado, los procesos estacionales explican las series que presentan estacionalidad. Se tiene con esto un proceso Autorregresivo Integrado de Media Móvil Estacional (SARIMA). Si el proceso seguido es un ARMA (el caso más general), el modelo se denomina ARIMA (P, D, Q) debido al número de diferencias estacionales tomadas (D), y a las órdenes de la parte autorregresiva (P) y de media móvil (Q) [2].

Funciones de Autocorrelación

Un requisito para el estudio de los modelos ARIMA, es que la serie de observaciones sea una serie estacionaria, lo cual significa que ni la media, ni la varianza, ni la autocorrelación entre las observaciones dependan del tiempo. De esta manera se puede decir que la serie esta “estabilizada”, permitiendo analizar la presencia de comportamientos regulares que permitan proponer un modelo matemático. Las herramientas que se emplean para este fin son la Función de Autocorrelación Parcial (FAP) y la Función de Autocorrelación Simple (FAS), esta última utilizada para el modelo propuesto [2].

“La FAS es la representación gráfica de los coeficientes de autocorrelación simple de un proceso, que miden el grado de relación total existente entre dos variables separadas en el tiempo por cierto retardo k. Si la dependencia (correlación pk) de las observaciones tiende a cero cuando aumenta el retardo, entonces el proceso estacionario recibe el nombre de ergódico.

La ergodicidad es una cualidad necesaria para poder estimar las características del proceso a partir de una única realización, ya que, en caso contrario, al aumentar el tamaño de la muestra no se adquiere información adicional por ser todas las observaciones muy dependientes entre sí” [2].

Autocorrelación de las compañías seleccionadas para el estudio de predicción.

Para graficar la autocorrelación de las empresas en estudio, se eliminó los efectos de tendencia y estacionalidad, con el fin de estabilizar la varianza, con ello transformó los datos en otros procesos que fueran aproximadamente estacionarios. Estas transformaciones son conseguidas a través de la integración, obtenida de la siguiente manera.

$$\omega_t = k_t - k_{t-1}$$

Formula 1:1ra diferencia [2]

Las siguientes imágenes corresponden a los gráficos de autocorrelación realizados a las acciones en estudio (ver Figuras 1 al 5).




Figura 1: Correlograma Acción Ecopetrol

En la anterior grafica de correlación para la serie de Ecopetrol, se identifica que el rezago y_{t-2} es el que más influyen dentro del comportamiento periódico de la serie.

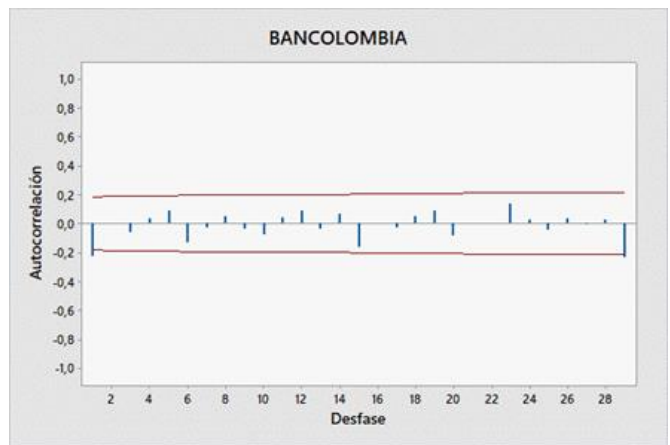


Figura 2: Correlograma Acción Bancolombia

En la anterior grafica de correlación para la serie de Bancolombia, se identifica que los rezagos y_{t-1} y y_{t-29} son los que más influyen dentro del comportamiento periódico de la serie.

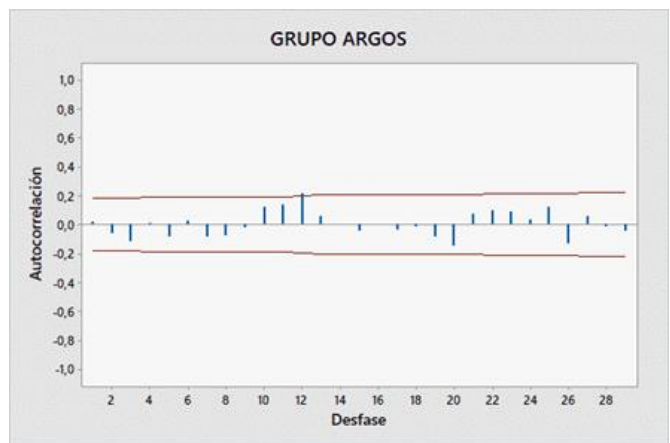


Figura 3: Correlograma Acción Grupo Argos

En la anterior grafica de correlación para la serie de Grupo Argos, se identifica que el rezago y_{t-12} es el que más influye dentro del comportamiento periódico de la serie.

