

# RELIGACIÓN

R E V I S T A

## Aplicación de series de tiempo en valores de activos financieros

*Application of time series to financial asset values*

Luz María Quinde Arreaga, Jimmy Rafael Landaburu Mendoza, Nuvia Aurora Zambrano Barros, Adolfo Hernán Elizondo Saltos

### RESUMEN

Las redes neuronales realizan un proceso de aprendizaje sobre un conjunto de datos conocidos, desarrollan algoritmos que solo afectan a características conocidas y pueden predecir el comportamiento probable del mismo tipo de conjunto de datos en un área determinada. En este trabajo se presenta el contenido teórico y los métodos de aprendizaje supervisado con una arquitectura de aprendizaje profundo, con el objetivo de obtener predicciones del precio de las acciones considerando diferentes tipos de modelos, utilizando herramientas computacionales especiales y comparándolos posteriormente. Entre los principales resultados y conclusiones se muestra que, entre los modelos de redes neuronales analizados, el mejor modelo es el modelo forward debido a que se utilizan como variables predictoras el precio de apertura, precio de cierre, precio alto y precio bajo, lo que en cierto sentido lo hace. Las arquitecturas más robustas proporcionan mejores resultados. Dado que los resultados dinámicos materiales no son óptimos, se recomienda incluirlos en el análisis posterior del mismo tema.

**Palabras Clave:** Inteligencia artificial; redes neuronales; LSTM; acciones de empresa.

---

#### Luz María Quinde Arreaga

Universidad Técnica Estatal de Quevedo | Quevedo | Ecuador. lquindea@uteq.edu.ec  
<http://orcid.org/0009-0009-2306-4561>

#### Jimmy Rafael Landaburu Mendoza

Universidad Técnica Estatal de Quevedo | Quevedo | Ecuador. jlandaburu@uteq.edu.ec  
<https://orcid.org/0000-0002-0327-343X>

#### Nuvia Aurora Zambrano Barros

Universidad Técnica Estatal de Quevedo | Quevedo | Ecuador. nzambrano@uteq.edu.ec  
<https://orcid.org/0000-0003-1204-154X>

#### Adolfo Hernan Elizondo Saltos

Universidad Técnica Estatal de Quevedo | Quevedo | Ecuador. aelizondos@uteq.edu.ec  
<http://orcid.org/0000-0001-7949-8697>

<http://doi.org/10.46652/rgn.v8i38.1117>

ISSN 2477-9083

Vol. 8 No. 38 octubre - diciembre, 2023, e2301117

Quito, Ecuador

Enviado: septiembre 02, 2023

Aceptado: noviembre 07, 2023

Publicado: noviembre 21, 2023

Publicación Continua



## ABSTRACT

Neural networks perform a learning process on a known data set, develop algorithms that only affect known characteristics and can predict the likely behavior of the same type of data set in a given area. This paper presents the theoretical content and methods of supervised learning with a deep learning architecture, aiming to obtain stock price predictions by considering different types of models, using special computational tools and then comparing them. Among the main results and conclusions are shown that among the analyzed neural network models, the best model is the forward model because the opening price, closing price, high price and low price are used as predictor variables, which in a sense makes it. More robust architectures provide better results. Since the material dynamic results are not optimal, it is recommended to include them in the further analysis of the same subject.

**Keywords:** Artificial intelligence; neural networks; LSTM; corporate actions.

## Introducción

A mediados del siglo XX, la llegada de las primeras máquinas electromecánicas para resolver problemas provocó un auge en el desarrollo de computadoras. Las diversas contribuciones de estos artefactos han permitido a grupos de personas acceder a tecnologías que son cada vez más útiles en la vida diaria de todas las personas (Arango & Llanos, 2012; Martin & Gutiérrez, 2003; Mercado Polo, et al., 2015).

Durante el siglo pasado, muchas industrias han dependido en gran medida del desarrollo y avance de las computadoras y sus diversas tecnologías y aplicaciones. Por otro lado, cada vez son más las empresas que consideran el desarrollo de la tecnología como un punto clave en la prestación de servicios (Arrieta, et al., 2009; Ortiz Arango, et al., 2013; Rego, et al., 2020; Rosales, et al., 2003). La realidad es que hoy es imposible imaginar un modelo de negocio que no considere a las computadoras y sus herramientas como un elemento fundamental en el desarrollo de productos y servicios, resultando en un aumento significativo en el intercambio de bienes y servicios. Esto sucede todos los días en todas las economías del mundo (Asanza & Olivo, 2018; Pérez Ramírez & Fernández Castaño, 2007; Ruiz & Gavino, 2011).

Durante las últimas tres décadas, la inteligencia artificial y sus diversos campos se han convertido en una de las herramientas informáticas más utilizadas desde una perspectiva académica y empresarial debido a sus numerosas aplicaciones potenciales, desde el reconocimiento de voz hasta la predicción de fenómenos naturales. En particular, el uso de herramientas de inteligencia artificial en el estudio de los movimientos de los mercados financieros es una de las áreas más populares, lo que permite a muchos académicos y empresarios prepararse para estudios cada vez más complejos, lo que abre oportunidades para invertir tiempo y recursos. Los modelos que ofrecen resultados a nivel comunitario mejoran y mejoran la calidad de vida de las personas.

El uso de herramientas de inteligencia artificial para profesionales de negocios y gestión es fundamental para los países en desarrollo que no han podido automatizar la mayoría de las operaciones financieras, ya que será difícil para las generaciones futuras desarrollar y proporcionar estas herramientas. Contribuyendo al sistema financiero para mejorar la vida de las personas (Davila & Ordoñez, 2021; Villada, et al., 2012; Weber, 2000).

En este trabajo se estudian, analizan y resumen paso a paso los contenidos teóricos y algunas técnicas relacionadas con el aprendizaje automático y el aprendizaje profundo, con el objetivo final de resumir y explicar los conceptos básicos dentro del tema y hacerlo de fácil acceso ser capaz de explicar y desarrollar de una manera. Un conjunto de herramientas de redes neuronales utilizadas para hacer predicciones sobre conjuntos de datos recopilados como series de tiempo en el capítulo final.

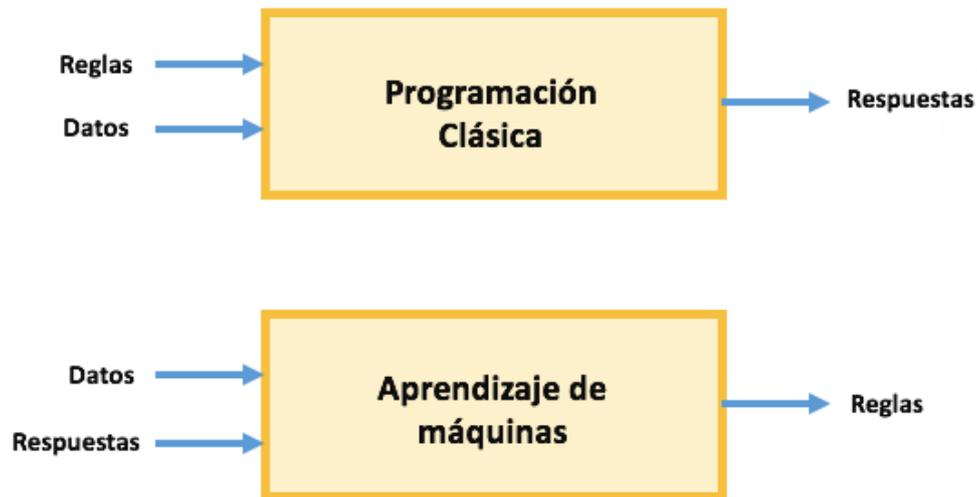
Basado en las técnicas y métodos estudiados, mediante el uso de herramientas computacionales en el campo del aprendizaje profundo, que permite la comparación de diferentes métodos desarrollados en el campo teórico del aprendizaje profundo, con la predicción de los precios de las acciones en conjuntos de datos de libre acceso.

