

**UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

**Predicción de Precios de Acciones mediante Arquitecturas de  
Aprendizaje Profundo Multi-Entrada y Multi-Salida  
incorporando Sentimiento Ponderado y Factores  
Macroeconómicos**

**Pamela Raquel Pupiales Alulema**

**Ingeniería en Ciencias de la Computación**

Trabajo de fin de carrera presentado como requisito  
para la obtención del título de  
**Ingeniero en Ciencias de la computación**

Quito, 14 de mayo de 2024

# **UNIVERSIDAD SAN FRANCISCO DE QUITO USFQ**

**Colegio de Ciencias e Ingenierías**

## **HOJA DE CALIFICACIÓN DE TRABAJO DE FIN DE CARRERA**

**Predicción de Precios de Acciones mediante Arquitectura de  
Aprendizaje Profundo Multi-Entrada y Multi-Salida incorporando  
Sentimiento Ponderado y Factores Macroeconómicos**

**Pamela Raquel Pupiales Alulema**

**Nombre del profesor, Título académico**

Felipe Grijalva Arévalo, PhD

Quito, 14 de mayo de 2024

## © DERECHOS DE AUTOR

Por medio del presente documento certifico que he leído todas las Políticas y Manuales de la Universidad San Francisco de Quito USFQ, incluyendo la Política de Propiedad Intelectual USFQ, y estoy de acuerdo con su contenido, por lo que los derechos de propiedad intelectual del presente trabajo quedan sujetos a lo dispuesto en esas Políticas.

Asimismo, autorizo a la USFQ para que realice la digitalización y publicación de este trabajo en el repositorio virtual, de conformidad a lo dispuesto en la Ley Orgánica de Educación Superior del Ecuador.

Nombres y apellidos: Pamela Raquel Pupiales Alulema

Código: 00213871

Cédula de identidad: 1751313089

Lugar y fecha: Quito, 14 de mayo de 2024

## **ACLARACIÓN PARA PUBLICACIÓN**

**Nota:** El presente trabajo, en su totalidad o cualquiera de sus partes, no debe ser considerado como una publicación, incluso a pesar de estar disponible sin restricciones a través de un repositorio institucional. Esta declaración se alinea con las prácticas y recomendaciones presentadas por el Committee on Publication Ethics COPE descritas por Barbour et al. (2017) Discussion document on best practice for issues around theses publishing, disponible en <http://bit.ly/COPETHeses>.

## **UNPUBLISHED DOCUMENT**

**Note:** The following capstone project is available through Universidad San Francisco de Quito USFQ institutional repository. Nonetheless, this project – in whole or in part – should not be considered a publication. This statement follows the recommendations presented by the Committee on Publication Ethics COPE described by Barbour et al. (2017) Discussion document on best practice for issues around theses publishing available on <http://bit.ly/COPETHeses>.

## RESUMEN

Este estudio se enfoca en la predicción de los precios de cierre de acciones de empresas tecnológicas extranjeras mediante el uso de arquitecturas de aprendizaje profundo Multi-Entrada Multi-Salida. Se desarrollaron y compararon tres arquitecturas principales: LSTM, GRU y TCN, con diferentes variaciones de ventanas de retroceso (1, 3, 5 y 7 días) y modelos diseñados para permitir la entrada simultánea de múltiples fuentes de información, incluyendo sentimiento ponderado y factores macroeconómicos. La metodología utilizada busca simplificar el proceso de predicción, mejorar la generalización de los resultados y ofrecer pronósticos aplicables en el ámbito económico.

El estudio se basa en una revisión exhaustiva de la literatura, que identifica tanto las fortalezas como las debilidades de los enfoques anteriores, proporcionando un contexto teórico necesario para el desarrollo de la investigación. Los modelos se entrenaron utilizando datos históricos y se evaluaron utilizando métricas relevantes como precisión, sensibilidad y especificidad. Se destaca la importancia de integrar técnicas avanzadas de redes neuronales recurrentes y convolucionales para abordar la variabilidad en los precios de las acciones.

Los resultados muestran que la arquitectura LSTM, con una ventana de tiempo de 7 días, fue la más efectiva para la predicción de los precios de cierre. Sin embargo, se identificaron problemas en los resultados debido a la variabilidad en las series de tiempo, lo que sugiere la necesidad de abordar esta cuestión en futuras investigaciones. Este estudio contribuye al avance del estado del arte en la predicción de series temporales en el ámbito financiero, estableciendo un precedente para investigaciones futuras en esta área interdisciplinaria entre la tecnología y la economía.

**Palabras clave:** Predicción de Precios de Acciones, Aprendizaje Profundo, Multi-Entrada, Multi-Salida, Series Temporales, Memoria a Corto y Largo Plazo, Unidades Recurrentes Cerradas, Redes Convolucionales Temporales, Ventana de retroceso, Factores Macroeconómicos, Redes Neuronales Recurrentes, Redes Neuronales Convolucionales.

## ABSTRACT

This study focuses on the prediction of closing stock prices of foreign technology companies by using Multi-Input Multi-Output deep learning architectures. Three main architectures were developed and compared: LSTM, GRU and TCN, with different variations of retracement windows (1, 3, 5 and 7 days) and models designed to allow simultaneous input of multiple sources of information, including weighted sentiment and factors. macroeconomics. The methodology used seeks to simplify the prediction process, improve the generalization of the results and offer forecasts applicable in the economic field.

The study is based on a comprehensive review of the literature, which identifies both the strengths and weaknesses of the previous approaches, providing a necessary theoretical context for the development of the research. The models were trained using historical data and evaluated using relevant metrics such as accuracy, sensitivity, and specificity. The importance of integrating advanced recurrent and convolutional neural network techniques to address variability in stock prices is highlighted.

The results show that the LSTM architecture, with a time window of 7 days, was the most effective for predicting closing prices. However, problems in the results were identified due to variability in the time series, suggesting the need to address this issue in future research. This study contributes to the advancement of the state of the art in time series prediction in the financial field, establishing a precedent for future research in this interdisciplinary area between technology and economics.

**Keywords:** Stock Price Prediction, Deep Learning, Multi-Input, Multi-Output, Time Series, Short Long-Term Memory, Closed Recurrent Units, Temporal Convolutional Networks, Retracement Window, Macroeconomic Factors, Recurrent Neural Networks, Convolutional Neural Networks.

## TABLA DE CONTENIDO

INTRODUCCIÓN .....	10
Contextualización y Justificación .....	10
Objetivos .....	11
Generales.....	11
Específicos .....	11
ESTADO DEL ARTE.....	12
DESARROLLO DEL TEMA .....	15
Memoria a Corto y Largo Plazo (LSTM) .....	15
Unidades Recurrentes Cerradas (GRU) .....	16
Redes Convolucionales Temporales (TCN) .....	17
Análisis Exploratorio del conjunto de datos .....	18
Arquitectura LSTM de Múltiples entradas y múltiples salidas secuenciales .....	21
Arquitectura GRU de Múltiples entradas y múltiples salidas secuenciales.....	23
Arquitectura TCN de Múltiples entradas y múltiples salidas secuenciales .....	25
Métodos de Evaluación.....	27
RESULTADOS.....	27
LSTM.....	28
GRU .....	29
TCN.....	30
CONCLUSIONES .....	34
REFERENCIAS BIBLIOGRÁFICAS.....	35
Anexo A: Repositorio GITHUB .....	37
Anexo B: Promedios De Curvas De Aprendizaje Por Fold.....	37
Anexo C: Predicciones y métricas LSTM .....	40
Anexo D: Predicciones y métricas GRU .....	48
Anexo E: Predicciones y métricas TCN .....	56
Anexo F: Predicciones LSTM sin AMZN y MSFT.....	64

**ÍNDICE DE TABLAS**

Tabla # 1. Hiper parámetros optimizados LSTM .....	22
Tabla # 2. Hiper parámetros constantes LSTM .....	22
Tabla # 3. Hiper parámetros LSTM para diferentes tamaños de ventana de tiempo .....	23
Tabla # 4. Hiper parámetros optimizados GRU.....	24
Tabla # 5. Hiper parámetros constantes GRU .....	24
Tabla # 6. Hiper parámetros GRU para diferentes tamaños de ventana de tiempo .....	24
Tabla # 7. Hiper parámetros optimizados TCN .....	26
Tabla # 8. Hiper parámetros constantes TCN .....	26
Tabla # 9. Hiper parámetros TCN para diferentes tamaños de ventana de tiempo .....	26
Tabla # 10. Métricas promedio LSTM, GRU y TCN de las mejores 2 ventanas de tiempo. ...	32
Tabla # 11. Métricas promedio LSTM sin AMZN y MSFT.....	33



## ÍNDICE DE FIGURAS

Figura # 1. Conjunto de datos Final Df Final .....	20
Figura # 2. Modelos de Red Neuronal LSTM con entradas y salidas .....	22
Figura # 3. Modelos de Red Neuronal GRU con entradas y salidas.....	24
Figura # 4. Modelos de Red Neuronal TCN con entradas y salidas .....	25
Figura # 5. Métricas promedio LSTM para conjunto de entrenamiento.....	28
Figura # 6. Métricas promedio LSTM para conjunto de validación.....	28
Figura # 7. Métricas promedio LSTM para conjunto de prueba.....	29
Figura # 8. Métricas promedio GRU para conjunto de entrenamiento.....	29
Figura # 9. Métricas promedio GRU para conjunto de validación .....	30
Figura # 10. Métricas promedio GRU para conjunto de prueba.....	30
Figura # 11. Métricas promedio TCN para conjunto de entrenamiento .....	31
Figura # 12. Métricas promedio TCN para conjunto de validación .....	31
Figura # 13. Métricas promedio TCN para conjunto de prueba .....	31

## INTRODUCCIÓN

### **Contextualización y Justificación**

En la actualidad, se aprecia una convergencia cada vez más estrecha entre la inteligencia artificial y el mundo de las finanzas. Con el progreso continuo de la investigación y el empleo de herramientas tecnológicas de vanguardia, se están abriendo nuevas puertas para perfeccionar la precisión en la predicción de los costos de acciones en los mercados bursátiles. Esta alianza entre la inteligencia artificial y las finanzas no solo está transformando el análisis y la toma de decisiones en los mercados financieros, sino que también está revolucionando la manera en que se comprenden y se anticipan los movimientos del mercado. La integración de algoritmos avanzados de aprendizaje automático y análisis de datos masivos está permitiendo a los analistas financieros acceder a un nivel de análisis y predicción que antes era impensable.

El análisis y predicción de los precios de acciones representan un área crucial en la investigación financiera y económica, dado su impacto en decisiones como la inversión, planificación financiera y estabilidad económica. Es así como este trabajo se enfoca en contribuir en la metodología de predicción, proponiendo varias arquitecturas de aprendizaje profundo multi-entrada, multi-salida y multi-variable que integran el sentimiento ponderado y factores macroeconómicos. La propuesta se diferencia de enfoques anteriores al ofrecer una perspectiva interesante, automatizada y más completa, como la predicción de n-series temporales en paralelo de varias empresas tecnológicas extranjeras (Apple, Amazon, Google, Google LLC, Microsoft y Tesla), lo cual podría significar una mejora valiosa a la hora de obtener resultados.