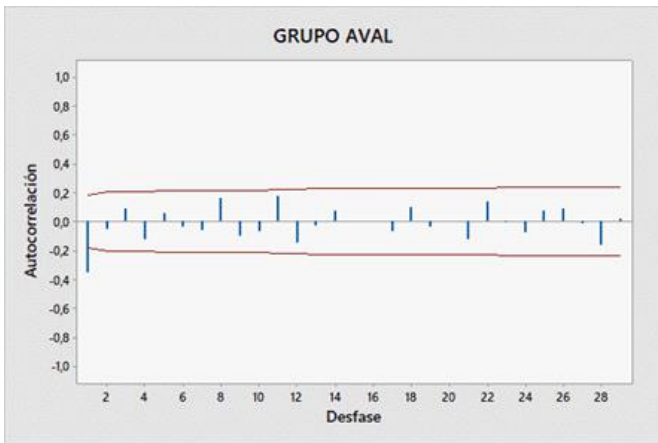


Figura 4: Correlograma Acción Grupo Aval

En la anterior grafica de correlación para la serie de Grupo Aval, se identifica que el rezago y_{t-1} es el que más influye dentro del comportamiento periódico de la serie.




Figura 5: Correlograma Acción Grupo Sura

En la anterior grafica de correlación para la serie de Grupo Sura, se identifica que los rezagos y_{t-5} y y_{t-23} son los que más influye dentro del comportamiento periódico de la serie.

Plataforma de agentes

Un agente es una entidad (física o abstracta), que se caracteriza por ser autónomo en la toma de decisiones y por su conocimiento de sí mismo y de los demás, al igual que su capacidad para actuar. Se clasifican en tres categorías principales de acuerdo la representación de su entorno. Los agentes pueden ser: reactivos, e híbridos [16].

Un sistema de multi-agente (MAS) es un sistema distribuido que consistente en un conjunto de entidades programas, idealmente diseñados para realizar tareas independientes y específicas que interactúan en forma de cooperación,

competencia y convivencia. Los cuales cuentan con diferentes maneras de comunicarse y negociar con otros agentes [17]. Dentro de una plataforma de agentes se ven implementados los servicios de:

- Sistema encargado para el transporte de mensajes (IPMT y APMT):
 - El IPMT (Internal Platform Message Transport), es el componente encargado de garantizar la comunicación entre los agentes de la plataforma.
 - El APMT (Agent Platform Message Transport), es el componente encargado de garantizar la comunicación con plataformas externas (Otros sistemas con los que el MAS necesite interactuar).
- Sistema de gestión de agentes (AMS): Es el componente encargado de conocer y gestionar el estado de los agentes que conforman la plataforma a la cual administra. También provee el denominado servicio de páginas blancas que relaciona los agentes con sus federaciones de agentes.
 - Facilitador de directorio (DF): Este servicio relaciona los agentes con sus funcionalidades o capacidades.
 - Canal de comunicaciones para los agentes (ACC): Agent communication Channel (ACC) Es el servicio o componente que se encarga de gestionar y hacer el enrutamiento de los mensajes que envían los agentes a destinos externos o internos, todos los agentes deben estar relacionados a un ACC que gestione su comunicación con el resto de la plataforma de agentes [18].

Estos componentes se ilustran en la Figura 6.

