



APLICACIÓN DE DEEP LEARNING PARA LA PREDICCIÓN DE ÍNDICES BURSÁTILES EXTRANJEROS USANDO MODELOS MULTIVARIADOS RECURRENTES Y CONVOLUCIONALES CON MECANISMOS DE ATENCIÓN

**ACTIVIDAD FORMATIVA EQUIVALENTE A TESIS PARA OPTAR AL GRADO DE
MAGÍSTER EN SISTEMAS DE INFORMACIÓN E INTELIGENCIA DE NEGOCIOS**

**Alumno: Patricio Iván Pimentel Ramírez
Profesor Guía: David Díaz Solís, Ph.D.**

Santiago, Abril 2024

**RESUMEN DE LA TESIS
PARA OPTAR AL TÍTULO DE MAGISTER EN SISTEMAS DE INFORMACIÓN E
INTELIGENCIA DE NEGOCIOS
POR: PATRICIO IVÁN PIMENTEL RAMÍREZ
AÑO: 2024
PROF.GUÍA: DAVID DÍAZ SOLÍS**

**APLICACIÓN DE DEEP LEARNING PARA LA PREDICCIÓN DE ÍNDICES
BURSÁTILES EXTRANJEROS USANDO MODELOS MULTIVARIADOS
RECURRENTES Y CONVOLUCIONALES CON MECANISMOS DE ATENCIÓN**

Este trabajo aplica *deep learning*, o modelos de redes neuronales profundas, para predecir los precios/retornos y la dirección del movimiento de índices financieros ETF (*exchange trade fund*) de los fondos de inversión BlackRock, Vanguard, Invesco y State Street, transados entre los años 1993 y 2023 en la Bolsa de Comercio NYSE (*new york stock exchange*). La aplicación combina modelos de redes neuronales convolucionales ConvNet (*convolutional neural network*), y redes recurrentes (*recurrent neural network*), entre las que se incluyen de memoria de largo y corto plazo LSTM (*long short term memory*), GRUs (*gated recurrent units*) y Bi-direccionales Bi-LSTM y Bi-GRU (*bidirectional networks*) con y sin mecanismos de atención del tipo *Luong*, *Badahnau*, *Soft Attention* y *MultiHead Attention*.

Los modelos univariados y multivariados se evalúan mediante métricas clásicas de error MSE (*mean square error*), RMSE (*root mean square error*), MAE (*mean absolute error*), MAPE (*mean absolute percentage error*) y MDAPE (*median absolute percentage error*), junto con la métrica de dirección DA (*directional accuracy*), y se comparan con los modelos *benchmark* correspondientes a ARIMA (*autoregressive-integrated moving average*), MLP (*multilayer perceptron*) y ARIMAX (*ARIMA-exogenous*). Finalmente, a los modelos Top10 con mejores métricas se les aplica un proceso de optimización de hiper-parámetros utilizando las librerías *AutoKeras* y *SciKeras*, además de re-estimarlos consecutivamente en ventanas deslizantes o *rolling windows*. Finalmente, los mejores modelos son evaluados en su capacidad de generar rentabilidad y en su relación de riesgo-retorno al seguir diferentes estrategias de *trading* realizando una simulación del tipo *backtesting*.

El presente trabajo supera el state-of-art de la literatura en relación a las métricas clásicas de error predicción. En específico, en la predicción de precios del ETF Vanguard (VTI) el modelo univariado Bi-GRU con atención Luong(dot-product) obtuvo MAE 0,0013302, MSE 2,681E-06, RMSE 0,0014958 y MAPE 0,01188 (1,188%).

Al realizar simulación de *backtesting* en el periodo desde 2003 a 2023, de las 72 combinaciones al aplicar 6 estrategias de *trading* a 12 modelos, hay 21 combinaciones (29,2%) que obtienen retornos negativos con un mínimo de -53,31%, hay 2 combinaciones (2,8%) que obtienen retornos igual a cero, y hay 49 combinaciones (68,1%) que obtienen retornos positivos con un retorno máximo de 1.110,86%. En cuanto a los ratios de riesgo-retorno, el modelo Bi-LSTM con atención Luong con estrategia que abre la posición sólo para compra *one_side_buy_sl_trailing*, obtiene el mejor *sharpe ratio* 0,70948, el mejor *calmar ratio* 0,38939 y el mejor *sortino ratio* 1,14878.

Con todo, se puede apreciar que los desarrollos en términos de modelos de deep learning recurrentes bidireccionales con mecanismos de atención y con optimización de hiper parámetros, demuestran el potencial para configurar arquitecturas capaces de alcanzar altas métricas de predicción y así apoyar a *traders* en la toma de decisiones de inversión para ganancias a corto plazo, en los activos revisados en el período de estudio, tanto en el mercado norteamericano como en el mercado alemán, dada la probada capacidad de generalización de estos modelos.

Acrónimos

ACF AutoCorrelation Function

ADF Augmented Dickey–Fuller

ANN “*Artificial Neural Network*” o RNA Redes Neuronales Artificiales

AR “*AutoReg*” o Modelo Autoregresivo

ARIMA Modelo Autoregresivo Integrado de Media Móvil

ARIMAX Modelo Autoregresivo Integrado de Media Móvil con variable exógena

BP “*Back Propagation*”

BiLSTM “*Bidirectional LSTM*”

B&H “*Buy-and-Hold*” es un tipo de enfoque pasivo, representa la compra al comienzo de la simulación y su mantención durante el período de estudio sin realizar transacciones.

CNN o *ConvNet* Convolutional Neural Networks

Dense “*Fully Connected Connections*” cada neurona de una capa determinada está completamente conectada con las neuronas de la capa siguiente.

DNN “*Deep Neural Network*” (redes neuronales profundas)

EMH “*Efficient Market Hypothesis*” o Hipótesis de mercado eficiente

FCFNN Fully Connected Feedforward Neural Networks

LSTM “*Long Short Term Memory*”

MA “*Moving Average*” o Modelo de Media Móvil

MLP “*Multilayer Perceptron*”

NAS “*Neural Architecture Search*” es un algoritmo que, dado un conjunto de datos, busca la red neuronal óptima que realiza la modelación predictiva en ese conjunto de datos.

OHLCV “*Open-High-Low-Close-Volume*”

RNAH Red Neuronal Artificial Híbrida

RNN “*Recurrent Neural Networks*”

TSF “*Time Series Forecasting*”

Glosario

ARIMA (AutoRegressive Integrated Moving Promedio): es un método tradicional benchmark de pronóstico de series de tiempo que modela la relación entre observaciones pasadas y la actual.

Convolutional Neural Networks (CNN o ConvNet): se utilizan normalmente para el procesamiento de imágenes, pero también se pueden adaptar para datos de series temporales tratando los pasos de tiempo como canales.

Gated Recurrent Unit (GRU): son similares a los LSTM pero con una arquitectura simplificada, resultando eficaces para la previsión de series temporales.

Hybrid Models: combina arquitecturas para crear un modelo mixto que aprovecha las fortalezas de los diferentes enfoques. Por ejemplo, combinar capas CNN & LSTM.

Hiper-parámetros: son un conjunto de propiedades que se pueden especificar para cambiar la forma en que se entrena un modelo y su optimización es crucial en el diseño de un modelo *deep learning*.

Deep Neural Network (DNN o red neuronal profunda): es una red neuronal artificial con varias capas entre las capas de entrada y salida, así son capaces de modelar interacciones no lineales para transformar entradas lineales y no lineales en salidas.

Deep Learning (DL): es una forma de algoritmo en el área de Machine Learning que (1) utiliza una cascada de múltiples capas de unidades de procesamiento no lineales para extracción y transformación, y cada capa sucesiva utiliza la salida de la capa anterior como entrada; (2) aprende de manera supervisada (por ej., clasificación) y/o no supervisada (por ej., análisis de patrones); (3) y es capaz de modelar diferentes niveles de representación según diferentes niveles de abstracción que forman una jerarquía de conceptos.

Long Short-Term Memory (LSTM): son redes neuronales recurrentes que capturan dependencias y patrones siendo adecuadas para datos secuenciales como series de tiempo.

RNN: es un tipo de red neuronal artificial adecuada para analizar y procesar datos de secuencia temporal, a diferencia de las redes neuronales tradicionales, que se basan en la conexión de peso entre las capas, RNN aplica las capas ocultas para preservar la información del momento previo, y la salida está influenciada por los estados actuales y los recuerdos anteriores.

Contenido

Capítulo 1: Introducción	7
1.1 Antecedentes o motivación	7
1.2 Problemática y justificación	8
1.3 Objetivos	9
1.4 Contribución	9
1.4 Resumen de la metodología	10
1.5 Principales resultados y conclusiones	10
Capítulo 2: Revisión Literaria	13
Capítulo 3: Metodología	19
3.1 Entendimiento de la data (Data Understanding)	20
3.2 Preprocesamiento de la data (Data Preprocessing)	24
3.3 Modelamiento predictivo (Predictive Modeling)	25
3.4 Evaluación del modelo y comparaciones	32
Capítulo 4: Resultados	38
4.2 Resultados de análisis de predictibilidad para 5 instrumentos ETFs	39
4.2 Resultados de análisis de predictibilidad de modelos tradicionales para ETF VTI	40
4.3 Resultados del análisis de predictibilidad de modelos DL para ETF VTI	42
4.4 Resultados del análisis de complejidad de modelos DL para ETF VTI	50
4.5 Resultados de análisis de re-estimación de modelos DL para ETF VTI	51
4.6 Resultados de análisis de rentabilidad para ETF VTI	54
Capítulo 5: Análisis de Resultados	58
Capítulo 6: Discusión	66
Capítulo 7: Conclusiones	67
Capítulo 8: Bibliografía	73
Anexo.	78
Anexo nro. 1.	78
Anexo nro. 2.	83
Anexo nro. 3.	84
Anexo nro. 4.	91

Capítulo 1: Introducción

En el presente capítulo se explica acerca del tema que se desarrollará en el presente trabajo, describiendo los antecedentes y la motivación que impulsan el desarrollo de la investigación. Luego, se realiza una descripción del problema, sus objetivos, la contribución de la investigación respecto a la literatura y la metodología con la que se abordará el problema. Finalmente, se presenta un resumen de los principales resultados y un resumen de conclusiones del estudio.

1.1 Antecedentes o motivación

Una de las áreas de investigación más atractivas en el mundo financiero es el mercado de valores (*stock market*). Predecir las acciones y el precio de índices financieros del mercado de valores es difícil debido a las incertidumbres involucradas (Patel et al., 2015). En el panorama dinámico de los mercados de valores, el arte y la ciencia involucrados en predecir los precios de las acciones ha captado la atención de inversionistas, economistas e investigadores (Lu and Xu, 2024). El mercado de valores se ve impactado en dos aspectos, uno son los eventos geopolíticos, sociales y globales sobre cuya base las tendencias de los precios podrían verse afectadas, y el segundo aspecto se centra en las tendencias históricas de los precios y la estacionalidad, lo que permite cierta capacidad de pronosticar los precios de las acciones en el corto plazo (Pardeshi et al., 2023).

La investigación teórica y el análisis empírico de los mercados de valores se centran principalmente en el precio y el volumen de operaciones. La predicción del precio de las acciones (*stock price*) tiene un papel importante en la inversión. Y la mayoría de los datos de los mercados de valores presentan características de datos de series temporales (*time series*). Las series temporales del mercado, definidas como una secuencia de datos ordenada, continua y en tiempo real, son la base para predecir las tendencias futuras del mercado (Lu and Xu, 2024). Por esto, *time series forecasting* se ha convertido en una tarea fundamental en el análisis de datos contemporáneo, su objetivo es predecir eventos futuros basándose en datos históricos.

1.2 Problemática y justificación

Debido a que los datos de los precios de las acciones se caracterizan por su alta frecuencia, no linealidad y su eventual larga memoria, es un desafío predecir los precios de las acciones con precisión (Zhang J. et al., 2023). El *deep learning* permite descubrir patrones y es favorecido con la creciente disponibilidad de datos (*big data*), así, las aplicaciones de *deep learning* destacan como métodos de predicción. Sobre los datos se pueden aplicar algoritmos de *deep learning* para analizar

los patrones subyacentes de las acciones (Dhaliwal et al., 2022), así, el *deep learning* se ha convertido en una técnica crítica en el campo del mercado financiero. (Pardeshi et al., 2023).

Dentro del *Deep Learning*, existe una amplia gama de diseño de redes neuronales. Las arquitecturas aplicadas en este trabajo utilizan modelos recurrentes y convolucionales, que son subtipos de redes profundas. Dentro de las redes recurrentes o *RNN*, se prueban principalmente arquitecturas del tipo Long Short Term Memory (LSTM) y *Gated Recurrent Units* (GRU), variantes que evitan el problema de fuga del gradiente. Por otra parte, las arquitecturas utilizadas en este trabajo también comprenden a las redes convolucionales o Convolutional Neural Networks (ConvNet) que según la dimensionalidad del espacio de entrada, por ejemplo 1-Dimensión, aprenden a identificar patrones similares a las señales de voz.

A nivel macroeconómico, uno de los indicadores clave para determinar la situación económica de un país es el movimiento de un índice bursátil, el cual es determinado por los movimientos de sus acciones subyacentes y/o inclusive por otros índices bursátiles, por esto se convierte en un tema crucial que se examina a lo largo del tiempo (Zhang L. and Kim H., 2020). A modo de ejemplo, el índice bursátil S&P 500 se le considera el más representativo del mercado de acciones de Estados Unidos, su movimiento es el marcador de tendencias de la economía norteamericana.

Los instrumentos financieros que replican índices bursátiles son denominados Fondos Cotizados en Bolsa (FCB) o *Exchange Trade Fund* (ETF). Los ETFs utilizados en el presente trabajo se encuentran entre los más transados por las AFPs (Administradoras de Fondos de Pensiones) dentro de la cartera de inversión extranjera de los Fondos de Pensiones. El set de datos se obtiene desde la bolsa de comercio *New York Stock Exchange* (NYSE) comprendido en general entre los años 1993 hasta 2023 con periodicidad diaria. Los *features*, o posibles variables explicativas del modelo, son seleccionados entre variables tales como el precio de apertura, el precio más alto, el precio más bajo, el precio de cierre, el precio de cierre ajustado y el volumen, junto con indicadores técnicos. En términos de análisis exploratorio, se eligen cinco variables (*features*) altamente correlacionadas con la variable a predecir que es el precio de cierre ajustado (*Adj Close*).

1.3 Objetivos

A continuación, se presentan los objetivos de la investigación, tanto el general como los específicos.

1.3.1. Objetivo general

Desarrollar un modelo de deep learning para predicción por medio del uso de redes que simulan la memoria y visión humana con el fin de predecir instrumentos financieros que replican índices bursátiles en un periodo de tiempo determinado con mecanismos que simulan la atención humana.

1.3.2. Objetivos específicos

- Realizar una revisión de literatura asociada a la predicción de series de tiempo en el ámbito financiero, con el fin de identificar las técnicas y mecanismos utilizados.
- Definir una metodología para entrenar una red neuronal profunda (*deep learning*) y definir los hiper parámetros mediante optimización que se ajusten a la realidad de la problemática.
- Aplicar la metodología al caso de estudio con el fin de evaluar la calidad de la predicción.
- Validar el desempeño de la red propuesta mediante la comparación con los métodos utilizados en la literatura en función de calidad predictiva y análisis de rentabilidad.

1.4 Contribución

La contribución del presente trabajo se centra en tres puntos en particular. En primer lugar, se busca desarrollar una arquitectura con redes recurrentes, convolucionales e híbridas para predecir el comportamiento de instrumentos financieros denominados fondos cotizados en bolsa, vale decir, predecir las réplicas de los índices bursátiles extranjeros transados en bolsas de comercio. En segundo lugar, se busca implementar los mecanismos de atención y optimizar los hiper parámetros automáticamente. Finalmente, en tercer lugar, se busca validar los resultados comparando con métodos tradicionales de referencia y realizar una simulación de la rentabilidad del modelo propuesto para validar la aplicabilidad de la predicción y constatar que las predicciones generan ganancia económica.

Por otra parte, el presente trabajo deja establecidos los lineamientos metodológicos para la selección y configuración de una red aplicada a algún caso de estudio en un área en específico.

1.4 Resumen de la metodología

La metodología utilizada en la presente investigación se detalla en el capítulo nro. 3 y en la figura nro. 1. En esta se detallan los datos provenientes de la bolsa de comercio con los que se hace la prueba empírica de los métodos. Luego, se realiza el preprocessamiento de los datos. Posteriormente, se trabaja en la configuración de las redes neuronales que simulan la memoria LSTM/GRU y visión humana CNN, se trabaja en la incorporación de mecanismos de atención que simulan la atención humana, en la optimización de hiper parámetros mediante AutoKeras y SciKeras, y en la ejecución de modelos tradicionales de referencia (ARIMA y MLP). Finalmente se realiza la comparación de todos los algoritmos mediante las métricas de error MAE, MSE/RMSE, MAPE/MDAPE y de dirección DA para luego realizar el análisis de re-estimación mediante la

simulación de ventanas deslizantes, el análisis de complejidad con diferentes número de parámetros, y el análisis de rentabilidad de los algoritmos.

1.5 Principales resultados y conclusiones

Los principales resultados obtenidos en la investigación fueron que los modelos *deep learning* bidireccionales mayoritariamente superaron en todas las métricas a los modelos tradicionales *benchmark* MLP, AR, ARIMA y ARIMAX y el restante de modelos *deep learning*.

En términos de métricas de error, respecto de los indicadores MAE y MSE, el 83% corresponden a modelos multivariados, el 75% con arquitectura Bidireccional (la arquitectura *bidirectional network* lidera mayoritariamente), el 46% de posiciones con el mecanismo de atención Luong, y el 42% de posiciones con *AutoKeras* y el 8% con *SciKeras*.

En términos de métricas de error, respecto de los indicadores MAPE y MDAPE, el 92% corresponden a modelos multivariados, el 38% con la arquitectura Bi-LSTM y el 21% con la arquitectura Bi-GRU (la arquitectura *bidirectional network* lidera), el 42% de posiciones con el mecanismo de atención Luong, y el 33% de posiciones con *AutoKeras* y el 8% con *SciKeras*.

En términos de capacidad de acierto, respecto del indicador DA, de los modelos en el parámetro train/test 90/10, el 63% corresponde a modelos multivariados, con arquitectura Bi-LSTM el 75% de las posiciones, el 54% de posiciones con el mecanismo de atención Bahdanau, y el 25% de posiciones con *AutoKeras*. En el Top 3 de mejores métricas DA, se logra imponer la arquitectura *bidirectional network* con mecanismo de atención Bahdanau, correspondientes a dos modelos univariados Bi-LSTM (84,295%) y Bi-GRU (83,013%), y un modelo multivariado Bi-GRU (82,372%) con resultados que superaron ampliamente a los modelos tradicionales benchmarking y al restante de modelos *deep learning*.

Cabe notar que no existe una arquitectura de red con mecanismo de atención y/u optimización de hiper parámetros que sirva de bala de plata en la predicción para liderar en todas las métricas, tanto de error como de dirección, porque se distinguen entre las arquitecturas configuradas un claro trade-off entre las métricas de error y las métricas de dirección. Por ejemplo, para el modelo MLPK existe trade-off entre una muy baja métrica de error MAE/MSE y una muy baja métrica DA, y para los modelos *deep learning* univariados existe trade-off entre una muy alta métrica de dirección DA y una muy alta métrica MDAPE.

La principal conclusión es que los modelos con arquitecturas bidireccionales recurrentes (BI-LSTM y BI-GRU) obtienen mayoritariamente mejores resultados que los restantes modelos *deep learning*. Más aún, aquellos modelos bidireccionales que incluyen mecanismos de atención (Luong y Bahdanau) con o sin optimización de hiper parámetros logran una capacidad predictiva

en el orden magnitud de la literatura, lo cual implica que no hay brecha existente entre los resultados del trabajo y la literatura.

El presente trabajo supera el state-of-art de la literatura, en la predicción de precios del ETF Vanguard (VTI) el modelo univariado Bi-GRU con atención Luong(dot-product) obtuvo MAE 0,0013302, MSE 2,681E-06, RMSE 0,0014958 y MAPE 0,01188 (1,188%).

Al realizar simulación de *backtesting* en el periodo desde 2003 a 2023, de las 72 combinaciones al aplicar 6 estrategias de *trading* a 12 modelos, hay 21 combinaciones (29,2%) que obtienen retornos negativos con un mínimo de -53,31%, hay 2 combinaciones (2,8%) que obtienen retornos igual a cero, y hay 49 combinaciones (68,1%) que obtienen retornos positivos con un máximo de 1.110,86%. Entre los retornos positivos, hay 8 modelos con estrategias que obtienen retornos superiores a su propia estrategia *buy-hold*, respecto a sus arquitecturas, corresponden a modelos multivariados bi-direccionales Bi-LSTM(7) y Bi-GRU(1) con mecanismos de atención Luong(4) y/o Bahdanau(4), mayoritariamente con capacidad predictiva por sobre el 80%, incluido el modelo más sofisticado con AutoKeras y SciKeras; y respecto a sus estrategias, el 62,5% corresponde a *two_side_sl_tp_reversed* que abre posiciones en ambos lados de compra y venta, y el 37,5% corresponde a la estrategia abre la posición sólo para compra.

Entre los retornos negativos hay un 81% de modelos con estrategias que abren la posición sólo para venta: *one_side_sell_sl_trailing* (47,7%) y *one_side_sell_sl_tp* (33,3%), las cuales incluyen al modelo benchmarking CNN y a los modelos univariados que presentaban las métricas más altas.

Así, se obtuvo en el análisis de rentabilidad que las redes multivariadas bidireccionales cuentan con mejor desempeño alcanzando los mejores retornos positivos respecto de su modelo convolucional de referencia, en cambio, los modelos univariados cuentan con los retornos mayoritariamente negativos.

En cuanto a los ratios, el modelo Bi-LSTM con atención Luong con estrategia que abre la posición sólo para compra *one_side_buy_sl_trailing*, tiene el mejor *sharpe ratio* 0,70948, el mejor *calmar ratio* 0,38939 y el mejor *sortino ratio* 1,14878.

En conclusión, la metodología propuesta y las arquitecturas bidireccionales con mecanismos de atención representan un mecanismo útil de toma de decisiones para los participantes del mercado financiero, tales como *traders* e inversionistas, permitiéndoles definir estrategias de *trading* que obtengan ganancias en el corto plazo.

El presente trabajo se organiza mediante pasos iniciando con la revisión de la literatura, la selección de los principales y más recientes métodos de predicción de precios y de retornos de

instrumentos financieros que replican índices bursátiles, considerando los tipos de variables disponibles, la granularidad y periodicidad de los datos de entrada. Luego, la recopilación y pre-procesamiento de los datos y variables a utilizar, la creación de indicadores técnicos y la modelación de los precios y retornos. Posteriormente, se realizará la selección de los modelos incluyendo técnicas clásicas (ARIMA), técnicas avanzadas CNN, LSTM, e híbridas junto con sus librerías y codificaciones, la aplicación y el entrenamiento iterativo de los modelos que generarán resultados parciales de la predicción, lo que conlleva a realizar ajustes y optimización de hiperparámetros de los modelos. Finalmente, los resultados finales de la predicción generarán resultados que al tabular permitirán las comparativas de métricas, la selección de los mejores modelos, el análisis de los principales hallazgos, y las conclusiones y discusiones sobre la base de la literatura disponible, sintetizando las principales contribuciones, y presentando ideas para trabajos a futuro.

El presente trabajo se estructura de la siguiente manera: el capítulo 2 presenta la revisión literaria, el capítulo 3 presenta la metodología propuesta y los datos utilizados, el capítulo 4 presenta los resultados obtenidos para cada modelo según tipos de arquitecturas, el capítulo 5 presenta el análisis de los resultados, el capítulo 6 presenta las conclusiones y, finalmente el capítulo 7 presenta las discusiones.

Capítulo 2: Revisión Literaria

Los métodos de predicción del mercado de valores (stock market prediction) se dividen en dos categorías principales: análisis técnico y fundamental (Alzazah & Cheng, 2020). El análisis técnico modela los precios futuros sobre la base del uso de los precios y volúmenes pasados e indicadores de éstos, bajo el supuesto de que el efecto de todas las variables macroeconómicas y la actualidad noticiosa ya están reflejadas en el precio histórico de las acciones (Murphy, 1999). El análisis fundamental impulsado por Benjamín Graham en 1928, se centra tanto en indicadores futuros y expectativas relacionados a la compañía como en los factores macroeconómicos (Vanstone & Finnie, 2009). Con respecto a los factores macroeconómicos, éstos engloban al producto interno bruto, tasas de interés, tipo de cambio, y la inflación, entre otros (Bustos y Pomares-Quimbaya, 2020).

Igualmente se sostiene que en la predicción del mercado de valores se utilizan tres tipos principales de datos estructurados: características básicas, indicadores técnicos e indicadores fundamentales (Htun et al., 2023). Las características básicas son los valores bursátiles, como los datos Open, High, Low, Close, Volume (OHLCV). Los indicadores técnicos se extraen de series históricas de precios mediante fórmulas matemáticas, los más comunes son el RSI, el oscilador estocástico y la media móvil de convergencia-divergencia según Alsubaie et al. (2019). Algunos estudios como el de Botunac et al. (2020) y Qolipour et al. (2021), utilizan una combinación de características básicas e indicadores técnicos para pronosticar la dirección del mercado de valores. Y los indicadores fundamentales son indicadores económicos Bustos y Pomares-Quimbaya (2020), que van desde factores macroeconómicos como las tasas de interés, el índice de precios al consumidor y el estado general de la economía, hasta factores microeconómicos, como la información de una empresa.

La Hipótesis del Mercado Eficiente o EMH (*Efficient Market Hypothesis*) es una teoría enunciada por Eugene Fama (1970) que establece que el precio actual de un activo en el mercado refleja toda la información disponible que existe (histórica, pública y privada), es decir, establece que los precios de las acciones reflejan toda la información y es imposible superar consistentemente al mercado en general, y que cuanto más eficiente sea un mercado, más aleatorios e impredecibles serán los rendimientos y, por lo tanto, un mercado perfectamente eficiente será completamente impredecible. Según lo planteado por la EMH, no es posible lograr un retorno ajustado por riesgo superior al del mercado. EMH indica que en mercados eficientes los precios futuros no pueden ser predichos usando información existente (Kumbure et al., 2022). Fama propuso tres niveles o formas de eficiencia de mercado: nivel Débil de hipótesis de eficiencia de mercado que asume que la información contenida en las series de tiempo de los precios pasados ya

está reflejada en el precio actual y por ende no es útil para poder predecir los precios futuros de las acciones; nivel Semi-Fuerte de hipótesis de eficiencia de mercado, los precios de los activos reflejan toda la información pública disponible que engloba a los precios pasados de los activos, y además incluye información relacionada con indicadores macroeconómicos; nivel Fuerte de hipótesis de eficiencia de mercado en que ningún tipo de información ya sea pública o privada de la compañía pueden ser usada para pronosticar el mercado, por ende, ningún inversor puede alcanzar retornos esperados superiores al mercado.

Hay argumentos en contra de la EMH, y uno de los más destacados se basa en las Finanzas Conductuales (*Behavioral Finance*) que postula que, en comparación con la historia humana de 200.000 años, el mercado no ha existido durante tanto tiempo. Por ejemplo, las opciones sobre acciones sólo se han negociado en mercados líquidos y transparentes desde que se abrió el CBOE - *Chicago Board Options Exchange* en 1973, y la vida media de una empresa del índice S&P 500 es de aprox. 20 años. Postula que algunas tendencias psicológicas de los seres humanos tienen la historia humana de evidencia detrás de ellas, y que muchos de los movimientos de los mercados fueron impulsados por los comportamientos de los participantes, y probablemente se repetirán, por tanto, el sistema de mercado debe tener algunos patrones, no puede ser totalmente aleatorio, pero esos patrones son extremadamente difíciles de encontrar y explotar debido a la multitud de factores que interactúan e impulsan el mercado.

La naturaleza especulativa, la volatilidad y las complejas dependencias secuenciales dentro de los mercados financieros presentan desafíos inherentes que requieren técnicas avanzadas de análisis de datos (Ahmed et al. 2024). Con el rápido desarrollo del hardware, el *machine learning* y los modelos de *deep learning* se han aplicado con éxito a muchos dominios de aplicaciones, pero sus ventajas han tardado enemerger para la predicción de series temporales (Aldosari et al. 2024), si bien existen controversias y debates, la mayoría de los experimentos basados en modelos de redes neuronales han demostrado su eficacia para mejorar la predicción y prevenir riesgos en el mercado financiero, así, a medida que se realizan más estudios, los investigadores interdisciplinarios están comenzando a explorar en mayor medida el uso de métodos basados en redes neuronales para la predicción del mercado financiero (Lu and Xu, 2024).

Podemos rastrear los modelos de redes neuronales y el *deep learning* desde 1943 en adelante, cuando Walter Pitts y Warren McCullough construyeron un modelo computacional utilizando algoritmos y matemáticas, denominado “*Threshold Logic Unit*” (TLU) que ha servido de inspiración para el desarrollo de otros modelos neuronales. En 1958 el científico Frank Rosenblatt, inspirado en el modelo anterior, creó el Perceptrón simple de una única neurona. En 1965 el Multilayer Perceptron (MLP) es capaz de resolver problemas que no son linealmente separables,

además aparece el concepto de capas de entrada, capas ocultas y salida, pero con valores de entrada y salida binarios. En la década de 1980 surgió el *Machine Learning* (aprendizaje automático), las neuronas sigmoides que son similares al Perceptrón permiten que las entradas puedan tener valores reales en vez de ser ceros o unos; también aparecen las neuronas “bias” que siempre suman 1 en las diversas capas para resolver ciertas situaciones; y con la “fórmula de activación” se logra que pequeñas alteraciones en valores de los pesos (deltas), se produzcan pequeñas alteraciones en la salida.

Con las Redes Feedforward las salidas de una capa son utilizadas como entradas en la próxima capa, no hay retroalimentación “hacia atrás”, siempre se “alimenta” de valores hacia adelante, así se crea el concepto de “*Fully Connected Feedforward Neural Networks*” (FCFNN) en que todas las neuronas de entrada están conectadas con todas las neuronas de la siguiente capa. Posteriormente, gracias al algoritmo de *back-propagation* se hizo posible entrenar redes neuronales de múltiples capas de manera supervisada, al calcular el error obtenido en la salida e ir propagándose hacia las capas anteriores, se van haciendo ajustes pequeños (minimizando costos) en cada iteración para lograr que la red aprenda.

En 1989 la primera red “*multilayered*” Convolutional Neural Networks (CNN o ConvNet), fue creada por Yann LeCun, enfocada inicialmente en el reconocimiento de imágenes (letras manuscritas), fue inspirada a partir del córtex visual de los animales. La imagen se divide en campos receptivos que alimentan una capa convolucional que extrae *features* de la imagen de entrada, por ejemplo, detectar líneas verticales, vértices, etc. Un siguiente paso es el *pooling* que reduce la dimensionalidad de las features extraídas manteniendo la información más importante, y así sucesivamente para alimentar otras redes multicapas. Se usan en procesamiento de imágenes y reconocimiento de video.