En el contexto ecuatoriano, esta investigación adquiere una relevancia aún mayor, dado el interés creciente en el desarrollo de herramientas y metodologías avanzadas para la predicción y gestión de riesgos en el mercado financiero local. Es importante destacar que el proyecto no solo ofrece la oportunidad de avanzar en este ámbito, sino también de destacar las limitaciones

de los modelos existentes y proponer soluciones innovadoras que puedan ser adaptadas y aplicadas en el contexto específico de Ecuador, por ejemplo, en áreas de gran relevancia económica como la proyección de ventas de productos emblemáticos como el camarón.

En resumen, este proyecto se posiciona como un esfuerzo característico para mejorar la precisión y aplicabilidad de las predicciones de precios de acciones, ofreciendo nuevas perspectivas y enfoques que pueden beneficiar tanto a la investigación académica como a la práctica financiera. En las próximas secciones de este trabajo, se detallarán elementos teóricos, metodológicos y empíricos que respaldan esta propuesta, así como los resultados y conclusiones obtenidos.

## **Objetivos**

### **Generales**

Desarrollar arquitecturas de aprendizaje profundo multi-entrada, multi-salida para la predicción de precios de acciones de cierre, incorporando de manera eficiente el sentimiento ponderado y factores macroeconómicos.

### **Específicos**

- Realizar una revisión exhaustiva de la literatura relacionada con la predicción de precios de acciones y modelos de aprendizaje profundo.
- Identificar las fortalezas y debilidades de los enfoques anteriores y establecer el contexto teórico para la investigación.
- Entrenar el modelo utilizando datos históricos y validar su desempeño utilizando métricas relevantes como precisión, sensibilidad y especificidad.
- Evaluar la capacidad del modelo para adaptarse a diferentes empresas y condiciones del mercado.

## ESTADO DEL ARTE

La predicción de precios de acciones ha sido un desafío emocionante durante décadas, marcando una historia de continuo avance y evolución. Inicialmente, los métodos utilizados para predecir las tendencias del mercado se basaban en enfoques tradicionales como el análisis técnico y fundamental, respaldados por modelos estadísticos. A pesar de que estos enfoques proporcionaban una comprensión del comportamiento del mercado, a menudo no lograban capturar la complejidad profunda de los datos financieros.

En los últimos años, se ha presenciado una evolución significativa en este campo, con un énfasis gradual en el uso de técnicas de aprendizaje automático, particularmente el aprendizaje profundo. Este cambio ha sido impulsado por una serie de factores, incluyendo avances tecnológicos, mayor disponibilidad de datos y mejoras en algoritmos. [1] El aprendizaje profundo ha demostrado ser una herramienta poderosa para la predicción de precios de acciones, gracias a su capacidad para modelar relaciones complejas y no lineales en extensos conjuntos de datos temporales.

Las series temporales, que son una secuencia de observaciones de una variable respuesta en el tiempo, juegan un papel crucial en este contexto. Cada punto de datos está asociado con un momento específico en el tiempo, y el análisis de las series temporales requiere estudiar y modelar patrones, tendencias y comportamientos que se presentan con el paso del tiempo para poder predecir valores futuros.

Tradicionalmente, el pronóstico de series de tiempo ha estado dominado por métodos lineales como la Media Móvil Integrada Autorregresiva (ARIMA), que son bien entendidos y efectivos en muchos problemas.[2] Sin embargo, estos métodos clásicos tienen algunas limitaciones, como la necesidad de datos completos, suposición de relaciones lineales, dependencia temporal fija, limitación a datos univariados y los pronósticos de un solo paso. Por estas razones, los métodos de aprendizaje automático se han convertido en una mejor alternativa para problemas de pronóstico de series temporales más complejos.

Las Neuronas tanto biológicas como artificiales se encuentran en conjunto y conectadas entre sí, se conoce que cada neurona obtiene impulsos eléctricos como señales, procesan la información y proceden a enviar a otras neuronas. Están conformadas por cuatro partes, dendritas (aceptan impulsos eléctricos de entrada), cuerpo (procesan la información), axón (transforma información que llega de la entrada para que la información sea recibida por otra neurona) y sinapsis (contacto electroquímico entre neuronas) [3].

Las redes neuronales artificiales (RNA) están inspiradas en el funcionamiento del cerebro humano, a pesar de que no llegan a desempeñarse de la misma manera, son útiles al momento de realizar diferentes actividades como el reconocimiento de voz, escritura, procesamiento de imágenes, entre otras. Tienen como objetivo encontrar patrones mediante técnicas algorítmicas convencionales.

Las RNA están formadas por una serie de neuronas artificiales, que constituyen dispositivos simples de cálculo que, bien a partir de un vector de entrada procedente del mundo exterior o a partir de estímulos recibidos de otras neuronas, proporcionan una respuesta única. [3] El predominio de las RNA en la predicción de series temporales es evidente por varias razones. En primer lugar, estas redes pueden recordar y aprender de las relaciones y patrones encontrados en datos históricos para predecir eventos futuros de manera efectiva [5]. Al mismo tiempo, las redes neuronales son adaptables y no requieren construcción manual, ya que pueden aprender automáticamente características relevantes a partir de los datos. Por tanto, tienen importantes ventajas sobre los modelos tradicionales.

Las redes neuronales recurrentes (RNN) son un tipo de arquitectura profunda que se caracteriza por su estructura en la dimensión temporal. En el contexto del modelado de series temporales, las RNN son ampliamente utilizadas debido a su capacidad para capturar dependencias secuenciales a lo largo del tiempo. [12] Sin embargo, las RNN tradicionales tienen limitaciones, ya que no pueden manejar eficazmente problemas con datos secuenciales debido a que consideran que todas las unidades de los vectores de entrada son independientes.

Para abordar estas limitaciones, se han desarrollado variantes de las RNN, como las Memoria a largo plazo (LSTM) y las Unidades recurrentes cerradas (GRU). Las LSTM, en particular, han demostrado ser efectivas en el manejo de dependencias temporales en secuencias de datos, como las series temporales financieras. Estas redes agregan una memoria interna que les permite recordar patrones a largo plazo y evitar el problema de desvanecimiento de gradientes [5] que afecta a las RNN estándar.

Las GRU también son relevantes en este contexto. Al igual que las LSTM, las GRU son capaces de capturar dependencias a largo plazo en los datos secuenciales. Aunque comparten algunas similitudes con las LSTM, las GRU tienen una estructura más simple y utilizan menos puertas internas, lo que puede hacerlas más eficientes en términos de cálculo y entrenamiento. Además, es interesante mencionar que no solamente los autores realizan predicción de series de tiempo mediante RNN también se realiza la predicción de la dirección de la tendencia del precio de las acciones que combina redes neuronales convolucionales (CNN) para la extracción de características.[7]

Pronosticar los movimientos de precios es el principal objetivo para determinar si el valor de un activo aumentará, disminuirá o permanecerá igual durante un período de tiempo. La integración de múltiples fuentes de datos, como el sentimiento ponderado y factores macroeconómicos, resalta la complejidad y la necesidad de un enfoque integral para comprender y predecir la dinámica del mercado. En resumen, este proyecto se sitúa en la intersección de la tecnología y la economía, empleando técnicas avanzadas de RNN y CNN para abordar una cuestión de importancia de la variación bursátil.

El actual proyecto, se alinea con el marco proporcionado por la norma ISO/IEC 23053:2022. Esta norma establece un marco para los sistemas de inteligencia artificial que utilizan aprendizaje automático, proporcionando modelos para su desarrollo, despliegue y mantenimiento. Se siguieron los principios delineados en esta norma para garantizar la transparencia y la robustez del sistema de predicción. Gracias a alinear el proyecto a estos

estándares reconocidos internacionalmente, se garantiza la coherencia y la calidad del enfoque metodológico, lo que fortalece la credibilidad y la aplicabilidad de los resultados en el campo de la predicción financiera.

## DESARROLLO DEL TEMA

### Memoria a Corto y Largo Plazo (LSTM)

Las redes LSTM son un tipo especial de RNN y son capaces de aprender a largo plazo, de mejor manera que RNN usando tres puertas, entrada, olvido y salida en la celda LSTM.

Sigma ( $\sigma$ ) representa la función sigmoidea logística y  $i, f, o, c$  representan la puerta de entrada, puerta de olvido, puerta de salida y los vectores de celda con el mismo tamaño que el vector oculto  $h$ . El procedimiento de la celda LSTM se detalla a continuación:

Puerta de olvido, es una capa sigmoidea que genera un número entre 0 y 1, donde 1 representa mantener la información y 0 deshacerse de la misma.

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f)$$

*Ecuación # 1. Puerta de olvido*

Puerta de entrada, es el siguiente paso y decide qué información se va a almacenar en el estado de la celda, específicamente la ecuación 2 decide que valores se actualizarán.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i)$$

*Ecuación # 2. Puerta de entrada*

La capa tanh crea un vector de nuevos valores que serán candidatos,  $c_t$  de la ecuación 3 que tienen la posibilidad de agregarse al estado.

$$\tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c)$$

*Ecuación # 3. Capa tanh*

Posteriormente la combinación de ambas ecuaciones hará que se cree una actualización del estado. Se multiplica el estado anterior por  $f_t$  lo que hará que se olviden las cosas que ya se habían olvidado anteriormente. Y los valores candidatos nuevos son  $i_t * \tilde{c}_t$ .

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t$$

*Ecuación # 4. Resultado de ecuación 2 y 3*

Puerta de salida, se ejecuta una capa sigmoidea que decide qué partes del estado de la celda se generará. Luego, se coloca el estado de la celda a través de tanh, con el fin de empujar los valores a estar entre -1 y 1, se multiplica por la salida de la puerta sigmoidea, de modo que solo produzca las partes que se decidieron. [11]

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

*Ecuación # 5. Puerta de salida*

$$h_t = o_t \tanh(c_t)$$

*Ecuación # 6. Estado oculto*

## **Unidades Recurrentes Cerradas (GRU)**

Al igual que las LSTM, las GRU también están diseñadas para manejar dependencias a largo plazo en los datos secuenciales. Sin embargo, las GRU tienen una estructura más simple y utilizan menos puertas internas. Esto las hace más eficientes en términos de cálculo y entrenamiento.

El procedimiento de una celda GRU se asemeja al de una LSTM, pero con menos componentes. A continuación, se describen los pasos de una GRU:

La puerta de actualización decide cuánta información nueva se debe agregar al estado oculto. Se calcula mediante una función sigmoidea y controla la mezcla entre la entrada actual y el estado anterior.

$$z_t = \sigma(W_z [h_{t-1}, x_t] + b_z)$$

*Ecuación # 7. Función sigmoidea para la puerta de actualización.*

La puerta de reinicio determina cuánto del estado anterior se debe olvidar. Al igual que la puerta de actualización, se calcula mediante una función sigmoidea.



$$r_t = \sigma(W_r [h_{t-1}, x_t] + b_r)$$

*Ecuación # 8. Función sigmoidea para la puerta de reinicio.*

Se crea un vector de nuevos valores candidatos que pueden agregarse al estado oculto. Esto se logra mediante una función de activación como la tangente hiperbólica.

$$\tilde{h}_t = \tanh(W_h [r_t \odot h_{t-1}, x_t] + b_h)$$

*Ecuación # 9. Función de activación tanh.*

Finalmente, se combina el estado anterior con el candidato de estado oculto para obtener el nuevo estado oculto.