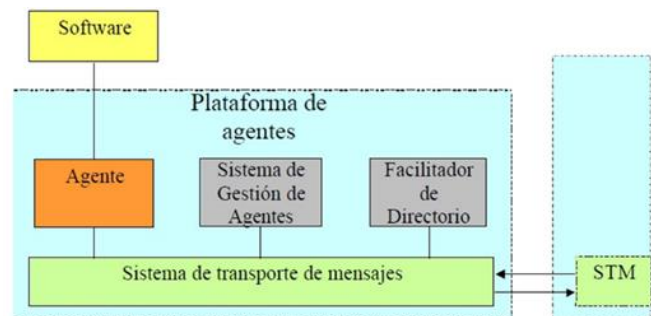


Figura 6: Modelo de referencia FIPA

Arquitectura del modelo propuesto

Para la ejecución de los procesos de predicción en el modelo propuesto, se debe contar con una plataforma de agentes y una plataforma de redes neuronales recurrentes.

Plataforma de Agentes.

La plataforma propuesta, se encuentra conformada por dos agentes que realizan tareas definidas y coordinadas [19].

Agente captador, toma datos cuantitativos de páginas de internet que suministran información de las acciones, tales como el precio de cierre. Los datos obtenidos por este agente son almacenados en la base de datos Datafic, junto a la fecha y hora en que fueron captados, de acuerdo con su caracterización de dato. Luego de esto envía un mensaje al agente RNA para que este se encargue de coordinar el proceso de pronóstico en base a los nuevos datos almacenados.

Agente RNA, es quien toma los datos que se encuentran en la base de datos Datafic, los envía a la interfaz despachadora y entrega los datos a la correspondiente red neuronal para que esta realice el cálculo correspondiente al pronóstico, dicho resultado es devuelto a la interfaz despachadora que se comunica con la plataforma de agentes por medio del Agente RNA.

En la plataforma de red neuronal, se realiza un proceso de inteligencia artificial para predecir el precio de las acciones, con neuronas interconectadas por cada acción, donde se elige el mejor desfase. En cada una de las etapas de entrenamiento de la red neuronal, se utiliza una función de error, al igual que un algoritmo para minimizar el error calculado, conocido como optimizador, con el cual se busca mejorar la precisión. El agente RNA, activa nuevamente otra de sus tareas, para almacenar en la base de datos, los resultados obtenidos en el proceso de predicción que realizan las redes neuronales.

La arquitectura propuesta es representada en la Figura 7.

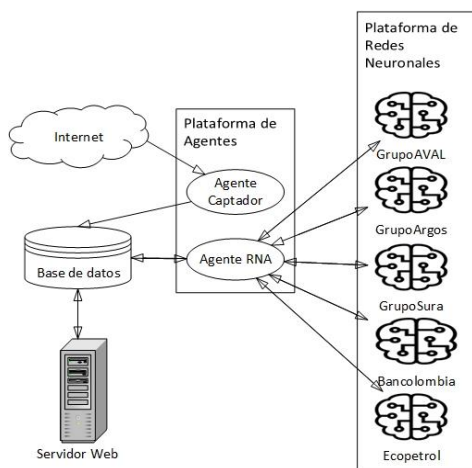


Figura 7: Arquitectura Propuesta

El repositorio o base de datos utilizado para el presente artículo se especifica con el siguiente modelo relacional elaborado en la Figura 8.

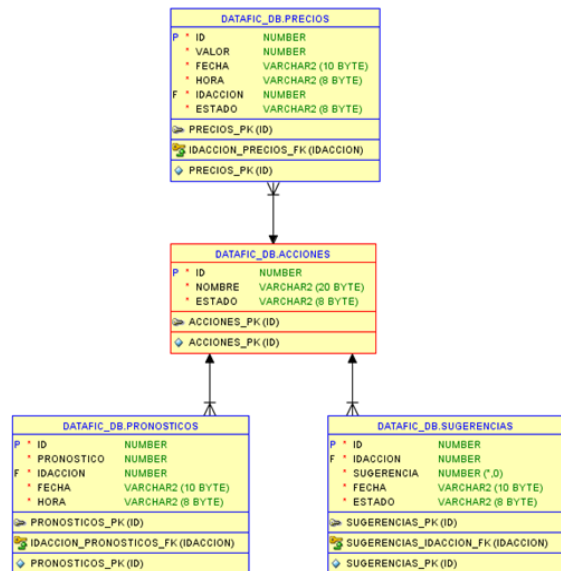


Figura 8: Modelo relacional

Caracterización de los procesos en la plataforma de red neuronal.