## **Marco contextual**

### **Inteligencia Artificial**

Sus verdaderos orígenes se encuentran en las obras publicadas por Alan Turing en los años cincuenta. Al hacerlo, quería saber cómo las computadoras podrían proporcionar la capacidad de pensar, o al menos proporcionar nuevos conocimientos. Todo esto se basa en el trabajo propuesto por Ada Lovelace en los albores de la informática a mediados del siglo XIX. Aunque no existe una definición universal, la inteligencia artificial puede entenderse como un intento de automatizar tareas intelectuales que normalmente realizan los humanos (Díaz & Sosa, 2018). Desde este punto de vista, los primitivos programas informáticos conocidos como inteligencia artificial simbólica, diseñados para resolver partidas de ajedrez y cartas, pueden entenderse como inteligencia artificial, pero esta programación se basa en un conjunto de reglas establecidas de la siguiente manera: Esto plantea la posibilidad de que depende directamente de ejecuta el resultado de la entrada recibida (Díaz Rodríguez et al., 2019). El problema al que se enfrenta este tipo de programas es que llega a sus límites a la hora de resolver tareas más complejas como el reconocimiento facial o el reconocimiento de voz. Por esta razón, tiene sentido cambiar el paradigma en el que opera el programa (ver Figura 1) y asegurar que el paradigma que define las “reglas” para obtener resultados a partir de los datos de entrada sea el mismo. Este paradigma se conoce como aprendizaje automático y es la principal motivación para la clasificación de la inteligencia artificial.

Figura 1: Comparación: Paradigma de programación para Deep-learning y Paradigma programación simbólica.



Fuente: Elaborado por los autores.

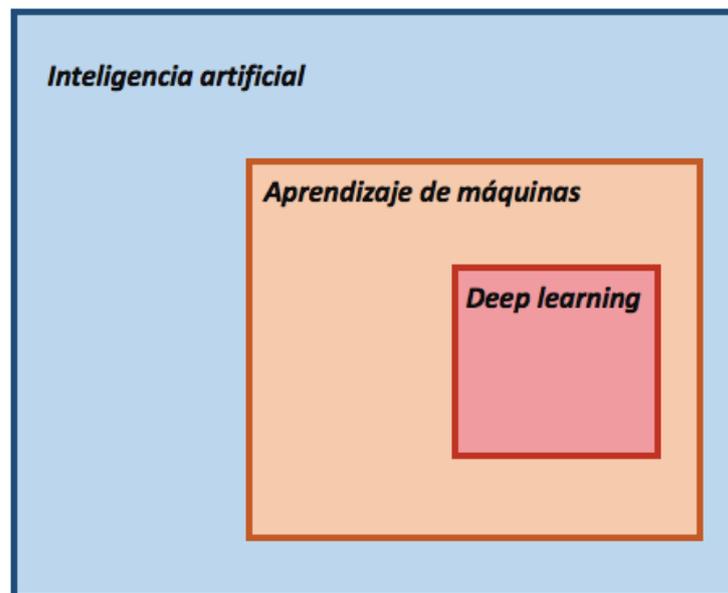
### Clasificación de la inteligencia Artificial

El problema de la inteligencia artificial actualmente está siendo considerado desde diversos ángulos, y su clasificación surge de la necesidad de identificar los diferentes enfoques que tiene la inteligencia artificial. El aprendizaje automático es un subcampo de la inteligencia artificial y la informática que se encarga del estudio de los mecanismos y modelos que permiten a las computadoras aprender. Este se encarga de generar en la computadora el proceso de aprendizaje que mejor se aproxima al comportamiento esperado utilizando el conjunto de datos de entrada proporcionados para cada análisis (Duque et al., 2006).

### Panorama de la inteligencia artificial y aplicación en finanzas

Este esquema de clasificación de la inteligencia artificial puede entenderse como una jerarquía que conduce al aprendizaje profundo. Este es el contexto específico del siguiente documento: Esta jerarquía se puede entender utilizando el diagrama que se muestra en la Figura 2.

Figura 2: Jerarquía del Aprendizaje profundo en IA.



Fuente: Elaborado por los autores.

### Aprendizaje profundo

Profundizando en la investigación de la inteligencia artificial a través del aprendizaje automático y considerando los objetivos de esta investigación, se procede a explicar el aprendizaje profundo. En comparación con otros elementos del aprendizaje automático, el aprendizaje profundo tiene las siguientes características: Uso de capas interconectadas. Aunque sus conexiones suelen estar ocultas a la vista del usuario, su objetivo principal es ejecutar diferentes grupos de cálculos de forma independiente, con el objetivo de integrar resultados que expliquen mejor el fenómeno en cuestión (Gallegos, 2005).

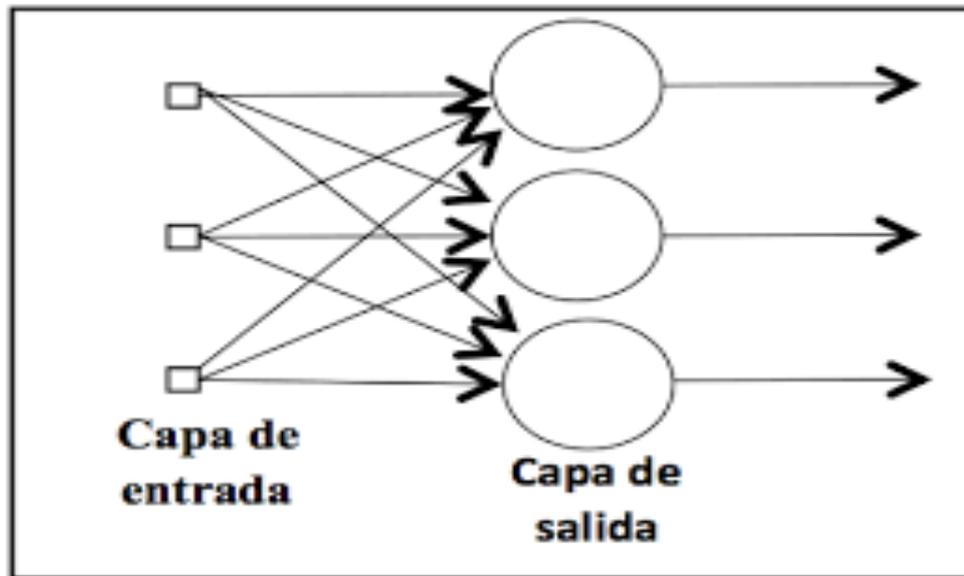
Este modelo de representación en capas se define en los lenguajes actuales como una red neuronal, que consiste en una compilación de varias capas apiladas unas sobre otras.