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t$$

*Ecuación # 10. Estado oculto actualizado.*

## **Redes Convolucionales Temporales (TCN)**

Las Redes Convolucionales Temporales (TCN) son una variante de las redes neuronales convolucionales (CNN) diseñadas específicamente para modelar secuencias y realizar pronósticos. A diferencia de las redes neuronales recurrentes (RNN), las TCN no tienen conexiones recurrentes, lo que evita problemas como el desvanecimiento o explosión del gradiente. Estas redes utilizan capas convolucionales 1D con dilatación y causalidad para capturar patrones a diferentes escalas temporales.

En una TCN, la capa de convolución 1D toma una entrada tridimensional (tensor) y produce una salida tridimensional. La entrada tiene forma (tamaño\_lote, longitud\_entrada, tamaño\_entrada) y la salida tiene forma (tamaño\_lote, longitud\_entrada, tamaño\_salida). La dilatación se utiliza para aumentar el campo receptivo de las capas convolucionales sin aumentar el número de parámetros, permitiendo así capturar patrones a diferentes escalas temporales.[13] Además, las TCN son causales, lo que significa que solo ven información del pasado y no del futuro, lo que es crucial para predecir secuencias de manera realista.

## **Análisis Exploratorio del conjunto de datos**

Al ser este trabajo una contribución, se utilizan los mismos conjuntos de datos que en el proyecto integrador realizado por Juan Sánchez, titulado “Evaluación de arquitecturas de aprendizaje automático en predicción de precio de acciones integrado con análisis de sentimiento y factores macroeconómicos.”. Por lo tanto, en esta fase se compiló la información necesaria que viene de tres conjuntos de datos diferentes que abarcan 5 años, desde el 1 de enero de 2015 hasta el 1 de enero de 2020.

Se llevó a cabo un análisis integral que combina datos textuales de redes sociales, datos históricos de acciones de empresas y factores macroeconómicos clave para comprender el sentimiento social en torno a las empresas, sus acciones en el mercado y los factores económicos que podrían influir en ellas. A continuación, se detalla brevemente el proceso y se realiza un análisis exploratorio del tratamiento de la información:

El primer conjunto de datos a observar es de aproximadamente 3 millones de registros, contiene información acerca del sentimiento de los usuarios en la red social Twitter (X) acerca de 5 empresas extranjeras reconocidas las cuales son: Apple (AAPL), Amazon (AMZN), Microsoft (MSFT), Tesla (TSLA) y Google (GOOG y GOOGL). [8]

Generando una distribución de probabilidad de sentimientos positivos y negativos. Estos datos se consolidaron en un conjunto denominado Ds, la fecha (Date), el símbolo del Ticker (ticker symbol), el sentimiento (Sentiment), las interacciones de los usuarios (Likes) y los estados citados (Retweets) para futuros análisis. Luego, se analiza la recopilación de datos históricos de acciones de las empresas, utilizando la base de datos históricos de Yahoo Finance. Estos datos fueron agrupados en un conjunto llamado Dst, que contiene información crucial como el precio de apertura (Open), máximo (High), mínimo (Low), cierre (Close), cierre ajustado (Adj Close) y volumen de acciones (Volumen).

Además, se incluyeron factores macroeconómicos clave de Estados Unidos proporcionados por el Bureau of Economic Analysis (BEA)[9] en un conjunto denominado Dm, que abarca

diversos indicadores económicos mensuales como la tasa de desempleo (unrate), tasa de ahorro personal (psr), oferta monetaria (m2), ingreso real disponible (dspic), gastos de consumo personal (pce), tipo de cambio efectivo real (reer), Tasa de interés para bonos federales a 10 años (ir) , Tasa Efectiva de los Bonos Federales (ffer), Inversión total en construcción (tcs), Índice total de producción industrial (indropo), Índice de Precios al Consumidor Subyacente (ccpi)

Posteriormente, realiza la ponderación del sentimiento diario por empresa, utilizando un "Factor de Consenso de Tweet" (TAS) que tiene en cuenta el alcance y las interacciones de cada tweet, calcula un promedio diario de sentimiento ponderado y se unen los datos de las diferentes empresas.

Para establecer una relación de causalidad entre el sentimiento en Twitter y el comportamiento de la acción en el mercado, el autor desplazo todas las fechas de sentimiento un día hacia adelante. Esto asegura que el sentimiento en  $t-1$  se relacione con el comportamiento de la acción en  $t$ . El conjunto de datos final preliminar incluye dimensiones como fecha, sentimiento ponderado, símbolo del ticker, precios de apertura, máximo, mínimo, cierre y volumen de acciones. Se agregaron los factores macroeconómicos ( $Dm$ ) al conjunto de datos preliminar, asegurando que coincidan con las unidades de tiempo diarias. Esto resulta en un conjunto de datos final compuesto por 19 columnas y 7544 filas.




Figura # 1. Conjunto de datos Final Df Final

Este conjunto de datos final será transformado para generar conjuntos de entrada y objetivo para el modelo. Se eliminará la dimensión de fecha, y se formará un agrupamiento en 3 dimensiones: Identificador temporal, Ventana de retroceso y características.

Cada conjunto de variables de entrada contendrá alrededor de 1247 saltos de tiempo por empresa, evaluando uno, tres, cinco y siete días consecutivos para predecir el siguiente día, con 17 características en cada día evaluado. El conjunto de variable objetivo se enfocará en el precio de cierre (Close) y tendrá una dimensionalidad de aproximadamente (1247, 1) [8].

Estos conjuntos se dividirán en entrenamiento, validación y prueba para el entrenamiento y evaluación del modelo respectivo. Este enfoque integrado proporciona una base sólida para analizar y predecir el comportamiento del mercado de acciones en función del sentimiento social y los factores macroeconómicos.

Los modelos reciben canales concatenados, los 6 canales conformarán una sola secuencia para que sea adaptable a las primeras capas de los modelos, debido a la concatenación los datos de cada canal se combinan a lo largo de la tercera dimensión de características, haciendo que los nuevos datos tengan dimensionalidad de (muestras, pasos de tiempo, características concatenadas).

Todos los modelos concluyen con una capa MLP de salida de 6 unidades, que representa las 6 salidas del modelo. La capa de salida produce un vector de tamaño variable, dependiendo del número de series temporales que se están analizando. Cada elemento en este vector representa una predicción para una serie temporal específica. Por lo tanto, si se están analizando 6 series temporales, la capa de salida generará un vector de tamaño 6, donde cada elemento del vector corresponde a una predicción para una empresa en particular.

### **Arquitectura LSTM de Múltiples entradas y múltiples salidas secuenciales**

Se realizan 4 modelos con la misma estructura en LSTM, se varia la ventana de tiempo (1, 3, 5 y 7 días) y los hiper parámetros que sean mejor adaptados a cada caso. Todos los modelos se componen de 3 capas principales: capa LSTM, capa Dropout y capa de salida MLP. Se utilizan 4 hiper parámetros optimizados durante el proceso de búsqueda de hiper parámetros. “hp\_units1” determina el número de unidades en la capa LSTM, mientras que “hp\_alpha” determina el parámetro de inclinación para la función de activación LeakyReLU, “hp\_l1” determina el valor de la regularización l2 para la capa LSTM y “hp\_l2” determina el valor de la regularización l2 para la capa de salida MLP.




Figura # 2. Modelos de Red Neuronal LSTM con entradas y salidas

## Hiper parámetros

Los hiper parámetros elegidos para la arquitectura son los siguientes:

Tabla # 1. Hiper parámetros optimizados LSTM

Hiper parámetro	Valor
Unidades	Rango 50-190 en saltos de 4
Alpha	Rango 0.1-0.3 en saltos de 0.1
L1	0.001, 0.01, 0.1, 0.2
L2	0.0001, 0.001

Tabla # 2. Hiper parámetros constantes LSTM

Hiper parámetro	Valor
Capas	(3) [(1) LSTM, (1) Dropout (0.2), (1) Dense]
Activación LSTM	LeakyReLU
Optimizador	Adam (tasa de aprendizaje=1e-4)


Tabla # 3. Hiper parámetros LSTM para diferentes tamaños de ventana de tiempo

	LSTM resultados de hiper parámetros por ventana (días)			
Hiper parámetro	1	3	5	7
Unidades	94	178	178	178
Alpha	0.1	0.1	0.1	0.1
L1	0.001	0.001	0.001	0.001
L2	0.0001	0.0001	0.0001	0.0001

En algunos casos se decidieron conservar los hiper parámetros predeterminados de “Keras”.

### Arquitectura GRU de Múltiples entradas y múltiples salidas secuenciales

Se realizan 4 modelos con la misma estructura en GRU, se varia la ventana de tiempo (1, 3, 5 y 7 días) y los hiper parámetros que sean mejor adaptados a cada caso. Todos los modelos se componen de 3 capas principales: capa GRU, capa Dropout y capa de salida MLP. Se utilizan 4 hiper parámetros optimizados durante el proceso de búsqueda de hiper parámetros. “hp\_units1” determina el número de unidades en la capa GRU, mientras que “hp\_alpha” determina el parámetro de inclinación para la función de activación LeakyReLU, “hp\_l1” determina el valor de la regularización l2 para la capa GRU y “hp\_l2” determina el valor de la regularización l2 para la capa de salida MLP.






Figura # 3. Modelos de Red Neuronal GRU con entradas y salidas

## Hiper parámetros

Los hiper parámetros elegidos para la arquitectura son los siguientes:

Tabla # 4. Hiper parámetros optimizados GRU

Hiper parámetro	Valor
Unidades	Rango 50-190 en saltos de 4
Alpha	Rango 0.1-0.3 en saltos de 0.1
L1	0.001, 0.01, 0.1, 0.2
L2	0.0001, 0.001

Tabla # 5. Hiper parámetros constantes GRU

Hiper parámetro	Valor
Capas	(3) [(1) GRU, (1) Dropout (0.2), (1) Dense]
Activación LSTM	LeakyReLU
Optimizador	Adam (tasa de aprendizaje=1e-4)

Tabla # 6. Hiper parámetros GRU para diferentes tamaños de ventana de tiempo

Hiper parámetro	GRU resultados de hiper parámetros por ventana (días)			
	1	3	5	7
Unidades	178	174	122	94
Alpha	0.1	0.2	0.1	0.1
L1	0.01	0.01	0.01	0.01
L2	0.0001	0.0001	0.0001	0.0001

En algunos casos se decidieron conservar los hiper parámetros predeterminados de “Keras”.