Las redes neuronales son un marco computacional que consiste en un procesamiento simple de conexión masiva entre unidades. Estas unidades son un análogo a las neuronas en el cerebro humano, debido a la estructura altamente conectada [8], donde se desarrolla el análisis y la transformación de los datos de entrada, para producir una solución.

La arquitectura de una red neuronal artificial cuenta con los siguientes parámetros (Véase Figura 9):

- La capa de entrada, cuyo número de neuronas depende de la cantidad de rezagos importantes para la serie de tiempo.
- La(s) capas ocultas.
- El patrón de interconexión entre las diferentes capas.
- El proceso de aprendizaje que es ejecutado por el algoritmo optimizador para actualizar los pesos de las conexiones neuronales, para el caso de estudio presentado se utilizó el algoritmo R-Prop.
- La función de transformación que convierte una entrada ponderada en salida, para el presente trabajo se utilizó la función lineal ya que genera valores de salida positivos como negativos y de cualquier cantidad de dígitos. Otras funciones son muy utilizadas como tangente, sigmoid, relu y demás, pero sus salidas son valores sujetos a rangos entre -1 y 1.
- El número de neuronas en cada capa oculta, al igual que el número de capas ocultas es un valor que resulta luego realizar pruebas con distintas cantidades de capas y neuronas ocultas, eligiéndose las cantidades con las cuales se hallan obtenido mejores resultados.
- La capa de salida [20]




Figura 9: Esquema de Red neuronal usado

Para el objetivo de la arquitectura, es aplicado el modelo de red neuronal (ARMA-NN), el cual implica las neuronas suelen estar dispuestas en capas (unidades de procesamiento), cada unidad de procesamiento tiene una función de activación. En presente artículo la función utilizada es la función lineal [8] y funciona entrenando la red con resultados obtenidos y conocidos a través de comparación entre el objeto de entrenamiento y el vector de salida.

Para determinar la medida del error y permitir el ajuste del modelo se utilizó el Porcentaje del Error Medio Absoluto (MAPE: Mean Absolute Porcentaje Error) determinado de la siguiente manera.

$$MAPE = 100 \times \frac{1}{n} \sum_{i=1}^n \frac{|Y_i P_i|}{Y_i}$$

Donde:

p_i Representa el valor predicho

y_i El valor real

n numero de observaciones [6].

Pruebas y resultados obtenidos

Se hicieron seis pruebas de entrenamiento y evaluación a las redes neuronales (procesos que son ejecutados automáticamente por el framework utilizado) para determinar la arquitectura más adecuada de cada red neuronal, basándose en la medida del porcentaje de error medio absoluto (MAPE) arrojado por el optimizador, aplicado a entrenamientos que constan de mil iteraciones o épocas (epochs). Adicional a ello se llevó a cabo otro procedimiento que consta de comparar gráficamente la serie de tiempo real y la serie de tiempo pronosticada en un mismo periodo.

Dentro de todo el proceso de entrenamiento y evaluación de las redes neurales se destinó el 70% de los datos a entrenamiento y el 30% restante a validación. Obteniéndose los siguientes resultados (véase Tabla 1 al 5).

Tabla 1: Evaluación Acción Ecopetrol

N° Capas Ocultas	1			2			
N° Neuronas	3	4	5	3, 1	4, 2	4, 3	5, 3
MAPE	2,43%	2,46%	2,65%	2,56%	2,46%	2,43%	2,66%

La tabla 1 muestra que, de acuerdo con los resultados arrojados por el proceso de evaluación, la arquitectura que mejor se ajusta al comportamiento de la serie Ecopetrol es con una capa oculta compuesta por tres neuronas, la cual se presenta en la Figura 10.




Figura 10: Pronóstico serie de Acciones Ecopetrol

Tabla 2: Evaluación Acción Bancolombia

N° Capas Ocultas	1			2		
N° Neuronas	3	4	5	3, 1	4, 2	5, 3
MAPE	1,34%	1,39%	1,64%	3,89%	1,39%	1,40%

La tabla 2 muestra que, de acuerdo con los resultados arrojados por el proceso de evaluación, se determina que la arquitectura que mejor se ajusta al comportamiento de la serie Bancolombia es con una capa oculta compuesta por tres neuronas, la cual se muestra en la Figura 11.