Las Recurrent Neural Networks (RNN) fueron creadas en 1989 y se caracterizan porque existen loops o conexiones hacia atrás (*lookback*), es decir, son capaces de recordar sus propias predicciones. Esto las hace adecuadas para el modelamiento de series de tiempo porque pueden procesar datos secuenciales, considerando las dependencias entre eventos pasados y futuros, lo que las convierte en una tecnología interesante para la previsión del mercado de valores. Centrado en el modelamiento de datos que siguen patrones de secuencias, estas redes han ganado mucha atracción dado sus excelentes resultados en este tipo de problemas (Peng and Guo 2022). Los bucles de retroalimentación son los que permiten que las RNN sean mejores en el reconocimiento de patrones que otras redes neuronales.

La arquitectura RNN que consta de múltiples capas de memoria a corto y largo plazo, son conocidas como Long Short Term Memory (LSTM), fueron inventadas por Hochreiter y

Schmidhuber, en el año 1997. LSTM permite que el modelo aprenda patrones de una serie de tiempo los cuales ocurren en diferentes períodos y que a menudo son difíciles de detectar para los analistas humanos (Hochreiter and Schmidhuber, 1997). La arquitectura LSTM crea un módulo adicional en una red neuronal que aprende cuándo recordar valores por períodos cortos o largos, y cuándo olvidar con celdas de memoria que contiene pesos que controlan cada compuerta o válvula, la cual administra como la información fluye dentro o fuera. La red aprende de manera efectiva qué información podría ser necesaria más adelante en una secuencia y cuándo esa información ya no es necesaria. Es ideal para procesar datos de tipo históricos *time series* y para aprender dependencias a largo plazo. El algoritmo de entrenamiento “backpropagation through time” optimiza estos pesos basado en el error del resultado.

LSTM ha sido aplicado en el diseño de un modelo de predicción para predecir los precios de las acciones y múltiples índices bursátiles (Yu and Yan, 2020), en la predicción de series de tiempo de la bolsa de valores de Teherán, Irán, (Nabipour et al. 2020), en el desarrollo de un modelo de pronóstico a corto plazo con una alta precisión de las series del mercado de valores de USA y China (Liu and Long, 2020), en la predicción del índice compuesto de Shanghai (*Shanghai Composite Index*) de China con un modelo híbrido CNN-LSTM para pronóstico del precio de las acciones (Lu W., et al. 2020), en la predicción de precios de acciones de Cisco, Coca-Cola, Nike y Goldman Sachs, en que MLP, CNN y LSTM superaron los experimentos relacionados a predicciones de la trayectoria del cambio de precios (Kamalov F. 2020). En una revisión literaria sobre el uso de algoritmos de *deep learning* se encontró que los modelos CNN y LSTM brindan resultados de predicción superiores con niveles de error más bajos que otros modelos (Mahmoud A. and Mohammed A., 2021), y en la comparación de modelos, CNN-LSTM tiene éxito en la predicción de series temporales financieras, sin embargo, CNN no es idónea en la predicción de datos numéricos de series de tiempo, y LSTM tiene limitada capacidad para extraer los *features* más valiosos de un *dataset* (Widiputra et al., 2021).

Con el transcurrir de los años y el incremento en la popularidad de las redes LSTM, el año 2014 surgió Gated Recurrent Unit (GRU), una variación mejorada de LSTM con una puerta de olvido, pero con menos parámetros que una LSTM ya que carece de una puerta de salida (Cho et al, 2014).

En el trabajo de Shi J et al 2022, las GRUs son utilizadas para comparar métodos diferentes de aprendizaje profundo (RNN, LSTM, GRU, junto a métodos tradicionales benchmark) en el conjunto de datos de la calidad del aire de Beijing, China, como una serie temporal multivariada (Shi J., Jain M., Narasimhan G. 2022), y en la fijación de precios de opciones del ETF estadounidense SPY de State Street (Shen Yanhui, 2023). Cabe notar que el término “opciones” se

refiere a un instrumento financiero que se basa en el valor de los instrumentos subyacentes, como acciones, índices y ETF.

La primera publicación de Bidirectional Long Short-Term Memory (Bi-LSTM) fue realizada por Graves y Schmidhuber ([Graves & Schmidhuber, 2005](#)), consisten en LSTMs hacia adelante y hacia atrás, sosteniendo que al crear predicciones de series temporales es esencial tener plenamente en cuenta la ley de información hacia adelante y hacia atrás de los datos, ya que esto puede mejorar en gran medida la precisión del pronóstico. Bi-LSTM utiliza los datos pasados y futuros para sacar conclusiones más extensas y precisas porque considera las leyes cambiantes de los datos.

Una Bidireccional Gated Recurrent Unit (Bi-GRU), es un modelo de procesamiento de secuencias que consta de dos GRU, uno toma la entrada hacia adelante y el otro hacia atrás. Es una red neuronal recurrente bidireccional con solo puertas de entrada y olvido ([Rana et al, 2016](#)).

Recientemente, investigadores realizaron una predicción usando Bi-LSTM y Bi-GRU de la presión como serie de tiempo de los ventiladores mecánicos para pacientes médicos ([Alam et al, 2023](#)), una predicción de precios de cierre de Bitcoin usando Bi-LSTM alimentado con datos de 10 *features* diseñadas entre 851 utilizando un nuevo método ([Modi et al, 2023](#)), y una predicción de precios Bi-LSTM basada en un mecanismo de atención que compararon con los modelos *benchmark*, los resultados mostraron que las Bi-direccionales tienen el mejor rendimiento aplicado al *dataset* de precios del Oro y Bitcoin ([Jiashu Lou, Leyi Cui, Ye Li, 2022](#)).

Por ejemplo, las redes neuronales recurrentes del tipo LSTM están siendo cada vez más utilizadas para modelar precios y retornos accionarios. Recientemente, en la predicción diaria del índice S&P 500 [Bhandari et al., 2022](#), en la predicción de *stock price* de bancos de China ([Peng and Guo 2022](#)), en la predicción de precios de acciones con ARIMA y LSTM ([Xiao R., et al. 2022](#)), y en el uso de un modelo basado en LSTM para proporcionar un pronóstico de mercado ([Mohanty et al., 2022](#)). Algunas nuevas aplicaciones, también combinan arquitecturas híbridas, por ejemplo, en el uso de CNN-LSTM para predecir el *close price* de las acciones de Tesla y American Express que superó a las arquitecturas benchmark en términos de precisión de pronóstico ([Dhaliwal A. et al., 2022](#)), en un pronóstico del desempeño de los índices bursátiles del US *stock market* durante el período COVID-19 ([Nematirad R. et al. 2023](#)), en la medición de la eficiencia de los modelos de predicción de *stock price* utilizando varios tipos de modelos LSTM ([Sangwan V. et al., 2023](#)), en el modelado de dependencia multivariante entre mercados de alta dimensión usando LSTM ([Xu and Cao 2023](#)), y en la predicción de datos de series temporales del mercado de valores utilizando un modelo híbrido de red neuronal CNN-LSTM ([Aadhitya A., et al., 2023](#)). Las redes neuronales recurrentes y sus variantes, también han sido incipientemente utilizadas para modelar activos de

otros mercados, por ejemplo, un estudio demuestra que el *deep learning* mejora la eficiencia computacional y la viabilidad operativa en comparación con los modelos *benchmark* para fijar el precio de las “*opciones*” estadounidenses como ETF’s ([Shen Y., 2023](#)), y en otro estudio que propone una nueva arquitectura y un marco más eficiente para la predicción de series de tiempo en que los modelos lineales tradicionales *benchmark* parecen ser incapaces de capturar la dependencia del tiempo ([Inzirillo H., Villelongue L. 2023](#)).

En relación con mecanismos de atención, investigadores propusieron un modelo LSTM con mecanismo de atención (*Self-Attention*) secuencial, llevando a cabo experimentos con acciones bancarias del *stock market* de la India ([Pardeshi et al. 2023](#)), una aplicación de modelo híbrido CNN-LSTM y XGBoost basado en mecanismo de Attention para predicción de acciones ([Zhuangwei S. et al., 2023](#)), y un pronóstico de carga a corto plazo utilizando una red CNN-LSTM con optimizador aumentado con mecanismo MultiHead Attention utilizando datos de demanda por electricidad ([Quansah and Tenkorang, 2023](#)).

Dado lo anterior, esta investigación tiene la finalidad de aplicar *Deep Learning* en modelos recurrentes, convolucionales e híbridos con mecanismos de atención para la predicción de precios de índices financieros *Exchange Trade Fund* (ETF) de los principales fondos de inversión extranjeros transados en la *New York Stock Exchange* (NYSE). Además, realizar un *rolling windows* y posteriormente un *backtesting* con estrategias *trading* para los modelos con mejores métricas.

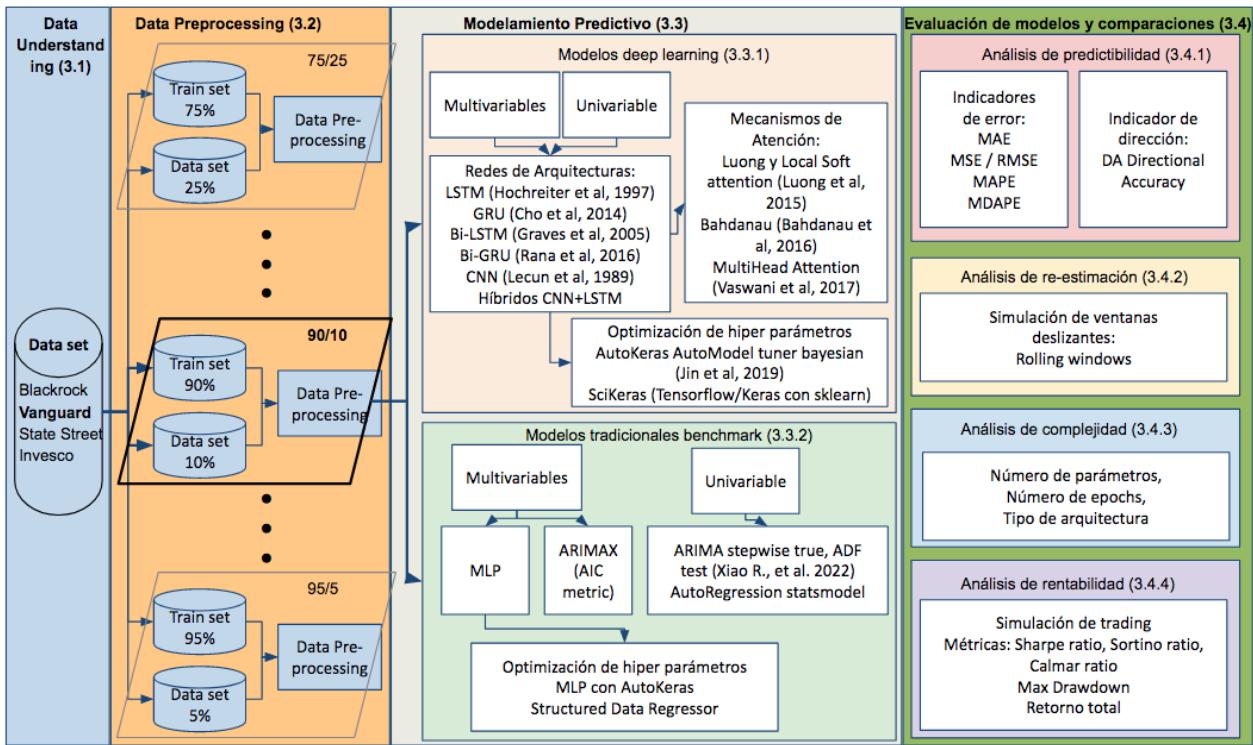
Finalmente, las preguntas que busca resolver esta investigación son las siguientes:

1. ¿Existe capacidad predictiva en precios o retornos de instrumentos financieros extranjeros usando redes LSTM/GRU y/o ConvNet?
2. ¿La capacidad obtenida por los modelos permite superar al mercado?
3. ¿Existe menor error en métricas de los modelos LSTM/GRU y/o ConvNet comparado con los modelos ARIMA y MLP?
4. ¿Al incorporar mayor número de rezagos de las variables explicativas se logra mejorar la capacidad predictiva o disminuye el error?
5. ¿Las variables provenientes del análisis técnico mejoran la capacidad predictiva o disminuyen el error?
6. ¿Qué es más conveniente modelar precios o retornos?.

Capítulo 3: Metodología

Este trabajo compara diferentes arquitecturas de redes neuronales, variando además la naturaleza de sus features o variables de entradas. En particular, se comparan modelos univariados y multivariados, además de probar diferentes conjuntos de las mismas. El desempeño de las arquitecturas depende de la capacidad de los modelos propuestos para identificar patrones recurrentes en los datos y hacer predicciones correctas de ellos. Se utilizan varias técnicas para mejorar el rendimiento de los modelos, incluida la ingeniería de características (feature engineering), la optimización de hiper-parámetros y el reentrenamiento continuo por medio de ventanas deslizantes (rolling windows). Se evalúa el desempeño de los modelos utilizando múltiples métricas, y se experimenta con distintas particiones de datos (train/test). A continuación, la figura presenta la metodología con el listado de pasos generales y algunas referencias utilizadas en el trabajo, e incluyendo los respectivos nombres y numeración de los subcapítulos del presente capítulo.

Figura nro. 1 de la Metodología de Predicción



3.1 Entendimiento de la data (Data Understanding)

3.1.1 Data a utilizar

Los índices (*index*) proporcionan información *real-time* sobre la salud de los mercados financieros y también una fotografía (*snapshot*) de la dirección del mercado. Cuando los índices bursátiles suben, es porque los inversores están comprando más acciones de los componentes de los índices de las que venden, y sus precios están subiendo; y lo contrario ocurre cuando los niveles del índice están disminuyendo. El número de índices sigue creciendo porque existe un creciente apetito por nuevas formas de invertir en los mercados de capital utilizando productos de inversión vinculados a índices.

Un producto de inversión o vehículo de inversión vinculado a un índice (*index-linked*) es diseñado para replicar lo más fielmente posible el desempeño del índice subyacente. Los productos *index-linked* más conocidos para invertir son los ETF (*Exchange Trade Fund*) o Fondos Cotizados en Bolsa (FCB). Un ejemplo es el ETF de Bitcoin (BTC) recientemente aprobado por la SEC el 11 de enero de 2024.

Los principales índices bursátiles a nivel mundial son el índice *CSI 300* (Shanghai and Shenzhen 300 Index), *HSI* (Hang Seng Index), *Nikkei 225*, *S&P 500*, *Dow Jones*, *Nasdaq*, *CRSP*, *EURO STOXX 50*, *MSCI*, *DAX 30*, *KOSPI*, *NIFTI 50*, entre otros. El objetivo de un ETF es replicar la evolución de un determinado índice bursátil y ofrecerle la misma rentabilidad que la de este índice, menos las comisiones. Las participaciones de los ETFs pueden comprarse y venderse en bolsa (al igual que las acciones), así, los ETFs combinan la facilidad de negociación de las acciones con la ventaja de diversificación de los fondos de inversión.

El índice *S&P 500* (*Standard and Poor's 500*) es uno de los índices bursátiles más representativo del mercado de acciones de Estados Unidos, y el marcador de tendencias de la economía norteamericana porque se basa en la capitalización bursátil de 500 grandes empresas del segmento *large cap* superior a 5 mil millones de dólares que cotizan en las bolsas NYSE o NASDAQ, capturando el 80% de toda la capitalización de mercado.

Por otra parte, el índice CRSP (*Center for Research in Security Prices*) es utilizado por propietarios de activos, sponsors de fondos y otras instituciones financieras para medir el desempeño del mercado de valores general de Estados Unidos. Más de 2 billones de dólares en activos de fondos están vinculados a los CRSP Market Indexes.

Los ETFs utilizados en el presente trabajo pertenecen a los actores de inversión más importantes de la economía global, tales como BlackRock, The Vanguard Group, State Street e Invesco. A continuación, se detallan los cinco (5) ETF seleccionados.

i) ETF Vanguard Total Stock Market Index Fund: Con stockname US9229087690, símbolo VTI, perteneciente al holding The Vanguard Group, Inc. sus datos históricos están comprendidos

desde el 14 de junio de 2001 hasta el 22 de noviembre de 2023. El objetivo de la inversión es seguir el rendimiento del índice *CRSP US Total Market* el cual mide el rendimiento de la inversión del mercado de valores compuesto por más de 3.500 empresas, representando el 100% del mercado de acciones invertibles de EE.UU. A continuación, la tabla de composición del ETF con Top 10 Holdings (26.13% del total de activos) al mes de noviembre de 2023:

Tabla nro. 1 de composición Top 10 Holdings del ETF Vanguard Total Stock Market Index Fund

Nombre	Símbolo	% Activos
Apple Inc	AAPL	6.07%
Microsoft Corp	MSFT	5.60%
Amazon.com Inc	AMZN	2.82%
NVIDIA Corp	NVDA	2.44%
Alphabet Inc Class A	GOOGL	1.85%
Tesla Inc	TSLA	1.61%
Meta Platforms Inc Class A	META	1.59%
Alphabet Inc Class C	GOOG	1.55%
Berkshire Hathaway Inc Class B	BRK.B	1.49%
Exxon Mobil Corp	XOM	1.12%

Fuente: Yahoo Finance

ii) ETF iShares Core S&P 500: Con stockname US4642872000, símbolo IVV, y perteneciente al Holding iShares ETFs by BlackRock, sus datos históricos están comprendidos desde el 18 de mayo de 2000 hasta el 25 de octubre de 2023. Su objetivo de inversión es medir el desempeño del sector de gran capitalización del mercado de valores estadounidense, según lo determinado por el índice *S&P Dow Jones Indices* (SPDJI). A continuación la tabla de composición del ETF con Top 10 Holdings (30.54% del total de activos) al mes de octubre de 2023:

Tabla nro. 2 de composición Top 10 Holdings del ETF iShares Core S&P 500

Nombre	Símbolo	% Activos
Apple Inc	AAPL	6.98%
Microsoft Corp	MSFT	6.51%
Amazon.com Inc	AMZN	3.20%
NVIDIA Corp	NVDA	2.98%
Alphabet Inc Class A	GOOGL	2.16%
Tesla Inc	TSLA	1.92%
Meta Platforms Inc Class A	META	1.85%
Alphabet Inc Class C	GOOG	1.85%
Berkshire Hathaway Inc Class B	BRK.B	1.77%
Exxon Mobil Corp	XOM	1.31%

Fuente: Yahoo Finance

iii) ETF SPDR S&P 500 ETF Trust: Con stockname US78462F1030, símbolo SPY, y perteneciente al Holding State Street Global Advisors (SSGA), sus datos históricos están comprendidos desde el 28 de enero de 1993 hasta el 27 de octubre de 2023. SPY fue el primer ETF que cotiza en los Estados Unidos. Y su objetivo de inversión busca proporcionar resultados de

inversión (antes de gastos) que correspondan al precio y al rendimiento del índice *S&P 500*. A continuación, la tabla de composición del ETF con Top 10 Holdings (30.51% del total de activos) al mes de octubre de 2023:

Tabla nro. 3 de composición Top 10 Holdings del ETF SPDR S&P 500 ETF Trust

Nombre	Símbolo	% Activos
Apple Inc	AAPL	6.98%
Microsoft Corp	MSFT	6.51%
Amazon.com Inc	AMZN	3.20%
NVIDIA Corp	NVDA	2.98%
Alphabet Inc Class A	GOOGL	2.15%
Tesla Inc	TSLA	1.92%
Meta Platforms Inc Class A	META	1.85%
Alphabet Inc Class C	GOOG	1.85%
Berkshire Hathaway Inc Class B	BRK.B	1.77%
Exxon Mobil Corp	XOM	1.31%

Fuente: Yahoo Finance

iv) ETF iShares MSCI Germany ETF: Con stockname US4642868065, símbolo EWG, y perteneciente al Holding iShares ETFs by BlackRock, sus datos históricos están comprendidos desde el 17 de mayo de 1996 hasta 27 de octubre de 2023. Está diseñado para medir el rendimiento de los segmentos de gran y mediana capitalización del mercado alemán. Con 58 componentes, el índice cubre alrededor del 85% del universo de acciones en Alemania. A continuación, la tabla de composición del ETF con Top 10 Holdings (55.68% del total de activos) al mes de octubre de 2023:

Tabla nro. 4 de composición Top 10 Holdings del ETF iShares MSCI Germany

Nombre	Símbolo	% Activos
SAP SE	SAP.DE	10.95%
Siemens AG	SIE.DE	8.80%
Allianz SE	ALV.DE	7.77%
Deutsche Telekom AG	DTE.DE	5.50%
Mercedes Benz Group AG	MUV2.DE	4.51%
Munchener Rückversicherungs-Gesellschaft AG	MBG.DE	4.30%
Bayer AG	BAYN.DE	3.81%
Infineon Technologies AG	IFX.DE	3.50%
Basf SE	BAS.DE	3.28%
DHL Group	DHL.DE	3.26%

Fuente: Yahoo Finance

v) ETF Invesco S&P 500 UCITS: Con stockname: IE00B3YCGJ38, símbolo SPXS.L y pertenece al Holding Invesco, sus datos históricos están comprendidos desde el 19 de mayo de 2010 hasta 09 de noviembre de 2023. Su objetivo de inversión es lograr el rendimiento neto total del Índice S&P 500, menos comisiones, gastos y costos de transacción.

Tabla nro. 5 de composición Top 10 Holdings ETF Invesco S&P 500 UCITS

Nombre Símbolo % Activos

NVIDIA Corporation	NVDA	4.06%
Arista Networks, Inc.	ANET	2.83%
Uber Technologies, Inc.	UBER	2.75%
Royal Caribbean Cruises Ltd.	RCL	2.56%
Builders FirstSource, Inc.	BLDR	2.56%
Super Micro Computer, Inc.	SMCI	2.54%
Advanced Micro Devices, Inc.	AMD	2.36%
Monolithic Power Systems, Inc.	MPWR	2.34%
Meta Platforms, Inc.	META	2.30%
Booking Holdings Inc.	BKNG	2.29%

Fuente: Stockanalysis <https://stockanalysis.com/etf>

3.1.2 Selección de Variables de interés

Se seleccionaron las siguientes variables junto con indicadores técnicos (los precios se encuentran en moneda USD). La variable a predecir es el precio de cierre ajustado o *adjusted close* (AdjC). A continuación las variables seleccionadas:

- Fecha (*date*)
- C = Precio de cierre (*close price*). El precio de cierre es el último precio al que se negocia la acción durante el día de negociación habitual (*regular trading day*). El precio de cierre de una acción es el punto de referencia estándar utilizado por los inversores para seguir su desempeño a lo largo del tiempo.
- AdjC = Precio ajustado o de cierre ajustado (*adjusted close*). Se le considera el verdadero precio de cierre. Incorpora elementos como dividendos, divisiones de acciones (*split*) y nuevas ofertas de acciones (*new stock*). Comparado con el precio de cierre C, es más detallado y preciso. Y debido a que circunstancias externas pueden causar cambios en el precio genuino, el ajuste realizado representa el precio real de la acción (Pardeshi et al. 2023). Además, las acciones pueden tener "acciones corporativas" que pueden afectar retroactivamente el precio de cierre de una acción, así todos los datos históricos de la empresa subyacente (o ticker) deben actualizarse para compensar esto.
- O = Precio de apertura (*open price*)
- L = Precio mínimo (*low price*)
- H = Precio máximo (*high price*)
- V = Volumen de transacción (*volume*). El volumen es la cantidad de un activo o valor que cambia de manos durante un período de tiempo, a menudo en el transcurso de un día. Por ejemplo, el volumen de negociación de acciones se referiría a la cantidad de acciones de

valores negociadas entre su apertura y cierre diario. El volumen de operaciones y los cambios en el volumen a lo largo del tiempo son datos importantes para los operadores técnicos (technical traders).

3.2 Preprocesamiento de la data (Data Preprocessing)

3.2.1 Cálculo de Indicadores Técnicos

Un indicador técnico es la herramienta más importante para el análisis técnico. Las decisiones sobre cómo y cuándo operar (*trading*) se pueden tomar sobre la base de señales de indicadores técnicos. La esencia de los indicadores técnicos es una transformación matemática del precio de un símbolo financiero destinada a pronosticar cambios futuros de precios. El retorno mide el cambio de precio P_t durante dos días según la ecuación:

$$\text{Retorno} = (P_t - P_{t-1})/P_t$$

A continuación, se muestran algunos de los indicadores técnicos y sus definiciones:

- Median Price (HL/2) — calculado con el precio promedio: (High + Low)/2
- Typical Price (HLC/3) — calculado con el precio típico: (High + Low + Close)/3.
- Weighted Close (HLCC/4) — calculado con el precio de Cierre ponderado: (High + Low + 2*Close)/4

3.2.2 Sliding Windows

La red LSTM tiene la capacidad de capturar o aprender dependencias de largo plazo en datos de series de tiempo financieras. Este trabajo opta por emplear el modelo LSTM con pasos de tiempo (*timestep*) o pasos hacia atrás (*lookback*) equivalentes a la totalidad de días comerciales por cada año (*trading days per year*). En redes LSTM el *timestep* se refiere al número de pasos de tiempo o secuencia de pasos que el modelo considera a la vez.

3.2.3 Escalamiento de variables

Se realiza una normalización de funciones para todos los modelos, garantizando escalamiento uniforme. Esto evita que *features* de diferentes magnitudes afecten la estabilidad del entrenamiento del modelo e incluso causan problemas de convergencia. Utilizamos la normalización Max-Min para todas las *features*. Suponiendo que x denota el *feature* individual, la ecuación de normalización se muestra como:

$$z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)}$$

Mediante la ecuación, todas las *features* se pueden escalar a números entre 0 y 1. Donde: z_i son los datos escalados; x_i son los datos a escalar; $\min(x)$ es el valor mínimo dentro de los datos a escalar. Cabe notar que para el cálculo de las estadísticas de $\min()$ sólo se usó la porción de datos de *training* de manera de evitar el *data-leakage problem*.

3.2.4 Splitting Training/Testing

Se trabajó con los períodos de *training* y de *testing*, que no se cruzan para evitar problemas de *data leakage*, el cual es el término empleado para referirse a un conjunto de datos que no pertenece a la sección de *training*, y este conjunto es empleado en el proceso de aprendizaje del modelo (Saravanan et al. 2020). El *data leakage* puede ocurrir en las situaciones de filtración de datos: desde la sección de *testing* a la sección *training*; datos predichos hacia la sección de *training*; y datos futuros a datos pasados.

3.3 Modelamiento predictivo (Predictive Modeling)

3.3.1 Modelos deep learning

En el trabajo se aplican redes neuronales recurrentes, convolucionales e híbridas con mecanismos de atención para conformar diversas arquitecturas.

La red neuronal recurrente RNN es propensa a provocar la desaparición y explosión del gradiente en el proceso de *back-propagation* (Huang, Shen y Liu, 2019), sin embargo, la red LSTM de memoria a largo y corto plazo, resuelve lo anterior. LSTM introdujo un mecanismo de puerta (gate), el cual puede verse como una simulación de la memoria humana, en la que puede recordar información útil y olvidar información inútil.

Un módulo o celda LSTM tiene 5 componentes esenciales que le permiten modelar datos tanto a corto como a largo plazo.

1. Estado de la celda (ct): representa la memoria interna de la celda que almacena tanto la memoria a corto plazo como la memoria a largo plazo.
2. Estado oculto (ht): esta es la información del estado de salida calculada, entrada actual, estado oculto anterior y entrada de celda actual que eventualmente se utilizará para predecir los precios futuros del mercado de valores. Además, el estado oculto puede decidir recuperar solo los tipos de memoria a corto y/o largo plazo almacenados en el estado de la celda para hacer la siguiente predicción.
3. Puerta de entrada (it): decide cuánta información de la entrada actual fluye al estado de la celda.

4. Puerta de olvido (f_t): decide cuánta información de la entrada actual y del estado de la celda anterior fluye al estado actual de la celda.
5. Puerta de salida (o_t): decide cuánta información del estado actual de la célula fluye hacia el estado oculto, de modo que, si es necesario, LSTM solo puede seleccionar los recuerdos a largo plazo, o los recuerdos a corto plazo y largo plazo.

3.3.2 Mecanismos de atención

Por otra parte, el mecanismo de Atención (*attention mechanism*) puede verse como una simulación de la atención humana, en la que el ser humano puede prestar atención a información útil e ignorar la información inútil.

El mecanismo de atención surge de una innovación de la traducción automática neuronal (*neural machine translation* o NMT), la cual es un enfoque para la traducción automática que tiene como objetivo construir una única red neuronal que pueda ajustarse conjuntamente para maximizar el rendimiento de la traducción del texto. Luong et al. trabaja en la exploración de arquitecturas útiles para NMT basada en la atención, examinando dos clases simples y efectivas de mecanismos de atención, un enfoque global y uno local (Luong M-T., Pham H., Manning C. D., 2015). Dado que la mayoría de los modelos de NMT pertenecen a una familia de codificadores-decodificadores (*encoder-decoder*), con un codificador y un decodificador para cada idioma, o implican la aplicación de un codificador específico del idioma de cada oración cuyos resultados luego se comparan. Un problema con este enfoque *encoder-decoder* es que una red neuronal debe poder comprimir toda la información necesaria de una oración fuente en un vector de longitud fija. Para abordar este problema, Bahdanau et al. introduce una extensión del modelo *encoder-decoder* que aprende a alinearse y traducirse conjuntamente (consistente de una *RNN encoder*). Cada vez que el modelo propuesto genera una palabra en una traducción, busca (soft) un conjunto de posiciones en una oración fuente donde se concentra la información más relevante. Luego, el modelo predice una palabra de destino en función de los vectores de contexto asociados con estas posiciones de origen y todas las palabras de destino generadas anteriormente. Este enfoque codifica la oración de entrada en una secuencia de vectores y elige un subconjunto de estos vectores de manera adaptativa mientras decodifica la traducción. (Bahdanau D., Cho K., Bengio Y., 2016). Aunque los modelos de traducción de secuencias dominantes se basan en redes neuronales complejas, recurrentes o convolucionales, que incluyen un *encoder-decoder*, Vaswani et al., proponen una nueva arquitectura de red simple, el Transformer, basada únicamente en mecanismos de atención, prescindiendo por completo de la recurrencia y las convoluciones (Vaswani et al., 2017).