### Redes Neuronales

Una red neuronal es un modelo computacional que utiliza un sistema de capas internas y externas conectadas por estructuras llamadas unidades que en conjunto simulan la arquitectura de conectividad entre neuronas en el cerebro humano. Después de pasar por un proceso de aprendizaje sobre un conjunto de datos conocidos, estas redes neuronales pueden predecir, dentro de un rango determinado, el comportamiento probable de un conjunto del mismo tipo de datos, y afectar sólo a características conocidas. Este es un algoritmo que puede hacer esto. Etapa preparatoria, sin consecuencias por las acciones (García Salgado & Morales Castro, 2016).

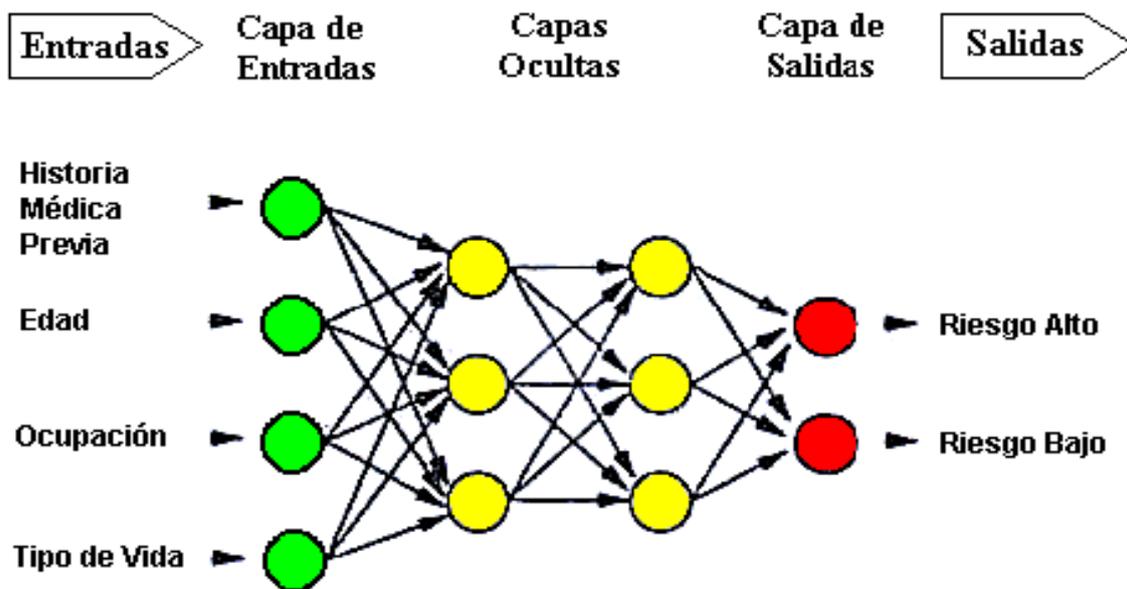
Un ejemplo de esta capa de investigación ocurre en el procesamiento y reconocimiento de imágenes, como se muestra en las Figuras 3 y 4.

Figura 3: Estructura para procesamiento de imágenes.



Fuente: Extraído de <http://grupo.us.es/gtocom/pid/pid10/RedesNeuronales.htm>

Figura 4: Estructura para procesamiento de imágenes.



Fuente: Extraído de <https://nabucco.es/redes-neuronales/>

## Contexto Económico

Las bolsas de valores son organizaciones privadas que operan mercados primarios y secundarios, donde diariamente se compran y venden varios tipos de valores corporativos. Este mercado está dirigido a inversores individuales o institucionales que pueden invertir sus ahorros en el mercado de valores contactando primero con un corredor de bolsa (bolsa de valores) que actúa como intermediario. Las acciones son valores de capital social emitidos por una empresa. Estos otorgan a los accionistas plenos derechos para participar en la empresa en relación con su desarrollo y los beneficios económicos asociados (Herrera, 2008).

Las bolsas de valores funcionan a través de una rueda electrónica basada en un sistema operativo donde se vinculan ofertas y demandas y se coordinan y completan las transacciones. A través de este software, las casas de bolsa acceden y pueden comprar y vender valores en línea con la búsqueda de rentabilidad de las inversiones realizadas por sus clientes.

## Metodología

Para lograr la realización de esta investigación se plantea una metodología basada en una serie de etapas:

Fase 1. Investigación y selección de diferentes redes neuronales artificiales factibles.

En esta etapa se realiza un estudio bibliográfico de diversos tipos de redes neuronales artificiales aplicadas al procesamiento de series de tiempo, en el que se consulta a expertos, revistas científicas, artículos online, entre otros. Esto permitió la selección de tipos de redes neuronales.

Fase 2. Diseño de la plataforma

En este paso, el diseño del software se utiliza como referencia para crear planos y diagramas que representan y abstraen las características más importantes de los tipos de redes neuronales seleccionados en el paso anterior.

Fase 3. Desarrollo e implementación de la plataforma.

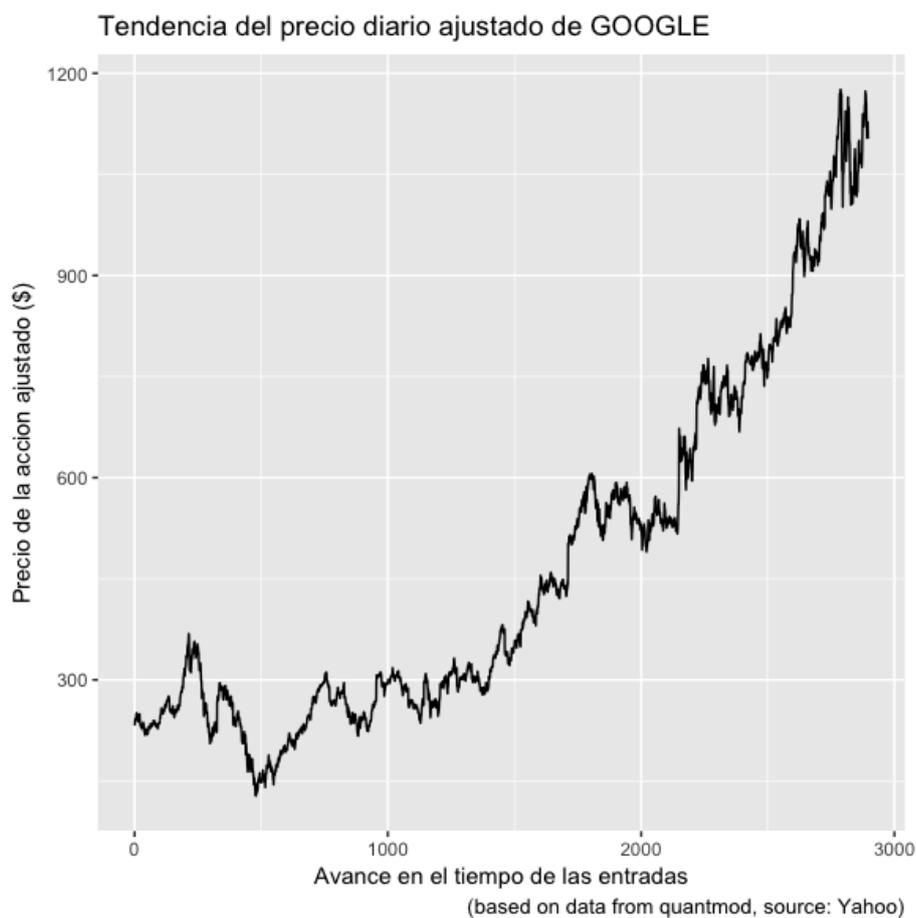
En esta fase, se implementan algoritmos de aprendizaje neuronal seleccionados en R y se construyen interfaces gráficas de usuario.