Figura 11: Pronóstico serie de Acciones Bancolombia

Tabla 3: Evaluación Acción Grupo Argos

N° Capas Ocultas	1			2		
N° Neuronas	3	4	5	3, 1	4, 2	5, 3
MAPE	7,03%	6,85%	7,57%	7,71%	7,26%	8,75%

La tabla 3 muestra que, de acuerdo con los resultados arrojados por el proceso de evaluación, se determina que la arquitectura que mejor se ajusta al comportamiento de la serie Grupo Argos es con una capa oculta compuesta por cuatro neuronas, la cual se muestra en la Figura 12.

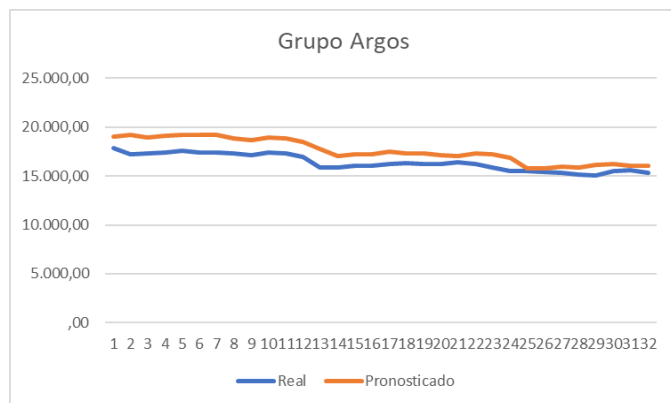


Figura 12: Pronóstico serie de Acciones Grupo Argos

La tabla 5 muestra que, de acuerdo con los resultados arrojados por el proceso de evaluación, se determina que la arquitectura que mejor se ajusta al comportamiento de la serie Grupo Sura es con una capa oculta compuesta por cinco neuronas, la cual se muestra en la Figura 14.




Figura 14: Pronóstico serie de Acciones Grupo Sura

Tabla 4: Evaluación Acción Grupo Aval

N° Capas Ocultas	1			2		
	3	4	5	3, 1	4, 2	5, 3
N° Neuronas						
MAPE	0,97%	0,89%	0,91%	0,90%	0,89%	8,75%

La tabla 4 muestra que, de acuerdo con los resultados arrojados por el proceso de evaluación, se determina que la arquitectura que mejor se ajusta al comportamiento de la serie Grupo Aval es con una capa oculta compuesta por cuatro neuronas, la cual se muestra en la Figura 13.

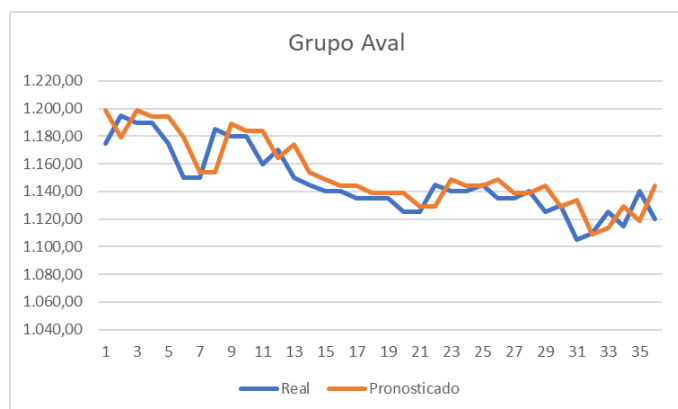


Figura 13: Pronóstico serie de Acciones Grupo Aval

Tabla 5: Evaluación Acción Grupo Sura

N° Capas Ocultas	1			2		
	3	4	5	3, 1	4, 2	5, 3
N° Neuronas						
MAPE	3,07%	2,64%	1,75%	1,76%	3,49%	2,87%

Gráficamente se puede concluir que las acciones cuyo pronóstico se basa con solo un rezago como es el caso de Ecopetrol, Grupo Argos y Grupo Aval, las redes neuronales las modelaron de mejor manera con un alto grado de ajuste al comportamiento real, en comparación con las acciones de Bancolombia y Grupo Sura que debido a que manejan dos rezagos para calcular su pronóstico las redes neuronales no modelaron con la misma eficacia sus respectivos comportamientos

Límites del sistema

El sistema analiza el movimiento únicamente de las acciones de Ecopetrol, Grupo Sura, Grupo Argos, Grupo Aval y Bancolombia, las cuales se considera son las más importantes y las que más dinámica han presentado en el último año.