## Arquitectura TCN de Múltiples entradas y múltiples salidas secuenciales

El modelo se compone de las siguientes capas: TCN (esta capa contiene más capas convolucionales dilatadas) y 2 capas MLP. Se utilizan 7 hiper parámetros optimizados durante el proceso de búsqueda de hiper parámetros. “hp\_ks” determina el número de unidades en kernel size de la capa TCN, “hp\_nb” determina el número de filtros a usar, “hp\_dp” determina la tasa del Dropout, “hp\_alpha” el parámetro de inclinación para la función de activación LeakyReLU, “hp\_units1” el número de unidades en una de las capas MLP, finalmente “hp\_11” y “hp\_12” son los valores que tomarán los regularizadores l2 en las capas MLP.




Figura # 4. Modelos de Red Neuronal TCN con entradas y salidas

## Hiper parámetros

Los hiper parámetros elegidos para la arquitectura son los siguientes:

Tabla # 7. Hiper parámetros optimizados TCN

Hiper parámetro	Valor
Tamaño del Kernel	Rango 3-6 en saltos de 1
Alpha	Rango 0.1-0.3 en saltos de 0.1
Filtros	Rango 16-240 en saltos de 16
Dilataciones	Se calcula según n_layers
Dropout	0.0, 0.2, 0.3
Unidades	Rango 20-160 en saltos de 4
L1	0.01, 0.1, 0.2
L2	0.0001, 0.001

Tabla # 8. Hiper parámetros constantes TCN

Hiper parámetro	Valor
Capas	(3) [TCN (Contiene más capas convolucionales), (2) Dense]
Activación TCN y Dense	LeakyReLu
Regularizador	l2
Optimizador	Adam (tasa de aprendizaje=1e-4)
Padding	Causal

Tabla # 9. Hiper parámetros TCN para diferentes tamaños de ventana de tiempo

Hiper parámetro	TCN resultados de hiper parámetros por ventana (días)			
	1	3	5	7
Tamaño del Kernel	6	6	4	3
Alpha	0.1	0.2	0.2	0.2
Filtros	192	192	208	80
Dropout	0.0	0.0	0.2	0.0
Unidades	56	68	48	152
L1	0.01	0.1	0.1	0.1
L2	0.0001	0.001	0.0001	0.001

En algunos casos se decidieron conservar los hiper parámetros predeterminados de “Keras-TCN”, es importante mencionar que, a pesar de que la implementación de Keras-TCN permite agregar la arquitectura TCN como una sola capa, TCN está compuesta por bloques residuales que internamente contienen capas convolucionales 1D.

### **Métodos de Evaluación**

Time Series Split es un método de validación cruzada adaptado para la evaluación de modelos de series de tiempo. Este método divide cada una de las secuencias de los canales en 15 subconjuntos, y por medio del método de ventana creciente se evalúa el desempeño del modelo 15 veces para todas las secuencias lo que da un total de 90 subconjuntos a analizar tanto para conjuntos de entrenamiento, validación y prueba. Es importante mencionar que el 20% de los datos de entrenamiento fueron destinados para el conjunto de validación. El desempeño de todos los modelos se evalúan mediante la medición de las siguientes métricas: error cuadrado medio (MSE), error absoluto medio (MAE), error porcentual absoluto medio (MAPE), Error cuadrático medio raíz (RMSE) y error porcentual medio (MPE).

## **RESULTADOS**

A continuación, se presentan los resultados promedio de la evaluación de las arquitecturas mediante las métricas de error preestablecidas en un gráfico de barras. Estas evaluaciones se llevaron a cabo sobre el conjunto de entrenamiento, validación y prueba para cada una de las ventanas de retroceso, en todas las arquitecturas. En general la métrica MSE en todos los modelos va aumentando de forma significativa el conjunto de validación y prueba con respecto al entrenamiento, para LSTM la ventana de 7 días, GRU 3 días y TCN 5 días son las mejores ventanas. Esto es un resumen de lo que fue el desempeño de cada uno de los modelos, en los anexos B, C y D se pueden apreciar de manera más detallada los resultados.

## LSTM

RMSE la cual indica cuanta es la diferencia entre los valores reales y las predicciones. En esta arquitectura la ventana 3 y 7 son muy parecidas, para la ventana de 3 días existe 2.97\$ en validación y 4.80\$ en prueba, por otro lado, para la ventana de 7 días 2.90\$ en validación y 5.03\$ en prueba. A pesar de que el valor de entrenamiento es mayor a en 3 días en comparación a 7 días, se puede decir que la ventana de 3 días se desempeña mejor debido a la poca diferencia con el conjunto de entrenamiento.

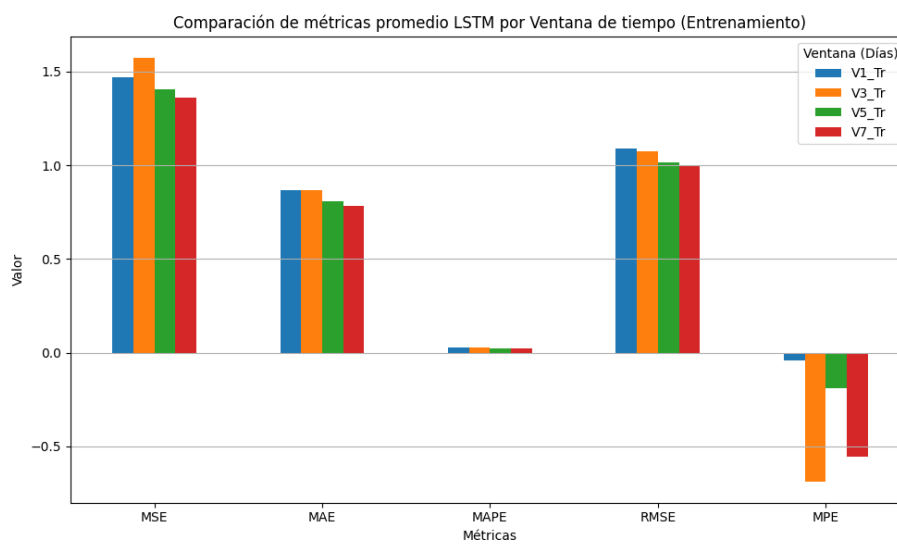


Figura # 5. Métricas promedio LSTM para conjunto de entrenamiento




Figura # 6. Métricas promedio LSTM para conjunto de validación




Figura # 7. Métricas promedio LSTM para conjunto de prueba

## GRU

RMSE en esta arquitectura la ventana 5 y 7 son parecidas, para la ventana de 5 días existe 3.36\$ en validación y 5.20\$ en prueba, por otro lado, para la ventana de 7 días 3.19\$ en validación y 5.11\$ en prueba. A pesar de que el valor de entrenamiento es mayor en 7 días en comparación a 5 días, se puede decir que la ventana de 7 días se desempeña mejor debido a la poca diferencia con el conjunto de entrenamiento.

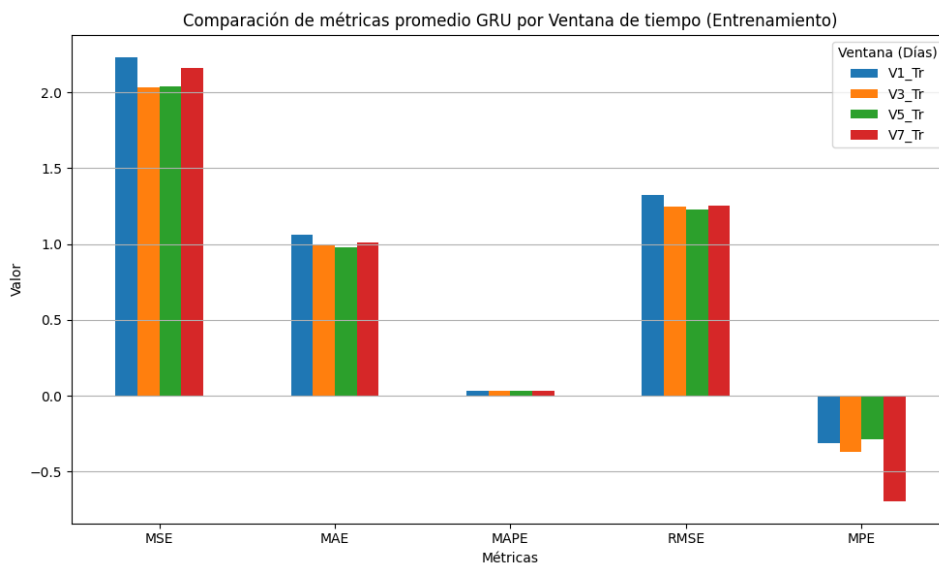


Figura # 8. Métricas promedio GRU para conjunto de entrenamiento




Figura # 9. Métricas promedio GRU para conjunto de validación

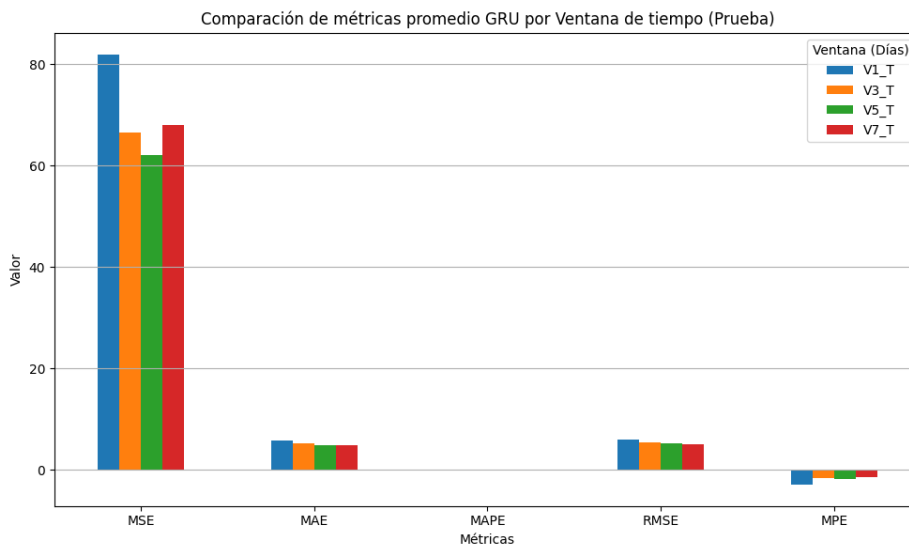


Figura # 10. Métricas promedio GRU para conjunto de prueba

## TCN

RMSE en esta arquitectura la ventana 1 y 5 son parecidas, para la ventana de 1 día existe 3.10\$ en validación y 4.92\$ en prueba, por otro lado, para la ventana de 5 días 3.26\$ en validación y 5.12\$ en prueba. El valor de entrenamiento en 1 día en comparación a los demás es mucho menor, se puede decir que la ventana de 1 día se desempeña mejor debido a la poca diferencia con el conjunto de entrenamiento.




Figura # 11. Métricas promedio TCN para conjunto de entrenamiento




Figura # 12. Métricas promedio TCN para conjunto de validación




Figura # 13. Métricas promedio TCN para conjunto de prueba

Tabla # 10. Métricas promedio LSTM, GRU y TCN de las mejores 2 ventanas de tiempo.