Los *inputs* de los mecanismos de atención son una lista con 2 o 3 elementos: Un tensor (noción que generaliza los vectores) de consulta Q de forma (batch_size, Tq, dim). Un tensor de

valor V de forma (batch_size, Tv, dim). Un tensor clave K de forma opcional (batch_size, Tv, dim), si no se proporciona ninguno, el valor se utilizará como clave K ([Fuente: keras.io](#)). Se incluyen los siguientes mecanismos:

Bahdanau Attention (o additive style): la librería AdditiveAttention() implementa el mecanismo ([Fuente: keras.io](#)). El cálculo sigue los pasos: cálculo del *attention score* utilizando Q y K como una suma no lineal $score = \text{reduce_sum}(\tanh(Q + K))$. Utiliza puntuaciones para calcular una distribución softmax, y utiliza la distribución softmax para crear una combinación lineal de V.

Luong Attention (o multiplicative style): la librería Attention() implementa el mecanismo ([Fuente: keras.io](#)). El score_mode {"dot", "concat"} es el modo a utilizar para calcular puntuaciones (*attention scores*):

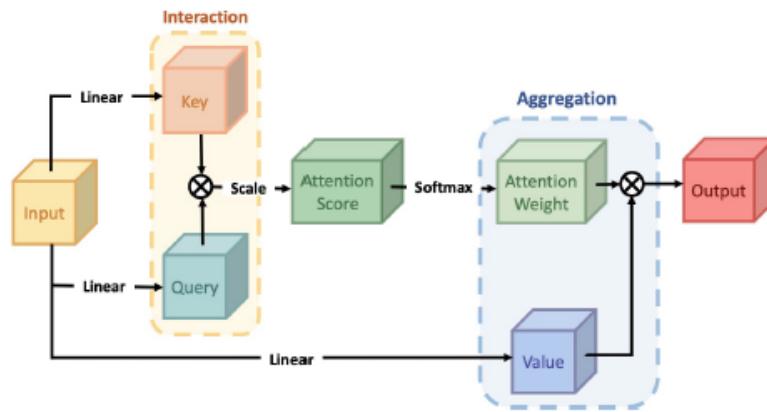
- "punto" (dot-product) se refiere al producto escalar entre los vectores de query Q y key K.
- "concat" se refiere a la tangente hiperbólica de la concatenación de los vectores query Q y key K.

Scaled Dot-Product Attention: Primero, el mecanismo *Attention* calcula las matrices Q , K y V respectivamente. Luego, el producto escalar o punto (dot-product) de las matrices Q y K^\top (K traspuesta) se escala por $[1/\sqrt{d_k}]$ para obtener las puntuaciones *attention score*, siendo d_k la dimensión del vector key. La función *softmax* normaliza estas puntuaciones para producir ponderaciones que indican la importancia de diferentes elementos ([Shen Yanhui, 2023](#)). Finalmente, se calcula la suma ponderada del vector V para generar la salida de atención (*Output*). Se aprecia el mecanismo en la siguiente figura.

Attention se calcula de la siguiente manera ([Aldosari et al., 2024](#)):

$$\text{Attention}(Q, K, V) = \text{softmax} \left[QK^\top / \sqrt{d_k} \right] V$$

Figura nro. 2 del Mecanismo de Atención



Fuente: Yanhui Shen, 2023. American Option Pricing using Self-Attention GRU and Shapley Value Interpretation.

Local Soft Attention: *Local soft attention* atiende sólo a unos pocos estados ocultos (ht) *hidden states* que caen dentro de una ventana más pequeña.

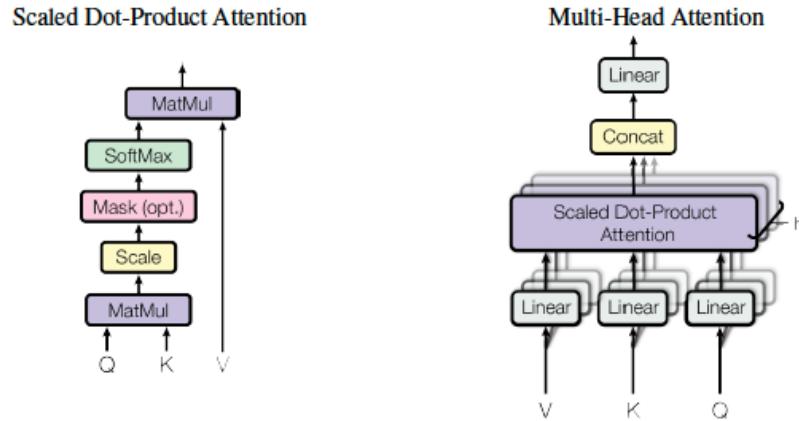
Multi-Head Attention: la librería MultiHeadAttention() implementa el mecanismo de atención multi-direccional. El mecanismo Multi-Head Attention es un componente clave de los modelos basados en *Transformer*, como BERT y GPT, que se utilizan para diversas tareas de procesamiento del lenguaje natural (Quansah and Tenkorang, 2023). Describen una nueva arquitectura de red simple, el *Transformer*, basado en mecanismos de atención, el cual prescinde por completo de la recurrencia y las convoluciones (Vaswani et al., 2017). Multi-Head Attention emplea múltiples heads de atención en paralelo, y destaca en capturar dependencias a extremadamente largo plazo en secuencias de datos. Cada head de atención se centra en diferentes partes de la secuencia de entrada, lo que permite que el modelo capture varios tipos de información y dependencias simultáneamente.

Concatenación (*Concat*) y transformación lineal después de calcular los resultados de *Attention()* para cada head, los concatenamos y aplicamos una transformación lineal para obtener el resultado final de Multi-Head Attention (Vaswani et al., 2017).

$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \text{head}_3, \dots, \text{head}_h)W^o$ donde $\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$, y donde *Concat()* concatena las salidas de todos los attention heads, y W^o es una transformación lineal aprendida.

Una instancia de Multi-Head Attention es *Self-Attention*, sólo si los vectores consulta, clave y valor (Q, K, V) son iguales.

Figura nro. 3 del Mecanismo de Atención Scaled Dot-Product (izq.) y Multi-Head Attention (der.)



Fuente: Vaswani et al., 2017. *Attention is all you need*.

3.3.3 Optimización de hiper-parámetros

Keras, creada por François Chollet, es una API de redes neuronales de alto nivel escrita en Python, capaz de ejecutarse sobre *TensorFlow*, *CNTK* o *Theano*. Actualmente *Keras* es oficialmente parte de *Tensorflow*.

AutoML se refiere a las técnicas para descubrir automáticamente el modelo de mejor rendimiento para un conjunto de datos usando NAS (*neural architecture search*).

AutoKeras, es una biblioteca de software de código abierto para el aprendizaje automático automatizado, que proporciona funciones para buscar automáticamente una arquitectura y algunos hiper-parámetros del modelo *deep learning*. Cabe notar que la calidad de los modelos predictivos dependen críticamente de la optimización de los hiper-parámetros de la red neuronal (Li et al. 2018). *AutoKeras* utiliza ENAS (*efficient neural architecture search*), una nueva versión de búsqueda automática de arquitectura de redes neuronales. El morfismo de red cambia la arquitectura de la red neuronal manteniendo su funcionalidad, lo que permite un entrenamiento más eficiente durante el proceso de búsqueda de ENAS.

A continuación un listado breve de parámetros y valores seteados para *AutoModel* de *AutoKeras* para los modelos multivariados con mejores métricas:

Tabla nro. 6 de parámetros para AutoModel de AutoKeras

Parámetro del AutoKeras	Valor seleccionado	Valores posibles	Explicación
max_trials	100	Integer	El número máximo de modelos Keras diferentes para probar.
objective	'val_loss'	['val_loss', 'val_accuracy']	Nombre de la métrica del modelo a minimizar o maximizar. El valor predeterminado es 'val_loss'.
tuner	'bayesian'	['greedy', 'bayesian', 'hyperband' o 'random']	También puede ser una subclase de AutoTuner.
seed	2023	Integer	Semilla aleatoria (random seed).
loss	'mean_squared_error'	['mean_squared_error']	Una función de pérdida de Keras.

batch_size	32	Integer	El modelo puede determinar si los datos de entrada son del mismo batch gracias a su configuración.
epochs	1.000	Integer	El número de épocas para entrenar cada modelo durante la búsqueda.
optimizer	Adam	string	Optimizador
learning rate	0.0001	Float	Tasa de aprendizaje (lr)
Monitor Patience	30	Integer	Si no se especifica, por default, Early Stopping con patience 30
validation_split	0.2	Decimal [0,1]	Fracción de los datos de entrenamiento que se utilizarán como datos de validación.

En el presente trabajo el parámetro tuner es igual a ‘bayesian’, considerando que los creadores de *AutoKeras* afirman que al utilizar la optimización bayesiana para seleccionar operaciones de morfismo de red, el espacio de búsqueda se puede explorar de manera más eficiente (Jin H. et al., 2019). *Random Search* es un algoritmo que comienza aleatoriamente en una solución dentro del espectro de las soluciones posibles que se compara con otra solución escogida aleatoriamente, y así sucesivamente; *Hyperband* es un algoritmo similar al *random search*, pero es capaz de identificar las configuraciones no óptimas a partir de un número determinado de iteraciones, ya que cuenta con un *early stopping*. Existe evidencia empírica que el Bayesian Optimization (algoritmo probabilístico basado en el teorema de Bayes para encontrar un óptimo global de una función de optimización), supera al *Random Forest* (Li et al. 2018).

Por otra parte, la librería *SciKeras* realiza la optimización de hiper-parámetros sobre los modelos entrenados que presentan mejor rendimiento. Hace posible el uso de Keras y TensorFlow con Sklearn, al proporcionar un contenedor (*wrapper*) alrededor de Keras que tiene una interfaz Scikit-Learn, tf.keras.wrappers.scikit_learn. Al entrenar los mejores modelos se define el Keras Sequential, se entrena en el conjunto de datos usando KerasRegression, y usando SciKeras que puede realizar un sklearn GridSearchCV, incluido en el paquete de scikit-learn. GridSearchCV es una técnica de validación cruzada que se ejecuta a través de los diferentes parámetros que se introducen en la cuadrícula de parámetros y extrae automáticamente la combinación de parámetros optimizados con los mejores valores. En GridSearchCV el parámetro scoring es transformado, es la versión negada de MSE, donde un valor más alto es mejor que valores bajos. A continuación un listado de valores de parámetros simulados con *SciKeras* generando el modelo más sofisticado MV-552KS-BILSTM-LUONG-AutoKeras-y-SciKeras:

Tabla nro. 7 de parámetros para *SciKeras* para generar el modelo MV-552KS-BILSTM-LUONG-AutoKeras-y-SciKeras

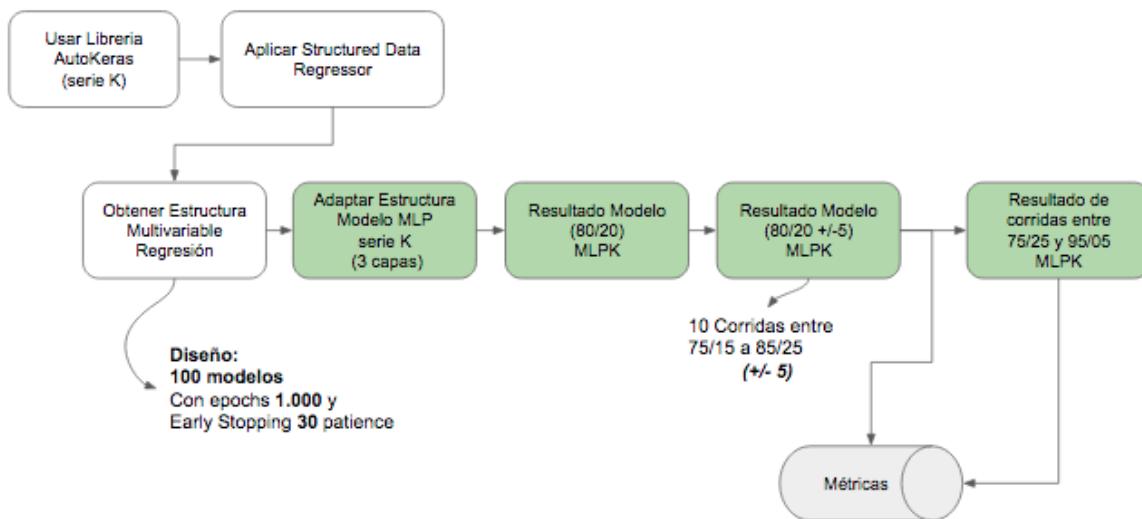
Parámetro de SciKeras	Valores
optimizer	['Adam', 'Nadam', 'Adamax', 'Adagrad', 'Adadelta', 'RMSprop', 'SGD']
batch_size	[16, 32, 64, 128]
activation	['sigmoid', 'relu', 'tanh']
loss	['mean_squared_error']
scoring_parameter	['neg_mean_squared_error']

3.3.4 Modelos tradicionales benchmark

Los modelos tradicionales para benchmarking son MLP, AutoRegresivo, ARIMA y ARIMAX.

El modelo MLP o *Multi Layer Perceptron* es una clase de red neuronal artificial de retroalimentación (*feed-forward*) que consta al menos de tres capas de nodos: entrada *Input*, oculta *Hidden* y de salida *Output*. El *backpropagation* es el mecanismo para actualizar los pesos y el sesgo (*bias*), comenzando desde la salida y propagándose a través de las capas previas. El modelo MLP aplicando *Structured Data Regressor* de *AutoKeras* se convierte en el modelo MLPK. En la siguiente figura se presenta el flujo de procesos para obtener el modelo MLPK y sus métricas de resultados.

Figura nro. 4 del flujo de procesos usando modelos MLP y MLPK (MLP con AutoKeras)



Fuente: Elaboración propia

El modelo ARIMA o autorregresivo integrado de promedio móvil, acrónimo del inglés *AutoRegressive Integrated Moving Average*, fue desarrollado el año 1976 por Box y Jenkins. Es un algoritmo de pronóstico basado en la idea de que la información de los valores pasados de la serie temporal por sí sola puede usarse para predecir los valores futuros. El modelo ARIMA en palabras: Y_t pronosticado = Constante + Combinación lineal de Retrasos de Y (hasta p rezagos) + Combinación lineal de errores de pronóstico rezagados (hasta q rezagos).

Se utilizó ARIMA con stepwise = “True” que realiza un *random search*. Al utilizar ARIMA con stepwise = “False” realiza un *grid search*, el cual se cae por falta de capacidad de memoria RAM en Google Colab Pro+.

ARIMA se caracteriza por 3 términos: p, d, q. Se utilizó la librería *auto-arima* del paquete *pmdarima* para identificar automáticamente los 3 términos (p, d, q).

Donde “p” representa el orden del término AutoRegresivo (AR) o rezagos que se utilizarán como predictores.

Donde “d” es el número de diferenciaciones necesarias para que la serie temporal sea estacionaria. En el presente trabajo, la serie de tiempo es estacionaria, entonces d = 0 (Xiao R., et al. 2022), esto se verificó usando la prueba Augmented Dickey Fuller, adfuller() del paquete *statsmodels*.

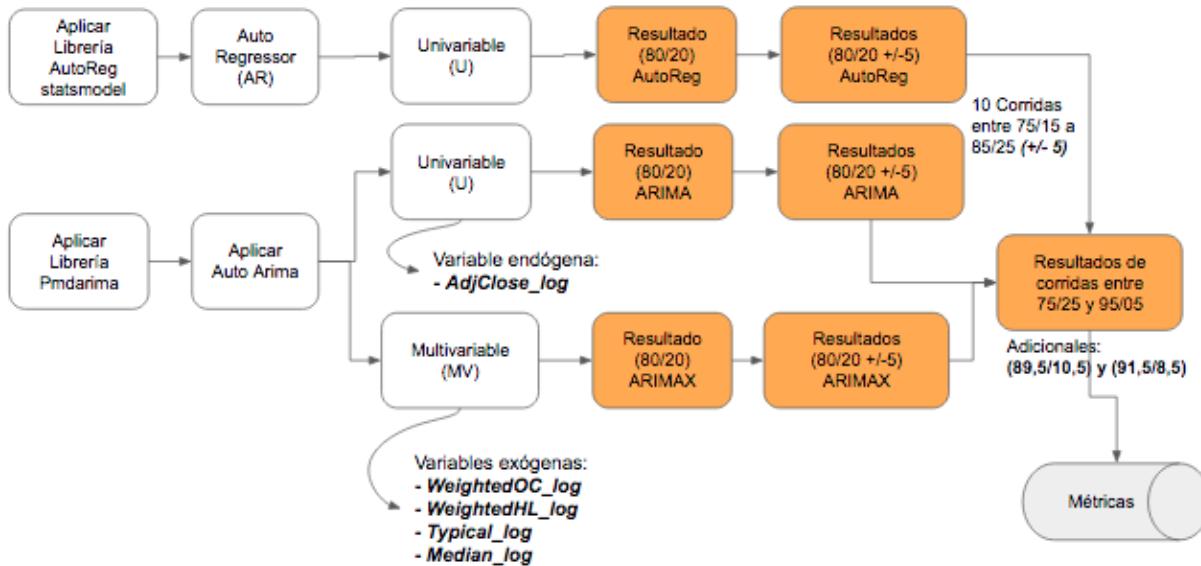
Donde “q” representa el número de rezagos sobre los errores de predicción utilizados en el modelo.

El modelo AutoRegresivo AR(p) intenta predecir la variable utilizando una combinación lineal de valores pasados de esta variable. La librería *statsmodels* estima parámetros utilizando métodos estadísticos de un modelo de regresión.

El modelo ARIMAX o *autoregressive integrated moving average exogenous variable* es un modelo ARIMA con variables explicativas adicionales, la X añadida al final significa exógeno, en otras palabras, agrega variables externas diferentes para ayudar a medir la variable endógena.

En los modelos ARIMA y ARIMAX rige el criterio de información de Akaike o AIC, por Hirotugu Akaike, es un estimador de la calidad relativa del modelo que tiene en cuenta su complejidad. Cuanto más bajo sea el AIC, mejor. A medida que va aumentando el número de parámetros de entrada o grados de un polinomio (el valor de MSE disminuye), el criterio de información Akaike o *AIC metric* penaliza los modelos complejos en favor de los sencillos para evitar el sobreajuste *overfitting*. En la siguiente figura se presenta el flujo de procesos para obtener las métricas de resultados usando los modelos AR, ARIMA y ARIMAX.

Figura nro. 5 del flujo de procesos usando modelos AutoReg, ARIMA y ARIMAX



Fuente: Elaboración propia

3.4 Evaluación del modelo y comparaciones

3.4.1 Análisis de predictibilidad

Para evaluar el efecto de pronóstico de los modelos, y para la selección de los modelos se utilizan los siguientes indicadores:

MSE (*mean square error*) es el error cuadrático medio, mide el promedio de las diferencias al cuadrado entre los valores predichos y los valores reales. MSE da más peso a los errores más

$$\text{grandes. } MSE_i = \frac{1}{n} \sum_{t=1}^n (y_{t,i} - \hat{y}_{t,i})^2 \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}$$

Donde n representa el número de observaciones (acciones en una cartera de inversión cuantitativa), y_i es el valor real de las acciones, \hat{y}_i el valor predicho. Cuanto más cerca de 0 esté el valor de MSE, menor será el error entre el valor predicho y el valor real, mayor será la precisión del pronóstico.

RMSE (*root mean square error*) es la raíz cuadrada del MSE. Tiene la misma unidad que la variable objetivo. RMSE proporciona una medida de la desviación estándar de los errores de predicción. Mide la desviación entre el valor predicho (observado) y el valor real. Se describe por

$$\text{RMSE} = \sqrt{\text{MSE}}$$

la ecuación: En el mundo real de las inversiones, un RMSE más bajo significa pronósticos más precisos, lo que puede ayudar a los inversores a tomar decisiones de inversión más informadas (Tao et al., 2024).

DA (Directional Accuracy) es la precisión direccional, mide el porcentaje de predicciones que tienen el signo correcto (es decir, si las predicciones indican un aumento o una disminución en la variable objetivo). DA es útil para evaluar la exactitud de la dirección predicha, particularmente en pronósticos financieros o de mercado. Especifica la precisión de predecir la dirección correcta del movimiento del precio hacia arriba o hacia abajo, según la ecuación:

$$DA_i = \frac{1}{n} \sum_{t=1}^n a_{t,i} \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}$$

$$a_{t,i} \{ 1, \text{ si } (\hat{p}_t - \hat{p}_{t-1}) \cdot (p_t - p_{t-1}) > 0 \ 0, \text{ si } (\hat{p}_t - \hat{p}_{t-1}) \cdot (p_t - p_{t-1}) < 0 \} \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}$$

Para la modelación de retornos, la fórmula es la siguiente:

$$DA_i = \frac{1}{n} \sum_{t=1}^{n-1} a_{t,i} \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}; \text{ donde } a_{t,i} \{ 1, \text{ si } \hat{r}_t > 0 \ 0, \text{ si } \hat{r}_t < 0 \}$$

MAE (mean absolute error) es el error absoluto medio mide la diferencia absoluta promedio entre los valores predichos y los valores reales. MAE proporciona el error promedio de los pronósticos del modelo sin interferencia de los *outliers* (valores atípicos). Representa el error absoluto, que puede reflejar la situación real del error del valor predicho (Huang et al., 2024). Donde n representa el número de observaciones (acciones en una cartera de inversión cuantitativa), y_i es el valor real de las acciones, \hat{y}_i el valor predicho (*predicted*).

$$MAE_i = \frac{1}{n} \sum_{t=1}^{n-1} |y_i - \hat{y}_i|_{t,i} \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}$$

MAPE (mean absolute percentage error) es el error porcentual absoluto medio calcula la diferencia porcentual promedio entre los valores predichos y reales. MAPE expresa el error como porcentaje, lo cual es útil para comprender la magnitud de los errores en relación con los valores reales. Utiliza valores absolutos para evitar que los errores positivos y negativos se cancelen entre sí (Huang et al., 2024). MAPE proporciona una magnitud relativa del error de predicción, así los inversores pueden evaluar el sesgo (*bias*) de pronóstico de un modelo basado en MAPE comparándolo con el valor real (Tao et al., 2024).

$$MAPE_i = \frac{100 \%}{n} \sum_{t=1}^{n-1} \left| \frac{y_i - \hat{y}_i}{y_i} \right|_{t,i} \quad \forall i \in 1 \dots N^{\circ} \text{ acciones}$$

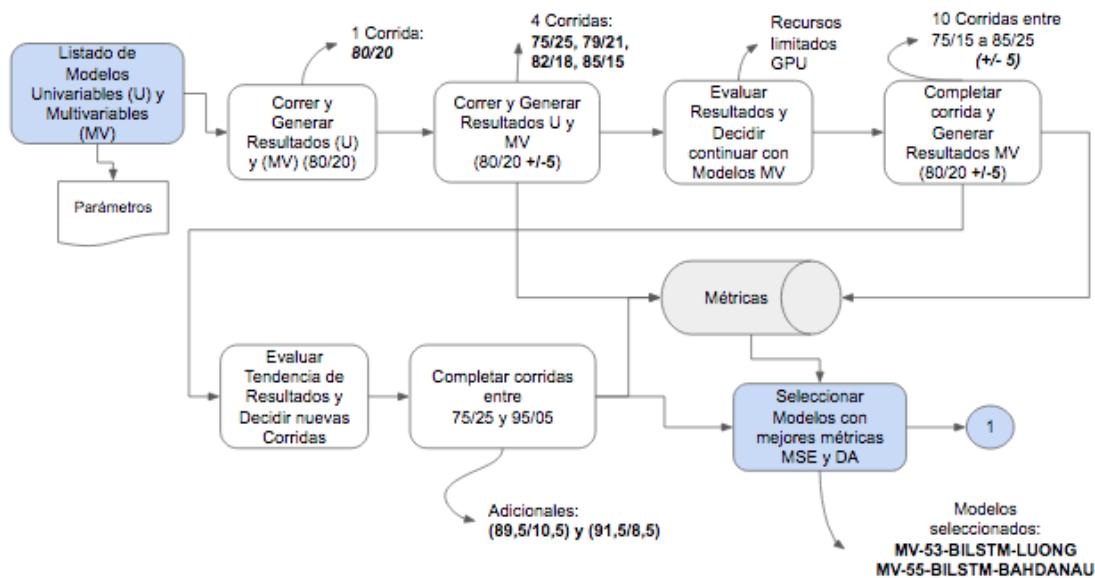
MDAPE (median absolute percentage error) es el error porcentual absoluto de la mediana es similar al MAPE pero utiliza la mediana en lugar de la media. MDAPE se ve menos afectado por valores atípicos (*outliers*) en comparación con MAPE, ya que utiliza la mediana. Cuanto menor sea su valor, mejor será el pronóstico.

$$MDAPE_i = 100 \% \text{ mediana} \left(\sum_{t=1}^{n-1} \left| \frac{y_i - \hat{y}_i}{y_i} \right|_{t,i} \right) \quad \forall i \in 1 \dots N^{\circ} \text{ acciones.}$$

Inspirado en el trabajo de Zhang, se obtiene un criterio para evaluar los modelos de predicción (Zhang J. et al., 2023): $Score = 0,7 \times DA - 0,2 \times MAPE - 0,1 \times MAE$

A continuación se presentan las figuras nro. 6, 7 y 8, correspondientes al flujo de procesos para obtener las métricas de resultados usando los modelos deep learning univariados (U) y multivariados (MV). La figura se divide en partes secuenciales (1), (2) y (3), que describen el flujo de proceso efectuado al correr los modelos para obtener sus métricas.

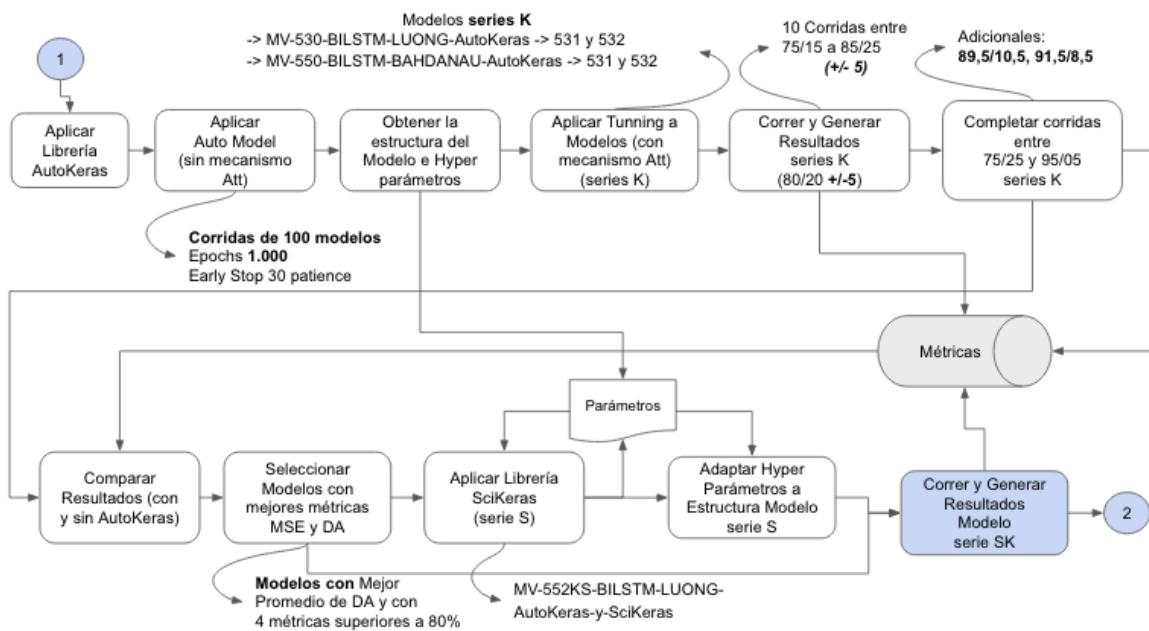
Figura nro. 6 del flujo de procesos usando modelos univariados U y multiVariados MV (1)



Fuente: Elaboración propia

En el diagrama de procesos (2) se puede apreciar la aplicación de AutoKeras para explorar una arquitectura óptima (serie K), y la aplicación de SciKeras para la optimización de los hiper-parámetros restantes (serie S). Se puede apreciar en la figura que el modelo más sofisticado es MV-55K2S-BILSTM-LUONG-AutoKeras-y-ScKeras.

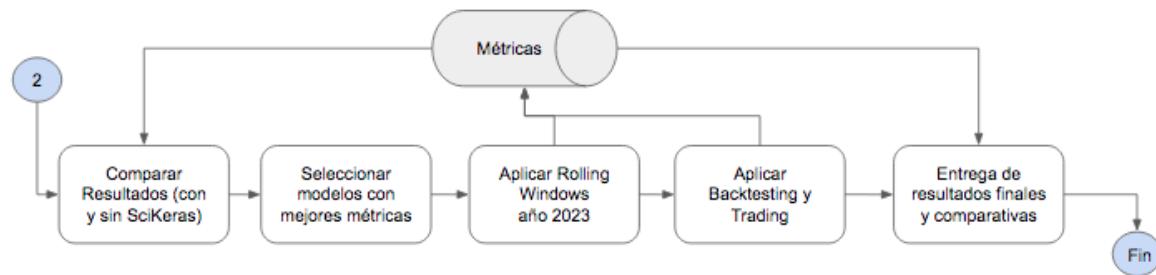
Figura nro. 7 del flujo de procesos usando modelos univariados U y multiVariados MV (2)



Fuente: Elaboración propia

En el diagrama de procesos (3) se incluye la aplicación de *rolling windows* durante el año 2023, y el *backtesting y trading* durante el período 2003-2023.

Figura nro. 8 del flujo de procesos usando modelos univariados U y multiVariados MV (3)



Fuente: Elaboración propia

3.4.2 Análisis de re-estimación

Se realiza simulación de ventanas deslizantes o *rolling windows* a los modelos con mejores métricas.

3.4.3 Análisis de complejidad

Se realizan corridas según tipo de arquitectura con diferentes números de parámetros y números de epochs, incluyendo epochs igual a 1.000 y early stopping con patience 30.

3.4.4 Análisis de rentabilidad

El *backtesting* o prueba retrospectiva, es el proceso de simular una estrategia de *trading* utilizando datos históricos del mercado para determinar su viabilidad y rentabilidad potencial. Esta evaluación crítica permite a los *traders* ajustar sus estrategias en un entorno controlado antes de la implementación en el mundo real (Ma et al., 2023). Se utiliza *signal backtester* de la librería *backtesting* que dispone de las siguientes seis estrategias de *trading*:

1. two_side_sl_tp_reversed: Esta estrategia abre posiciones en ambos lados de compra y venta. Cierra la posición con *stoploss* o *take profit*. Si tiene una posición de compra abierta y da una señal de venta, cierra la última posición y abre una nueva.
2. two_side_sl_trailing_reversed: Esta estrategia abre posiciones en ambos lados de compra y venta, y cierra la posición con *stoploss*. El *stoploss* es dinámico, si el precio cambia, su *stoploss* cambiará. Además, si tiene una posición de compra abierta y da una señal de venta, cierra la última posición y abre una nueva.
3. one_side_buy_sl_tp: Esta estrategia abre una posición solo en una compra lateral. Cierra posición con *stoploss* o *takeprofit*.
4. one_side_sell_sl_tp: Esta estrategia abre una posición solo en venta por un lado. Cierra posición con *stoploss* o *takeprofit*.
5. one_side_buy_sl_trailing: Esta estrategia abre una posición solo en una compra lateral. Cierra la posición con *stoploss*. El *stoploss* es dinámico, si el precio cambia, su *stoploss* cambiará.
6. one_side_sell_sl_trailing: Esta estrategia abre una posición solo en venta por un lado. Cierra la posición con *stoploss*. El *stoploss* es dinámico, si el precio cambia, su *stoploss* cambiará.