Fase 4. Test y comparación de resultados

Este paso se basa en comparar los resultados de los tipos de redes neuronales aplicadas al dominio financiero utilizando series temporales clasificadas. Se toman un conjunto de pruebas y un conjunto de entrenamiento para determinar el rendimiento y el tiempo de respuesta de las RNA. La simulación se ejecuta varias veces y se obtienen los mejores resultados.

Los datos utilizados en el experimento son valores históricos del mercado de valores de Google, incluido el precio de apertura, el precio de cierre, el valor ajustado y el volumen de negociación diario de las acciones desde el 3 de enero de 2007 hasta el 29 de junio de 2018. Esta base de datos fue tomada de la biblioteca “quantmod”, que está disponible directamente en R. La variable de interés más importante en la base de datos obtenida es el precio ajustado de la acción. Se trata de evaluar adecuadamente los movimientos de precios intradía a través de un proceso directo. El mercado de valores interviene más precisamente en la gestión de las empresas. El comportamiento de estas variables de inferencia se muestra en la Figura 5.

Figura 5: Precio diario ajustado de acciones de Google.



Fuente: Elaborado por los autores.

Las variables restantes se incluyen en el modelo como parte de los datos de entrada:

Precio de Apertura Precio más alto

Precio más bajo Precio de cierre

Volumen de acciones en el mercado

## Rezago de un período del precio ajustado

### Variable binaria de tendencia

Dado que es una empresa con un precio de acciones alto, esperamos que las tendencias en los datos de Google sean más volátiles y el precio sea más volátil (Jiménez Caballero, 2000). Por esta razón, el análisis de la funcionalidad de las arquitecturas de redes neuronales como modelos de optimización toma en cuenta bases de datos segmentadas para poder comprender las regiones óptimas para la funcionalidad de la arquitectura propuesta.

## Resultados

Como se ha mencionado, lo que se busca es predecir el precio ajustado de una acción, sin embargo, dado que variable como el volumen, tendencia y precios tienen unidades completamente diferentes se requiere hacer una normalización de la base de datos antes de proceder con los cálculos. Esta normalización se hace para cada una de las variables, incluyendo la del precio ajustado de la acción, lo que provoca que el resultado en términos de loss function no pueda traducirse de forma exacta a lenguaje convencional por lo que sería necesaria una conversión sobre los resultados obtenidos.

Esta conversión consiste en multiplicar el valor obtenido como promedio en la loss function por la desviación estándar del conjunto de datos, a partir de lo cual los resultados pueden entenderse en el lenguaje convencional como la cantidad de dólares con la cual estamos fallando en nuestras predicciones:

$$\text{Dólares de falla} = \text{Loss std} (\text{P. Ajustado})$$

### Regiones de similar crecimiento

Una primera estrategia de optimización consiste en tomar las regiones de la base de datos cuyos comportamientos sean similares y separar estos datos como los conjuntos de entrenamiento, validación y prueba respectivamente. Por la tendencia creciente que tiene la base de datos, se disponen de los siguientes períodos con las especificaciones del conjunto de datos seleccionados respectivamente:

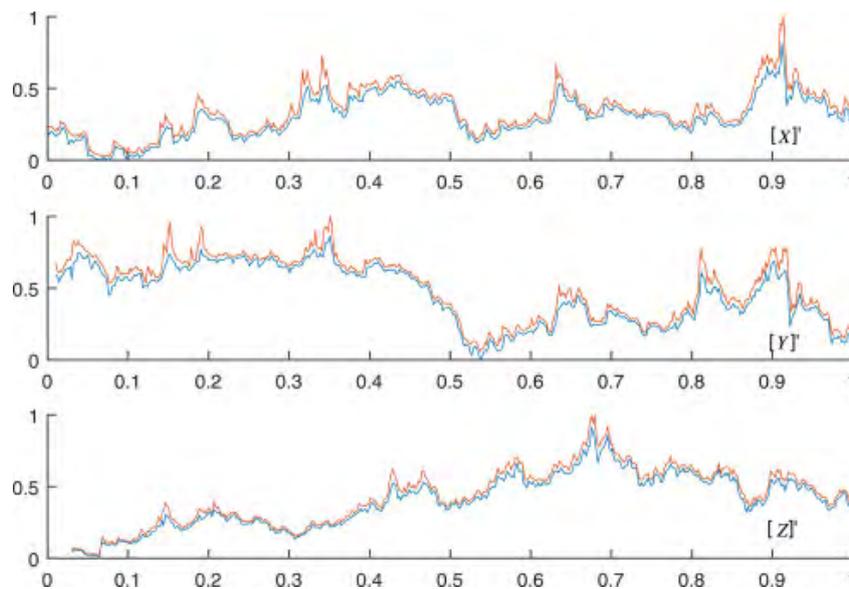
1. Conjunto de Entrenamiento.–Los datos comprendidos entre el 6 de noviembre de 2015 y el 1 de mayo de 2017.
2. Conjunto de Validación.–Los datos comprendidos entre el 11 de mayo de 2012 y el 12 de diciembre de 2013.
3. Conjunto de Prueba.–Los datos comprendidos entre el 25 de noviembre de 2008 y el 22 de diciembre del 2009.

Cuyo comportamiento se puede visualizar en la gráfica 6

### Región Estable

Por la complejidad de la predicción del modelo, una selección más adecuada del conjunto de datos necesarios para el entrenamiento y validación resulta de tomar la región más estable dentro del total de la base de datos. Por esta razón se toman los conjuntos de datos a partir de un subconjunto de la base original, considerando la región más estable, comprendida entre el 22 de diciembre del año 2009 y el 15 de diciembre del año 2012. Este subconjunto de datos puede visualizarse en la figura 7.

Figura 6: Donde el primer grupo de datos (I) representa el conjunto de prueba; el segundo grupo de datos (II) representa el conjunto de validación y finalmente el tercer grupo de datos (III) representa el conjunto de entrenamiento.



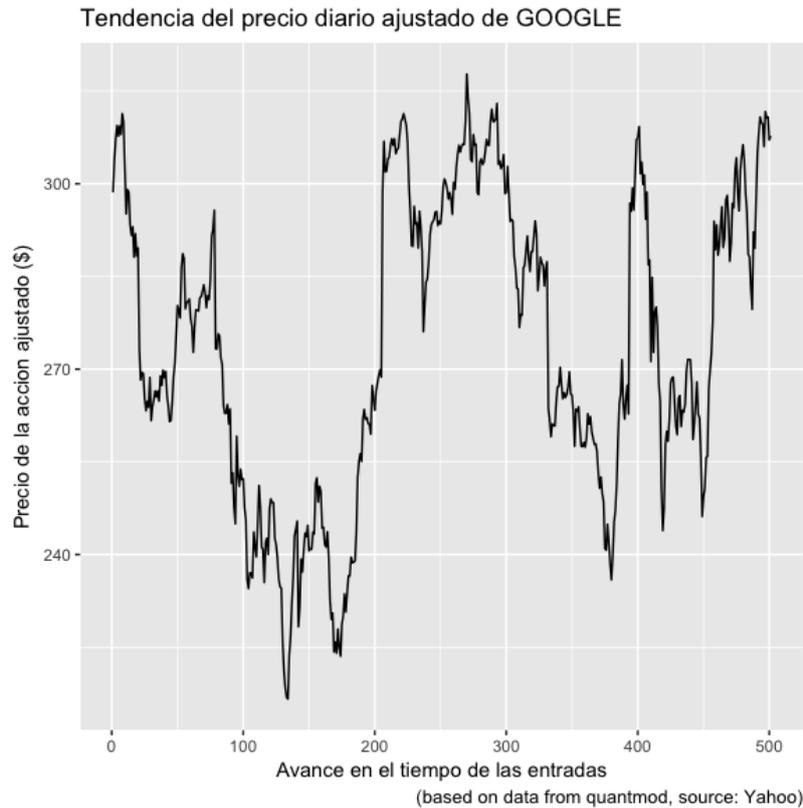
Fuente: Elaborado por los autores.