Conjunto	Modelo	MSE	MAE	MAPE	RMSE	MPE
Entrenamiento	LSTM (V3)	1.5752	0.8674	0.0267	1.0760	-0.6868
Validación	LSTM (V3)	18.9458	2.5544	0.0562	2.9718	-0.6313
Prueba	LSTM (V3)	54.3599	4.4960	0.0911	4.8027	0.27067
<b>Entrenamiento</b>	<b>LSTM (V7)</b>	<b>1.36388</b>	<b>0.7858</b>	<b>0.0241</b>	<b>0.9949</b>	<b>-0.5544</b>
<b>Validación</b>	<b>LSTM (V7)</b>	<b>16.9406</b>	<b>2.4890</b>	<b>0.0544</b>	<b>2.9077</b>	<b>-0.1835</b>
<b>Prueba</b>	<b>LSTM (V7)</b>	<b>55.2682</b>	<b>4.6255</b>	<b>0.0926</b>	<b>5.0331</b>	<b>0.72245</b>
Entrenamiento	GRU (V5)	2.04044	0.9789	0.0307	1.2247	-0.2884
Validación	GRU (V5)	22.4253	2.9100	0.0639	3.3620	-1.5660
Prueba	GRU (V5)	62.1675	4.9018	0.0962	5.2027	-1.7654
<b>Entrenamiento</b>	<b>GRU (V7)</b>	<b>2.16172</b>	<b>1.0067</b>	<b>0.0317</b>	<b>1.2499</b>	<b>-0.6953</b>
<b>Validación</b>	<b>GRU (V7)</b>	<b>22.8293</b>	<b>2.7627</b>	<b>0.0570</b>	<b>3.1931</b>	<b>-1.2442</b>
<b>Prueba</b>	<b>GRU (V7)</b>	<b>67.9921</b>	<b>4.8053</b>	<b>0.0895</b>	<b>5.1154</b>	<b>-1.3895</b>
Entrenamiento	TCN (V1)	1.71508	0.8427	0.0256	1.0304	-0.4899
Validación	TCN (V1)	20.9028	2.6951	0.0581	3.1058	-1.1271
Prueba	TCN (V1)	56.2124	4.6507	0.0918	4.9216	-1.5748
<b>Entrenamiento</b>	<b>TCN (V5)</b>	<b>3.71585</b>	<b>1.2237</b>	<b>0.0379</b>	<b>1.4732</b>	<b>0.77102</b>
<b>Validación</b>	<b>TCN (V5)</b>	<b>17.8381</b>	<b>2.7966</b>	<b>0.0673</b>	<b>3.2694</b>	<b>-0.3658</b>
<b>Prueba</b>	<b>TCN (V5)</b>	<b>50.9575</b>	<b>4.7805</b>	<b>0.1060</b>	<b>5.1268</b>	<b>0.22639</b>

Según la tabla 10 la mejor métrica es LSTM con ventana de tiempo 7 aun así se puede ver que existe considerable diferencia en los resultados de las métricas, sin embargo, esto se debe a la naturaleza de las secuencias de tiempo ya que son variables y también que se recomendaría tener un conjunto de datos más grande. Por esa razón es que los resultados no son tan satisfactorios como



se esperaría, pero es un buen enfoque de como por muchos factores intervienen en los modelos y hacen que sus resultados cambien completamente así sea por un mínimo cambio.

Las secuencias más variables son AMZN y MSFT por lo que se realizó una prueba con la mejor métrica LSTM de ventana de 7 días sin estas secuencias de tiempo teniendo los siguientes resultados.

*Tabla # 11. Métricas promedio LSTM sin AMZN y MSFT*

	<b>MSE</b>	<b>MAE</b>	<b>MAPE</b>	<b>RMSE</b>	<b>MPE</b>
Entrenamiento	1.02485475	0.72105525	0.03874775	0.9057785	0.11293
Validación	5.3097615	1.69168725	0.05229	1.97590375	0.6167705
Prueba	13.1952375	2.730878	0.08369225	3.00980125	2.43468575

Se puede notar que los resultados de este modelo son mucho mejor a comparación con todos los demás realizados, es importante aclarar que nunca van a ser perfectos ya que la predicción de series de tiempo siempre va a tener márgenes de error, pero con esta prueba se puede ver que en efecto si se mejoran significativamente los resultados. Por lo que a futuro se puede seguir con el estudio y encontrar muchas más series temporales con menos variabilidad.

Para revisar de mejor manera la programación del proyecto se recomienda ver el repositorio que está disponible en el anexo A y para tener una mejor perspectiva del entrenamiento y desempeño de todos los modelos se recomienda ver el Anexo B, C, D, E y F.

## CONCLUSIONES

El objetivo fundamental de este proyecto fue construir y determinar la arquitectura más eficiente, considerando la eficacia para la predicción de precios de cierre de acciones y su desempeño según sus métricas. A través de la utilización de datos provenientes de diferentes contextos, se llevó a cabo un análisis extenso utilizando varias métricas de evaluación. El enfoque consistió en evaluar 3 arquitecturas de aprendizaje profundo unidireccionales distintas, cada arquitectura teniendo diferentes ventanas de retroceso de 1, 3, 5 y 7 días, por lo tanto, se construyeron un total de 12 modelos de aprendizaje profundo, con el objetivo de determinar los modelos óptimos para cada arquitectura.

Con respecto a los resultados de las predicciones en general muestran que conforme va avanzando el número de evaluaciones los resultados en efecto mejoran, sin embargo, existen evaluaciones que a pesar de estar en las mejores condiciones para mostrar resultados favorables no lo hacen y se debe a que existen secuencias con considerable variabilidad lo cual provoca que tanto las predicciones como las evaluaciones en las métricas no sean satisfactorios.

En la culminación de este proyecto se logró determinar que estructura más eficiente evaluada en este contexto. La LSTM con ventana de retroceso de 7 días, logró el mejor desempeño evaluando simplemente las métricas de error. Dentro de mismo proyecto surgieron aspectos, que por cuestiones de tiempo quedaron para posibles investigaciones futuras, por ejemplo, seguir explorando más arquitecturas bidireccionales, probar más configuraciones de los hiper parámetros, modificar más las ventanas de retroceso y también las ventanas al futuro, con el propósito de entender mejor las herramientas propuestas.

## REFERENCIAS BIBLIOGRÁFICAS

- [1] N.Heredia, “Predicción del precio de acciones mediante técnicas de minería de datos”, Tesis de maestría, Universidad Politécnica de Madrid, 2016.
- [2] J. Brownlee, "Predict the Future with MLPs, CNNs and LSTMs in Python," Deep Learning for Time Series Forecasting, 2018. [Online]. Disponible : <https://machinelearningmastery.com/deep-learning-for-time-series-forecasting/>.
- [3] Y. O. Lao-León, A. Rivas-Méndez, M. C. Pérez-Pravia, & F. Marrero-Delgado. “Procedimiento para el pronóstico de la demanda mediante redes neuronales artificiales”. *Ciencias Holguín*, 2017, 23(1), 43-59.
- [4] J. Du, Q. Liu, K. Chen and J. Wang, "Forecasting stock prices in two ways based on LSTM neural network," 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), Chengdu, China, 2019, pp. 1083-1086, doi: 10.1109/ITNEC.2019.8729026.
- [5] M. Guimerá Castell, "Predicción de índices bursátiles por medio de redes neuronales artificiales. Aplicación al caso del IBEX 35", Tesis de maestría, Universitat Politècnica de València, 2020.
- [6] E. B. Kim, J. H. Park, Y. S. Lee y C. Lim, "Two-dimensional attention-based multi-input LSTM for time series prediction", *Communications for Statistical Applications and Methods*, vol. 28, no. 1, pp. 39-57, 2021.
- [7] C. Yang, J. Zhai, and G. Tao, "Deep Learning for Price Movement Prediction Using Convolutional Neural Network and Long Short-Term Memory", *Mathematical Problems in Engineering*, vol. 2020, Article ID 2746845, 13 pages, 2020. [Online]. Disponible: <https://doi.org/10.1155/2020/2746845>
- [8] J. Sánchez, “Evaluación de arquitecturas de aprendizaje automático en predicción de precio de acciones integrado con análisis de sentimiento y factores macroeconómicos.”, Proyecto Integrador, Universidad San Francisco de Quito, 2023.

- [9] Google LLC, Kaggle, "USA key economic indicators." Disponible: <https://www.kaggle.com/datasets/calven22/usa-key-macroeconomic-indicators>, 2022.
- [10] H. Li, Y. Shen y Y. Zhu, "Stock price prediction using attention-based multi-input LSTM." Asian conference on machine learning. PMLR, 2018.
- [11] E. Solís, S. Noboa, & E. Cuenca. "Financial time series forecasting applying deep learning algorithms." In *Conference on Information and Communication Technologies of Ecuador*, (pp. 46-60). Cham: Springer International Publishing. 2021
- [12] ISO/IEC. ISO/IEC 23053:2022 - Information technology -- Artificial intelligence -- Framework for Artificial Intelligence (AI) Systems Using Machine Learning (ML). [Online]. Disponible : <https://www.iso.org/standard/74438.html?browse=tc>, 2022.
- [13] Bai, S., Kolter, J. Z., & Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling.
- [14] Lea, C., Flynn, M. D., Vidal, R., Reiter, A., & Hager, G. D. (2016). Temporal Convolutional Networks for Action Segmentation and Detection.
- [15] Zhang, C., Sjarif, N. N. A., & Ibrahim, R. (2024). 1D-CapsNet-LSTM: A deep learning-based model for multi-step stock index forecasting. *Journal of King Saud University - Computer and Information Sciences*. <https://doi.org/10.1016/j.jksuci.2024.101959>

## Anexo A: Repositorio GITHUB


[MI PricePrediction.git](#)

## Anexo B: Promedios De Curvas De Aprendizaje Por Fold


A continuación, se presentan las curvas de aprendizaje promedio de los 15 Time Series Split de entrenamiento y validación de cada modelo con sus desviaciones estándares correspondientes.