Uno de los supuestos del *backtesting* es que en cada operación de compra o venta se invierte el 100% del patrimonio. Los parámetros de la librería son los siguientes: Saldo inicial 10.000; Comisión o expense ratio 0.05%; Takeprofit y Stoploss, ambos con 50%, para evitar que la operación se cierre por el concepto *take profit* y *stop loss* respectivamente; y Trailing Stop 3%.

Con el fin de evaluar la capacidad predictiva del modelo, se realiza un análisis de rentabilidad para los modelos seleccionados y el respectivo modelo *benchmark* MV-80-CNN-LUONG (CNN).

A continuación se describen los conceptos (Huang et al., 2024):

- Expense ratio: es una tarifa, como porcentaje de los gastos, que se cobran a los inversores para cubrir los costos operativos de un ETF que se deducen de las distribuciones de dividendos y ganancias de capital (no del capital).

- Retorno: cantidad total que una inversión ha ganado o perdido en el período.
- Equity: patrimonio Final y Peak alcanzado en que se convirtió la inversión inicial.
- Sharpe ratio = $(Rp - Rf)/\sigma_p$ = (Retorno anual / Volatilidad anual) muestra que el tamaño del riesgo juega un papel fundamental en la determinación del rendimiento de la cartera. Volatilidad es el grado de volatilidad en la tasa de rendimiento de la inversión. Rp es la tasa de retorno de la operación, Rf es la tasa libre de riesgo, σ_p es la desviación estándar del exceso de rendimiento.
- Sortino ratio = $(Rp - Rf)/\sigma_d$ es una modificación del ratio Sharpe, penaliza a la baja la volatilidad. σ_d es la desviación estándar a la baja (*downside*).
- Calmar ratio = (Retorno anual / Max Drawdown) evalúa el rendimiento de la inversión en relación al riesgo.
- Max Drawdown (MDD) = $(P - Q)/P$ pérdida porcentual máxima durante el período de trading, donde P representa el valor promedio neto más alto durante el período, y donde Q representa el valor promedio neto más bajo después de ese punto máximo.

Capítulo 4: Resultados

La tabla nro. 8 presenta la descripción de los códigos de los 62 modelos utilizados: Benchmark (MLP, AR, ARIMA, ARIMAX), Univariados (UNI) y Multivariados (MV). Para facilitar la lectura e identificación de los modelos, la nomenclatura de la columna “Códigos” de la tabla para los modelos *deep learning* es la siguiente: UNI o MV (uni o multi-variable); número correlativo; arquitectura (Stacked LSTM, CNN-convolutional y/o LSTM, BILSTM o BIGRU); mecanismo de atención (Luong, Bahdanau, MultiHead o Local Soft)

Tabla nro. 8 Descripción de los Códigos de los Modelos

Nro.	Clasificación	Sub-Clasificación	Mecanismo de Atención	Score mode	AutoKeras	Códigos	Descripción
1	CLÁSICO	BENCHMARK	N/A	N/A	N/A	AR	AR AutoRegresivo
2	CLÁSICO	BENCHMARK	N/A	N/A	N/A	ARIMA	ARIMA (con Stepwise = True)
3	CLÁSICO	BENCHMARK	N/A	N/A	N/A	ARIMAX	ARIMAX
4	CLÁSICO	BENCHMARK	N/A	N/A	AutoKeras	MLPK	MLP-AutoKeras
5	LSTM	Stacked LSTM	N/A	N/A	N/A	UNI-10-Stacked LSTM	Modelo-Univariado Nro. 01 - Stacked LSTM 50
6	LSTM	Stacked LSTM	N/A	N/A	N/A	UNI-20-Stacked LSTM	Modelo-Univariado Nro. 02 - Stacked LSTM 128/64
7	CNN	CNN	N/A	N/A	N/A	UNI-30-CNN	Modelo-Univariado Nro. 3.1 - Convolutional 128/64 (Flatten)
8	CNN	CNN	N/A	N/A	N/A	UNI-40-CNN	Modelo-Univariado Nro. 04 - Convolutional 64 (Flatten)
9	BIDIR	BIGRU	N/A	N/A	N/A	UNI-51-BIGRU	Modelo-Univariado Nro 5.1 - Bidirectional GRU 32/16
10	BIDIR	BILSTM	N/A	N/A	N/A	UNI-52-BILSTM	Modelo-Univariado Nro 5.2 - Bidirectional LSTM
11	BIDIR	BILSTM	LUONG	DOT	N/A	UNI-53-BILSTM-LUONG	Modelo-Univariado Nro 5.3 - Bidirectional LSTM & Luong (dot-product)
12	BIDIR	BIGRU	LUONG	DOT	N/A	UNI-54-BIGRU-LUONG	Modelo-Univariado Nro 5.4 - Bidirectional GRU & Luong (dot-product)
13	BIDIR	BILSTM	BAHDANAU	ADDITIVE	N/A	UNI-55-BILSTM-BAHDANAU	Modelo-Univariado Nro 5.5 - Bidirectional LSTM & Bahdanau
14	BIDIR	BIGRU	BAHDANAU	ADDITIVE	N/A	UNI-56-BIGRU-BAHDANAU	Modelo-Univariado Nro 5.6 - Bidirectional GRU & Bahdanau
15	BIDIR	BILSTM	MULTIHEAD	N/A	N/A	UNI-57-BILSTM-MULTIHEAD	Modelo-Univariado Nro 5.7 - Bidirectional LSTM & MultiHeadAttention
16	BIDIR	BILSTM	MULTIHEAD	N/A	N/A	UNI-575-BILSTM-MULTIHEAD	Modelo-Univariado Nro 5.75 - Bidirectional GRU & MultiHeadAttention
17	HYBRID	CNN-LSTM	LUONG	DOT	N/A	UNI-60-CNN-LSTM-LUONG	Modelo-Univariado Nro. 06 - Luong LSTM & Conv64
18	LSTM	LSTM	LUONG	DOT	N/A	UNI-70-LSTM-LUONG	Modelo-Univariado Nro. 07 - Stacked LSTM 32 & Luong
19	LSTM	LSTM	LUONG	DOT	N/A	UNI-71-LSTM-LUONG	Modelo-Univariado Nro. 071 Stacked LSTM 32 & Luong (dot-product)
20	LSTM	LSTM	LUONG	CONCAT	N/A	UNI-72-LSTM-LUONG	Modelo-Univariado Nro. 072 Stacked LSTM 32 & Luong (concat)
21	LSTM	LSTM	BAHDANAU	ADDITIVE	N/A	UNI-73-LSTM-BAHDANAU	Modelo-Univariado Nro. 073 - Stacked LSTM 32 & Bahdanau
22	LSTM	LSTM	LOCALSOFT	N/A	N/A	UNI-74-LSTM-LOCALSOFT	Modelo-Univariado Nro. 074 - Stacked LSTM 32 & Local Soft Attention
23	LSTM	LSTM	MULTIHEAD	N/A	N/A	UNI-75-LSTM-MULTIHEAD	Modelo-Univariado Nro. 075 - Stacked LSTM 32 & MultiHeadAttention
24	CNN	CNN	LUONG	DOT	N/A	UNI-80-CNN-LUONG	Modelo-Univariado Nro. 08 - Luong & Conv64 (Flatten)
25	LSTM	Stacked LSTM	N/A	N/A	N/A	MV-1-Stacked LSTM	Modelo-Multivariado Nro. 01 - Stacked LSTM 50
26	GRU	Stacked GRU	N/A	N/A	N/A	MV-12-Stacked GRU	Modelo-Multivariado Nro. 012 - Stacked GRU 50
27	LSTM	Stacked LSTM	N/A	N/A	N/A	MV-2-Stacked LSTM	Modelo-Multivariado Nro. 02 - LSTM 128/64
28	GRU	Stacked GRU	N/A	N/A	N/A	MV-22-Stacked GRU	Modelo-Multivariado Nro. 022 - Stacked GRU 128/64
29	CNN	CNN	N/A	N/A	N/A	MV-31-CNN	Modelo-Multivariado Nro. 03.1 - Convolutional 128/64 (Flatten)
30	CNN	CNN	N/A	N/A	N/A	MV-32-CNN	Modelo-Multivariado Nro. 03.2 Convolutional 256/128 (Flatten)
31	HYBRID	CNN-LSTM	N/A	N/A	N/A	MV-33-CNN-LSTM	Modelo-Multivariado Nro. 03.3 Conv 128/64 & LSTM 128/64 (MaxPooling)
32	CNN	CNN	N/A	N/A	N/A	MV-40-CNN	Modelo-Multivariado Nro. 4 Conv 64 (Flatten)
33	HYBRID	CNN-LSTM	N/A	N/A	N/A	MV-41-CNN-LSTM	Modelo-Multivariado Nro. 41 Conv 64 & LSTM 64 (MaxPooling)
34	HYBRID	CNN-LSTM	N/A	N/A	N/A	MV-42-CNN-LSTM	Modelo-Multivariado Nro. 42 Conv 64 & LSTM 128/64 (MaxPooling)
35	HYBRID	CNN-BIGRU	N/A	N/A	N/A	MV-43-CNN-BIGRU	Modelo-Multivariado Nro. 43 Conv 64 & BidirGRU 32/16 (MaxPooling)
36	HYBRID	CNN-BIGRU	LUONG	DOT	N/A	MV-44-CNN-BIGRU-LUONG	Modelo-Multivariado Nro. 44 Conv 64 & BidirGRU 32/16 & Luong (MaxPooling)
37	HYBRID	CNN-LSTM	LUONG	DOT	N/A	MV-45-CNN-LSTM-LUONG	Modelo-Multivariado Nro. 45 Conv 64 & LSTM 50 & Luong (MaxPooling)
38	BIDIR	BIGRU	N/A	N/A	N/A	MV-51-BIGRU	Modelo-Multivariado Nro. 5.1 - Bidirectional GRU 32/16
39	BIDIR	BILSTM	N/A	N/A	N/A	MV-52-BILSTM	Modelo-Multivariado Nro. 5.2 - Bidirectional LSTM 32/16
40	BIDIR	BILSTM	LUONG	DOT	N/A	MV-53-BILSTM-LUONG	Modelo-Multivariado Nro. 5.3 - Bidirectional LSTM 32/16 & Luong
41	BIDIR	BILSTM	LUONG	DOT	AutoKeras	MV-530-BILSTM-LUONG-AutoKeras	Modelo-Multivariado Nro. 5.3K - Bidirectional LSTM 10/20 & Luong
42	BIDIR	BILSTM	LUONG	DOT	AutoKeras	MV-531-BILSTM-LUONG-AutoKeras	Modelo-Multivariado Nro. 5.3K1 - Bidirectional LSTM 10/20 & Luong
43	BIDIR	BILSTM	LUONG	DOT	AutoKeras	MV-532-BILSTM-LUONG-AutoKeras	Modelo-Multivariado Nro. 5.3K2 - Bidirectional LSTM 10/20 & Luong
44	BIDIR	BILSTM	LUONG	DOT	AutoKeras y ScikitKeras	MV-552KS-BILSTM-LUONG-AutoKeras-y-S	Modelo-Multivariado Nro. 5.5K2-SK - Bidirectional LSTM 10/20 & Luong
45	BIDIR	BIGRU	LUONG	DOT	N/A	MV-54-BIGRU-LUONG	Modelo-Multivariado Nro. 5.4 - Bidirectional GRU 32/16 & Luong
46	BIDIR	BILSTM	BAHDANAU	ADDITIVE	N/A	MV-55-BILSTM-BAHDANAU	Modelo-Multivariado Nro. 5.5 - Bidirectional LSTM & Bahdanau
47	BIDIR	BILSTM	BAHDANAU	ADDITIVE	AutoKeras	MV-550-BILSTM-BAHDANAU-AutoKeras	Modelo-Multivariado Nro. 5.5K - Bidirectional LSTM 10/20 & Bahdanau
48	BIDIR	BILSTM	BAHDANAU	ADDITIVE	AutoKeras	MV-551-BILSTM-BAHDANAU-AutoKeras	Modelo-Multivariado Nro. 5.5K1 - Bidirectional LSTM 10/20 & Bahdanau
49	BIDIR	BILSTM	BAHDANAU	ADDITIVE	AutoKeras	MV-552-BILSTM-BAHDANAU-AutoKeras	Modelo-Multivariado Nro. 5.5K2 - Bidirectional LSTM 10/20 & Bahdanau
50	BIDIR	BIGRU	BAHDANAU	ADDITIVE	N/A	MV-56-BIGRU-BAHDANAU	Modelo-Multivariado Nro. 5.6 - Bidirectional GRU 32/16 & Bahdanau
51	BIDIR	BILSTM	MULTIHEAD	N/A	N/A	MV-57-BILSTM-MULTIHEAD	Modelo-Multivariado Nro. 5.7 - Bidirectional LSTM 32/16 & MultiHeadAttention
52	BIDIR	BILSTM	LUONG	DOT	N/A	MV-58-BILSTM-LUONG	Modelo-Multivariado Nro. 5.8 - Bidirectional LSTM 64/32/16 & Luong
53	BIDIR	BIGRU	LUONG	DOT	N/A	MV-59-BIGRU-LUONG	Modelo-Multivariado Nro. 5.9 - Bidirectional GRU 64/32/16 & Luong
54	HYBRID	CNN-LSTM	LUONG	DOT	N/A	MV-60-CNN-LSTM-LUONG	Modelo-Multivariado Nro. 06 - Luong LSTM 32 & Conv 64 (Flatten)
55	LSTM	STACK-LSTM	LUONG	DOT	N/A	MV-70-STACK-LSTM-LUONG	Modelo-Multivariado Nro. 07 - Stacked LSTM 32 & Luong

56	LSTM	STACK-LSTM	LUONG	DOT	N/A	MV-71-STACK-LSTM-LUONG	Modelo-Multivariado Nro. 071 Stacked LSTM 32 & Luong (dot-product)
57	LSTM	STACK-LSTM	LUONG	CONCAT	N/A	MV-72-STACK-LSTM-LUONG	Modelo-Multivariado Nro. 072 Stacked LSTM 32 & Luong (concat)
58	LSTM	STACK-LSTM	BAHDANAU	ADDITIVE	N/A	MV-73-STACK-LSTM-BAHDANAU	Modelo-Multivariado Nro. 073 - Stacked LSTM 32 & Bahdanau
59	LSTM	STACK-LSTM	LOCALSOFT	N/A	N/A	MV-74-STACK-LSTM-LOCALSOFT	Modelo-Multivariado Nro. 074 - Stacked LSTM 32 & Local Soft Attention
60	LSTM	STACK-LSTM	MULTIHEAD	N/A	N/A	MV-75-STACK-LSTM-MULTIHEAD	Modelo-Multivariado Nro. 075 - Stacked LSTM 32 & MultiHeadAttention
61	BIDIR	BIGRU	LOCALSOFT	N/A	N/A	MV-76-BIGRU-LOCAL SOFT	Modelo-Multivariado Nro. 076 - Bidirectional LSTM 32/16 & Local Soft Attention
62	CNN	CNN	LUONG	N/A	N/A	MV-80-CNN-LUONG	Modelo-Multivariado Nro. 08 - Conv 64 (Flatten)

4.2 Resultados de análisis de predictibilidad para 5 instrumentos ETFs

La tabla nro. 9 presenta los resultados de los modelos *deep learning* para 5 ETFs diferentes, 4 ETF de origen norteamericano y 1 ETF de origen alemán, que obtuvieron sus más altas métricas de dirección DA.

Tabla nro. 9 de Resultados de testing, métricas de modelos univariados para 5 ETFs

Nombre del ETF	ETF	Código del modelo	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
SPDR	US78462F1030	UNI-54-BIGRU-LUONG	0,00233471	9,33E-06	0,0030543	78,378%	inf	25,3422065
iShares USA	US4642872000	UNI-40-CNN	0,0195498	6,71E-06	0,002590	78,98%	145,00981	22,965
iShares USA	US4642872000	UNI-74-LSTM-LOCALSOFT	0,0019454	6,630E-06	0,002575	78,98%	144,29777	22,834
iShares Germany	US4642868065	UNI-56-BIGRU-BAHDANAU	0,0037612	2,619E-05	0,0051172	77,65%	inf	31,23714
Vanguard	US9229087690	UNI-71-LSTM-LUONG	0,00191104	6,500E-06	0,00255026	76,598%	inf	21,8193205
Invesco	IE00B3YCGJ38	UNI-40-CNN	0,00104492	1,920E-06	0,00138523	76,9231%	88,59562286	18,75549473
Invesco	IE00B3YCGJ38	UNI-74-LSTM-LOCALSOFT	0,00103655	1,900E-06	0,00137921	76,9231%	87,88545103	18,46126735
Invesco	IE00B3YCGJ38	UNI-75-LSTM-MULTIHEAD	0,00104093	1,910E-06	0,0013814	76,9231%	88,25720904	18,67441285
Mínimo			0,00103655	1,90E-06	0,00137921	76,60%	87,89	18,46
Máximo			0,0195498	2,62E-05	0,0051172	78,98%	145,01	31,24
Promedio			0,00407807	7,64E-06	0,00250408	77,67%	110,81	22,51
Desviación estándar			0,00631815	0,0000080	0,00124919	0,009824	30,90	4,31

Se aprecia en la tabla anterior que para el ETF BlackRock iShares USA US4642872000, los modelos UNI-40-CNN y UNI-74-LSTM-LOCAL-SOFT obtienen el más alto DA de 78,98%.

Respecto de los resultados de predicción de retornos de los modelos multivariados se presenta un resumen con las mejores métricas DA para cada uno de los 5 instrumentos ETF.

Tabla nro. 10 de Resultados de testing, métricas de modelos multivariados para 5 ETFs

Nombre del ETF	ETF	Código del modelo	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
SPDR	US78462F1030	MV-54-BIGRU-LUONG	0,00234687	9,33E-06	0,00305422	77,799%	1,724844	2,14470
iShares USA	US4642872000	MV-53-BILSTM-LUONG	0,0019757	6,733E-06	0,002595	80,78%	1,72027	1,311
iShares USA	US4642872000	MV-55-BILSTM-BAHDANAU	0,0019501	6,540E-06	0,002558	80,48%	1,69240	1,289
iShares Germany	US4642868065	MV-53-BILSTM-LUONG	0,0038399	2,689E-05	0,0051858	77,19%	2,16643	3,021880
Vanguard	US9229087690	MV-2-Stacked LSTM	0,00179427	5,740E-06	0,002395781	76,826%	1,544683	1,9018244
Invesco	IE00B3YCGJ38	MV-56-BIGRU-BAHDANAU	0,00102727	1,817E-06	0,0013479	76,9231%	1,08501	0,91628
Mínimo			0,00102727	1,82E-06	0,0013479	76,83%	1,08501	0,91628
Máximo			0,0038399	2,69E-05	0,0051858	80,78%	2,16643	3,021880604
Promedio			0,00215569	0,0000095	0,00285612	0,783330	1,65560634	1,76411522
Desviación estándar			0,00093292	0,0000088	0,00127361	0,018137	0,34904269	0,76100717

Se aprecia en la tabla anterior que para el ETF BlackRock iShares USA US4642872000, dos modelos destacan, MV-53-BILSTM-LUONG con DA 80,78% y MV-55-BILSTM-BAHDANAU con DA 80,48%.

No obstante lo anterior, entre los 5 instrumentos analizados preliminarmente, se selecciona el instrumento ETF Vanguard Group VTI US9229087690, denominado ETF VTI o por extensión, “Vanguard Total Stock Market Index Fund ETF Shares” para continuar con la predicción de retornos.

4.2 Resultados de análisis de predictibilidad de modelos tradicionales para ETF VTI

La tabla nro. 11 presenta los resultados de los modelos tradicionales AutoReg, ARIMA y ARIMAX con epochs 40, batch size 32 y train/test 90/10, para ETF Vanguard.

Tabla nro. 11 de Resultados de testing, métricas para AR, ARIMA y ARIMAX para ETF Vanguard Group - US9229087690

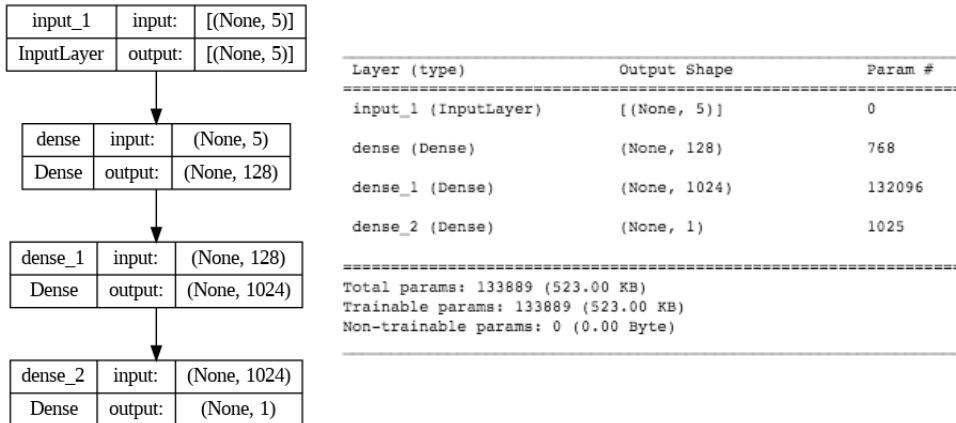
Porcentaje	AUTOREG				ARIMA				ARIMAX			
	MAE	MSE	RMSE	DA	MAE	MSE	RMSE	DA	MAE	MSE	RMSE	DA
90-10	0,007808303	0,000131736	0,011477628	55,575%	0,009773617	0,000163321	0,012779698	55,575%	0,009362195	0,000152383	0,012344345	55,575%
Mínimo	0,007681139	0,000129805	0,011393201	54,646%	0,007926323	0,000107476	0,010367052	54,425%	0,007926323	0,000107476	0,010367052	54,425%
Máximo	0,008489004	0,000178538	0,013361796	56,932%	0,009795500	0,000214333	0,014640121	56,844%	0,009795500	0,000214337	0,014640241	56,844%
Promedio	0,008055696	0,000146566	0,012094435	55,841%	0,009196522	0,000168694	0,012937808	55,755%	0,009208752	0,000171512	0,013044839	55,768%
Desviación estandar	0,0002406	0,0000135	0,0005528	0,0050183	0,0004999	0,0000298	0,0011732	0,0048919	0,0004817	0,0000303	0,0011897	0,0049414

*Filas Mínimo, Máximo, Promedio y Desviación estandar considera corridas train/test entre 75/25 y 95/05.

* En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

En la figura nro. 9 se presenta la arquitectura del modelo MLPK (correspondiente al modelo MLP con *AutoKeras*).

Figura nro. 9 de la arquitectura del modelo MLPK en gráfica (izq.) y texto (der.) para ETF Vanguard



La tabla nro. 12 presenta los resultados de las métricas del modelo MLPK con parámetros epochs 40, batch size 32, train/test 90/10, para ETF Vanguard.

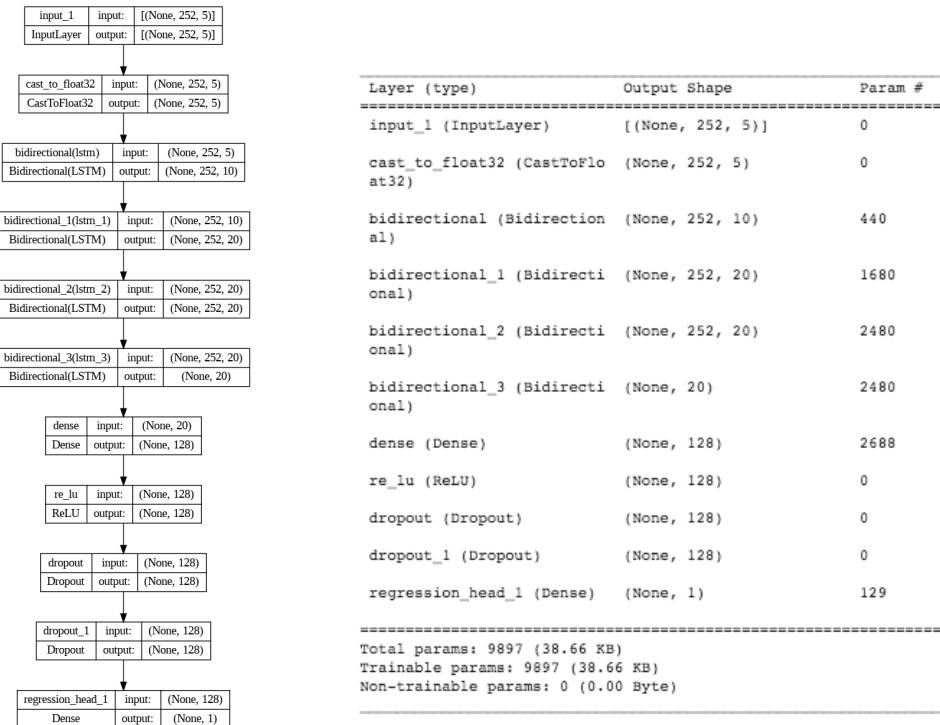
Tabla nro. 12 de Resultados de testing, métricas de MLPK para ETF Vanguard Group - US9229087690

Código	Porcentaje	MAE	MSE	RMSE	DA (%)	MDAPE (%)
MLPK	90-10	0,0009288963	1,738E-06	0,000947063	66,938%	142,376514
Mínimo		0,000083803	1,20E-08	0,00010873	65,76%	140,2971924
Máximo		0,002143404	4,61E-06	0,002147686	69,25%	145,3095083
Promedio		0,000589418	7,96E-07	0,000668476	66,64%	141,4555574
Desviación estándar		0,000605562	0,000001341	0,000565199	0,009375246	1,201954163

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera corridas train/test entre 75/25 y 95/05. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Para la predicción de los 5 ETFs, los modelos destacados fueron los candidatos para aplicar AutoModel de *AutoKeras* lo cual dió origen a los modelos series K. Por ejemplo, el modelo MV-53-BILSTM-LUONG dió origen a los nuevos modelos MV-530-BILSTM-LUONG-AutoKeras, MV-531-BILSTM-LUONG-AutoKeras y MV-532-BILSTM-LUONG-AutoKeras.