Tomando una línea base: Método Naive.

Previo al análisis de los resultados con las arquitecturas de redes neuronales, debe pensarse que un modelo tiene que resultar con mejores características de predicción que aquello que consideremos trivial; es por ello que incorporar un método de predicción trivial como aquel que vaticina al día siguiente el mismo resultado del valor ajustado de la acción para el día anterior puede ser un buen inicio al momento de medir y comparar el modelo.

Es por ello que considerando el conjunto de datos de la región estable, se genera una función ca-paz de medir el error de un método de predicción cuya salida sea exactamente igual al valor obtenido el día anterior; este método será incorporado como Naive en la tabla de resultados y permitirá tener una idea más clara de lo que está ocurriendo.

Figura 7: Precio diario ajustado de acciones de Google en la región estable.



Fuente: Elaborado por los autores.

Es menester señalar que los precios de las acciones no fluctúan tanto entre un día y otro, sino que sus cambios se evidencian con el paso del tiempo (que es lo que se considera para el entrenamiento) por lo que un modelo que solo repite la predicción del día anterior puede ser mejor en términos de loss function puede ser mejor, pero no resulta práctico para una aplicación en la práctica.

## Red de alimentación

Considerando la primera arquitectura descrita en el presente documento, el primer modelo de predicción es una red completamente conectada (FeedForwardNetwork). En este caso se escoge una capa, con un total de 28 neuronas además de la capa de salida con una sola neurona. Esta arquitectura se escoge considerando otros modelos de algunas áreas en predicción de tiempo y a su vez optimizando la cantidad de neuronas en la capa. Por su naturaleza, en esta arquitectura todos los datos de entrada resultarán como insumos para la arquitectura, es por ello que la dimensión de entrada depende directamente de la cantidad de variables y el rezago en el tiempo.

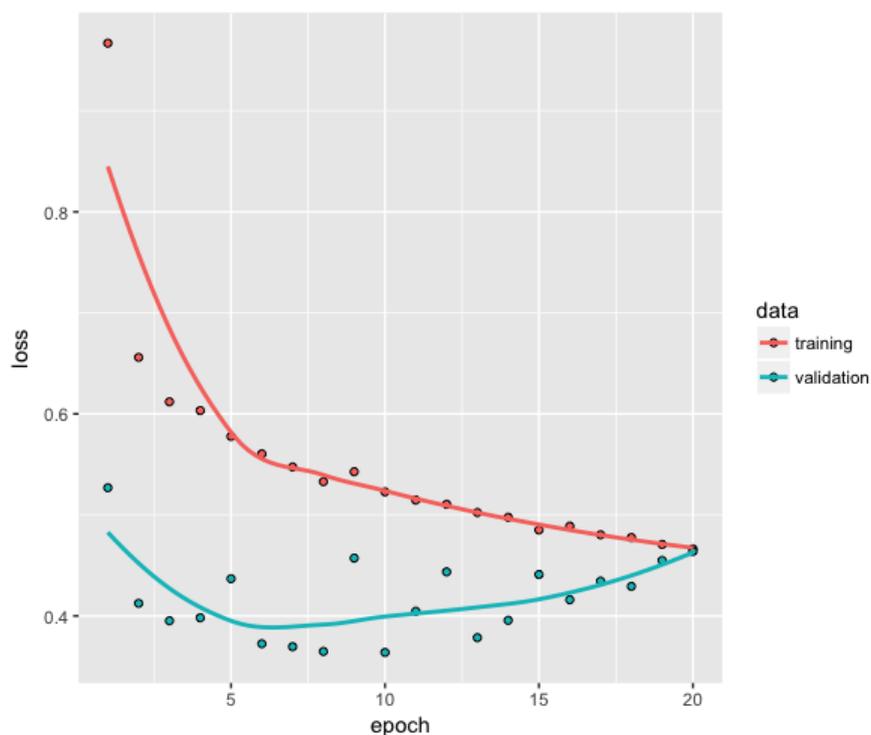
A través de una repetición constante del modelo, modificando los parámetros externos y propios del modelo, se encuentra que el modelo con los mejores resultados para la arquitectura aquí descrito son los siguientes:

Rezago = 5 Paso = 2

Resultados obtenidos en las regiones de similar crecimiento

Con los parámetros escogidos, se obtiene el siguiente figura 8 de los valores de loss function, a lo largo de las diferentes épocas:

Figura 8: Loss functions de la primera arquitectura en regiones de similar comportamiento.



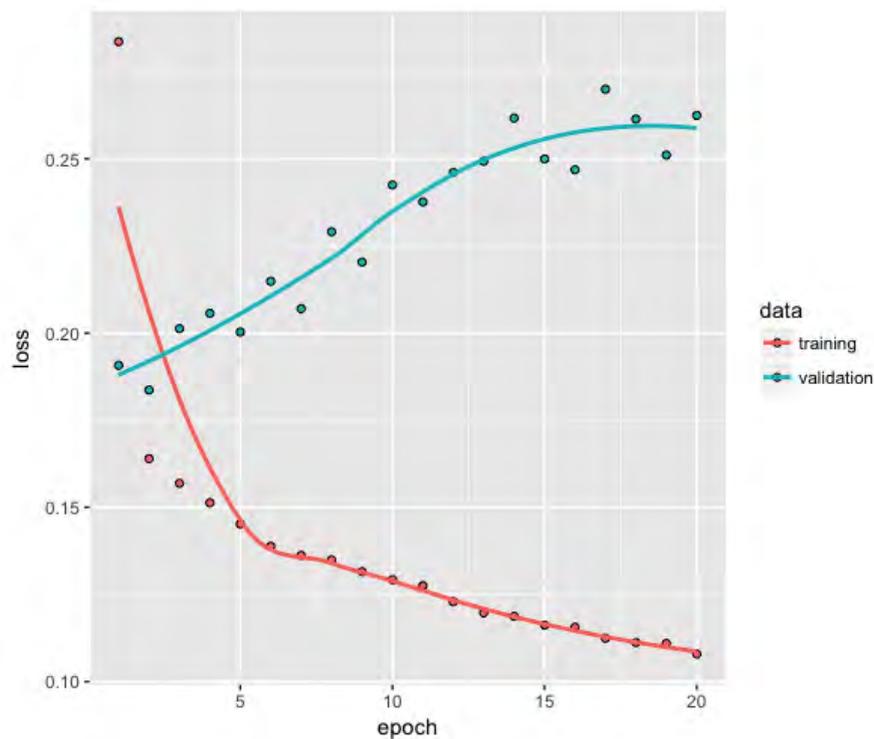
Fuente: Elaborado por los autores.