### LSTM


#### Ventana 1 día



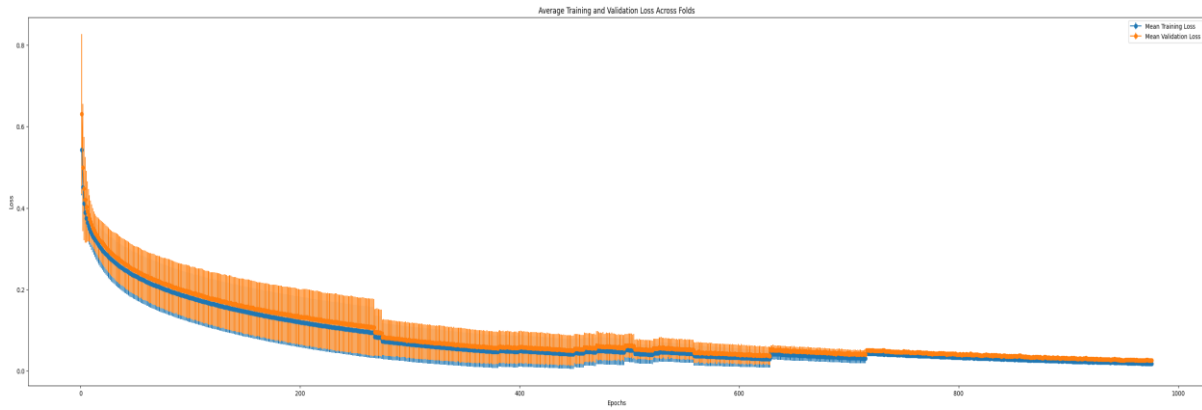
#### Ventana 3 días



#### Ventana 5 días




### Ventana 7 días

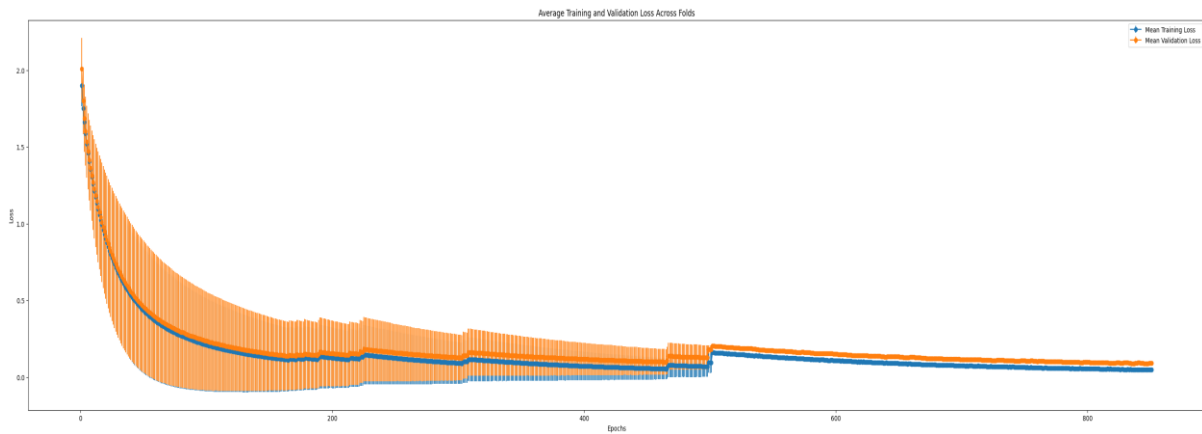


### GRU


### Ventana 1 día




### Ventana 3 días



### Ventana 5 días




## Ventana 7 días




## TCN

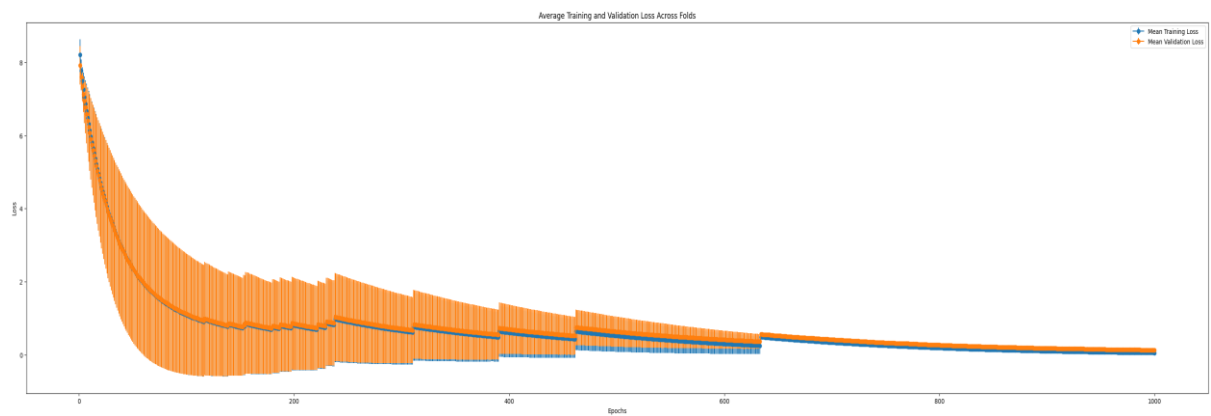
## Ventana 1 día




## Ventana 3 días



## Ventana 5 días




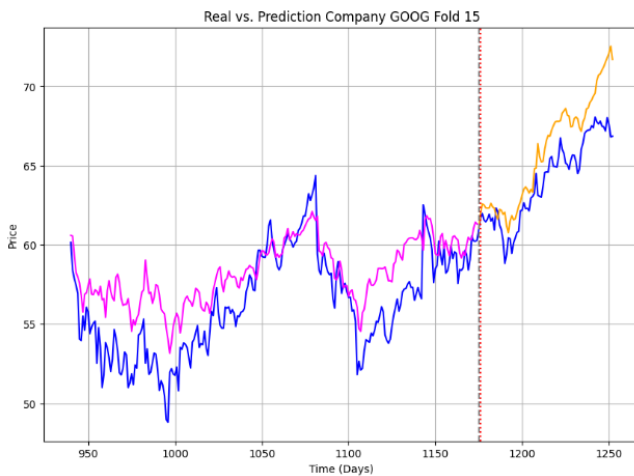



### Ventana 7 días





## Anexo C: Predicciones y métricas LSTM

A continuación de muestran todas las predicciones para todas las ventanas de tiempo.

### Ventana de tiempo 1 día







### Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.151642592	0.8140633672	0.0269748538	1.005857838	-0.11121221
AMZN	2.702326422	1.177705801	0.03910890712	1.495165241	0.03606274952
GOOG	0.789851872	0.6637790237	0.01973627144	0.8521862408	-0.09639943052
GOOGL	0.8713479431	0.7070898755	0.02041731827	0.8922787191	-0.06153005485
MSFT	2.851232224	1.306197773	0.02572355959	1.630813274	-0.1807734435
TSLA	0.4555469492	0.5323893553	0.03490168449	0.6558266019	0.1802992233






### Validación



	MSE	MAE	MAPE	RMSE	MPE
AAPL	8.549391839	2.097376572	0.05646415089	2.46580456	0.03279330187
AMZN	52.51175679	4.677096827	0.08141474981	5.353602624	-4.696595877
GOOG	5.238129217	1.720548515	0.03923686232	2.013061647	-0.4478194079
GOOGL	4.898403753	1.679555812	0.03775722463	1.961765836	-0.1636797309
MSFT	47.34160449	4.649658461	0.05522303445	5.393984752	-4.809436772
TSLA	5.893276211	1.876732953	0.1046663041	2.166010165	5.643325239

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	21.78667482	3.666502991	0.0935017761	4.070913425	-0.6308907699
AMZN	110.0887697	7.594904019	0.1152807531	8.027438059	-5.768534224
GOOG	10.39443546	2.495025796	0.05544232476	2.752892002	0.5344931405
GOOGL	10.30165352	2.586554548	0.05668427002	2.855612931	1.109087678
MSFT	183.7690268	9.766035272	0.09749319159	10.03636214	-8.987505751
TSLA	16.00235485	3.267953708	0.1851105477	3.479171946	13.63491907

## Ventana de tiempo 3 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	0.8761778795	0.6969792958	0.0229373742	0.8655015893	-0.4616760424
AMZN	2.707451828	1.162029477	0.03759088191	1.424409475	-1.239723693
GOOG	1.06854552	0.7579382658	0.02185619929	0.9496882808	-0.7554966498
GOOGL	1.116202558	0.7683640611	0.02153661153	0.964776158	-0.784077746
MSFT	3.22637461	1.320731251	0.02454850996	1.63322323	-0.7326461029
TSLA	0.4567331438	0.4989158435	0.03200789216	0.6189491445	-0.1472992844


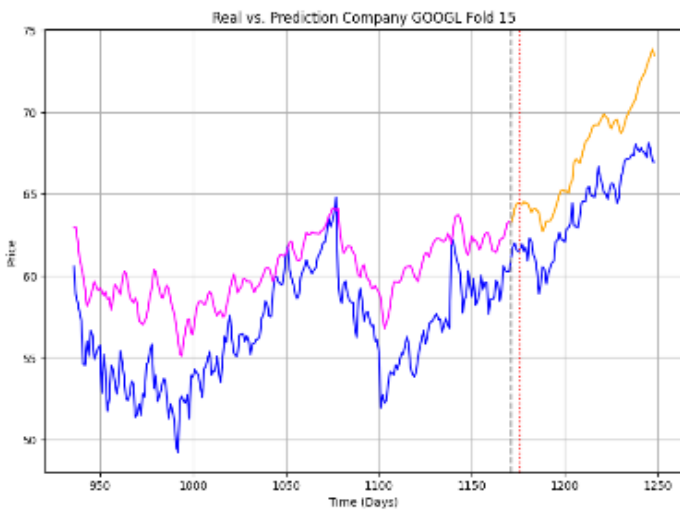



## Validación



	MSE	MAE	MAPE	RMSE	MPE
AAPL	6.305782678	1.794725417	0.04800791995	2.161575661	0.4418294602
AMZN	50.62546772	4.659007213	0.08202324499	5.348208737	-4.668897336
GOOG	5.309747453	1.682954981	0.0396597331	1.912188444	-0.3704366946
GOOGL	4.633493309	1.618080042	0.03705440157	1.861746059	0.1017130619
MSFT	43.10635365	4.101028211	0.04721636885	4.827195298	-3.77462747
TSLA	3.694089249	1.470645108	0.08362161077	1.719973073	4.482076301

Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	17.45287928	3.386414249	0.08890527737	3.770288984	1.191922606
AMZN	105.8583104	7.405137255	0.1199692707	7.855189707	-6.301337631
GOOG	11.64440084	2.500582619	0.0575014651	2.722267688	0.8957552084
GOOGL	8.70143903	2.394267358	0.05345511284	2.617497609	2.451416053
MSFT	172.3619459	8.749045002	0.08331251717	9.060643769	-7.17117036
TSLA	10.14095979	2.540804751	0.1438281062	2.790576415	10.55747221

Ventana de tiempo 5 días





### Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	0.7990839565	0.6428282068	0.02125454035	0.8075860273	-0.1144432535
AMZN	2.119854961	0.997559681	0.03233741067	1.254915683	-0.4424966035
GOOG	1.022978238	0.7154976718	0.02043898375	0.9020528781	-0.2672315121
GOOGL	1.092004426	0.7390429454	0.02046249542	0.9293377137	-0.2089279045
MSFT	2.880266377	1.24331704	0.02350626392	1.549961611	-0.3353325824
TSLA	0.5241141454	0.5196962657	0.03288299438	0.6405835138	0.2475233266