Figura nro. 10 arquitectura del modelo MULTIVAR-53 con AutoKeras en gráfica (izq.) y texto (der.) para ETF Vanguard



4.3 Resultados del análisis de predictibilidad de modelos DL para ETF VTI

Se presentan las tablas de resultados de las **métricas** de los modelos *deep learning* con parámetros train/test 90/10, epochs 40, batch size 32, para predicción de retornos del instrumento ETF Vanguard VTI. Los resultados por métricas en las siguientes tablas:

- **métricas MSE** de los modelos *univariados* (tabla nro. 15) y *multivariados* (tabla nro. 16)
- **métricas RMSE** de los modelos *univariados* (tabla nro. 17) y *multivariados* (tabla nro. 18)
- **métricas MAE** de los modelos *univariados* (tabla nro. 19) y *multivariados* (tabla nro. 20)
- **métricas MAPE** de los modelos *multivariados* (tabla nro. 21)
- **métricas MDAPE** de los modelos *univariados* (tabla nro. 22) y *multivariados* (tabla nro. 23)

Tabla nro. 13 de Resultados testing de métricas DA de modelos Multivariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	80,449%	77,363%	0,0207
MV-12-Stacked GRU	80,449%	77,363%	0,0207
MV-2-Stacked LSTM	79,167%	77,409%	0,0147
MV-22-Stacked GRU	79,487%	77,101%	0,0166
MV-31-CNN	80,128%	75,104%	0,0245
MV-32-CNN	75,000%	74,339%	0,0215
MV-33-CNN-LSTM	79,167%	77,428%	0,0190
MV-40-CNN	80,128%	77,026%	0,0248
MV-41-CNN-LSTM	80,449%	76,068%	0,0251
MV-42-CNN-LSTM	78,846%	77,027%	0,0271
MV-43-CNN-BIGRU	72,756%	76,714%	0,0217
MV-44-CNN-BIGRU-LUONG	78,846%	76,674%	0,0223
MV-45-CNN-LSTM-LUONG	79,808%	77,085%	0,0220
MV-51-BIGRU	79,808%	77,194%	0,0259
MV-52-BILSTM	80,128%	77,518%	0,0190
MV-53-BILSTM-LUONG	80,128%	61,921%	0,0814
MV-530-BILSTM-LUONG-AutoKeras	78,526%	74,929%	0,0626
MV-531-BILSTM-LUONG-AutoKeras	79,808%	77,363%	0,0207
MV-532-BILSTM-LUONG-AutoKeras	79,808%	77,144%	0,0139
MV-54-BIGRU-LUONG	80,021%	72,125%	0,0451
MV-55-BILSTM-BAHDANAU	78,846%	76,532%	0,0151
MV-550-BILSTM-BAHDANAU-AutoKeras	80,342%	76,709%	0,0198
MV-551-BILSTM-BAHDANAU-AutoKeras	79,808%	75,704%	0,0244
MV-552-BILSTM-BAHDANAU-AutoKeras	79,701%	75,893%	0,0200
MV-56-BIGRU-BAHDANAU	80,128%	76,950%	0,0209
MV-57-BILSTM-MULTIHEAD	80,449%	77,121%	0,0225
MV-58-BILSTM-LUONG	81,517%	77,477%	0,0178
MV-59-BIGRU-LUONG	80,021%	76,970%	0,0255
MV-60-CNN-LSTM-LUONG	80,128%	77,094%	0,0205
MV-70-STACK-LSTM-LUONG	80,449%	77,175%	0,0249
MV-71-STACK-LSTM-LUONG	80,288%	77,304%	0,0170
MV-72-STACK-LSTM-LUONG	80,288%	77,345%	0,0231
MV-73-STACK-LSTM-BAHDANAU	79,647%	77,164%	0,0215
MV-74-STACK-LSTM-LOCAL SOFT	79,647%	76,717%	0,0174
MV-75-STACK-LSTM-MULTIHEAD	80,449%	75,906%	0,0278
MV-76-BIGRU-LOCAL SOFT	80,449%	76,580%	0,0256
MV-80-CNN-LUONG	65,705%	76,430%	0,0256
Mínimo	65,71%		
Máximo	81,52%		
Promedio	79,21%		
Desviación estándar	0,0274		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 14 de Resultados testing de métricas DA de modelos univariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
UNI-10-Stacked LSTM	79,216%	76,211%	0,0208
UNI-20-Stacked LSTM	79,608%	75,848%	0,0239
UNI-30-CNN	79,216%	77,205%	0,0237
UNI-40-CNN	69,804%	77,180%	0,0182
UNI-51-BIGRU	80,128%	77,167%	0,0229
UNI-52-BILSTM	79,808%	77,237%	0,0250
UNI-53-BILSTM-LUONG	82,372%	76,404%	0,0226
UNI-54-BIGRU-LUONG	80,662%	76,237%	0,0223
UNI-55-BILSTM-BAHDANAU	82,372%	76,881%	0,0197
UNI-56-BIGRU-BAHDANAU	81,090%	77,138%	0,0175
UNI-57-BILSTM-MULTIHEAD	79,808%	77,263%	0,0262
UNI-60-CNN-LSTM-LUONG	80,449%	76,847%	0,0205
UNI-70-LSTM-LUONG	80,449%	76,805%	0,0197
UNI-71-LSTM-LUONG	80,769%	76,864%	0,0225
UNI-72-LSTM-LUONG	80,449%	77,024%	0,0280
UNI-73-LSTM-BAHDANAU	79,487%	76,939%	0,0220
UNI-74-LSTM-LOCAL SOFT	79,808%	77,246%	0,0219
UNI-75-LSTM-MULTIHEAD	80,769%	77,027%	0,0320
UNI-80-CNN-LUONG	75,641%	67,077%	0,0554
Mínimo	69,80%		
Máximo	82,37%		
Promedio	79,57%		
Desviación estándar	0,0267		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 15 de Resultados testing, métricas MSE de modelos multivariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	1,259E-05	8,549E-06	0,000004994
MV-12-Stacked GRU	1,259E-05	8,549E-06	0,000004994
MV-2-Stacked LSTM	1,272E-05	8,558E-06	0,000004994
MV-22-Stacked GRU	1,277E-05	8,577E-06	0,000004993
MV-31-CNN	1,260E-05	9,781E-06	0,000006079
MV-32-CNN	1,468E-05	1,046E-05	0,000006538
MV-33-CNN-LSTM	1,263E-05	8,570E-06	0,000004996
MV-60-CNN-LSTM-LUONG	1,259E-05	8,587E-06	0,000005007
MV-70-STACK-LSTM-LUONG	1,260E-05	8,646E-06	0,000005000
MV-71-STACK-LSTM-LUONG	1,373E-05	8,661E-06	0,000005076
MV-72-STACK-LSTM-LUONG	1,382E-05	8,727E-06	0,000005061
MV-73-STACK-LSTM-BAHDANAU	1,387E-05	8,783E-06	0,000005191
MV-74-STACK-LSTM-LOCAL SOFT	1,379E-05	8,661E-06	0,000005077
MV-75-STACK-LSTM-MULTIHEAD	1,384E-05	8,661E-06	0,000005065
MV-76-BIGRU-LOCAL SOFT	1,259E-05	8,434E-06	0,000004875
MV-80-CNN-LUONG	3,152E-05	3,327E-05	0,000040772
MV-40-CNN	1,259E-05	9,332E-06	0,000004768
MV-41-CNN-LSTM	1,259E-05	8,549E-06	0,000004994
MV-42-CNN-LSTM	1,266E-05	8,559E-06	0,000004998
MV-43-CNN-BIGRU	1,515E-05	1,018E-05	0,000005322
MV-44-CNN-BIGRU-LUONG	1,261E-05	8,592E-06	0,000005029
MV-45-CNN-LSTM-LUONG	1,261E-05	8,611E-06	0,000005038
MV-51-BIGRU	1,279E-05	8,831E-06	0,000004908
MV-52-BILSTM	1,267E-05	8,799E-06	0,000004920
MV-53-BILSTM-LUONG	1,192E-05	8,501E-06	0,000004717
MV-530-BILSTM-LUONG-AutoKeras	2,004E-05	9,085E-06	0,000005227
MV-531-BILSTM-LUONG-AutoKeras	1,266E-05	8,610E-06	0,00000487

MV-532-BILSTM-LUONG-AutoKeras	1,842E-05	9,149E-06	0,000005074
MV-54-BIGRU-LUONG	1,852E-05	9,154E-06	0,000005125
MV-55-BILSTM-BAHDANAU	1,218E-05	8,606E-06	0,000004791
MV-551-BILSTM-BAHDANAU-AutoKeras	1,258E-05	8,630E-06	0,000004883
MV-552-BILSTM-BAHDANAU-AutoKeras	2,072E-05	9,139E-06	0,000005321
MV-550-BILSTM-BAHDANAU-AutoKeras	2,030E-05	9,183E-06	0,000005228
MV-56-BIGRU-BAHDANAU	1,235E-05	8,600E-06	0,000004721
MV-57-BILSTM-MULTIHEAD	1,281E-05	8,871E-06	0,000004784
MV-58-BILSTM-LUONG	1,823E-05	9,212E-06	0,000005030
MV-59-BIGRU-LUONG	1,798E-05	9,312E-06	0,000005069
UNI-51-BIGRU	1,516E-05	7,692E-06	0,000002707
Mínimo	1,192E-05		
Máximo	1,192E-05		
Promedio	1,464E-05		
Desviación estándar	0,0000		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 16 de Resultados testing, métricas MSE de modelos univariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
UNI-52-BILSTM	1,510E-05	7,983E-06	0,000002
UNI-53-BILSTM-LUONG	2,056E-05	8,374E-06	0,000003
UNI-54-BIGRU-LUONG	2,104E-05	8,464E-06	0,0000039
UNI-55-BILSTM-BAHDANAU	2,115E-05	8,443E-06	0,0000039
UNI-56-BIGRU-BAHDANAU	2,174E-05	8,248E-06	0,0000039
UNI-57-BILSTM-MULTIHEAD	1,488E-05	7,903E-06	0,0000029
UNI-10-Stacked LSTM	1,012E-05	7,574E-06	0,0000026
UNI-20-Stacked LSTM	1,008E-05	7,555E-06	0,0000026
UNI-40-CNN	1,468E-05	7,739E-06	0,0000030
UNI-60-CNN-LSTM-LUONG	1,474E-05	7,836E-06	0,0000030
UNI-70-LSTM-LUONG	1,472E-05	7,807E-06	0,0000030
UNI-71-LSTM-LUONG	1,480E-05	7,505E-06	0,0000028
UNI-72-LSTM-LUONG	1,472E-05	7,832E-06	0,0000030
UNI-73-LSTM-BAHDANAU	1,490E-05	7,807E-06	0,0000030
UNI-74-LSTM-LOCAL SOFT	1,502E-05	7,476E-06	0,0000028
UNI-75-LSTM-MULTIHEAD	1,474E-05	7,924E-06	0,0000031
UNI-80-CNN-LUONG	1,644E-05	1,886E-05	0,0000133
UNI-30-CNN	1,012E-05	8,287E-06	0,0000030
Mínimo	1,008E-05		
Máximo	1,008E-05		
Promedio	1,551E-05		
Desviación Standar	0,0000		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 17 de Resultados testing, métricas RMSE de modelos Multivariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	0,005019	0,003358	0,001675321
MV-12-Stacked GRU	0,005019	0,003358	0,001675321
MV-2-Stacked LSTM	0,005043	0,00335965	0,001675295
MV-22-Stacked GRU	0,005053	0,00336355	0,001675353
MV-31-CNN	0,005019	0,00357215	0,001775180
MV-32-CNN	0,005419	0,00369215	0,001877623
MV-33-CNN-LSTM	0,005026	0,00336135	0,001675055
MV-60-CNN-LSTM-LUONG	0,005017	0,0033656	0,001677253
MV-70-STACK-LSTM-LUONG	0,00502	0,00337855	0,001674440
MV-71-STACK-LSTM-LUONG	0,005235	0,0033792	0,001691804
MV-72-STACK-LSTM-LUONG	0,005254	0,0033919	0,001687474

MV-73-STACK-LSTM-BAHDANAU	0,005263	0,00340385	0,001717101
MV-74-STACK-LSTM-LOCAL SOFT	0,005247	0,0033802	0,001692602
MV-75-STACK-LSTM-MULTIHEAD	0,005259	0,0033794	0,001689702
MV-76-BIGRU-LOCAL SOFT	0,005019	0,0033371	0,001657729
MV-80-CNN-LUONG	0,007694	0,00600055	0,003301136
MV-40-CNN	0,005019	0,00350765	0,001595551
MV-41-CNN-LSTM	0,005019	0,003358	0,001675321
MV-42-CNN-LSTM	0,005032	0,00335985	0,001675781
MV-43-CNN-BIGRU	0,005505	0,0036814	0,001688860
MV-44-CNN-BIGRU-LUONG	0,005022	0,0033669	0,001682472
MV-45-CNN-LSTM-LUONG	0,005022	0,00336905	0,001678639
MV-51-BIGRU	0,005058	0,003422	0,001658352
MV-52-BILSTM	0,005033	0,00341365	0,001655212
MV-53-BILSTM-LUONG	0,004883	0,0033539	0,001615819
MV-530-BILSTM-LUONG-AutoKeras	0,007749	0,0035954	0,001853945
MV-531-BILSTM-LUONG-AutoKeras	0,005031	0,003374	0,001652036
MV-532-BILSTM-LUONG-AutoKeras	0,007433	0,0036109	0,001815215
MV-54-BIGRU-LUONG	0,007454	0,0036088	0,001829815
MV-55-BILSTM-BAHDANAU	0,004936	0,00337635	0,001633993
MV-551-BILSTM-BAHDANAU-AutoKeras	0,005016	0,00337825	0,001651710
MV-552-BILSTM-BAHDANAU-AutoKeras	0,00786	0,00360555	0,001873528
MV-550-BILSTM-BAHDANAU-AutoKeras	0,007793	0,00361615	0,001851671
MV-56-BIGRU-BAHDANAU	0,00497	0,0033762	0,001634996
MV-57-BILSTM-MULTIHEAD	0,005061	0,00343255	0,001627491
MV-58-BILSTM-LUONG	0,007394	0,00362295	0,001806068
MV-59-BIGRU-LUONG	0,007345	0,00364045	0,001819581
Mínimo	0,004883		
Máximo	0,00786		
Promedio	0,005628135135		
Desviación estándar	0,0010561		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 18 de Resultados testing, métricas RMSE de modelos univariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
UNI-51-BIGRU	0,005507	0,0028153	0,000742616
UNI-52-BILSTM	0,005495	0,00293715	0,000889623
UNI-53-BILSTM-LUONG	0,007854	0,0031414	0,001370735
UNI-54-BIGRU-LUONG	0,007943	0,00315815	0,001395926
UNI-55-BILSTM-BAHDANAU	0,007962	0,0031564	0,001395930
UNI-56-BIGRU-BAHDANAU	0,008075	0,00305375	0,001346907
UNI-57-BILSTM-MULTIHEAD	0,005457	0,00291865	0,000898433
UNI-10-Stacked LSTM	0,004501	0,00284895	0,000797466
UNI-20-Stacked LSTM	0,004489	0,0028459	0,000795302
UNI-40-CNN	0,005418	0,00288315	0,000917406
UNI-60-CNN-LSTM-LUONG	0,005429	0,00290335	0,000907733
UNI-70-LSTM-LUONG	0,005427	0,0028973	0,000919007
UNI-71-LSTM-LUONG	0,00544	0,0027744	0,000759161
UNI-72-LSTM-LUONG	0,005427	0,00290225	0,000917505
UNI-73-LSTM-BAHDANAU	0,005458	0,00289615	0,000919371
UNI-74-LSTM-LOCAL SOFT	0,005481	0,00276815	0,000770463
UNI-75-LSTM-MULTIHEAD	0,00543	0,0029161	0,000917917
UNI-80-CNN-LUONG	0,005734	0,0042021	0,001459435
UNI-30-CNN	0,004501	0,002974	0,000787337
Mínimo	0,004489		
Máximo	0,008075		
Promedio	0,0058259		
Desviación estándar	0,0011513		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 19 de Resultados testing, métricas MAE de modelos Multivariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	0,0038082	0,00246209	0,001172601
MV-12-Stacked GRU	0,0038082	0,00246209	0,001172601
MV-2-Stacked LSTM	0,0038468	0,00246157	0,001171187
MV-22-Stacked GRU	0,003859	0,00246757	0,001172902
MV-31-CNN	0,0038101	0,00260283	0,00120248
MV-32-CNN	0,0041452	0,00268696	0,00131457
MV-33-CNN-LSTM	0,0038212	0,0024627	0,001169266
MV-60-CNN-LSTM-LUONG	0,0038068	0,00246823	0,001173143
MV-70-STACK-LSTM-LUONG	0,0038112	0,00248647	0,001178127
MV-71-STACK-LSTM-LUONG	0,0039798	0,00248265	0,001184822
MV-72-STACK-LSTM-LUONG	0,0040053	0,00249763	0,001186664
MV-73-STACK-LSTM-BAHDANAU	0,00401	0,00251280	0,00122592
MV-74-STACK-LSTM-LOCAL SOFT	0,0039995	0,00248208	0,001193926
MV-75-STACK-LSTM-MULTIHEAD	0,004009	0,00248303	0,001182685
MV-76-BIGRU-LOCAL SOFT	0,0038082	0,00245588	0,001171664
MV-80-CNN-LUONG	0,0063531	0,00477600	0,00273181
MV-40-CNN	0,00381	0,00258602	0,001111564
MV-41-CNN-LSTM	0,0038082	0,00246209	0,001172601
MV-42-CNN-LSTM	0,0038288	0,00245977	0,001169710
MV-43-CNN-BIGRU	0,0042405	0,00278207	0,00123300
MV-44-CNN-BIGRU-LUONG	0,003822	0,00247526	0,001175805
MV-45-CNN-LSTM-LUONG	0,0038098	0,00246830	0,001170905
MV-51-BIGRU	0,0039093	0,00254970	0,001182115
MV-52-BILSTM	0,0038501	0,00252320	0,001159757
MV-53-BILSTM-LUONG	0,0037588	0,0024836	0,001139819
MV-530-BILSTM-LUONG-AutoKeras	0,0038513	0,00246997	0,001128388
MV-531-BILSTM-LUONG-AutoKeras	0,0038354	0,002471143	0,001156447
MV-532-BILSTM-LUONG-AutoKeras	0,003752	0,00247649	0,001121135
MV-54-BIGRU-LUONG	0,0038314	0,00248735	0,001141978
MV-55-BILSTM-BAHDANAU	0,0038223	0,00250050	0,001146683
MV-551-BILSTM-BAHDANAU-AutoKeras	0,0038099	0,00247494	0,001153932
MV-552-BILSTM-BAHDANAU-AutoKeras	0,0037787	0,00246376	0,001127308
MV-550-BILSTM-BAHDANAU-AutoKeras	0,0038171	0,00247442	0,001121836
MV-56-BIGRU-BAHDANAU	0,0038523	0,00250432	0,001160550
MV-57-BILSTM-MULTIHEAD	0,0038821	0,00253598	0,001139287
MV-58-BILSTM-LUONG	0,0037358	0,00250430	0,001127802
MV-59-BIGRU-LUONG	0,0037442	0,00252801	0,001154663
Mínimo	0,0037358		
Máximo	0,0063531		
Promedio	0,0039305837		
Desviación estándar	0,00042335		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 20 de Resultados testing, métricas MAE de modelos univariados ETF Vanguard Group VTI - US922908769

Código	90-10	Promedio	DesvSt
UNI-51-BIGRU	0,0042478	0,00210505	0,00053799
UNI-52-BILSTM	0,00422	0,00218992	0,00065149
UNI-53-BILSTM-LUONG	0,0040349	0,00214762	0,00062135
UNI-54-BIGRU-LUONG	0,0040982	0,00215671	0,00064092
UNI-55-BILSTM-BAHDANAU	0,0041035	0,00215818	0,00063604
UNI-56-BIGRU-BAHDANAU	0,0042046	0,00208241	0,00052845
UNI-57-BILSTM-MULTIHEAD	0,0041757	0,00217080	0,00065635
UNI-10-Stacked LSTM	0,0035566	0,002114495	0,00058144

UNI-20-Stacked LSTM	0,0035501	0,00211049	0,00058307
UNI-40-CNN	0,0042874	0,00213597	0,00069256
UNI-60-CNN-LSTM-LUONG	0,0041194	0,00214568	0,00065723
UNI-70-LSTM-LUONG	0,0041181	0,00214355	0,000671011
UNI-71-LSTM-LUONG	0,0041295	0,00204939	0,00053498
UNI-72-LSTM-LUONG	0,0041183	0,002151125	0,00066915
UNI-73-LSTM-BAHDANAU	0,0041441	0,00213997	0,00066519
UNI-74-LSTM-LOCAL SOFT	0,0041774	0,00204826	0,00054620
UNI-75-LSTM-MULTIHEAD	0,0041206	0,00215915	0,00066786
UNI-80-CNN-LUONG	0,0043533	0,00304504	0,00083040
UNI-30-CNN	0,0035566	0,00218486	0,00056583
Mínimo	0,0035501		
Máximo	0,0043533		
Promedio	0,00407692		
Desviación estándar	0,00023664		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 21 de Resultados testing, MAPE de modelos Multivariados ETF Vanguard Group - US9229087690

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	1,704816	1,75207635	0,29552461
MV-12-Stacked GRU	1,717196	1,74889065	0,29225303
MV-2-Stacked LSTM	1,72197	1,75369925	0,29285715
MV-22-Stacked GRU	1,710425	1,86213845	0,35074404
MV-31-CNN	1,851274	1,91101815	0,37044689
MV-32-CNN	1,707401	1,75054195	0,29507477
MV-33-CNN-LSTM	1,712355	1,75625275	0,29630346
MV-60-CNN-LSTM-LUONG	1,705291	1,7718413	0,29640474
MV-70-STACK-LSTM-LUONG	1,698591	1,76065335	0,29789598
MV-71-STACK-LSTM-LUONG	1,719491	1,77327915	0,30999041
MV-72-STACK-LSTM-LUONG	1,728615	1,7787494	0,31056394
MV-73-STACK-LSTM-BAHDANAU	1,706785	1,7539887	0,29054183
MV-74-STACK-LSTM-LOCAL SOFT	1,707652	1,76081655	0,29528089
MV-75-STACK-LSTM-MULTIHEAD	1,704816	1,74499845	0,28740493
MV-76-BIGRU-LOCAL SOFT	3,773467	3,7349103	2,69222477
MV-80-CNN-LUONG	1,710627	1,86767585	0,33768619
MV-40-CNN	1,703935	1,7520323	0,29553209
MV-41-CNN-LSTM	1,795186	1,75178175	0,29156884
MV-42-CNN-LSTM	1,880057	1,9912381	0,24083442
MV-43-CNN-BIGRU	1,70509	1,7595468	0,28938462
MV-44-CNN-BIGRU-LUONG	1,703933	1,7547453	0,29726290
MV-45-CNN-LSTM-LUONG	1,751456	1,8182917	0,26156541
MV-51-BIGRU	1,736556	1,8005344	0,25757801
MV-52-BILSTM	1,698998	1,77276345	0,25694770
MV-53-BILSTM-LUONG	1,724525	1,7630754	0,25983318
MV-530-BILSTM-LUONG-AutoKeras	1,782007	1,76251315	0,27475762
MV-531-BILSTM-LUONG-AutoKeras	1,678033	1,7691718	0,25324693
MV-532-BILSTM-LUONG-AutoKeras	1,709425	1,77482	0,26878120
MV-54-BIGRU-LUONG	1,714934	1,784141	0,25441538
MV-55-BILSTM-BAHDANAU	1,703155	1,76313895	0,27448418
MV-551-BILSTM-BAHDANAU-AutoKeras	1,686496	1,75827255	0,25983956
MV-552-BILSTM-BAHDANAU-AutoKeras	1,688715	1,7665302	0,25776757
MV-550-BILSTM-BAHDANAU-AutoKeras	1,718198	1,78467815	0,25902107
MV-56-BIGRU-BAHDANAU	1,717522	1,81284545	0,23513847
MV-57-BILSTM-MULTIHEAD	1,668891	1,79098455	0,26185541
MV-58-BILSTM-LUONG	1,688715	1,80717995	0,28805561
MV-59-BIGRU-LUONG	1,703986	1,75203485	0,29553165
Mínimo	1,668891		
Máximo	3,773467		
Promedio	1,77677256		

Desviación estándar	0,34003145
---------------------	------------

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 22 de Resultados testing, métricas MDAPE de modelos Multivariados ETF Vanguard Group VTI

Código	90-10	Promedio	DesvSt
MV-1-Stacked LSTM	1,440638000	1,418451000	0,181855269
MV-12-Stacked GRU	1,440638000	1,418451000	0,181855269
MV-2-Stacked LSTM	1,415105000	1,392628400	0,172997344
MV-22-Stacked GRU	1,410430000	1,404028450	0,171868045
MV-31-CNN	1,395806000	1,449303000	0,181689297
MV-32-CNN	1,578883000	1,470029600	0,182527957
MV-33-CNN-LSTM	1,397304000	1,383943750	0,174298189
MV-60-CNN-LSTM-LUONG	1,437307000	1,386059400	0,183065582
MV-70-STACK-LSTM-LUONG	1,419990000	1,387402350	0,169937359
MV-71-STACK-LSTM-LUONG	12,808974000	1,950710100	2,561978169
MV-72-STACK-LSTM-LUONG	12,743137000	1,959862550	2,544630775
MV-73-STACK-LSTM-BAHDANAU	12,848782000	1,976998700	2,564708326
MV-74-STACK-LSTM-LOCAL SOFT	12,960116000	1,944958800	2,599188334
MV-75-STACK-LSTM-MULTIHEAD	12,759483000	1,957111700	2,548697841
MV-76-BIGRU-LOCAL SOFT	1,440638000	1,386575000	0,167487338
MV-80-CNN-LUONG	14,608168000	3,844116250	3,748313064
MV-40-CNN	1,397412000	1,491733100	0,247519344
MV-41-CNN-LSTM	1,440638000	1,418451000	0,181855269
MV-42-CNN-LSTM	1,377541000	1,392837250	0,164793943
MV-43-CNN-BIGRU	1,557658000	1,592850350	0,176145258
MV-44-CNN-BIGRU-LUONG	1,398578000	1,385722750	0,165136303
MV-45-CNN-LSTM-LUONG	1,441153000	1,393286700	0,163109650
MV-51-BIGRU	1,488339000	1,434212150	0,163592678
MV-52-BILSTM	1,438286000	1,409880400	0,134503578
MV-53-BILSTM-LUONG	1,293822000	1,391716950	0,136791066
MV-530-BILSTM-LUONG-AutoKeras	1,360431000	1,373987250	0,145822311
MV-531-BILSTM-LUONG-AutoKeras	1,390169000	1,391495550	0,144550966
MV-532-BILSTM-LUONG-AutoKeras	1,270700000	1,369099100	0,164696169
MV-54-BIGRU-LUONG	1,367189000	1,390075100	0,160093462
MV-55-BILSTM-BAHDANAU	1,360063000	1,399989250	0,152870187
MV-551-BILSTM-BAHDANAU-AutoKeras	1,393504000	1,397986400	0,154286556
MV-552-BILSTM-BAHDANAU-AutoKeras	1,370023000	1,367444100	0,143827875
MV-550-BILSTM-BAHDANAU-AutoKeras	1,354900000	1,385754450	0,142116268
MV-56-BIGRU-BAHDANAU	1,412480000	1,401580850	0,136666251
MV-57-BILSTM-MULTIHEAD	1,390507000	1,417085100	0,122235954
MV-58-BILSTM-LUONG	1,310005000	1,385549700	0,155281532
MV-59-BIGRU-LUONG	1,314022000	1,419005600	0,183818540
Mínimo	1,270700000		
Máximo	14,608168000		
Promedio	3,303589703		
Desviación estándar	4,387763387		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

Tabla nro. 23 de Resultados testing, métricas MDAPE de modelos univariados ETF Vanguard Group VTI

Código	90-10	Promedio	DesvSt
UNI-51-BIGRU	25,28035	24,348999	2,360280872
UNI-52-BILSTM	24,97468	24,174169	2,308331258
UNI-53-BILSTM-LUONG	23,78268	23,44053	1,761419205
UNI-54-BIGRU-LUONG	24,12483	23,440421500	1,771494625

UNI-55-BILSTM-BAHDANAU	23,98907	23,5232465	1,711910141
UNI-56-BIGRU-BAHDANAU	24,56592	23,744420000	2,099310970
UNI-57-BILSTM-MULTIHEAD	24,68496	23,824306500	1,997920189
UNI-10-Stacked LSTM	24,62865	23,366975500	1,349723049
UNI-20-Stacked LSTM	24,61215	23,299401000	1,361682101
UNI-40-CNN	29,93742	23,335430500	1,935823872
UNI-60-CNN-LSTM-LUONG	24,13483	23,399022000	1,501663965
UNI-70-LSTM-LUONG	24,13829	23,328692000	1,340571039
UNI-71-LSTM-LUONG	24,23574	23,356388000	1,521332520
UNI-72-LSTM-LUONG	24,11590	23,464508500	1,297339903
UNI-73-LSTM-BAHDANAU	24,32718	23,275962500	1,402497315
UNI-74-LSTM-LOCAL SOFT	24,51828	23,348863000	1,501430247
UNI-75-LSTM-MULTIHEAD	24,14721	23,547403000	1,864836368
UNI-80-CNN-LUONG	25,64379	34,874287500	8,351441636
UNI-30-CNN	24,62865	23,898141500	1,670967723
Mínimo	23,78268		
Máximo	29,93742		
Promedio	24,777641		
Desviación estándar	1,300651010		

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. *Columnas Promedio y Desviación estándar (DesvSt) considera corridas train/test entre 75/25 y 95/05.

4.4 Resultados del análisis de complejidad de modelos DL para ETF VTI

A continuación se presentan los resultados de los **modelos con parámetros epochs 1.000**, con early stopping y patience 30, train/test 90/10, para predicción del ETF Vanguard. En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

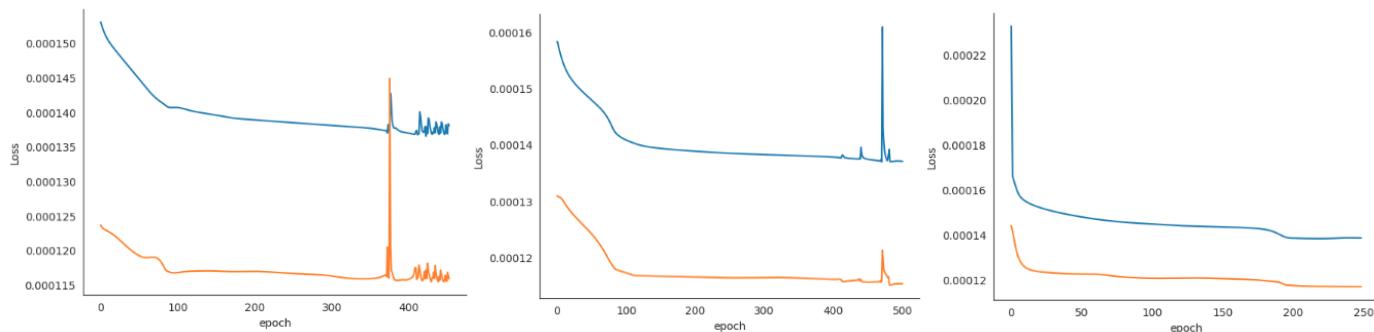
Tabla nro. 24 de Resultados de métricas con epochs 1.000 modelos ETF Vanguard Group - US9229087690

MODELOS	TRAIN/TEST	EPOCHS o EARLY STOPPING	MAE	MSE	RMSE	DA	MDAPE (%)	MAPE (%)
UNI-56-BIGRU-BAHDANAU	90-10	249	0,00201262	6,82E-06	0,00261175	83,01%	23,93519047	inf
UNI-55-BILSTM-BAHDANAU	90-10	501	0,00199375	6,73E-06	0,00259345	84,30%	23,61746511	inf
UNI-54-BIGRU-LUONG	90-10	1.000	0,00200707	6,88E-06	0,00262303	80,45%	23,65703378	inf
UNI-53-BILSTM-LUONG	90-10	453	0,00199513	6,76E-06	0,00259937	82,37%	23,57354072	inf
MV-59-BIGRU-LUONG	90-10	1.000	0,001884421	6,15E-06	0,002480345	79,17%	1,300348687	1,682884229
MV-58-BILSTM-LUONG	90-10	32	0,001911709	6,28E-06	0,002506022	80,45%	1,371195552	1,706084979
MV-552KS-BILSTM-LUONG-AutoKeras-y-Sci Keras	90-10	162	0,001916334	6,23E-06	0,002495204	80,13%	1,432119222	1,708298665
MV-552-BILSTM-BAHDANAU-AutoKeras	90-10	805	0,002183218	8,48E-06	0,002912681	75,64%	1,416972147	1,95015872
MV-550-BILSTM-BAHDANAU-AutoKeras	90-10	490	0,002149653	7,83E-06	0,002797334	78,21%	1,336825522	1,777203171
MV-54-BIGRU-LUONG	90-10	1.000	0,001869646	5,99E-06	0,002446844	79,17%	1,376223443	1,668907314
MV-532-BILSTM-LUONG-AutoKeras	90-10	497	0,001924003	6,44E-06	0,002538285	75,96%	1,261517403	1,721140579
MV-530-BILSTM-LUONG-AutoKeras	90-10	651	0,002033919	7,36E-06	0,002713552	75,32%	1,353860206	1,817799065
Mínimo			0,001870	0,000006	0,002447	75,32%	1,261517	1,668907
Máximo			0,002183	0,000008	0,002913	84,30%	23,935190	1,950159

Promedio	0,001990	0,000007	0,002610	79,52%	8,802691	1,764227
Desviación estándar	0,000099	0,000001	0,000138	0,0290	10,999719	0,095795

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Figura nro. 11 Gráfico de Train y Test Loss vs epochs de modelos UNI-53-BILSTM-LUONG (izq.), UNI-55-BILSTM-BAHDANAU (centro) y UNI-56-BIGRU-BAHDANAU (der.)



4.5 Resultados de análisis de re-estimación de modelos DL para ETF VTI

A continuación se presentan los resultados de los modelos al efectuar rolling windows.