De este modelo se obtienen valores para la loss de 0.5507, validation loss de 0.4179 y en la evaluación con los datos de prueba un valor de 1.46.

#### Resultados obtenidos en la región estable

Sobre este conjunto de datos, dado que los valores son continuos se toma como conjunto de entrenamiento y de validación las primeras 400 entradas, en dos conjuntos parejos, cada uno con un total de 200 entradas. De este entrenamiento y de su correspondiente validación se obtienen los resultados que se muestran a continuación:

Figura 9: Loss functions de la primera arquitectura en región estable.



Fuente: Elaborado por los autores.

Se encuentra entonces que los valores de loss function a lo largo de las etapas se han reducido de forma significativa. Esto se debe a que se encuentra un patrón más repetitivo en el flujo de los datos dentro de esta región estable. No obstante, los valores tienen una tendencia creciente, lo cual es causado por problemas de sobre-entrenamiento en el modelo.

## Red LSTM

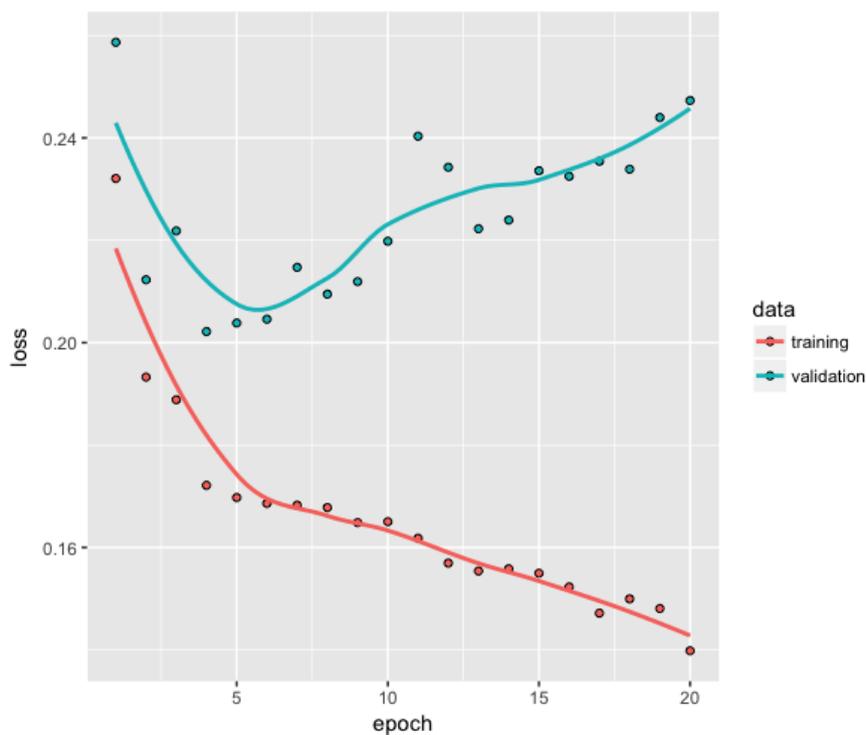
El segundo modelo que se toma en cuenta en el presente documento es una red LSTM como se describió en el capítulo anterior. Se recuerda que este modelo puede ofrecer mejores resultados pues toma en cuenta información del pasado como remanente que se introduce en la predicción del presente. Esta arquitectura contiene una sola capa LSTM interna con un total de 32 neuronas así como la capa exterior de salida que arroja un out-put de un solo valor.

Se procede de la misma forma que con la arquitectura anterior, modificando uno por uno los parámetros externos, encontrando que los mejores resultados se obtienen a partir de los siguientes parámetros:

Rezago = 4 Paso = 2

Por conveniencia, se usa la base de datos dentro de la región estable como se describió en la arquitectura anterior, tomando los mismos conjuntos de datos para obtener los resultados que se muestran en la figura 10

Figura 10: Loss functions de la segunda arquitectura en región estable.



Fuente: Elaborado por los autores.

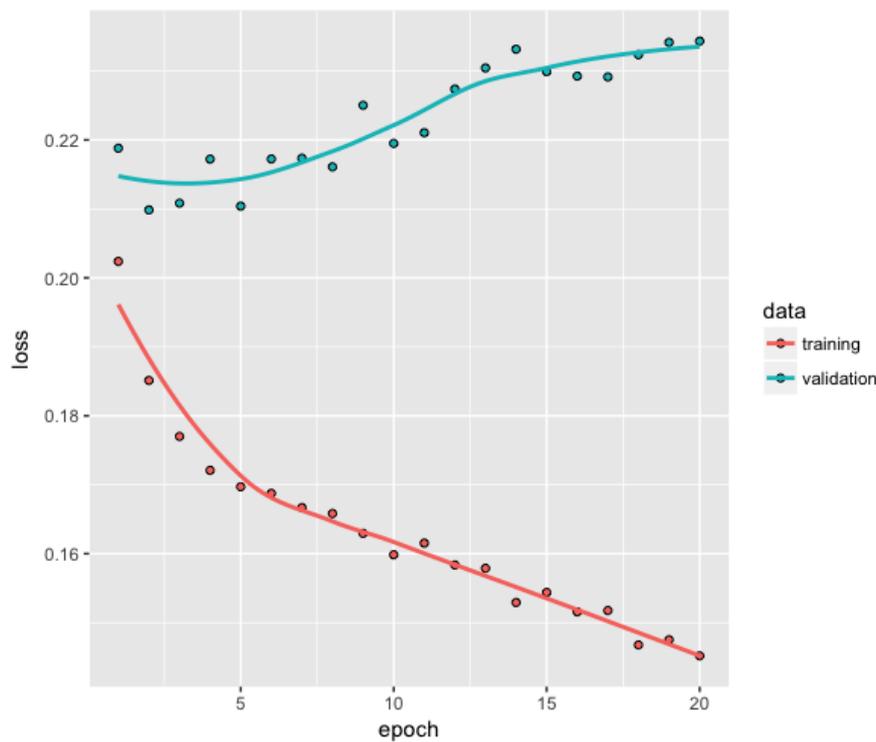
A través del gráfico se puede identificar que los valores obtenidos para las loss functions mantienen un rango de valores cercanos (aunque en promedio más bajos) que los obtenidos por la arquitectura FFN, sin embargo, vale rescatar de ahora los valores no tuvieron un crecimiento exagerado como ocurrió con la arquitectura anterior.

#### Ligera modificación del modelo anterior

Una de las variantes actuales de la red LSTM es la red GRU, de la cual no se ha hecho detalle dentro del presente documento, pero la cual funciona de forma muy similar a la LSTM. Esta red incluye ciertos componentes de activación o no activación de las memorias de los cálculos de las épocas pasadas mejorando ligeramente la red.

Los parámetros que se utilizan dentro del contexto externo del problema son similares a los utilizados en la red LSTM en esta misma sección al igual que el conjunto de datos, tomados desde la región estable. Los resultados obtenidos se muestran en la figura 11.

Figura 11: Loss functions de la segunda arquitectura (red GRU) en región estable.



Fuente: Elaborado por los autores.