### Validación



	MSE	MAE	MAPE	RMSE	MPE
AAPL	7.539202114	2.040309579	0.05429546877	2.437837522	0.5929315592
AMZN	48.39044293	4.527130369	0.07795584049	5.146380546	-3.940624692
GOOG	6.195959651	1.924497549	0.04417929992	2.187744044	-0.1092837762
GOOGL	6.535950538	2.04255394	0.04590398086	2.300854809	0.1724197679
MSFT	43.40083949	4.426376308	0.0527238407	5.13358249	-3.894100047
TSLA	3.862008846	1.462941752	0.08292894092	1.717013626	3.999598636

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	21.46381273	3.647532998	0.09670549781	4.124471071	0.9511464403
AMZN	101.9780159	7.515524261	0.1200717978	8.058697142	-5.065240859
GOOG	13.08357459	2.668865612	0.06000824132	2.922572139	0.8291802458
GOOGL	11.50286803	2.629316443	0.05701668337	2.868093576	1.089207388
MSFT	180.6376737	9.207935816	0.09020641397	9.518439504	-7.242874436
TSLA	8.590149073	2.391012679	0.1326769683	2.63305234	8.144493951

## Ventana de tiempo 7 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	0.7753966925	0.6456875097	0.0213180357	0.809274905	-0.16788113
AMZN	2.349805785	1.010335465	0.0315343382	1.280111177	-0.9124834126
GOOG	0.9431131369	0.6849286619	0.01952298062	0.8787361242	-0.8704465755
GOOGL	1.030090782	0.7136271085	0.01981294932	0.9153826256	-0.9099818198
MSFT	2.674714321	1.17971351	0.02215512111	1.48521865	-0.2075166054
TSLA	0.4101594865	0.4806649695	0.03051272819	0.6008734247	-0.2585615312

## Validación

	MSE	MAE	MAPE	RMSE	MPE
AAPL	8.42765362	2.175303402	0.05794422306	2.52920533	0.3187037052
AMZN	43.34855706	4.509408298	0.08198293419	5.190754939	-3.29621863
GOOG	4.284732114	1.534394161	0.03333095464	1.803227049	0.793086285
GOOGL	4.01861952	1.458251117	0.03087033604	1.721681541	0.4556796612
MSFT	38.56331068	3.901283304	0.04544547492	4.616193829	-2.427811596
TSLA	3.001241097	1.355464841	0.07694631747	1.58565918	3.055347563

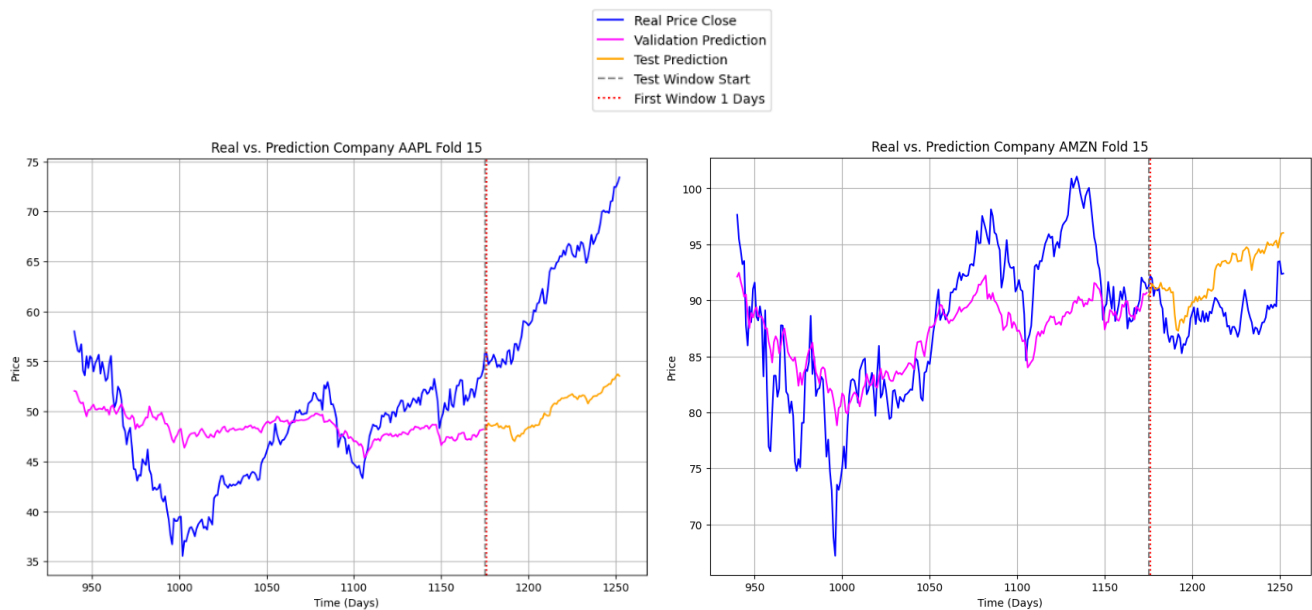
## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	21.28624162	3.732034764	0.1016040808	4.164120924	1.173547049
AMZN	100.6607847	7.395434925	0.1184844467	7.901897926	-4.314443317
GOOG	14.04524498	2.453372641	0.05534313609	2.870404816	1.138340566
GOOGL	11.11750782	2.317722479	0.05073366502	2.682076728	1.099400566
MSFT	176.5814834	9.644017827	0.1016927759	10.11807814	-4.806458122
TSLA	7.918024011	2.210657194	0.1280115971	2.46259261	10.04432093





## Anexo D: Predicciones y métricas GRU

A continuación se muestran todas las predicciones para todas las ventanas de tiempo.

## Ventana de tiempo 1 día







## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.574954036	0.9608944159	0.03182264801	1.182758038	-0.3423282269
AMZN	4.372401294	1.421661861	0.04443534026	1.807015707	-0.6822974664
GOOG	1.296031138	0.8433843007	0.02471211619	1.066530111	-0.3072553348
GOOGL	1.38866898	0.8872018541	0.02537780567	1.104360293	-0.1917808528
MSFT	3.856391985	1.523344851	0.02929841941	1.878847784	-0.4356443456
TSLA	0.9033364403	0.7330737618	0.04731588217	0.8981199293	0.08178752066




## Validación





	MSE	MAE	MAPE	RMSE	MPE
AAPL	11.44585787	2.481448212	0.06562062201	2.889835719	-2.171366835
AMZN	75.42859587	5.924727489	0.101716648	6.670973408	-7.524391353
GOOG	8.048586001	2.155753008	0.04830946656	2.496322308	-1.888731231
GOOGL	7.339818307	2.087907111	0.04634267789	2.417887506	-1.374183926
MSFT	73.47163417	6.203932201	0.0732302192	6.944864336	-6.92702262
TSLA	9.024175995	2.335200187	0.1279810995	2.649989171	6.144992234

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	32.68629013	4.406093858	0.1081267171	4.778794819	-4.390360727
AMZN	143.9199902	8.556338262	0.127560904	8.928174856	-10.20182319
GOOG	13.76619825	2.779960288	0.06069428783	3.054617675	-1.932824799
GOOGL	12.06150937	2.709731669	0.05844964542	3.001338528	-0.9541173766
MSFT	269.5274287	12.36691959	0.1241340344	12.63654956	-12.05858232
TSLA	19.84953869	3.644540004	0.2027991904	3.891883067	12.39134353

## Ventana de tiempo 3 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.386424516	0.8637034521	0.02853374616	1.069033853	-0.3346240418
AMZN	3.630841419	1.362924781	0.04442784986	1.677860496	-0.4427579289
GOOG	1.323928222	0.8306733511	0.02426652437	1.059446529	-0.2923821768
GOOGL	1.407843361	0.8646493941	0.02455240431	1.092033105	-0.2950906223
MSFT	3.746726325	1.428889709	0.02765542183	1.812909944	-0.2561098915
TSLA	0.716183385	0.6359692332	0.0408326658	0.7783389907	-0.6046422455




## Validación





	MSE	MAE	MAPE	RMSE	MPE
AAPL	8.79959511	2.147849797	0.05667310326	2.528377335	-0.8005689343
AMZN	62.52981349	5.230627359	0.0935202983	5.921800497	-5.819568016
GOOG	7.85102656	2.139884626	0.04799108066	2.440117091	-1.273389812
GOOGL	7.368120167	2.074671903	0.04592644986	2.381013204	-0.8496310481
MSFT	51.97460329	5.011003194	0.0596951637	5.747802966	-5.356620767
TSLA	5.99932543	1.852786403	0.1014413361	2.136915966	4.54819585

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	27.00668231	3.907382172	0.09490815116	4.307927347	-2.311345397
AMZN	131.149875	8.199019653	0.1264616051	8.51365142	-7.140805185
GOOG	13.31107193	2.8285212	0.06122734341	3.114228401	-0.8779295255
GOOGL	12.62223589	2.844549523	0.06108676555	3.113017373	0.01764875012
MSFT	200.1375086	10.23253549	0.1004694378	10.5083182	-9.383544879
TSLA	14.55787652	3.080811266	0.1701631915	3.280875649	10.60454132

## Ventana de tiempo 5 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.301076461	0.8340110798	0.02767607542	1.033051014	-0.186712716
AMZN	3.964458137	1.363213377	0.0437155595	1.693759155	-0.537117196
GOOG	1.3046683	0.8142313951	0.02366464732	1.031193442	-0.2839904828
GOOGL	1.425686936	0.8562025136	0.024295275	1.076288891	-0.243041143
MSFT	3.647622517	1.415489411	0.02724317684	1.785779007	-0.2411949096
TSLA	0.5991355796	0.5904366484	0.03819093821	0.7283810236	-0.238690624

## Validación




	MSE	MAE	MAPE	RMSE	MPE
AAPL	9.275337529	2.193310679	0.05778688922	2.619174804	-0.7977955041
AMZN	58.48274301	5.025768339	0.09052319446	5.685691583	-5.881859934
GOOG	5.861319944	1.838491411	0.04169770047	2.136464624	-1.044574169





GOOGL	6.003849951	1.855549446	0.04184857922	2.149734483	-0.7421213837
MSFT	49.603961	4.831313427	0.05726116544	5.595258258	-5.009405596
TSLA	5.324796813	1.7161163	0.09454922241	1.985850269	4.079646777

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	25.24863501	3.987294538	0.09887927851	4.365035945	-2.239598838
AMZN	119.6433573	7.700909261	0.1185037216	8.052243066	-7.926667079
GOOG	9.575376681	2.362947168	0.05250481662	2.641501232	-0.6611512806
GOOGL	9.747431161	2.470313223	0.05461716168	2.74298382	-0.08387132515
MSFT	195.6734357	10.06198634	0.0979617299	10.34296845	-9.096809382
TSLA	13.11700792	2.827700843	0.1548955905	3.071511669	9.415305429

## Ventana de tiempo 7 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.320660037	0.8551305669	0.02804481833	1.051630756	-0.8494006394
AMZN	3.918189385	1.364282169	0.04498968404	1.670151011	-0.508911168
GOOG	1.364431329	0.8291893103	0.02392383694	1.05510914	-0.6601391708
GOOGL	1.549735969	0.8851435864	0.02486899334	1.11083049	-0.7312494446
MSFT	4.056626151	1.462794927	0.02776783348	1.831254145	-0.413756416
TSLA	0.7607054367	0.6439606426	0.04071250114	0.7808322108	-1.008797126