Tabla nro. 25 de Resultados de Rolling Windows deep learning del ETF Vanguard Group - US9229087690

Modelo	Train/ Test	Promedio MAE	Promedio MSE	Promedio RMSE	Promedio DA	Promedio MAPE %	Promedio MDAPE %	Best Model Promedio MSE	Best Model Promedio DA
UNI-53-BILSTM-LUONG	90/10	0,001336050956	2,62E-06	0,001483489535	76,44%	1,192433911	1,192433911	1,08E-07	88,00%
UNI-54-BIGRU-LUONG	90/10	0,001330297107	2,68E-06	0,001495825474	74,59%	1,188105776	1,188105776	3,81E-08	84,00%
MV-552-BILSTM-BAHDANAU-AutoKeras	90/10	0,001357073125	2,74E-06	0,001516329388	76,01%	1,212526367	1,212526367	1,71E-08	87,50%
MV-530-BILSTM-LUONG-AutoKeras	90/10	0,001363191439	2,78E-06	0,001517871113	78,74%	1,211953895	1,211953895	2,31E-08	88,89%
MV-75-STACK-LSTM-MULTIHEAD	90/10	0,001375166656	2,82E-06	0,001525179463	79,04%	1,221449206	1,221449206	5,07E-08	88,89%
MV-74-STACK-LSTM-LOCAL SOFT	90/10	0,001384539964	2,83E-06	0,001542856696	75,41%	1,23476511	1,23476511	4,75E-08	88,89%
MV-552KS-BILSTM-LUONG-AutoKeras-y-SciKeras	90/10	0,001381360081	2,85E-06	0,001532679096	78,02%	1,230156244	1,230156244	5,10E-08	91,67%
MV-58-BILSTM-LUONG	90/10	0,00139742851	2,85E-06	0,001543201301	76,37%	1,244180587	1,244180587	7,91E-08	88,89%
MV-532-BILSTM-LUONG-AutoKeras	90/10	0,001387090993	2,88E-06	0,001533644827	77,04%	1,235556912	1,235556912	3,47E-08	88,89%
MV-54-BIGRU-LUONG	90/10	0,001401644196	2,88E-06	0,001555927374	76,59%	1,249760059	1,249760059	4,13E-09	88,89%
MV-55-BILSTM-BAHDANAU	90/10	0,00137554592	2,98E-06	0,001518612745	77,56%	1,226000492	1,226000492	1,59E-08	85,19%
MV-59-BIGRU-LUONG	90/10	0,001397248351	3,00E-06	0,001558150209	75,41%	1,243107951	1,243107951	2,46E-08	88,89%
MV-70-STACK-LSTM-LUONG	90/10	0,001448162782	3,00E-06	0,001595971964	76,89%	1,292782173	1,292782173	5,89E-08	88,89%
UNI-56-BIGRU-BAHDANAU	90/10	0,001502559282	3,35E-06	0,001658373329	72,41%	1,342696513	1,342696513	3,74E-08	92,00%
UNI-55-BILSTM-BAHDANAU	90/10	0,001506105557	3,36E-06	0,001658143406	73,00%	1,345555417	1,345555417	4,09E-08	88,00%
Mínimo		0,001330297107	2,62E-06	0,001483489535	72,41%	1,188105776	1,188105776	4,13E-09	84,00%
Máximo		0,001506105557	3,36E-06	0,001658373329	79,04%	1,345555417	1,345555417	1,08E-07	92,00%
Promedio		0,001396230995	2,91E-06	0,001549083728	76,23%	1,244735374	1,244735374	4,21E-08	88,50%
Desviación estándar		0,000052108	0,000000211	0,000051708	0,018813238	0,047390179	0,047390179	0,000000026	0,020040271

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Como un intento de obtener mayor entendimiento de la métrica de dirección DA en relación con cada una de las métricas de error se presentan las siguientes figuras en 2-dimensiones para distintos tipos de clasificaciones de modelos.

Figura nro. 11 de métrica MAE versus métrica DA en 2-D para ETF Vanguard

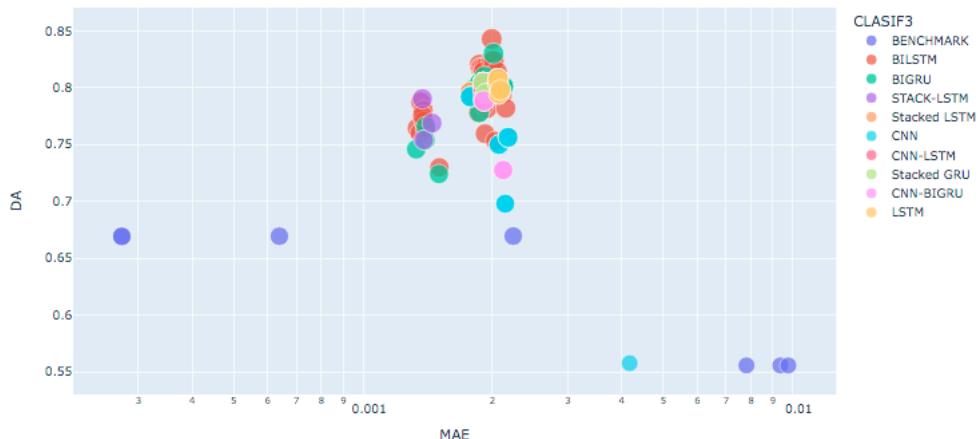


Figura nro. 12 de métrica MAPE versus métrica DA en 2-D para ETF Vanguard

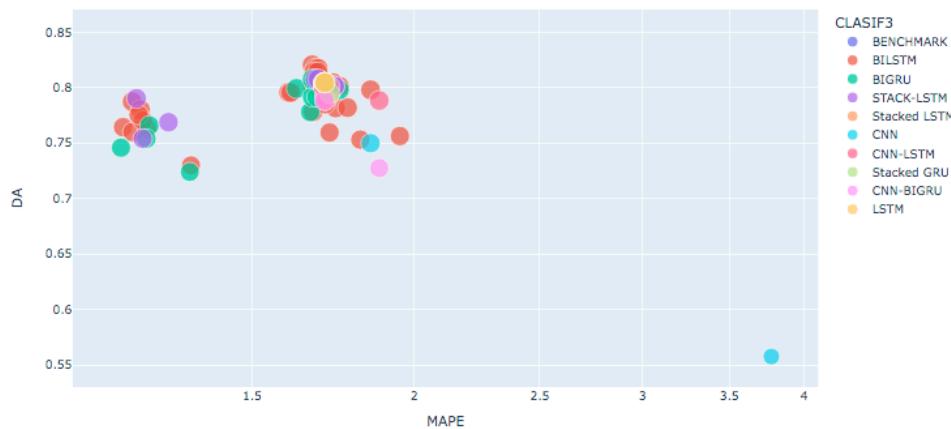


Figura nro. 13 de métrica MSE versus métrica DA en 2-D para ETF Vanguard

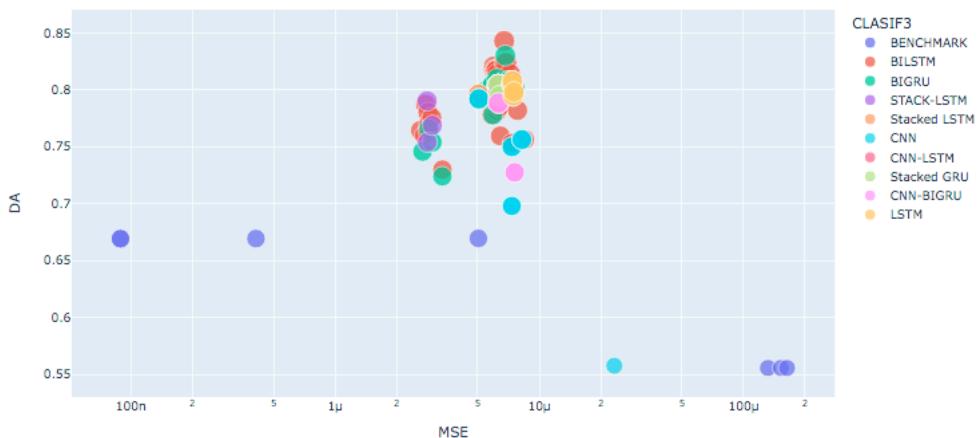
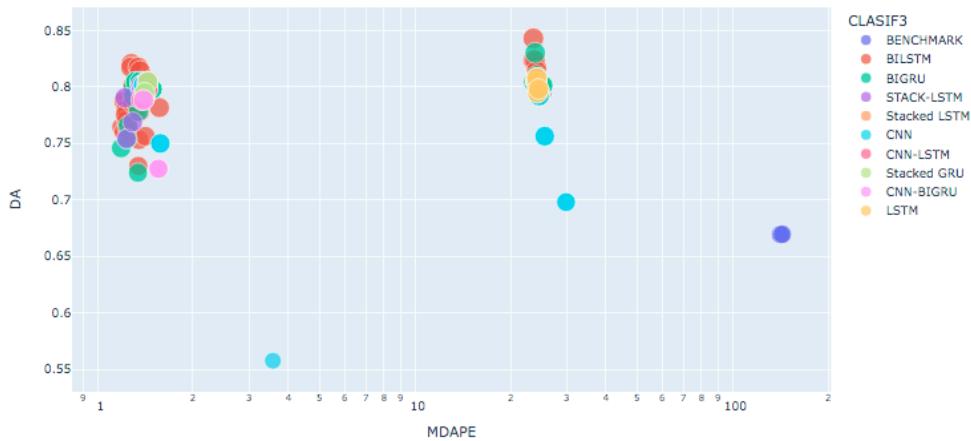


Figura nro. 14 de métrica MDAPE versus métrica DA en 2-D para ETF Vanguard



Como un intento de obtener mayor entendimiento de la métrica de dirección DA en relación con las métricas de error MSE y MAE o MAPE se presentan las siguientes figuras en 3-dimensiones para distintos tipos de clasificaciones de modelos.

Figura nro. 15 de métricas MAE, MSE y DA en 3-D para ETF Vanguard

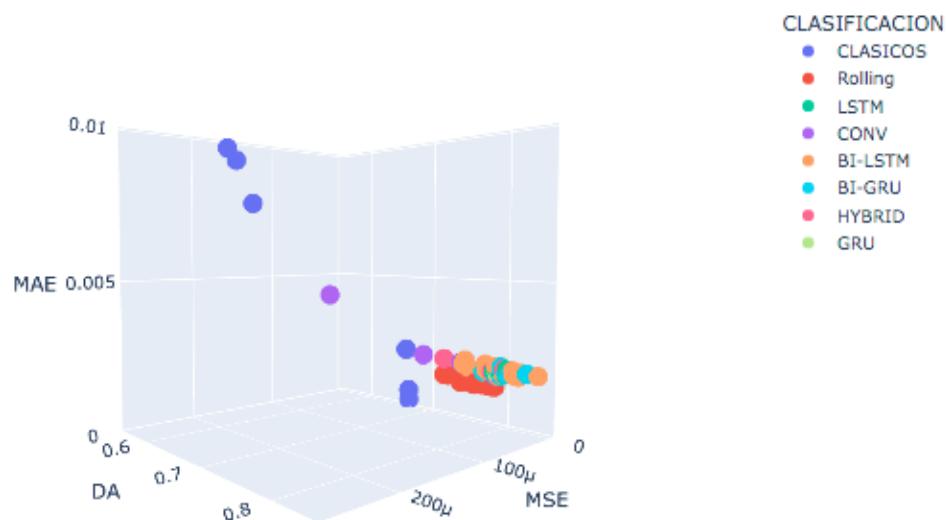


Figura nro. 16 de métricas MAPE, MSE y DA en 3-D para ETF Vanguard

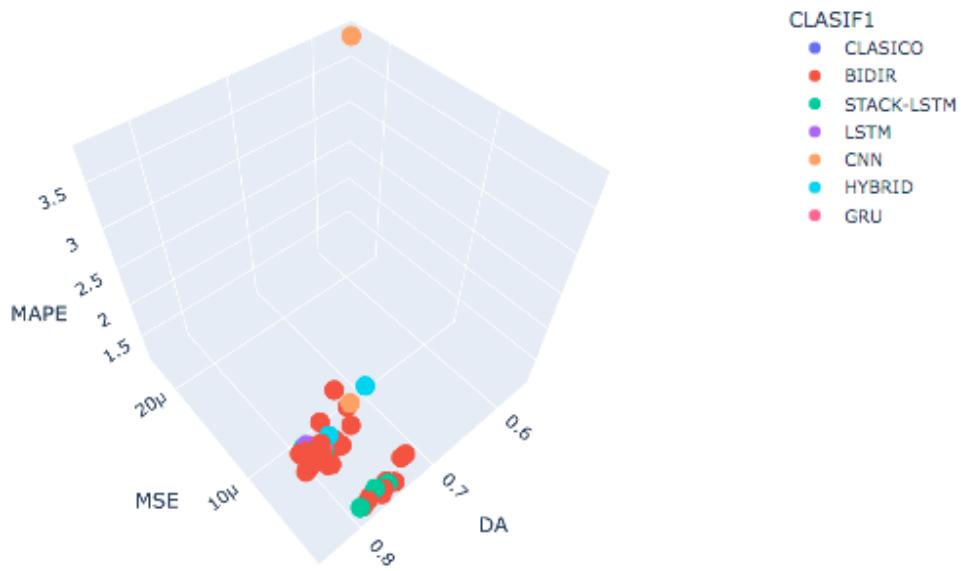


Figura nro. 17 de métricas MAPE, MSE y DA en 3-D para ETF Vanguard

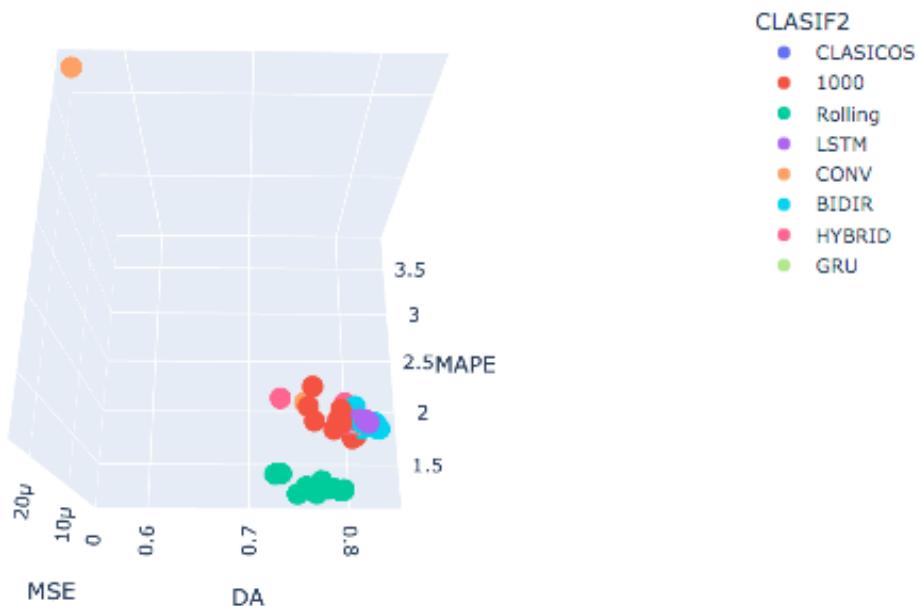
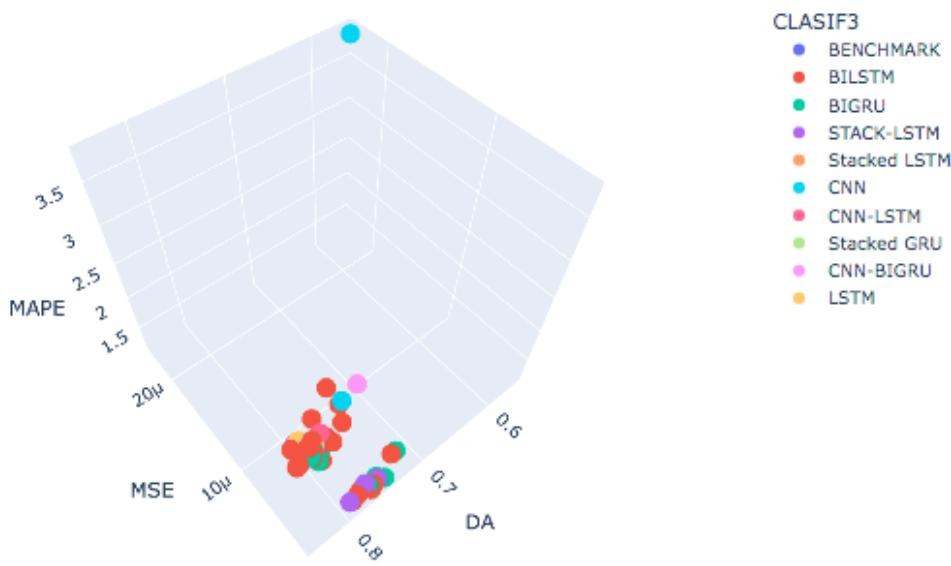


Figura nro. 18 de métricas MAPE, MSE y DA en 3-D para ETF Vanguard



4.6 Resultados de análisis de rentabilidad para ETF VTI

A continuación los resultados luego de efectuar **backtesting** y **trading**. Tabla con vista ordenada por columna “Calmar Ratio” marcada en color amarillo.

Tabla nro. 26 de **Retornos positivos** de backtesting y estrategias del ETF Vanguard Group - US9229087690

Modelo	Estrategia	Equity Final [\$]	Equity Peak [\$]	Retorno [%]	Buy & Hold Retorno [%]	Sharpe Ratio	Sortino Ratio	Calmar Ratio	Max. Drawdown [%]
MV-58-BILSTM-LUONG	one_side_buy_sl_trailing	51.316,94	51.316,94	413,17	382,62	0,70948	1,14878	0,38939	-21,44
MV-532-BILSTM-LUONG-AutoKeras	one_side_buy_sl_trailing	38.379,18	38.379,18	283,79	382,62	0,65203	1,04952	0,34125	-19,98
MV-530-BILSTM-LUONG-AutoKeras	one_side_buy_sl_trailing	38.348,23	38.440,57	283,48	382,62	0,60587	0,96878	0,33487	-20,35
MV-550-BILSTM-BAHDANAU-AutoKeras	one_side_buy_sl_trailing	39.386,45	39.386,45	293,86	382,62	0,59754	0,95111	0,30084	-23,11
MV-532-BILSTM-LUONG-AutoKeras	two_side_sl_tp_reversed	58.304,78	61.288,34	483,05	382,62	0,37906	0,70212	0,26005	-34,73
MV-58-BILSTM-LUONG	two_side_sl_trailing_reversed	42.197,65	42.197,65	321,98	382,62	0,57315	0,91043	0,25472	-28,72
MV-59-BIGRU-LUONG	one_side_buy_sl_trailing	38.160,18	38.160,18	281,6	382,62	0,59769	0,92992	0,2442	-27,8
MV-532-BILSTM-LUONG-AutoKeras	one_side_buy_sl_tp	52.191,11	52.347,76	421,91	382,62	0,57455	0,89023	0,2438	-34,62
MV-54-BIGRU-LUONG	one_side_buy_sl_trailing	44.921,71	45.056,26	349,22	382,62	0,63547	1,03416	0,24199	-31,59
MV-59-BIGRU-LUONG	two_side_sl_tp_reversed	121.086,44	122.346,84	1.110,66	382,62	0,52306	0,98985	0,24045	-54,1
MV-550-BILSTM-BAHDANAU-AutoKeras	two_side_sl_trailing_reversed	38.421,39	38.421,39	284,21	382,62	0,56144	0,889	0,23948	-28,49
MV-59-BIGRU-LUONG	two_side_sl_trailing_reversed	44.153,02	44.613,02	341,53	382,62	0,54512	0,86784	0,21569	-35,02
MV-552-BILSTM-BAHDANAU-AutoKeras	one_side_buy_sl_trailing	38.078,62	38.078,62	280,79	382,62	0,54508	0,86451	0,20984	-32,29
MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	two_side_sl_trailing_reversed	27.851,99	28.807,95	178,52	382,62	0,47281	0,72589	0,20436	-25,21
MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	one_side_buy_sl_trailing	27.851,99	28.807,95	178,52	382,62	0,47281	0,72589	0,20436	-25,21
MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	one_side_buy_sl_tp	25.693,54	29.339,27	156,94	382,62	0,42048	0,62393	0,18522	-25,57
MV-80-CNN-LUONG	one_side_buy_sl_trailing	26.692,54	31.107,63	166,93	382,62	0,37608	0,56468	0,18414	-26,78
MV-530-BILSTM-LUONG-AutoKeras	two_side_sl_trailing_reversed	34.666,85	34.860,93	246,67	382,62	0,49503	0,7893	0,1826	-34,42
MV-552-BILSTM-BAHDANAU-AutoKeras	two_side_sl_trailing_reversed	34.182,99	34.182,99	241,83	382,62	0,48279	0,75777	0,16857	-36,86
MV-550-BILSTM-BAHDANAU-AutoKeras	two_side_sl_tp_reversed	53.366,06	54.195,56	433,66	382,62	0,41223	0,63179	0,15093	-56,7
MV-550-BILSTM-BAHDANAU-AutoKeras	one_side_buy_sl_tp	51.636,46	52.437,96	416,36	382,62	0,41757	0,63546	0,14824	-56,65
MV-552-BILSTM-BAHDANAU-AutoKeras	one_side_buy_sl_tp	19.492,82	19.901,44	94,93	382,62	0,27667	0,40015	0,14591	-22,8
MV-59-BIGRU-LUONG	one_side_buy_sl_tp	22.473,00	22.473,00	124,73	382,62	0,38113	0,5535	0,14396	-28,14
MV-552-BILSTM-BAHDANAU-AutoKeras	two_side_sl_tp_reversed	49.404,27	53.372,55	394,04	382,62	0,39299	0,59894	0,14211	-57,34
MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	two_side_sl_tp_reversed	48.696,30	52.610,22	386,96	382,62	0,39161	0,59685	0,1418	-56,93
UNI-56-BIGRU-BAHDANAU	one_side_buy_sl_tp	39.548,94	45.553,51	295,49	382,62	0,36792	0,55069	0,13389	-52,09
MV-54-BIGRU-LUONG	one_side_buy_sl_tp	39.111,81	39.228,82	291,12	382,62	0,43004	0,65275	0,12648	-54,68
MV-58-BILSTM-LUONG	one_side_buy_sl_tp	39.919,92	40.539,42	299,2	382,62	0,36357	0,54359	0,12334	-56,95
MV-59-BIGRU-LUONG	one_side_sell_sl_tp	17.891,94	18.116,12	78,92	382,62	0,20201	0,5169	0,11092	-26,09
UNI-56-BIGRU-BAHDANAU	two_side_sl_tp_reversed	30.262,24	37.331,67	202,62	382,62	0,27878	0,41249	0,10713	-52,09

UNI-53-BILSTM-LUONG	one_side_buy_sl_tp	30.278,66	34.870,39	202,79	382,62	0,30226	0,44643	0,107	-52,18
MV-80-CNN-LUONG	two_side_sl_trailing_reversed	19.572,95	26.408,70	95,73	382,62	0,25144	0,36911	0,10287	-32,54
MV-58-BILSTM-LUONG	two_side_sl_tp_reversed	31.777,35	32.270,85	217,77	382,62	0,28845	0,42884	0,1013	-57,59
MV-54-BIGRU-LUONG	two_side_sl_tp_reversed	35.322,58	36.809,52	253,23	382,62	0,27664	0,49159	0,09751	-65,46
MV-54-BIGRU-LUONG	two_side_sl_trailing_reversed	22.446,41	23.352,04	124,46	382,62	0,27423	0,42564	0,07329	-55,19
UNI-53-BILSTM-LUONG	one_side_buy_sl_trailing	11.858,24	13.109,01	18,58	382,62	0,19567	0,27245	0,07266	-11,55
MV-530-BILSTM-LUONG-AutoKeras	one_side_buy_sl_tp	23.358,49	23.414,64	133,58	382,62	0,19409	0,25343	0,06135	-69,24
MV-532-BILSTM-LUONG-AutoKeras	two_side_sl_trailing_reversed	17.934,76	18.651,37	79,35	382,62	0,19694	0,3019	0,05791	-50,18
UNI-53-BILSTM-LUONG	two_side_sl_tp_reversed	18.228,76	22.479,66	82,29	382,62	0,1547	0,22375	0,05615	-53,22
MV-530-BILSTM-LUONG-AutoKeras	two_side_sl_tp_reversed	20.924,64	21.041,09	109,25	382,62	0,16076	0,2119	0,05078	-72,6
MV-80-CNN-LUONG	one_side_buy_sl_tp	17.091,31	21.170,50	70,91	382,62	0,11969	0,15564	0,03868	-68,85
UNI-55-BILSTM-BAHDANAU	one_side_buy_sl_tp	16.032,66	18.473,02	60,33	382,62	0,11037	0,14068	0,03203	-73,11
MV-59-BIGRU-LUONG	one_side_sell_sl_trailing	11.558,47	11.702,53	15,58	382,62	0,097	0,14935	0,03184	-22,38
UNI-55-BILSTM-BAHDANAU	one_side_buy_sl_trailing	10.725,12	11.764,34	7,25	382,62	0,07652	0,10535	0,03033	-11,34
UNI-56-BIGRU-BAHDANAU	one_side_buy_sl_trailing	10.797,59	11.957,31	7,98	382,62	0,08847	0,11998	0,02262	-16,66
MV-532-BILSTM-LUONG-AutoKeras	one_side_sell_sl_tp	11.168,41	12.576,71	11,68	382,62	0,03193	0,06308	0,01084	-50,13
MV-550-BILSTM-BAHDANAU-AutoKeras	one_side_sell_sl_tp	10.322,65	10.695,47	3,23	382,62	0,03235	0,04792	0,00891	-17,49
MV-80-CNN-LUONG	two_side_sl_tp_reversed	11.073,60	17.203,98	10,74	382,62	0,02273	0,0289	0,00666	-75,27
MV-552-BILSTM-BAHDANAU-AutoKeras	one_side_sell_sl_tp	10.197,64	10.757,80	1,98	382,62	0,02179	0,0343	0,00534	-17,97
Mínimo		10.197,64	10.695,47	1,98	382,62	0,02179	0,0289	0,00534	-75,27
Máximo		121.086,44	122.346,84	1110,86	382,62	0,70948	1,14878	0,38939	-11,34
Promedio		32.129,79	33.706,31	221,29	382,62	0,3475	0,5458	0,1446	-39,991
Desviación estándar		18875,05	18782,38	188,75	0,0	0,1923	0,3148	0,0963	18,2598

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Tabla nro. 27 de **Retornos negativos** de backtesting y estrategias del ETF Vanguard Group - US9229087690

Modelo	Estrategia	Equity Final [\$]	Equity Peak [\$]	Retorno [%]	Buy & Hold Retorno [%]	Sharpe Ratio	Sortino Ratio	Calmar Ratio	Max. Drawdown [%]
UNI-55-BILSTM-BAHDANAU	two_side_sl_tp_reversed	9.926,19	13.845,90	-0,74	382,62	0	0	0	-79,26
UNI-53-BILSTM-LUONG	two_side_sl_trailing_reversed	9.916,93	12.215,50	-0,83	382,62	0	0	0	-21,52
MV-550-BILSTM-BAHDANAU-AutoKeras	one_side_sell_sl_trailing	9.750,05	10.094,19	-2,5	382,62	0	0	0	-17,96
MV-54-BIGRU-LUONG	one_side_sell_sl_tp	9.104,08	10.092,71	-8,96	382,62	0	0	0	-45,58
MV-530-BILSTM-LUONG-AutoKeras	one_side_sell_sl_trailing	9.035,59	10.252,96	-9,64	382,62	0	0	0	-28,49
MV-530-BILSTM-LUONG-AutoKeras	one_side_sell_sl_tp	8.964,26	10.873,62	-10,36	382,62	0	0	0	-31,82
MV-552-BILSTM-BAHDANAU-AutoKeras	one_side_sell_sl_trailing	8.960,87	10.085,96	-10,39	382,62	0	0	0	-24,39
UNI-53-BILSTM-LUONG	one_side_sell_sl_trailing	8.366,28	10.184,06	-16,34	382,62	0	0	0	-20,64
MV-58-BILSTM-LUONG	one_side_sell_sl_trailing	8.243,64	10.085,96	-17,56	382,62	0	0	0	-29,73
UNI-55-BILSTM-BAHDANAU	two_side_sl_trailing_reversed	8.006,00	10.097,93	-19,94	382,62	0	0	0	-26,88
MV-58-BILSTM-LUONG	one_side_sell_sl_tp	7.972,96	10.151,43	-20,27	382,62	0	0	0	-31,09
UNI-56-BIGRU-BAHDANAU	one_side_sell_sl_tp	7.667,35	12.146,40	-23,33	382,62	0	0	0	-37,97
UNI-55-BILSTM-BAHDANAU	one_side_sell_sl_trailing	7.462,35	10.209,39	-25,38	382,62	0	0	0	-29,41
MV-80-CNN-LUONG	one_side_sell_sl_trailing	7.342,83	10.576,91	-26,57	382,62	0	0	0	-30,58
UNI-56-BIGRU-BAHDANAU	two_side_sl_trailing_reversed	7.093,94	11.437,76	-29,06	382,62	0	0	0	-40,05
UNI-56-BIGRU-BAHDANAU	one_side_sell_sl_trailing	6.590,97	10.219,59	-34,09	382,62	0	0	0	-37,73
MV-80-CNN-LUONG	one_side_sell_sl_tp	6.520,16	10.576,91	-34,8	382,62	0	0	0	-38,35
UNI-55-BILSTM-BAHDANAU	one_side_sell_sl_tp	6.122,23	10.213,51	-38,78	382,62	0	0	0	-41,12
UNI-53-BILSTM-LUONG	one_side_sell_sl_tp	6.037,65	11.149,05	-39,62	382,62	0	0	0	-46,79
MV-54-BIGRU-LUONG	one_side_sell_sl_trailing	4.996,12	10.088,59	-50,04	382,62	0	0	0	-64,76
MV-532-BILSTM-LUONG-AutoKeras	one_side_sell_sl_trailing	4.669,10	10.216,23	-53,31	382,62	0	0	0	-71,92
Mínimo		4.669,10	10.085,96	-53,31	382,62	0	0	0	-79,26
Máximo		9.926,19	13.845,90	-0,74	382,62	0	0	0	-17,96
Promedio		7.749,98	10.705,46	-22,50	382,62	0	0	0	-37,91
Desviación estándar		1529,65	975,36	15,30	0,00	0,00	0,00	0,00	16,39

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Se presentan las figuras gráficas resultantes de aplicar del *backtesting* y *trading* a los siguientes modelos: para MV-58-BILSTM-LUONG que presenta el mejor *calmar ratio* con 170 trades y para MV-59-BIGRU-LUONG que presenta el mejor retorno con 176 trades.

Figura nro. 19 de Gráfico del backtesting trading del modelo MV-58-BILSTM-LUONG



Figura nro. 20 de Gráfico del backtesting trading del modelo MV-59-BIGRU-LUONG



Capítulo 5: Análisis de Resultados

Respecto a la conveniencia de modelar retornos o precios, se decidió retornos en etapas tempranas del desarrollo del trabajo, los resultados experimentales comprobaron la superioridad en rendimiento al modelar retornos debido a la propiedad de normalización.

Con respecto a las variables provenientes de indicadores técnicos, se correlacionan con la variable objetivo AdjClose en un rango que va entre 0,82% y 0,95% visualizado en un *heatmap*.