## Doble LSTM

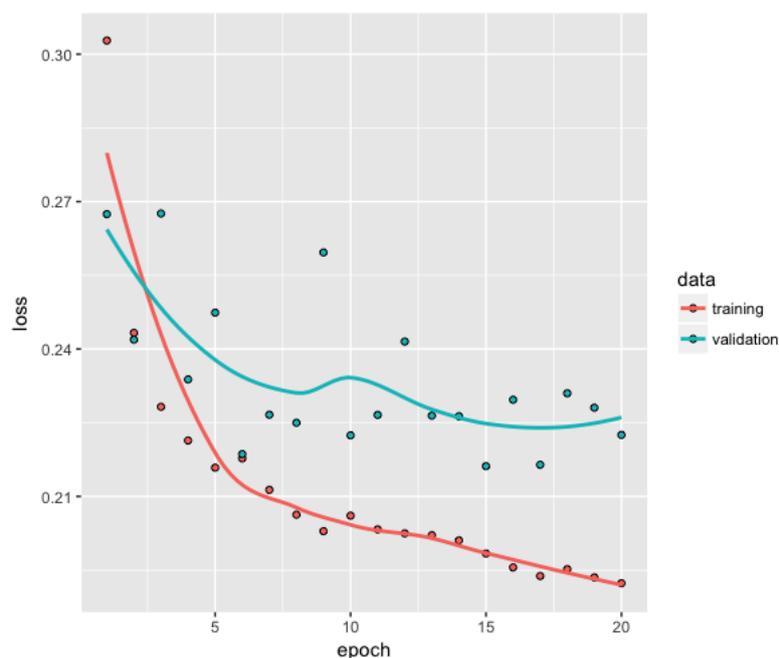
En esta arquitectura se introduce el recurrent dropout. Además, con el objetivo de mejorar el procesamiento de los datos se hace uso de dos capas internas del tipo LSTM: Una de ellas con 64 neuronas internas y la segunda con un total de 32 neuronas. Al final de la arquitectura se utiliza la acostumbrada capa de salida.

Una vez más, el proceso de elección de los parámetros externos se hizo probando uno por uno los resultados, con lo que se toma en para este caso los valores como sigue:

Rezago = 4 Paso = 2

A partir de los cuales se obtiene los resultados que se muestran en la figura 12.

Figura 12: Loss functions de la tercera arquitectura (doble LSTM) en región estable



Fuente: Elaborado por los autores.

### Comparación entre modelos de la región estable

A partir de los 4 modelos programados y desarrollados en el presente capítulo que toman en cuenta el conjunto de datos obtenido de la región estable y tomando como referencia el promedio como medida, se obtiene la tabla 1 de resultados del valor de loss function (entrenamiento y validación) para cada uno de ellos:

## Experimentos y resultados

Tabla 1. Loss functions para los modelos.

Loss and Validation loss para cada uno de los modelos		
Arquitectura	Loss Function(MAE)	Validation Loss(MAE)
Feed Forward Network	0.1367	0.2315
LSTM	0.1656	0.2253
GRU	0.1629	0.2231
Doble LSTM	0.2116	0.2337

Fuente: Elaborado por los autores.

El modelo más adecuado va a ser el que provea mejores resultados en términos de mayor precisión en el vaticinio del precio ajustado de la acción. Sin embargo, se tiene que hacer uso del conjunto de datos prueba para poder medir la precisión de los modelos pues no se puede concluir a partir de la loss function de validación si un modelo es mejor que otro. Como los cuatro modelos de la región estable presentados en este documento ocupan el mismo conjunto de datos de prueba, se puede comparar que tan precisos resultaron ser los modelos, como se detalla en la tabla 2.

Tabla 2. Resultados para todos los modelos. Loss obtenida a través de predict\_generator.

Arquitectura	Loss Function(MAE) para conjunto de prueba	Valor en Dólares (\$)
Feed Forward Network	0.2785	6,78
LSTM	0.3248	7,91
GRU	0.3203	7,80
Doble LSTM	0.3055	7,44
Naive	0.2208	5,37

Fuente: Elaborado por los autores.

## Conclusion

El comportamiento humano siempre será difícil de entender o predecir (Madrid, et al., 2011); en el ámbito de las finanzas, es este comportamiento el que determina el precio de las acciones, el volumen de ventas y el accionar de las mismas empresas lo que hace de la predicción y aprendizaje del mismo una actividad sumamente complicada. En este documento se ha pretendido generar un acercamiento a algunos métodos matemáticos y computacionales que permitan un vaticinio y predicción de los valores de activos financieros a través de la comparación de diferentes arquitecturas utilizadas en deep-learning dando cuenta de la difícil actividad a la que se aplica su teoría.

Una vez comparadas las distintas arquitecturas del deep-learning en conjunto con el método Naive, se encontró que los resultados obtenidos a partir de este último resultaron mejores que aquellos obtenidos por medio de arquitecturas de redes neuronales, según como puede observarse en la tabla 2. El hecho de que las predicciones realizadas a través del método Naive resulten mejores obedece a dos hechos fundamentales:

1. Los precios entre las acciones no tienden a cambiar tanto entre un día y otro salvo intervenciones externas.
2. Las variaciones del precio dependerán de forma directa del comportamiento humano que obedece a estímulos emocionales, difíciles de aproximar mediante algoritmos matemáticos por la complejidad que estos representan: Decisiones gubernamentales, ventas de grandes grupos de acciones, caídas en la economía entre otros hechos propios del comportamiento humano.

Por otro lado, a partir de este documento puede concluirse que entre los modelos de redes neuronales analizados, el mejor resultó ser el de FeedForward en razón de que se utilizó como variables de predicción los precios de apertura, cierre, alto y bajo que de alguna manera permitieron que esta arquitectura más robusta obtenga mejores resultados por sobre las de recurrencia pues la dinámica de los datos no resultó ser la más apropiada y razón por la cual se recomendaría su inclusión en futuros análisis del mismo tema.

## Referencias

- Arango, F.O., & Llanos, A.I.C. (2012). Modelado del comportamiento del tipo de cambio peso-dólar mediante redes neuronales diferenciales. *Estocástica: finanzas y riesgo*, 2(1), 49-63. <https://doi.org/10.24275/uam/azc/dcsh/efr/2012v2n1/Ortiz>
- 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. *Semestre Económico*, 12(25), 95-109. <https://revistas.udem.edu.co/index.php/economico/article/view/277>
- Asanza, W.R., & Olivo, B.M. (2018). Redes neuronales artificiales aplicadas al reconocimiento de patrones. *Editorial UTMACH*, 1(4), 5.
- Conti, D., Simó, C., & Rodríguez, A. (2005). Teoría de carteras de inversión para la diversificación del riesgo: enfoque clásico y uso de redes neuronales artificiales (RNA). *Ciencia e Ingeniería*, 26(1), 35-42.
- Dávila, M.K.L., & Ordóñez, L.B.T. (2021). Calculando el riesgo de insolvencia, de los métodos tradicionales a las redes neuronales artificiales. Una revisión de literatura. *INNOVA Research Journal*, 6(3), 270-287. <https://doi.org/10.33890/innova.v6.n3.2021.1790>
- Díaz, H., & Sosa, M. (2018). Inclusión financiera y ahorro en México: un análisis logístico binario y de redes neuronales artificiales. *Estocástica: finanzas y riesgo*, 8(1), 53-84. <https://www.doi.org/10.24275/uam/azc/dcsh/efr/2018v8n1/Diaz>