## Validación

	MSE	MAE	MAPE	RMSE	MPE
AAPL	8.935261843	2.190965631	0.05787500278	2.555500224	-1.074367055
AMZN	58.4418758	4.726590679	0.07657885112	5.406367562	-4.543165024
GOOG	4.482639791	1.559569067	0.03269203663	1.832507039	-0.1781291603

GOOGL	4.75480752	1.662822721	0.03465076199	1.934623642	0.2752686997
MSFT	56.14014691	4.857886228	0.05378453244	5.601211164	-4.222029027
TSLA	4.221407084	1.578528945	0.08666343177	1.828595589	2.276798904

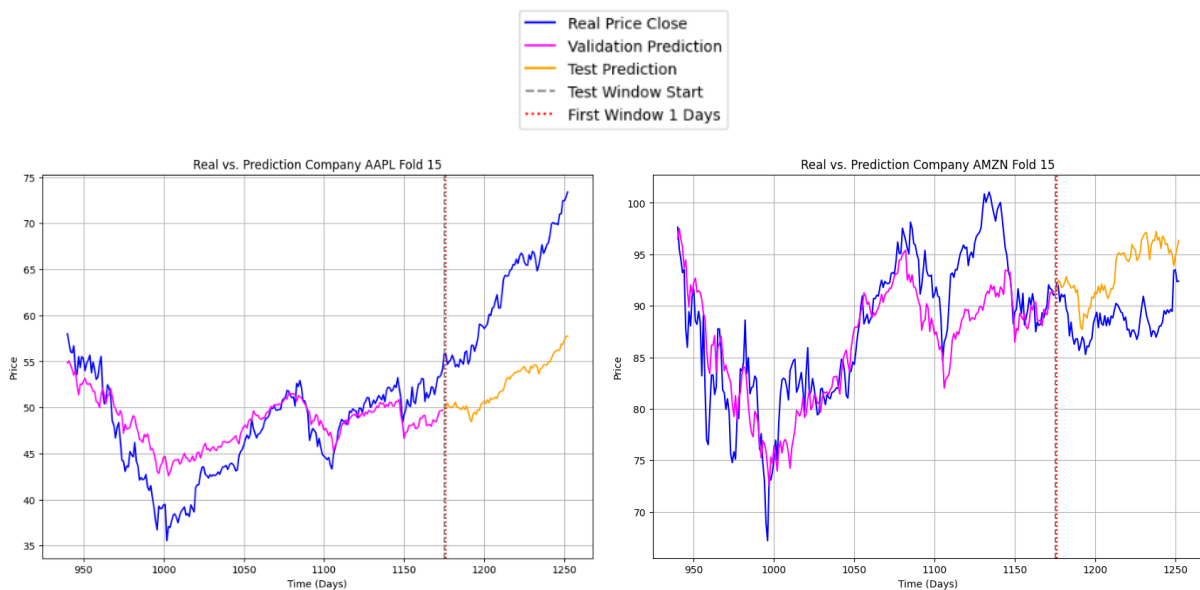
## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	27.54041003	4.19467861	0.1042891877	4.610115192	-2.771535962
AMZN	121.582836	7.489080853	0.1102760422	7.91177464	-6.303539505
GOOG	7.229229158	2.059874403	0.0431116443	2.307118906	-0.1249618546
GOOGL	7.222990025	2.013634424	0.04143832862	2.281657383	0.6212437453
MSFT	234.2096499	10.51783329	0.09771262086	10.83527805	-8.36099852
TSLA	10.16765104	2.557240412	0.1407029519	2.74673666	8.602289267


## Anexo E: Predicciones y métricas TCN

A continuación de muestran todas las predicciones para todas las ventanas de tiempo.

### Ventana de tiempo 1 día







## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	0.7586388494	0.6275099162	0.02074689753	0.7816049665	-0.2034625215
AMZN	3.566145323	1.218696369	0.0379347354	1.477483539	-0.9229220935
GOOG	1.292574997	0.7651096248	0.02133357512	0.9312704325	-0.4695155103
GOOGL	1.389053676	0.7832732369	0.02126097766	0.9529219499	-0.7120948101
MSFT	2.892967822	1.190632779	0.02212614842	1.460807307	-0.6413314683
TSLA	0.391150048	0.4710688327	0.03056230227	0.5783236989	0.009804445947

## Validación




	MSE	MAE	MAPE	RMSE	MPE
AAPL	6.075432231	1.777282358	0.0466925799	2.110024798	-0.3817308779
AMZN	55.96926663	4.886671324	0.08691911994	5.553290645	-5.043128612
GOOG	4.847993933	1.685323281	0.03919581587	1.953177253	-0.7329991543





GOOGL	4.985400183	1.72155917	0.03931767452	1.972588291	-0.5920307949
MSFT	49.68018151	4.615047803	0.05379749594	5.321589498	-4.53914855
TSLA	3.858542743	1.484901996	0.08277386437	1.724272972	4.525845741

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	18.23862712	3.254736658	0.08076594386	3.572703849	-1.802011863
AMZN	103.4078271	7.280562971	0.1145161737	7.687675492	-7.924654026
GOOG	11.21017755	2.519378825	0.05734904918	2.734514659	-0.6606401386
GOOGL	11.3156637	2.613774996	0.0579492658	2.838462566	-0.08001555044
MSFT	183.2724178	9.690205416	0.09550856169	9.958394983	-8.956731404
TSLA	9.830185436	2.545550492	0.1448910926	2.738090478	9.974778933

## Ventana de tiempo 3 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.558782533	0.8710422955	0.02929482891	1.081405726	0.8891596046
AMZN	3.769497818	1.292868171	0.04240242874	1.652457789	1.145152666
GOOG	1.640977809	0.8989169293	0.02598690881	1.094077593	0.6766765028
GOOGL	1.893917894	0.969798323	0.02725254211	1.174420225	0.796951673
MSFT	4.032131471	1.450233008	0.02773396924	1.780410358	0.8425342544
TSLA	0.9726644418	0.7088692559	0.04524543162	0.8568151091	0.52704119

## Validación




	MSE	MAE	MAPE	RMSE	MPE
AAPL	8.911166466	2.104684243	0.05541033799	2.528591291	0.2989285455
AMZN	44.54293718	4.551285692	0.0824490625	5.211116119	-3.786855886





GOOG	6.563642719	1.940017423	0.04412433404	2.24747381	0.3001297632
GOOGL	6.592676954	1.939604408	0.04354026087	2.244632327	0.5665429332
MSFT	38.75233692	4.026949244	0.04836419602	4.760205173	-3.815643952
TSLA	7.963212041	2.144233501	0.1171679405	2.420453772	5.34271105

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	23.56518652	3.705785482	0.09243136672	4.096980827	-1.258069358
AMZN	103.3057333	7.353170224	0.1157346004	7.735702935	-5.702715372
GOOG	15.15812508	2.951504279	0.06494389459	3.196981847	0.731321091
GOOGL	14.49316389	2.949973968	0.06358307766	3.211474703	1.3437471
MSFT	157.9810366	8.986933589	0.0896880454	9.297535403	-8.146175776
TSLA	17.28411636	3.236101805	0.1808124982	3.455807469	11.18213481

## Ventana de tiempo 5 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.827108824	0.939141603	0.03186028312	1.156446459	0.8831211207
AMZN	8.266815635	1.821374043	0.05664540032	2.153955309	0.6302744352
GOOG	1.765803569	0.9313610776	0.0265954565	1.151712002	0.3739358358
GOOGL	2.238917425	1.024797247	0.02812603252	1.259815748	0.1509109826
MSFT	7.04721325	1.851175826	0.03441012795	2.18333545	1.363196305
TSLA	1.149283564	0.7743611548	0.04998404074	0.9341114807	1.224733034

## Validación




	MSE	MAE	MAPE	RMSE	MPE
AAPL	10.24668228	2.366599143	0.064536649	2.794305183	-0.2810883388
AMZN	42.54008948	4.333356276	0.08012115982	5.005046188	-4.182680349
GOOG	7.852426539	2.077637398	0.04643993931	2.408588827	0.187257041





GOOGL	7.35156137	2.024467806	0.04488639384	2.350452969	0.1445628447
MSFT	31.31702621	3.827190312	0.04939835464	4.581618964	-3.980634141
TSLA	7.721262194	2.150804392	0.1187092429	2.476865918	5.917390827

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	27.24923026	4.041273351	0.1058265673	4.526530287	-1.093378844
AMZN	88.97230867	6.322887462	0.0989557131	6.790025878	-5.748825091
GOOG	17.00733331	3.077245543	0.06699461251	3.340082457	1.179076654
GOOGL	15.33228803	2.97661292	0.06358962135	3.248503909	1.545424548
MSFT	135.9815597	8.440912139	0.08637589277	8.783330909	-8.131719277
TSLA	21.20266112	3.824347678	0.2142664817	4.072468718	13.60778043

## Ventana de tiempo 7 días





## Entrenamiento

	MSE	MAE	MAPE	RMSE	MPE
AAPL	1.672189853	0.9481144216	0.031045413	1.164280544	-0.7518824153
AMZN	6.275595433	1.637255832	0.05100454585	1.987224266	0.1299290405
GOOG	2.022515826	0.983172105	0.02778084127	1.216262903	-0.581005825
GOOGL	1.790579246	0.9437351998	0.02611388919	1.17523251	-0.6034295413
MSFT	4.447468304	1.530066391	0.02873701901	1.881901849	-0.100581947
TSLA	0.9546859112	0.7333720764	0.04618582916	0.8860424304	-1.154049533

## Validación

	MSE	MAE	MAPE	RMSE	MPE
AAPL	13.33861284	2.627996834	0.07038336571	3.102659602	-1.065272882
AMZN	66.65534125	5.405336407	0.08597101153	6.041697764	-4.008488028

GOOG	5.894233148	1.772476131	0.03795600331	2.069974854	0.2169331162
GOOGL	5.592204694	1.766639488	0.0374732039	2.058323288	0.5337174453
MSFT	49.24918414	4.749455437	0.05388556482	5.56136899	-4.392083395
TSLA	5.597292749	1.835029325	0.1007274844	2.108347498	3.091132251

## Prueba

	MSE	MAE	MAPE	RMSE	MPE
AAPL	36.17536246	4.895219502	0.1260153512	5.294714977	-3.191941752
AMZN	141.9274005	8.911921379	0.1315955492	9.301931148	-5.648983333
GOOG	10.56105201	2.380706625	0.05118664323	2.658555658	0.001126797117
GOOGL	9.799888751	2.352980554	0.05009881265	2.641696462	0.6955231826
MSFT	218.066798	10.64435541	0.1038064691	11.00398519	-9.014062609
TSLA	13.2506573	2.911052528	0.1630978568	3.163104114	10.752398

## Anexo F: Predicciones LSTM sin AMZN y MSFT

A continuación se muestran todas las predicciones para la arquitectura LSTM en la ventana de tiempo de 7 días, sin las secuencias de tiempo con mayor variabilidad.