Respecto del análisis de los resultados de las métricas de los 5 instrumentos para predicción de retornos: en los modelos *tradicionales benchmark*, AutoReg presenta la menor métrica MSE para ETF Invesco y AutoReg y ARIMA en la capacidad de acierto DA 57,33%; en los modelos *univariados* la arquitectura Stacked LSTM logra las mejores predicciones en términos del error MSE el modelo UNI-71-LSTM-LUONG para ETF Invesco, y en la capacidad de acierto DA 78,98% el modelo UNI-40-CNN para ETF BlackRock USA; y en los modelos *multivariados*, las arquitecturas Bidirectional LSTM y GRU con atención Badahnau y Luong logran mejores predicciones en términos de métricas de error MSE, y en capacidad de acierto DA el modelo MV-53-BILSTM-LUONG para ETF Vanguard obtuvo 80,78%.

Con el ETF Blackrock Germany que replica acciones alemanas, la capacidad de acierto DA obtuvo 77,65% comprobando así la capacidad de generalización de las redes implementadas. Respecto de las métricas de error MAE/MSE, los ETF's que replican acciones norteamericanas obtuvieron mejores métricas de error del orden exponencial(-6), en cambio el ETF alemán obtuvo métricas del orden exponencial(-5).

Luego de seleccionar el ETF Vanguard Group VTI US9229087690 entre los 5 instrumentos ETFs, se obtienen los siguientes resultados:

Para los modelos con epochs 40:

- en resultados del modelo AutoReg, ARIMA y ARIMAX, el modelo AutoReg obtuvo la menor métrica MSE, sin embargo con una muy baja métrica DA 55,575% (tabla nro. 11). Cabe notar que a medida que el % train aumenta, los modelos ARIMA y ARIMAX convergen en (p,d,q) en idénticos valores (1,0,0);
- en resultados del modelo MLPK, obtuvo la mejor métrica MSE 1,738exp(-6), sin embargo con una baja métrica DA 66,939% (tabla nro. 12);
- en los resultados de las métricas DA de los modelos *deep learning* multivariados, destacan 4 modelos con capacidad de acierto sobre 81% con un promedio DA 79,21% (tabla nro. 13), y en los modelos *deep learning* univariados, destacan 3 modelos con capacidad de acierto sobre 81% con un promedio DA 79,57% (tabla nro. 14);

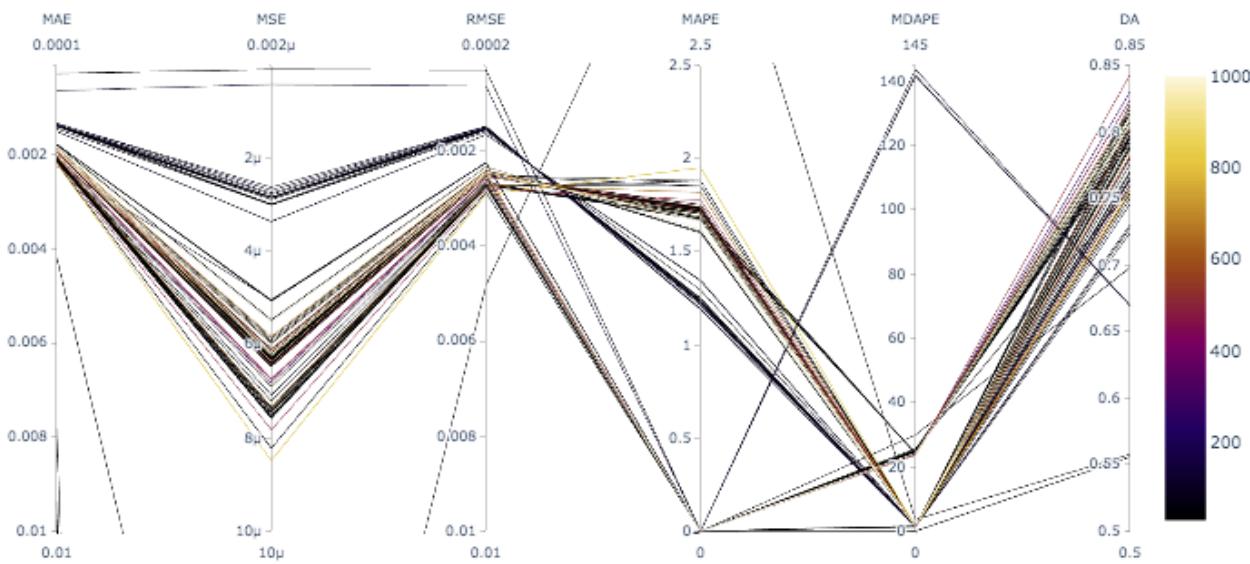
- en los resultados de la métrica MAE en modelos multivariados (tabla nro. 15) se obtuvo un promedio de 0,00393 y en modelos univariados (tabla nro. 16) se obtuvo un promedio de 0,00407;
- en los resultados de la métrica MSE, en modelos multivariados (tabla nro. 17) se obtuvo un promedio de $1,464\exp(-5)$ y en modelos univariados (tabla nro. 18) se obtuvo un promedio de $1,551\exp(-5)$;
- en los resultados de la métrica RMSE en modelos multivariados (tabla nro. 19) se obtuvo un promedio de 0,0056 y en modelos univariados (tabla nro. 20) se obtuvo un promedio de 0,0058;
- en los resultados de la métrica MAPE en modelos multivariados (tabla nro. 21) se obtuvo un promedio de 1,7767;
- en los resultados de las métrica MDAPE en modelos multivariados (tabla nro. 22) se obtuvo un promedio de 3,303 y en modelos univariados (tabla nro. 23) se obtuvo un promedio de 24,777.

Para los modelos con epochs 1.000, con early stopping y patience 30, que igualaron las condiciones de entrenamiento de la arquitectura *AutoKeras*, se obtuvieron 3 métricas de dirección DA sobre 82% con un promedio DA 79,52% (tabla nro. 24) con gráficos Loss versus Epochs (Figura nro. 11). Sin embargo, los modelos con epochs 1.000 no superan a las métricas de error logradas previamente con los modelos con epochs 40.

Para los modelos con *rolling windows* se obtuvieron las mejores métricas en los indicadores de error, sin embargo, sus indicadores de dirección DA no superaron el umbral de 80% (tabla nro. 25): en los resultados de la métrica MAE se obtuvo un promedio de 0,00139; en los resultados de la métrica MSE se obtuvo un promedio de $2,91\exp(-6)$; en los resultados de la métrica RMSE se obtuvo un promedio de 0,00154; en los resultados de la métrica MAPE se obtuvo un promedio de 1,2447.

La figura nro. 21 presenta un gráfico de coordenadas paralelas que incluye todas las métricas de error junto con la métrica de dirección DA con colores según nivel de entrenamiento en epochs de 0 a 1.000. En la figura se puede apreciar que mientras más entrenamiento tiende a epochs 1.000 se obtienen mejores resultados en el indicador DA.

Figura nro. 21 de gráfico de coordenadas paralelas de métricas de error con métrica DA



Los resultados del presente trabajo se encuentran en conformidad a la literatura reciente: respecto de las redes CNN que se usan para el reconocimiento de imágenes y la extracción de características, también se puede usar para la predicción de series temporales pero la precisión de pronóstico de CNN por sí sola es relativamente baja en comparación con LSTM (Lu W. et al. 2020); respecto de la predicción de precios de acciones, LSTM tiene mejor rendimiento, y ARIMA es inferior a LSTM para expresar cambios en el precio de las acciones (Xiao et al. 2022); el modelo *benchmark* ARIMA no puede describir series de tiempo no lineales, necesita satisfacer muchas condiciones previas antes del modelado, y no puede lograr resultados satisfactorios en la predicción de stock (Zhuangwei et al. 2023); y finalmente, de acuerdo con experimentos con datos bursátiles chinos a gran escala, las redes multivariadas LSTM tienen una mayor precisión de predicción en el mercado de valores (Fei G., et al., 2022).

La tabla nro. 28 presenta las **mejores métricas de error MAE y MSE/RMSE** por cada modelo considerando train/test 90/10 para distintos Epochs.

Tabla nro. 28 mejores métricas de error MAE y MSE para ETF Vanguard Group - US9229087690

Tipo de Modelo	Train/Test	Código	Epoch o EarlyStopping	MAE	MSE	RMSE	DA (%)	MDAPE (%)	MAPE (%)
Benchmark	90-10	MLPK	40	0,000856396	1,41E-06	0,000870421	66,939%	142,2643638	inf
Rolling	90-10	UNI-53-BILSTM-LUONG	120	0,001336051	2,62E-06	0,001483490	76,444%	1,192433911	1,192433911
Rolling	90-10	UNI-54-BIGRU-LUONG	120	0,001330297	2,68E-06	0,001495825	74,591%	1,188105776	1,188105776
Rolling	90-10	MV-552-BILSTM-BAHDANAU-AutoKeras	120	0,001357073	2,74E-06	0,001516329	76,007%	1,212526367	1,212526367
Rolling	90-10	MV-530-BILSTM-LUONG-AutoKeras	120	0,001363191	2,78E-06	0,001517871	78,741%	1,211953895	1,211953895
Rolling	90-10	MV-75-STACK-LSTM-MULTIHEAD	120	0,001375167	2,82E-06	0,001525179	79,037%	1,221449206	1,221449206
Rolling	90-10	MV-74-STACK-LSTM-LOCAL SOFT	120	0,00138454	2,83E-06	0,001542857	75,407%	1,23476511	1,23476511
Rolling	90-10	MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	120	0,00138136	2,85E-06	0,001532679	78,021%	1,230156244	1,230156244

Rolling	90-10	MV-58-BILSTM-LUONG	120	0,001397429	2,85E-06	0,001543201	76,370%	1,244180587	1,244180587
Rolling	90-10	MV-532-BILSTM-LUONG-AutoKeras,	120	0,001387091	2,88E-06	0,001533645	77,037%	1,235556912	1,235556912
Rolling	90-10	MV-54-BIGRU-LUONG	120	0,001401644	2,88E-06	0,001555927	76,593%	1,249760059	1,249760059
Rolling	90-10	MV-55-BILSTM-BAHDANAU	120	0,001375546	2,98E-06	0,001518613	77,556%	1,226000492	1,226000492
Mínimo				0,000856396	1,41E-06	0,000870421	66,94%	1,188105776	1,188105776
Máximo				0,001401644	2,98E-06	0,001555927	79,04%	142,2643638	1,249760059
Promedio				0,0013288154	2,69E-06	0,0014696697	76,06%	12,9759377	1,222444414
Desviación estándar				0,000150400	0,000000417	0,000189789	0,031535806	40,7152994	0,019757637

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Considerar que la métrica MAPE(*) tiene tendencia a expandirse hasta el infinito “inf” debido a un valor cero observado ([Aldosari et al. 2024](#)).

Considerando la tabla anterior de mejores métricas de los indicadores de error MAE y MSE: el 83% corresponde a modelos multivariados y el 17% corresponde a modelos univariados; con respecto a la arquitectura, Bidireccional lidera el 75% de las posiciones, Stacked LSTM con 17% y la arquitectura MLPK con 8%; con respecto al mecanismo de atención, el mecanismo Luong lidera con 46% de posiciones, le sigue Bahdanau con 25%, Multi Head Attention con 4%, Local Soft Attention con 4% y sin mecanismo de atención 21%; con respecto a la optimización de hiperparámetros, con el 42% de posiciones con AutoKeras y el 8% con SciKeras.

La tabla nro. 29 presenta las **mejores métricas de error MAPE** por cada modelo considerando train/test 90/10 para distintos Epochs.

Tabla nro. 29 métricas de finales MAPE para ETF Vanguard Group - US9229087690

Tipo de Modelo	Train/Test	Código	Epoch o EarlyStopping	MAE	MSE	RMSE	DA (%)	MAPE (%)
Rolling	90-10	UNI-54-BIGRU-LUONG	120	0,001330297	2,682E-06	0,001495825	74,591%	1,188105776
Rolling	90-10	UNI-53-BILSTM-LUONG	120	0,001336051	2,619E-06	0,001483490	76,444%	1,192433911
Rolling	90-10	MV-530-BILSTM-LUONG-AutoKeras	120	0,001363191	2,776E-06	0,001517871	78,741%	1,211953895
Rolling	90-10	MV-552-BILSTM-BAHDANAU-AutoKeras	120	0,001357073	2,739E-06	0,001516329	76,007%	1,212526367
Rolling	90-10	MV-75-STACK-LSTM-MULTIHEAD	120	0,001375167	2,824E-06	0,001525179	79,037%	1,221449206
Rolling	90-10	MV-55-BILSTM-BAHDANAU	120	0,001375546	2,979E-06	0,001518613	77,556%	1,226000492
Rolling	90-10	MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	120	0,001381360	2,850E-06	0,001532679	78,021%	1,230156244
Rolling	90-10	MV-74-STACK-LSTM-LOCAL SOFT	120	0,001384540	2,832E-06	0,001542857	75,407%	1,23476511
Rolling	90-10	MV-532-BILSTM-LUONG-AutoKeras	120	0,001387091	2,881E-06	0,001533645	77,037%	1,235556912
Rolling	90-10	MV-59-BIGRU-LUONG	120	0,001397248	2,996E-06	0,001558150	75,407%	1,243107951
Rolling	90-10	MV-58-BILSTM-LUONG	120	0,001397429	2,852E-06	0,001543201	76,370%	1,244180587
Rolling	90-10	MV-54-BIGRU-LUONG	120	0,001401644	2,884E-06	0,001555927	76,593%	1,249760059
Mínimo				0,001330297	2,62E-06	0,00148349	74,59%	1,188105776
Máximo				0,001401644	3,00E-06	0,00155815	79,04%	1,249760059
Promedio				0,0013738864	2,83E-06	0,0015269805	76,77%	1,224166376
Desviación estándar				0,000023252	0,000000110	0,000022428	0,013691902	0,019760020

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Considerando la tabla anterior de mejores métricas de los indicadores de error MDAPE y MAPE, el 92% corresponde a modelos multivariados y el 8% restante corresponde a modelos univariados; con respecto a la arquitectura, Bi-LSTM lidera el 38% de las posiciones, Bi-GRU le sigue con 21%, Stacked LSTM con 25%, GRU con 8%, la arquitectura CNN con 4% y la arquitectura híbrida CNN-LSTM con 4%; y con respecto al mecanismo de atención, el mecanismo Luong lidera con 42% con mejores métricas, le sigue Bahdanau con 25%, Multi Head Attention con 4%, Local Soft Attention con 4% y sin mecanismo de atención 25%; con respecto a la optimización de hiperparámetros, con el 33% de posiciones con *AutoKeras* y el 8% con *SciKeras*.

La tabla nro. 30 presenta las **mejores métricas de dirección DA** por cada modelo considerando train/test 90/10 para distintos Epochs.

Tabla nro. 30 mejores métricas de dirección finales DA para ETF Vanguard Group - US9229087690

Tipo de Modelo	Train/Test	Código	Epoch o EarlyStopping	MAE	MSE	RMSE	DA (%)	MDAPE (%)	MAPE (%)	Score (Zhang J. et al., 2023)
Epochs 1.000	90-10	UNI-55-BILSTM-BAHDANAU	501	0,001993750	6,730E-06	0,002593450	84,30%	23,61746511	in	N/A
Epochs 1.000	90-10	UNI-56-BIGRU-BAHDANAU	249	0,002012620	6,820E-06	0,002611750	83,01%	23,93519047	in	N/A
Epochs 1.000	90-10	UNI-53-BILSTM-LUONG	453	0,001995130	6,760E-06	0,002599370	82,37%	23,57354072	in	N/A
Epochs 40	90-10	UNI-53-BILSTM-LUONG	40	0,002017430	6,900E-06	0,002627430	82,37%	23,88724579	in	N/A
Epochs 40	90-10	MV-58-BILSTM-LUONG	40	0,001867907	5,973E-06	0,002443980	82,05%	1,27940929	1,668891313	-0,3282
Epochs 40	90-10	MV-532-BILSTM-LUONG-AutoKeras	40	0,001875993	5,988E-06	0,002447139	81,73%	1,275291807	1,678032988	-0,3301
Epochs 40	90-10	MV-552-BILSTM-BAHDANAU-AutoKeras	40	0,001889360	6,120E-06	0,002473837	81,73%	1,346548916	1,686495965	-0,3318
Epochs 1.000	90-10	UNI-53-BILSTM-LUONG	556	0,001906840	6,090E-06	0,002467230	81,69%	24,17510977	in	N/A
Epochs 1.000	90-10	UNI-55-BILSTM-BAHDANAU	568	0,001912540	6,170E-06	0,002483600	81,69%	24,14690857	in	N/A
Epochs 40	90-10	MV-550-BILSTM-BAHDANAU-AutoKeras	40	0,001908537	6,238E-06	0,002497588	81,41%	1,363936562	1,674728282	-0,3294
Epochs 40	90-10	UNI-55-BILSTM-BAHDANAU	40	0,002051750	7,210E-06	0,002684260	81,41%	24,17487307	1,685256514	-0,3316
Epochs 1.000	90-10	UNI-54-BIGRU-LUONG	912	0,001918260	6,220E-06	0,002494260	80,99%	24,17932479	in	N/A
Mínimo				0,001867907	5,97E-06	0,00244398	80,99%	1,275291807	1,668891313	-0,3318
Máximo				0,00205175	7,21E-06	0,00268426	84,30%	24,17932479	1,686495965	-0,3282
Promedio				0,001945843	6,43E-06	0,0025353245	82,06%	16,41290374	1,678681012	-0,33022
Desviación estándar				0,000063569	0,000000420	0,000082192	0,00883530	11,151435131	0,007351750	0,001513935

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Considerando la tabla anterior de mejores métricas del indicadores de dirección, el 63% corresponde a modelos multivariados y el 37% restante corresponde a modelos univariados; con respecto a la arquitectura, Bi-LSTM lidera el 75% de las posiciones, Bi-GRU le sigue con 21%, la arquitectura Stacked LSTM con 4%; y con respecto al mecanismo de atención, el mecanismo Bahdanau lidera con 54% con mejores métricas, le sigue Luong con 42% y Multi Head Attention con 4%; con respecto a la optimización de hiperparámetros, con el 25% de posiciones con *AutoKeras*.

Finalmente, respecto al *backtesting* y *trading*, se aplicaron las estrategias desde 2003 al 2023 equivalente a 21 años, los resultados con retornos positivos se presenta en la tabla nro. 26 y con retornos negativos en la tabla nro. 27.

Entre las 72 combinaciones resultante de aplicar 6 estrategias entre 12 modelos, hay 21 combinaciones que obtienen retornos negativos (29,2%) con un mínimo de -53,3%, hay 2 combinaciones (2,8%) que obtienen retornos igual a cero, y hay 49 combinaciones que obtienen retornos positivos (68,1%) con un máximo de 1.110,8%. Entre los retornos positivos, hay 8 modelos con estrategias ganadoras superiores a Buy & Hold durante el período 2003 al 2023, corresponden a modelos multivariados.

Con estrategia two_side_sl_tp_reversed (62,5%) destacan los modelos:

- MV-59-BIGRU-LUONG,
- MV-532-BILSTM-LUONG-AutoKeras,
- MV-550-BILSTM-BAHDANAU-AutoKeras,
- MV-552-BILSTM-BAHDANAU-AutoKeras y
- MV-552KS-BILSTM-LUONG-AutoKeras-y-SciKeras(*modelo sofisticado);

Con estrategia one_side_buy_sl_tp (25%) destacan los modelos:

- MV-532-BILSTM-LUONG-AutoKeras y
- MV-550-BILSTM-BAHDANAU-AutoKeras;

Con estrategia one_side_buy_sl_trailing (12,5%) destaca el modelo:

- MV-58-BILSTM-LUONG.

La tabla nro. 31 presenta una vista ordenada **por Retorno(%)**, la cual incluye modelos mayoritariamente con estrategia *two_side_sl_tp_reversed* estrategia que abre posiciones en ambos lados de compra y venta.

Tabla nro. 31 de vista por Retorno y estrategias del backtesting

Modelo	Estrategia	Equity Final [\$]	Equity Peak [\$]	Retorno (%)	Buy & Hold Retorno (%)	Return (Ann.) [%]	Volatility (Ann.) [%]	Sharpe Ratio	Sortino Ratio	Calmar Ratio	Max Drawdown [%]	# Trades	Win Rate (%)	Profit Factor
MV-59-BIGRU-LUONG	two_side_sl_tp_reversed	121.086,44	122.346,84	1.110,86	382,62	13,01	24,87	0,52306	0,98985	0,24045	-54,10	176	59,09	2,51
MV-532-BILSTM-LUONG-AutoKeras	two_side_sl_tp_reversed	58.304,78	61.288,34	483,05	382,62	9,03	23,82	0,37906	0,70212	0,26005	-34,73	294	54,42	1,59
MV-550-BILSTM-BAHDANAU-AutoKeras	two_side_sl_tp_reversed	53.366,06	54.195,56	433,66	382,62	8,56	20,76	0,41223	0,63179	0,15093	-56,70	49	63,27	4,71
MV-532-BILSTM-LUONG-AutoKeras	one_side_buy_sl_tp	52.191,11	52.347,76	421,91	382,62	8,44	14,69	0,57455	0,89023	0,24380	-34,62	146	68,49	2,41
MV-550-BILSTM-BAHDANAU-AutoKeras	one_side_buy_sl_tp	51.636,46	52.437,96	416,36	382,62	8,38	20,08	0,41757	0,63546	0,14824	-56,55	25	80,00	7,51
MV-58-BILSTM-LUONG	one_side_buy_sl_trailing	51.316,94	51.316,94	413,17	382,62	8,35	11,77	0,70948	1,14878	0,38939	-21,44	170	47,06	2,03
MV-552-BILSTM-BAHDANAU-AutoKeras	two_side_sl_tp_reversed	49.404,27	53.372,55	394,04	382,62	8,15	20,73	0,39299	0,59894	0,14211	-57,34	7	85,71	5,60

MV-552KS-BILSTM-BAHDANAU-AutoKeras y SciKeras	two_side_sl_tp_reversed	48.696,30	52.610,22	386,96	382,62	8,07	20,61	0,39161	0,59685	0,14180	-56,93	7	85,71	5,54
Mínimo		48.696	51.317	387	383	8,07	11,77	0,3791	0,5968	0,1418	-57,34	7	47,06	1,59
Máximo		121.086	122.347	1.111	383	13,01	24,87	0,7095	1,1488	0,3894	-21,44	294	85,71	7,51
Promedio		60.750	62.490	508	383	9,00	19,67	0,4751	0,7743	0,2146	-46,55	109,25	67,97	3,99
Desviación estándar		24.554	24.385	246	0,00	1,65	4,39	0,12	0,21	0,09	14,13	103,69	14,62	2,14

*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

Entre los 8 modelos con retornos positivos, obtuvieron retornos entre 386,96% hasta 1.110,86%, y la inversión inicial de \$10.000 la incrementaron entre \$52.610 hasta \$122.346, la mayoría de los casos corresponde a la estrategia que abre posiciones en ambos lados de compra y venta (62,5%), y la estrategia abre la posición sólo para compra (37,5%), lo cual es esperable puesto que el periodo de *testing* abarca el conflicto ruso entre el 24 de febrero de 2022 al 22 de noviembre de 2023 y también abarca el conflicto en Gaza entre 07 de octubre de 2023 al 22 de noviembre de 2023.

Los modelos con retornos negativos tienen mayoritariamente 81% de estrategias que abren la posición sólo para venta, *one_side_sell_sl_tp* (33,3%) y *one_side_sell_sl_trailing* (47,7%), incluyendo al modelo MV-80-CNN-LUONG benchmarking con capacidad predictiva en torno a DA 60%, e incluyendo mayoritariamente a todos los modelos univariados que obtuvieron retornos negativos, a pesar de que presentaban altas métricas de dirección.

En cuanto a los mejores *calmar ratio* le corresponde a los modelos MV-58-BILSTM-LUONG (0,38939), MV-532-BILSTM-LUONG-AutoKeras (0,34125), y MV-530-BILSTM-LUONG-AutoKeras (0,33487), y mayoritariamente a modelos con estrategia *one_side_buy_sl_trailing* que abre la posición sólo para compra.

La tabla nro. 31 presenta una vista ordenada por resultado *calmar ratio*, con modelos mayoritariamente con estrategia *one_side_buy_sl_trailing* que abre la posición sólo para compra.

Tabla nro. 32 de vista por Calmar Ratio y estrategias del backtesting

Modelo	Estrategia	Equity Final [\$]	Equity Peak [\$]	Retorno (%)	Buy & Hold Retorno [%]	Return (Ann.) [%]	Volatility (Ann.) [%]	Sharpe Ratio	Sortino Ratio	Calmar Ratio	Max. Drawdown [%]	# Trades	Win Rate [%]	Profit Factor
MV-58-BILSTM-LUONG	<i>one_side_buy_sl_trailing</i>	51.316,94	51.316,94	413,17	382,62	8,35	11,77	0,70948	1,14878	0,38939	-21,44	170	47,06	2,03
MV-532-BILSTM-LUONG-AutoKeras	<i>one_side_buy_sl_trailing</i>	38.379,18	38.379,18	283,79	382,62	6,82	1,05	0,65203	1,04952	0,34125	-19,98	214	54,67	1,76
MV-530-BILSTM-LUONG-AutoKeras	<i>one_side_buy_sl_trailing</i>	38.348,23	38.440,57	283,48	382,62	6,81	11,25	0,60587	0,96878	0,33487	-20,35	172	48,84	1,86
MV-550-BILSTM-BAHDANAU-AutoKeras	<i>one_side_buy_sl_trailing</i>	39.386,45	39.386,45	293,86	382,62	6,95	11,64	0,59754	0,95111	0,30084	-23,11	162	46,30	1,87
MV-532-BILSTM-LUONG-AutoKeras	<i>two_side_sl_tp_reversed</i>	58.304,78	61.288,34	483,05	382,62	9,03	23,82	0,37906	0,70212	0,26005	-34,73	294	54,42	1,59
MV-58-BILSTM-LUONG	<i>two_side_sl_trailing_reversed</i>	42.197,65	42.197,65	321,98	382,62	7,32	12,76	0,57315	0,91043	0,25472	-28,72	228	43,86	1,68

MV-59-BIGRU-LUONG	one_side_buy_sl_trailing	38.160,18	38.160,18	281,60	382,62	6,79	11,36	0,59769	0,92992	0,24420	-27,80	193	49,22	1,80	
MV-532-BILSTM-LUONG-AutoKeras	one_side_buy_sl_tp	52.191,11	52.347,76	421,91	382,62	8,44	14,69	0,57455	0,89023	0,24380	-34,62	146	68,49	2,41	
MV-54-BIGRU-LUONG	one_side_buy_sl_trailing	44.921,71	45.056,26	349,22	382,62	7,65	12,03	0,63547	1,03416	0,24199	-31,59	251	50,20	1,73	
MV-59-BIGRU-LUONG	two_side_sl_tp_reversed	121.086,4	122.346,8	4	1.110,86	382,62	13,01	24,87	0,52306	0,98985	0,24045	-54,10	176	59,09	2,51
Mínimo		38.160,18	38.160,18	281,60	382,62	6,79	1,05	0,3791	0,7021	0,2404	-54,10	146	43,86	1,59	
Máximo		121.086,4	122.346,8	4	1.110,86	382,62	13,01	24,87	0,7095	1,1488	0,3894	-19,98	294	68,49	2,51
Promedio		52429,27	52892,02	424,29	382,62	8,12	13,52	0,5848	0,9575	0,2852	-29,64	200,60	52,22	1,92	
Desviación estándar		25122,09	25586,26	251,22	0,00	1,89	6,76	0,09	0,12	0,05	10,26	46,05	7,30	0,31	

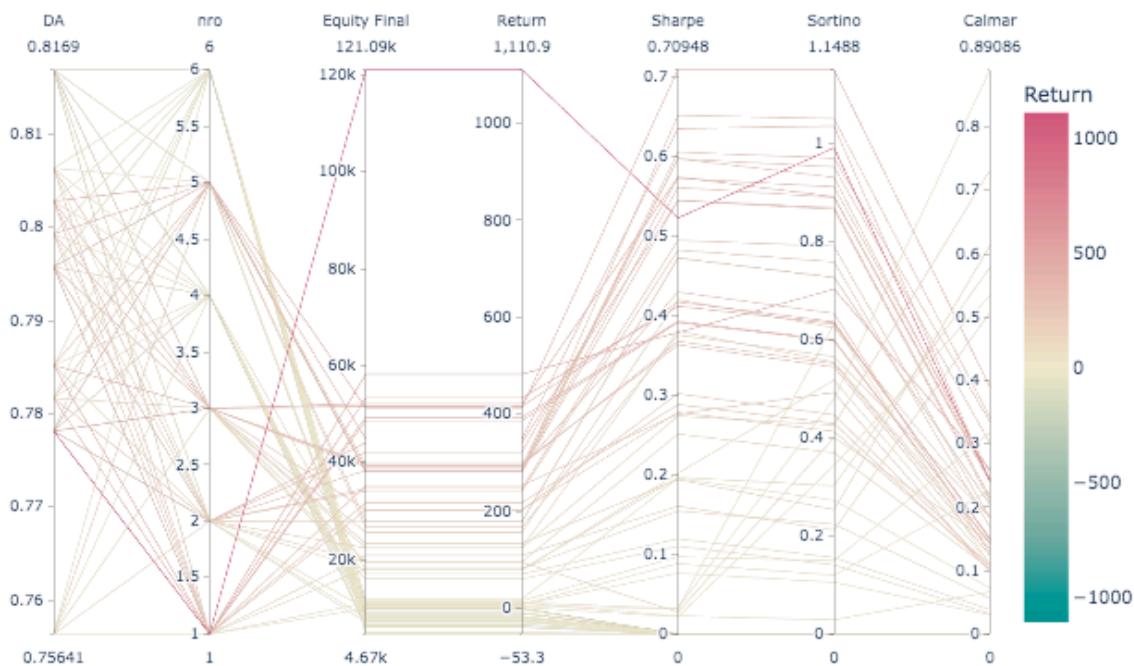
*Filas Mínimo, Máximo, Promedio y Desviación estándar considera el listado de modelos correspondiente a la tabla. * En color amarillo las métricas más destacadas, y en color rojo las métricas no destacadas.

En cuanto al mejor *sharpe ratio* le corresponde a los modelos MV-58-BILSTM-LUONG (0,70948), MV-532-BILSTM-LUONG-AutoKeras (0,65203) y MV-54-BIGRU-LUONG (0,63547) todos con estrategia *one_side_buy_sl_trailing*.

En cuanto al *sortino ratio* le corresponde a los modelos MV-58-BILSTM-LUONG (1,14878), MV-532-BILSTM-LUONG-AutoKeras (1,04952) y MV-54-BIGRU-LUONG (1,03416) con estrategia *one_side_buy_sl_trailing*.

La figura nro. 15 presenta el gráfico de coordenadas paralelas que incorpora la métrica de dirección (DA) junto con el número correspondiente a la estrategia (nro.), el patrimonio (Equity Final), el retorno (Return) y los ratios (Sharpe, Sortino y Calmar), con colores según nivel de retorno (Return) de -100 a 1.111.