El sistema está diseñado para recomendar a los inversores a la hora de tomar una decisión de compra, lo cual significa que el modelo está diseñado para predecir un comportamiento con un determinado grado de error.

En el modelo propuesto únicamente se toma variables cuantitativas, lo que genera un aumento del grado de error, si existe una variación significativa en el comportamiento de las acciones desde un enfoque fundamental.

Conclusiones

En este artículo se ha propuesto una nueva arquitectura, para afrontar la tarea de construir modelos de predicción para el mercado bursátil, considerando aspectos prácticos.

La interacción entre un sistema multi-agente y la red neuronal con los demás componentes de la arquitectura, han establecido una buena comunicación permitiendo la integración lograr los resultados propuestos.

Al utilizar diferentes tecnologías y lenguajes de programación en cada componente de la arquitectura, ha mejorado la capacidad de cálculo y lógica entre los componentes.

Referencias

[1] M. Fallah and S. Mod, “Modélisation de l’impact du trafic routier sur la pollution de l’air et des eaux de ruissellement Masoud Fallah Shorshani Thèse de doctorat de l’Université Paris-Est Masoud Fallah Shorshani Modélisation de l’impact du trafic routier sur la pollution,” no. 37, pp. 51–82, 2015.

[2] O. Monzó, “Predicción del Ibx 35 con un modelo estocástico de salto de Poisson compuesto,” Universitat Politècnica De València, 2014.

[3] J. J. Murphy, ANÁLISIS TÉCNICO DE LOS MERCADOS FINANCIEROS, vol. 39, no. 5. 1999.

[4] S. O. Adebisi, A. A., Ayo, C. K., Adebisi, M. O., & Otokiti, “Stock Price Prediction using Neural Network with Hybridized Market Indicators,” J. Emerg. Trends Comput. Inf. Sci., vol. 3, no. 1, pp. 1–9, 2012.

[5] B. Londoño and P. Sánchez, “NOVEL ALGORITHM FOR DETECTION OF REPETITIVE TASKS IN THE KEYBOARD,” vol. 2, no. 3, pp. 55–69, 2015.

[6] R. Hafezi, J. Shahrabi, and E. Hadavandi, “A bat-neural network multi-agent system (BNNMAS) for stock price prediction: Case study of DAX stock price,” Appl. Soft Comput. J., vol. 29, pp. 196–210, 2015.

[7] P. A. Sánchez-Sánchez and J. R. García-González, “A new methodology for neural network training ensures error reduction in time series forecasting,” J. Comput. Sci., vol. 13, no. 7, p. 211.217, 2017.

[8] Z. Tang and P. A. Fishwick, “Feedforward Neural Nets as Models for Time Series Forecasting,” ORSA J. Comput., vol. 5, no. 4, pp. 374–385, 1993.

[9] M. R. Hassan, B. Nath, and M. Kirley, “A fusion model of HMM, ANN and GA for stock market forecasting,” Expert Syst. Appl., vol. 33, no. 1, pp. 171–180, 2007.

[10] P. Sánchez-Sánchez and J. García-González, “Autoregressive Moving Average Recurrent Neural Networks Applied to the Modelling of Colombian Exchange Rate,” Int. J. Artif. Intell., vol. 16, no. 2, 2018.

[11] R. Lee and J. Liu, “iJADE WeatherMAN: A weather forecasting system using intelligent multiagent-based fuzzy neuro network,” IEEE Trans. Syst. Man Cybern. Part C Appl. Rev., vol. 34, no. 3, pp. 369–377, 2004.

[12] E. Kustermann et al., “In Vivo Observation of Stem Cell Migration: A High-Resolution Magnetic Resonance Investigation,” Stroke, vol. 10, pp. 2002–2002, 2002.

[13] P. C. Chang and C. H. Liu, “A TSK type fuzzy rule based system for stock price prediction,” Expert Syst. Appl., vol. 34, no. 1, pp. 135–144, 2008.

[14] A. P. Canelles, “Análisis Técnico de Los Mercados Financieros Basado en Técnicas de Integigencia Artificial,” 2014.

[15] R. De Arce and R. Mahía, “MODELOS ARIMA,” U.D.I Econ. e Informática, pp. 1–31.