- Díaz Rodríguez, H.E., Sosa Castro, M., & Cabello Rosales, A. (2019). Determinantes del endeudamiento de los hogares en México: un análisis con redes neuronales. *Problemas del desarrollo*, 50(199), 115-140. <https://doi.org/10.22201/iiec.20078951e.2019.199.67463>
- Duque, F.V., Trejos, W.M., & Henao, M.A. (2006). Pronóstico de las tasas de cambio. Una aplicación al Yen Japonés mediante redes neuronales artificiales. *Scientia et technica*, 1(30). <https://revistas.utp.edu.co/index.php/revistaciencia/article/view/6539>
- Gallegos, J.D.C. (2005). Las redes neuronales artificiales en las finanzas. *Industrial Data*, 8(2), 0. <https://www.redalyc.org/articulo.oa?id=81680205>
- García Salgado, O., & Morales Castro, A. (2016). Desempeño financiero de las empresas: una propuesta de clasificación por RNA<sup>1</sup>. *Dimensión empresarial*, 14(2), 11-23. <http://dx.doi.org/10.15665/rde.v14i2.686>
- Herrera, J.B. (2008). El Caos y las Redes Neuronales en la Economía y Finanzas Interpretando el desorden perfecto: Modelado y predicción. *Pensamiento Crítico*, 8, 131-142. <https://doi.org/10.15381/pc.v8i0.9156>
- Jiménez Caballero, J.L. (2000). Utilización de redes neuronales en finanzas. *Futuro e Perspectivas. X Jornadas Luso-Espanholas de Gestão Científica*. <https://hdl.handle.net/11441/143655>
- Jiménez Caballero, J.L., & Ruiz Martínez, R.J. (2000). Las redes neuronales en su aplicación a las finanzas. *Banca & Finanzas*, 54, 19-26.
- Lastre-Valdés, M.M. (2015). Predicción de insolvencia, confiabilidad y calidad de los sistemas organizaciones. *Ciencias Holguín*, 21(4), 1-14.
- Madrid, A., Chaparro, A., Bustos, R., & Ríos, A. (2011). Diseño de una herramienta de planificación estratégica aplicando teoría de redes neuronales artificiales. *Revista Internacional Administración & Finanzas*, 4(4). <http://ssrn.com/abstract=1952137>
- Martín, F.F., & Gutiérrez, M.C.L. (2003). Interdisciplinariedad y multidisciplinariedad en aplicaciones a las finanzas. *Revista de economía y empresa*, 20(49), 51-66.
- Mercado Polo, D., Pedraza Caballero, L., & Martínez Gómez, E. (2015). Comparación de Redes Neuronales aplicadas a la predicción de Series de Tiempo. *Prospectiva*, 13(2), 88-95. <http://dx.doi.org/10.15665/rp.v13i2.491>
- Ortiz Arango, F., Cabrera Llanos, A.I., & López Herrera, F. (2013). Pronóstico de los índices accionarios DAX y S&P 500 con redes neuronales diferenciales. *Contaduría y administración*, 58(3), 203-225. [https://doi.org/10.1016/S0186-1042\(13\)71227-0](https://doi.org/10.1016/S0186-1042(13)71227-0)
- Pérez Ramírez, F.O., & Fernández Castaño, H. (2007). Las redes neuronales y la evaluación del riesgo de crédito. *Revista Ingenierías Universidad de Medellín*, 6(10), 77-91.
- Rego, A.Z., López, I.P., & Bringas, P.G. (2020). Inteligencia artificial: una aproximación desde las finanzas. *Boletín de estudios económicos*, 75(229), 99-117.
- Rosales, S.G., Ramos, I.R., & Cuervo, C.M. (2003). Revisión del estado del arte de la aplicación de redes neuronales artificiales en economía y finanzas. In *Emergent solutions for the information and knowledge economy: proceedings of the Tenth International Association for Fuzzy-Set Management and Economy Congress* (pp. 167-184). Secretariado de Publicaciones y Medios Audiovisuales.

- Ruiz, D.C., & Gavino, G.Q. (2011). Aplicación del algoritmo Backpropagation de redes neuronales para determinar los niveles de morosidad en los alumnos de la Universidad Peruana Unión. *Revista de Investigación Business Intelligence*, 1(2). [https://revistas.upeu.edu.pe/index.php/ri\\_bi/article/view/908](https://revistas.upeu.edu.pe/index.php/ri_bi/article/view/908)
- Salgado, O.G. (2014). Empresas exitosas y no exitosas que cotizan en la BMV del Sector Comercial: Una clasificación con Análisis Discriminante Múltiple, Modelos Logit y Redes Neuronales Artificiales. *Estocástica: finanzas y riesgo*, 4(1), 33-62. <https://www.doi.org/10.24275/uam/azc/dcsh/efr/2014v4n1/Garcia>
- Sosa Sierra, M.C. (2007). Inteligencia artificial en la gestión financiera empresarial. *Pensamiento & Gestión*, (23), 153-186. <http://www.redalyc.org/articulo.oa?id=64602307>
- Villamil Torres, J.A., & Delgado Rivera, J.A. (2007). Entrenamiento de una red neuronal multicapa para la tasa de cambio euro-dólar (EUR/USD). *Ingeniería e investigación*, 27(3), 106-117.
- Villada, F., Muñoz, N., & García, E. (2012). Aplicación de las Redes Neuronales al Pronóstico de Precios en el Mercado de Valores. *Información tecnológica*, 23(4), 11-20. <http://dx.doi.org/10.4067/S0718-07642012000400003>
- Weber, R. (2000). Data Mining en la empresa y en las finanzas utilizando tecnologías inteligentes. *Revista Ingeniería de Sistemas*, 14(1), 61-78.

## **Autores**

**Luz María Quinde Arreaga.** Doctorante en Estadística y Matemática Aplicada, Universidad Nacional de Tumbes, Tumbes-Perú–Magister en Estadística mención en Gestión de la Calidad y Productividad–Escuela Superior Politécnica del Litoral, Guayaquil Ecuador–Ingeniera En Sistemas computacionales, Universidad Estatal De Milagro, Milagro Ecuador–Analista de Soporte de Microcomputadores–Escuela Superior Politécnica Del Litoral, Guayaquil Ecuador, Actualmente Docente de la Universidad Técnica Estatal de Quevedo–Facultad de Ciencias Sociales Económicas y Financieras.

**Jimmy Rafael Landaburu Mendoza.** Economista por la Universidad de Guayaquil. Máster en economía con mención en finanzas y proyectos corporativos por la Universidad de Guayaquil; cuenta con una especialidad la planificación financiera por el Tecnológico de Monterrey, y es especialidad en proyectos de inversión pública y privada por la ESPOL.

**Nuvia Aurora Zambrano Barros.** Licenciada (Extensión Quevedo). Secretaria Bilingüe (Quevedo). Distinción Mejor Docente (Unidad de Estudios a Distancia).

**Adolfo Hernán Elizondo Saltos.** Doctor en Economía Empresas Finanzas y Computación por la Universidad de Huelva – España, Máster en Economía y Desarrollo Territorial por la Universidad de Huelva – España, Master en Administración de Empresas por la Universidad Técnica Estatal de Quevedo – Ecuador, Economista por la Universidad Técnica Estatal de Quevedo, Actualmente docente en la Universidad técnica Estatal de Quevedo–Facultad de Ciencias Sociales Económicas y Financieras.

## **Declaración**

### **Conflicto de interés**

No tenemos ningún conflicto de interés que declarar.

### **Financiamiento**

Sin ayuda financiera de partes ajenas a este artículo.

### **Notas**

El artículo se desprende de una tesis de pregrado de licenciatura en Finanzas de la Universidad Nacional de Loja.