Figura nro. 15 de gráfico de coordenadas paralelas incluyendo métrica DA junto con ratios



Capítulo 6: Discusión

La hipótesis de mercado eficiente de Fama plantea que es imposible poder lograr retornos esperados superiores al mercado. El presente trabajo muestra evidencia experimental que existen modelos que logran *directional accuracy* superior al 80% tal como se presentan en la literatura.

Los modelos multivariados con menores métricas de error tienden a tener modelos univariados con métricas de error correlacionadas, por ejemplo, cuando el modelo multivariado MV-53-BILSTM-LUONG destaca, también el modelo UNI-53-BILSTM-LUONG destaca entre los univariados. Análogamente, los modelos series K presentan métricas correlacionadas y con órdenes de magnitud similares.

La evidencia experimental muestra que en general hay un trade-off entre las métricas de error y la métrica de dirección DA. Por otra parte, los modelos que ya presentaban mejores métricas en el indicador DA fueron los que en los modelos con epochs 1.000 mejoraron considerablemente la métrica en este indicador DA, es decir, mientras más entrenamiento en *epochs*, alcanza mejor métrica DA. Y cuando a estos modelos se les aplicó *rolling windows* todas sus métricas de error mejoraron, pero la métrica DA no mejoró, y no superó el umbral de 80%.

En cuanto a las rentabilidades, al hacer la simulación de *backtesting* y estrategias de *trading* sobre los modelos con mejores métricas del indicador DA, al aplicarles *backtesting* todos los modelos univariados presentaron mayoritariamente retornos negativos. En cambio, los modelos multivariados con más altas métricas DA obtuvieron mayoritariamente los más altos retornos. Al parecer, las *features* adicionales hacen más robustos a los modelos multivariados, en estos modelos las estrategias son sólidas para los *traders* y es probable que generen ganancias cuando se implementen en la realidad.

Considerando que el backtesting se realizó con la señal resultante de aplicar los modelos con epochs 1.000, es razonable pensar que hay margen para futuros re-procesos con señales resultantes de aplicar los modelos *rolling windows*. Además, The Vanguard Group presenta durante el año 2024 para el ETF US9229087690 (VTI) un *expense ratio* de 0,03% lo cual es ratificado en Bloomberg como *current management fee*, sin embargo, uno de los supuestos del *backtesting* operó con una comisión más alta de 0.05%, lo cual genera margen para re-procesos futuros.

Capítulo 7: Conclusiones

La principal contribución de este trabajo corresponde a que se encontró evidencia experimental en favor de que existe capacidad predictiva en el mercado bursátil en la dirección del retorno para la clase de activo ETF, inclusive con el período analizado que incluyó el conflicto ruso y el conflicto en Gaza, ambos impactaron los mercados bursátiles.

De acuerdo a los resultados experimentales, hay evidencia de que los modelos de *deep learning* planteados ofrecen distintas ventajas en el manejo de modelos no lineales y la captura de relaciones temporales para instrumentos ETF del mercado bursátil de NYSE. El presente trabajo está de acuerdo con la literatura: los resultados aplicados a datos financieros en [Siami-Namini y Namin \(2018\)](#) muestran que LSTM supera a ARIMA en término de menor error de pronóstico y mayor precisión; y los resultados en [Qiu et al. \(2020\)](#) que utilizan LSTM, demuestran una mejora en las predicciones del precio de las acciones cuando se emplea un mecanismo de atención ([Ghosh et al., 2022](#)).

Los resultados experimentales confirman la literatura en relación con los mecanismos de atención, la cual plantea que la introducción del mecanismo de atención puede mejorar aún más la precisión de la predicción del precio de las acciones ([Zhang et al., 2023](#)). Por otra parte, el mecanismo de atención *Local Soft Attention* no obtuvo métricas destacadas, según la literatura se centra en la salida de una sola unidad (single unit) en un instante, lo que mejora la precisión local, pero inevitablemente pasa por alto las *features* globales esenciales ([Fan et al., 2023](#)).

En el presente trabajo, los mecanismos Bahdanau y Luong logran métricas superiores, más aún Luong con producto punto “dot” sobre la concatenación “concat”.

Con el objetivo de mejorar la precisión de los pronósticos, en este trabajo se propusieron redes ConvNet para extraer *features*, redes recurrentes para procesar datos de secuencia de tiempo y redes híbridas. Los resultados experimentales de los modelos convolucionales CNN e híbridos propuestos CNN-LSTM, en general no superaron el rendimiento de los demás modelos. De acuerdo a la literatura, es debido a que las capas *pooling* en CNN provocan pérdida de información valiosa al ignorar las relaciones parte-todo ([Xi, Bing & Jin, 2017](#)).

Se utilizaron datos de ETF's de 4 índices bursátiles norteamericanos y 1 índice alemán de los principales fondos de inversión extranjeros tales como BlackRock, Vanguard, State Street e Invesco. Los resultados experimentales del presente trabajo mostraron que los modelos con mejores métricas pueden predecir efectivamente estos índices bursátiles, y que los mejores modelos propuestos tienen un cierto grado de generalización.

En el presente trabajo se evaluaron los modelos con diversos indicadores de error, junto con lo anterior, un indicador enfocado en la optimización de la dirección para medir la capacidad predictiva del movimiento del retorno (*directional accuracy*). Todo lo anterior contribuyó a tener una visión amplia para evaluar en su completitud cada uno de los modelos.

En términos de indicadores de error MAE y MSE/RMSE, los modelos ConvNet, LSTM, Bi-direccionales e híbridos superan casi en la totalidad de los casos a los modelos *benchmarks* (MLP, AutoReg, ARIMA y ARIMAX) salvo para MLPK (MLP con *Auto Keras*) que obtuvo altas métricas MAE y MSE.

En términos de rentabilidad expresada mediante *calmar ratio*, los modelos multivariados superaron en el 100% de los casos a los modelos univariados. Son 8 modelos con estrategias ganadoras que superan en rentabilidad a la estrategia *buy-hold*, fueron las siguientes: *two_side_sl_tp_reversed* (62,5%), *one_side_buy_sl_tp* (25%) y *one_side_buy_sl_trailing* (12,5%). El modelo más sofisticado MV-552KS-BILSTM-LUONG-AutoKeras-y-SciKeras se encuentra entre los modelos con estrategias ganadoras, en cambio, el modelo benchmarking MV-80-CNN-LUONG, que obtuvo baja capacidad predictiva en el indicador DA, se encuentra entre los modelos con retornos negativos, al igual que todos los modelos univariados que participaron en el backtesting. Los modelos con retorno negativo corresponden a los modelos univariados y tienen mayoritariamente 81% de estrategias que abren la posición sólo para venta: *one_side_sell_sl_tp* (33,3%) y *one_side_sell_sl_trailing* (47,6%).

Con respecto, al efecto de las nuevas variables de indicadores técnicas, se encontró evidencia en los modelos multivariados que avaló el uso de estas, al realizar corridas en torno train/test 80/20 +/-5%, que se extendió en la vecindad de 90/10, hasta train/test 95/5.

A los modelos con mejores métricas se les aplicó una ventana móvil (modelos *rolling*), los modelos *rolling* lograron métricas de error superiores, sin embargo los modelos *rolling* no superaron las métricas de dirección.

Los resultados muestran que los modelos con mecanismos de atención logran una capacidad predictiva en el orden magnitud de la literatura, es decir, no hay brecha existente entre el trabajo y la literatura. Los modelos Bi-direccionales con mecanismos de atención Bahdanau y Luong para predecir el precio ajustado de cierre (*Adj Close*) del instrumento ETF Vanguard Group VTI US9229087690 obtuvieron capacidad predictiva de dirección que se encuentra en el orden de magnitud presente en la literatura reciente, la cual se presenta a continuación a modo de referencia y comparación.

Qiu y Song (2016) desarrollaron una red neuronal optimizada basada en un algoritmo genético GA para predecir la dirección del precio del día siguiente en el índice del stock market. Se utilizó GA para optimizar los pesos iniciales y el sesgo del modelo. Se generaron dos tipos de conjuntos de datos utilizando varios indicadores técnicos del precio diario del índice Nikkei 225, obteniendo una capacidad predictiva del 60,87% en el primer set y del 81,27% en el segundo set (Yildirim et al., 2021). Hu et al. (2018) introdujeron un algoritmo seno-coseno (ISCA) mejorado para optimizar las ponderaciones y sesgos de Back Propagation Neural Network para predecir las direcciones de los precios de apertura (*Open Price*) de las acciones de los índices S&P 500 y Dow Jones Industrial Average DJIA. Utilizando datos de Google Trends, además de los precios Open, High, Low, Close y el volumen de operaciones, obtuvieron un índice de acierto del 86,81% (86.64% sin *Google Trend*) para el índice S&P 500 y un índice de acierto del 88,98% (88.81% sin *Google Trend*) para el índice DJIA (Yildirim et al., 2021).

Los resultados experimentales para predecir el precio ajustado de cierre *Adj Close* del ETF Vanguard (VTI) del presente trabajo, muestran que los modelos que obtuvieron las más altas métricas DA son modelos univariados y multivariados todos con mecanismos de atención: UNI-55-BILSTM-BAHDANAU (84,295%), UNI-56-BIGRU-BAHDANAU (83,013%), MV-59-BIGRU-LUONG (82,394%), UNI-53-BILSTM-LUONG (82,372%), MV-58-BILSTM-LUONG (82,051%) y MV-54-BIGRU-LUONG (82,042%). La diferencia del presente trabajo con la literatura es el precio objetivo. El precio ajustado de cierre (*Adj Close Price*) es considerado como el verdadero precio de cierre, incluye split, new stock y dividendos, los cuales no son incluidos en el precio de apertura (*Open Price*).

Los resultados de la literatura recopilados por Lawi el año 2022 son los siguientes:

Tabla nro. 33 resultados según indicador (Lawi et al., 2022)

Modelo	Indicador	Resultado	Literatura
ARIMA-LS-SVM	MSE	0,015	(Xiao J, Zhu X, Huang C, Yang X, Wen F, Zhong M., 2020). A new approach for stock price analysis and prediction based on SSA and SVM.
	RMSE	0,108	
KNNC	MAE	4,42E-05	(Khattak AM, Ullah H, Khalid HA, Habib A, Asghar MZ, Kundi FM., 2019). Stock market trend prediction using supervised learning.
	RMSE	4,89E-03	
ARMA-GRACH-NN	RMSE	1,385	(Sun J, Xiao K, Liu C, Zhou W, Xiong H., 2019). Exploiting intra-day patterns for market shock prediction: a machine learning approach.
LSTM	MAE	0,222	(Qian F., Chen X., 2019). Stock prediction based on LSTM under different stability.
	RMSE	0,027	
LSTM	MAPE	0,016	(Jin Z, Yang Y, Liu Y., 2019). Stock closing price prediction based on sentiment analysis and LSTM.
	MAE	2,396	
	RMSE	0,196	

Recientemente en la literatura, la predicción con modelo híbrido CNN-LSTM con MultiHead Attention utilizando un *dataset* de demanda/carga a corto plazo por electricidad (Quansah P., and Tenkorang E. 2023) obtuvo una métrica MAPE 1,9376. La predicción del Chinese Stock Index CSI300 usando un modelo híbrido CNN-Bi-LSTM (CNN de 2-Dimensión) con

mecanismo de atención obtuvo una métrica MAPE 1,023 (Zhang J., et al. 2023). Utilizando puntuaciones de predicción para mercados en caída, el modelo de red neuronal con técnica *gridsearch* predice la reversión de la tendencia ascendente en el mercado de valores KOSDAQ de Corea del Sur, el cual obtuvo métricas MAE 0,039 y MSE 1,521E-03 (Song Yoojeong, 2024). Un novedoso modelo de *deep learning* denominado SDTP, con mejor capacidad de extracción de características de los datos de series temporales y predicción de precios de índice Shanghai Composite Index, China, obtuvo un MAE 21,731, RMSE 31,604 y MAPE 0,732 (Tao et al. 2024). Se realizó una comparación de rendimiento entre los modelos LSTM, GRU, ANN y SVM y se describió un modelo óptimo, así LSTM obtuvo un RMSE de 0,000428 (Sethia et al., 2019). El modelo híbrido Bi-LSTM y GRU aplicado a los precios de apertura (Open Prices) de las empresas pertenecientes al índice NIFTY-50 de la India, obtuvo métricas MAE 0,0028890, MSE 1,80E-05, RMSE 0,0042403 y MAPE 28,058 (Karim et al., 2022). Ahmed propuso un *framework* novedoso que integra Bi-LSTM con mecanismo de atención y el algoritmo XGBoost para predecir el *Close Price* diario del Bitcoin-USD, obtuvo un MAE 84,40, RMSE 106,14 y MAPE 0,0037 (Ahmed et al. 2024).

El presente trabajo obtiene resultados en el orden de magnitud y en algunos casos supera el *state-of-art* de la literatura, en la predicción de precios del ETF Vanguard (VTI) con los siguientes modelos Bi-direccionales:

- UNI-54-BIGRU-LUONG(dot-product) obtuvo un MAE 0,0013302, MSE 2,681E-06, RMSE 0,0014958 y MAPE 0,01188 (1,188%);
- UNI-53-BILSTM-LUONG(dot-product) obtuvo un MAE 0,0013360, MSE 2,619E-06, RMSE 0,0014834 y MAPE 0,01192 (1,192%);
- MV-552-BILSTM-BAHDANAU-AutoKeras obtuvo un MAE 0,0013571, MSE 2,738E-06, RMSE 0,0015163 y MAPE 0,01212 (1,212%).

Cabe notar que en la literatura de *stock price o stock market prediction* se encuentra con frecuencia el uso de MultiHead Attention y Self Attention. Sin embargo, en el presente trabajo, se utilizan de manera novedosa los mecanismos de atención Luong(dot-product) y Bahdanau.

En relación con la simulación de backtesting y trading, recientemente en la literatura se encuentra el modelo de predicción basado en Bi-LSTM con mecanismo de atención, en que agrega la estrategia de tiempo y volumen basada en programación dinámica y método de ponderación de entropía para tomar decisiones comerciales, en su backtesting de simulación, logró un rendimiento *annualized yield* del 170%, el valor de una inversión de \$1.000 se convirtió en \$8.542,3, y obtuvo un retorno del 1089,34% en dos años (Jiashu Lou, Leyi Cui, Ye Li, 2022). De acuerdo a Ma, en su backtesting de simulación con datos de S&P 500, la estrategia de trading de Stockformer logró un

cumulative return del 13,19% y un *annualized return* del 30,80% (Ma et al., 2023). El backtesting de simulación del presente trabajo logró resultados comparables, entre 2003 y 2023 (21 años), el valor de una inversión de \$10.000: con el modelo MV-59-BIGRU-LUONG se convirtió en \$121.086 con un retorno de 1.110,86% y retorno anualizado de 13,01%; con el modelo MV-532-BILSTM-LUONG-AutoKeras se convirtió en \$58.304 con un retorno de 483,05% y retorno anualizado de 9,03%; y con el modelo MV-550-BILSTM-BAHDANAU-AutoKeras se convirtió en \$53.366 con un retorno de 433,66% y retorno anualizado de 8,55%.

Finalmente, se describen las limitaciones del estudio y las sugerencias de trabajos a futuro. Se limitó el análisis de los determinantes de la predictibilidad, así se sugiere analizar en profundidad en futuros trabajos los determinantes del mercado de valores que están relacionados con factores macroeconómicos, como las tasas de interés, la inflación y el crecimiento económico; las características específicas de las empresas holdings como el tamaño medido como capitalización de mercado, el book-to-market ratio (valor contable de una empresa y su valor de mercado), y el momentum (tendencia del precio de las acciones de una empresa durante un período de tiempo); indicadores de sentimiento para medir el estado de ánimo y/o el sentimiento de los inversores y traders, así se sugiere para futuros trabajo el incorporar índice de opciones de compra put-call ratio, el índice VIX y/o la encuesta de sentimiento AAII. El estudio excluyó variables como el riesgo de contraparte, riesgo de liquidez, volatilidad del mercado e incertidumbre regulatoria. Se sugiere explorar estas variables en un futuro trabajo.

El estudio se limitó a la serie temporal de 5 ETFs, 4 de USA y 1 de Alemania, y los sets de datos empleados varían desde el año 1993 al 2023, excluyendo índices que replican acciones de otros mercados de valores relevantes en la economía mundial. El estudio se limitó al dataset, excluyendo la composición de los activos subyacentes del índice bursátil que replican los ETFs, por tal motivo se sugiere investigar a futuro las características y la composición de los índices con el objetivo de generar una mejor predictibilidad.

Se sugiere explorar nuevas redes y nuevas configuraciones para construir arquitecturas híbridas que permitan con otras técnicas de preprocesamiento de los datos de entrada tales como CNN de 2-Dimensión, puesto que el presente trabajo sólo se limitó a considerar CNN de 1-Dimensión.

Con respecto a las cotizaciones de los activos en *trading days*, con precios de apertura y de cierre de la bolsa NYSE, sería interesante probar con una menor frecuencia de tiempo *intraday*, aumentando la frecuencia de las variables de entrada tal como frecuencia por hora, cuartos de hora, minutos y así sucesivamente. Respecto de los *features* de los modelos multivariados, se sugiere

explorar nuevos indicadores técnicos, promedios móviles (moving averages), índice RSI Relative Strength Index, bandas de Bollinger, e indicadores de variables macroeconómicas.

En el trabajo futuro se sugiere enfocarse en el uso de otras técnicas de predicción tal como los modelos: N-BEATS *Neural Basis Expansion Analysis for interpretable Time-Series*, N-HiTS *Neural Hierarchical Interpolation for Time Series* y PatchTST *Patch Time Series Transformer*.

Se sugiere procesar los modelos con más recursos, intensivamente en modo alta capacidad de procesamiento TPU (10 veces más rápida y más “energía eficiente” que las *top-of-the-line* GPU) y en modo alta capacidad de RAM sobre *Google Colab Pro+* para aplicar *AutoKeras* y *SciKeras* a un mayor número de modelos, con epochs más altos, y mayor número de hiper-parámetros.

De manera suplementaria, se sugiere incorporar e integrar información heterogénea no estructurada de múltiples fuentes, tales como noticias financieras, de actualidad y sentimientos de los inversores, con la finalidad de mejorar la capacidad de predicción, tal como el estudio que contrasta la eficiencia de los modelos de predicción del precio de acciones utilizando varios tipos de modelos LSTM con la ayuda del *Sentiment Analysis* ([Sangwan et al. 2023](#)).

Finalmente, se recomienda testear el modelo en otro periodo de *testing*, ya que el dataset abarca hasta el 22 de noviembre 2023, que incluye el reciente conflicto en Gaza y el conflicto ruso.

Capítulo 8: Bibliografía

1. Ahmed S., Riaz U., Hussain S. (2024). A Novel Decision Ensemble Framework: Customized Attention-BiLSTM and XGBoost for Speculative Stock Price Forecasting. ArXiv, abs/2401.11621. <https://doi.org/10.48550/arXiv.2401.11621>
2. Alam J., Rabbi J., Ahamed S. (2023). Bi-GRU Forecasting Pressure Of Ventilator Using A Hybrid Deep Learning Model Built With Bi-LSTM and Bi-GRU To Simulate Ventilation. Published in the International Conference on Recent Progresses in Science, Engineering and Technology (ICRPSET-2022). ArXiv, abs/2302.09691. <https://doi.org/10.48550/arXiv.2302.09691>
3. Aldosari M., Miller J., Habib N., Budak I., Rana S., Saeed F., Liu N. (2024). A Survey of Deep Learning and Foundation Models for Time Series Forecasting. ArXiv, abs/2401.13912. <https://arxiv.org/abs/2401.13912v1>
4. Alzazah F. S., Cheng X. (2020). Recent advances in stock market prediction using text mining: A survey. E-Business - Higher Education and Intelligence Applications, 1-34. <https://doi.org/10.5772/intechopen.92253>
5. Bahdanau D., Cho K., Bengio Y., (2016). Neural Machine Translation by Jointly Learning to Align and Translate. CoRR, abs/1409.0473. <https://doi.org/10.48550/arXiv.1409.0473>
6. Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. C. (2022). Predicting stock market index using LSTM. Machine Learning with Applications, 9(February), 100320. <https://doi.org/10.1016/j.mlwa.2022.100320>
7. Bustos O., Pomares-Quimbaya A. (2020). Stock market movement forecast: A systematic review. Expert Systems with Applications, 156, 113464. <https://doi.org/10.1016/j.eswa.2020.113464>
8. Cho, K., Van Merriënboer, B., Bahdanau, D, Bougares, F., Schwenk, H., Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. Conference on Empirical Methods in Natural Language Processing. ArXiv preprint arXiv:1406.1078. <https://doi.org/10.48550/arXiv.1406.1078>
9. Dhaliwal A., Polatidis N., Pimenidis E. (2022). A Novel LSTM-CNN Architecture to Forecast Stock Prices. International Conference on Artificial Neural Networks. (pp. 466-477). Cham: Springer International Publishing. https://doi.org/10.1007/978-3-031-15919-0_39

10. Fan G., He Z., Li J. (2023). Structural dynamic response reconstruction using Self-Attention enhanced generative adversarial networks. *Engineering Structures*, 276, 115334. <http://doi.org/10.1016/j.engstruct.2022.115334>
11. Fei G., Jiangshe Z., Chunxia Z., Shuang X., Cong M., (2022). Long Short-Term Memory Networks with Multiple Variables for Stock Market Prediction. *Neural Processing Letters*, 55(4), 4211-4229. <https://doi.org/10.1007/s11063-022-11037-8>
12. Ghosh P., Neufeld A., Sahoo J. (2020). Forecasting directional movements of stock prices for intraday trading using LSTM and random forests. *Finance Research Letters*, 46, 102280. <https://doi.org/10.1016/j.frl.2021.102280>
13. Graves A., Schmidhuber J. (2005). Framewise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610. <https://doi.org/10.1016/j.neunet.2005.06.042>
14. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. <http://dx.doi.org/10.1162/neco.1997.9.8.1735>
15. Huang X., Wu C., Du X., Wang H., Ye Ming. (2024). A novel stock trading utilizing long short term memory prediction and evolutionary operating-weights strategy. *Expert Systems with Applications*, 246, 123146. <https://doi.org/10.1016/j.eswa.2024.123146>
16. Htun H., Biehl M., Petkov N. (2023). Survey of feature selection and extraction techniques for stock market prediction. *Financial Innovation*, 9(1), 26. <https://doi.org/10.1186/s40854-022-00441-7>
17. Inzirillo H., Villelongue L. (2023). An Attention Free Long Short-Term Memory for Time Series Forecasting. *ArXiv*, abs/2209.09548. <https://doi.org/10.48550/arXiv.2209.09548>
18. Jiashu L., Cui L., Li Ye. (2022). Bi-LSTM Price Prediction based on Attention Mechanism. *ArXiv*, abs/2212.03443. <https://doi.org/10.48550/arXiv.2212.03443>
19. Jin H., Song Q., Hu X. (2019). Auto-Keras: An Efficient Neural Architecture Search System. In Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining (pp. 1946-1956). <https://doi.org/10.1145/3292500.3330648>
20. Jin Z., Yang Y., Liu Y.. (2019). Stock closing price prediction based on sentiment analysis and LSTM. *Neural Computing and Applications*, 32, 9713-9729. <https://doi.org/10.1007/s00521-019-04504-2>
21. Kamalov F. (2020). Forecasting significant stock price changes using neural networks. *Neural Computing and Applications*, 32(23), 17655-17667.

<https://doi.org/10.48550/arXiv.1912.08791>

22. Karim M., Foysal M., Das S. (2022). Stock Price Prediction Using Bi-LSTM and GRU-Based Hybrid Deep Learning Approach. In Proceedings of Third Doctoral Symposium on Computational Intelligence: DoSCI 2022 (pp. 701-711). Singapore: Springer Nature Singapore. https://doi.org/10.1007/978-981-19-3148-2_60
23. Khattak AM., Ullah H., Khalid H., Habib A., Asghar M., Kundi F. (2019). Stock Market Trend Prediction using Supervised Learning. In Proceedings of the 10th International Symposium on Information and Communication Technology (pp. 85-91). <https://doi.org/10.1145/3368926.3369680>
24. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197, 116659. <https://doi.org/10.1016/j.eswa.2022.116659>
25. Lawi, A., Mesra, H., & Amir, S. (2022). Implementation of Long Short-Term Memory and Gated Recurrent Units on grouped time-series data to predict stock prices accurately. *Journal of Big Data*, 9(1), 89. <https://doi.org/10.1186/s40537-022-00597-0>
26. Liu H. and Long Z. (2020). An improved deep learning model for predicting stock market price time-series. *Digital Signal Processing*, 102, 102741. <https://doi.org/10.1016/j.dsp.2020.102741>
27. Lu W., Li J., Li Y., Sun A., Wang J. (2020). A CNN-LSTM-Based Model to Forecast Stock Prices. *Complexity*, 2020(1), 6622927. <https://doi.org/10.1155/2020/6622927>
28. Luong M-T., Pham H., Manning C. D. (2015). Effective Approaches to Attention-based Neural Machine Translation. *ArXiv*, abs/1508.04025. <https://doi.org/10.48550/arXiv.1508.04025>
29. Ma B., Wang Y., Lu Y., Hu T., Xu J., Houlihan P. (2023). StockFormer: A Swing trading Strategy Based on STL Decomposition and Self-Attention Networks. *ArXiv*, abs/2401.06139. <https://doi.org/10.48550/arXiv.2401.06139>
30. Mahmoud A. and Mohammed A. (2021). A survey on deep learning for time-series forecasting. *Machine learning and big data analytics paradigms: analysis, applications and challenges*, 365-392. https://doi.org/10.1007/978-3-030-59338-4_19
31. Modi P., Arshi K., Kunz P., Zoubir A. (2023). A Data-driven Deep Learning Approach for Bitcoin Price Forecasting In 2023 24th International Conference on Digital Signal Processing (DSP) (pp. 1-4). IEEE.. <https://doi.org/10.48550/arXiv.2311.06280>

32. Mohanty S., Vijay A., Gopakumar N. (2022). StockBot: Using LSTMs to Predict Stock Prices. ArXiv preprint arXiv:2207.06605. <https://doi.org/10.48550/arXiv.2207.06605>
33. Nabipour M., Nayyeri P., Jabani H., Mosavi A., Salwana E., Shahab S. (2020). Deep learning for stock market prediction. *Entropy*, 22(8), 840. <https://doi.org/10.48550/arXiv.2004.01497>
34. Nematirad R., Ahmadisharaf A., Lashgari A. (2023). Forecasting the Performance of US Stock Market Indices During COVID-19: RF vs LSTM. ArXiv preprint arXiv:2306.03620. <https://doi.org/10.48550/arXiv.2306.03620>
35. Pardeshi K. Sukpal S. G., Ahmed M. A. (2023). Stock Market Price Prediction: A Hybrid LSTM and Sequential Self-Attention based Approach. ArXiv, abs/2308.04419. <https://doi.org/10.48550/arXiv.2308.04419>
36. Patel, J., Shah S., Thakkar P., Kotecha K. (2015). Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. *Expert systems with applications*, 42(1), 259-268. <https://doi.org/10.1016/j.eswa.2014.07.040>
37. Peng, Z. Y., & Guo, P. C. (2022). A Data Organization Method for LSTM and Transformer When Predicting Chinese Banking Stock Prices. *Discrete Dynamics in Nature and Society*, 2022(1), 7119678. <https://doi.org/10.1155/2022/7119678>
38. Qian F., Chen X. (2019). Stock prediction based on LSTM under different stability. In 2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA) (pp. 483-486). IEEE. <https://doi.org/10.1109/ICCCBDA.2019.8725709>
39. Quansah P., and Tenkorang E. (2023). Short-Term Load Forecasting Using a Particle-Swarm Optimized Multi-Head Attention-Augmented CNN-LSTM Network. ArXiv, abs/2309.03694. <https://doi.org/10.48550/arXiv.2309.03694>
40. Rana R., Epps J., Jurdak R., Li X., Goecke R., Brereton M., Soar J. (2016). Gated Recurrent Unit (GRU) for Emotion Classification from Noisy Speech. ArXiv, abs/1612.07778. <http://arxiv.org/abs/1612.07778>
41. Xiao R., Feng Y., Yan L., Ma Y. (2022). Predict stock prices with ARIMA and LSTM. ArXiv, abs/2209.02407. <https://doi.org/10.48550/arXiv.2209.02407>
42. Sethia A., Raut P. (2019). Application of LSTM, GRU and ICA for Stock Price Prediction. In Information and Communication Technology for Intelligent Systems: Proceedings of

- ICTIS 2018, Volume 2 (pp. 479-487). Springer Singapore.
https://doi.org/10.1007/978-981-13-1747-7_46.
43. Shi J., Jain M., Narasimhan G. (2022). Time Series Forecasting Using Various Deep Learning Models. ArXiv, abs/2204.11115. <https://doi.org/10.48550/arXiv.2204.11115>
44. Shen Yanhui. (2023). American Option Pricing using Self-Attention GRU and Shapley Value Interpretation. ArXiv, abs/2310.12500. <https://doi.org/10.48550/arXiv.2310.12500>
45. Song Yoojeong. (2024). Enhancing Stock Market Trend Reversal Prediction Using Feature-Enriched Neural Networks. Heliyon, 10(2).
<https://doi.org/10.1016/j.heliyon.2024.e24136>.
46. Sun J., Xiao K., Liu C., Zhou W., Xiong H. (2019). Exploiting intra-day patterns for market shock prediction: a machine learning approach. Expert Systems with Applications, 127, 272-281. <https://doi.org/10.1016/j.eswa.2019.03.006>
47. Tao, Zicheng & Wu, Wei & Wang, Jianxin. (2023). Series decomposition Transformer with period-correlation for stock market index prediction. Expert Systems with Applications, 237, 121424. <https://doi.org/10.1016/j.eswa.2023.121424>
48. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I. (2017). Attention is all you Need. Advances in neural information processing systems, 30. <https://doi.org/10.48550/arXiv.1706.03762>
49. Widiputra H., Mailangkay A., Gautama E. (2021). Multivariate CNN-LSTM Model for Multiple Parallel Financial Time-Series Prediction. Complexity, 2021(1), 9903518. <https://doi.org/10.1155/2021/9903518>
50. Xiao J., Zhu X., Huang C., Yang X., Wen F., Zhong M. (2018). A New Approach for Stock Price Analysis and Prediction Based on SSA and SVM. International Journal of Information Technology & Decision Making, 18(01), 287-310. <https://doi.org/10.1142/S021962201841002X>
51. Yıldırım D., Toroslu I., Fiore U. (2021). Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators. Financial Innovation, 7, 1-36. <https://doi.org/10.1186/s40854-020-00220-2>.
52. Yu P. and Yan X. (2020). Stock price prediction based on deep neural networks. Neural Computing and Applications, 32(6), 1609-1628. <https://doi.org/10.1007/s00521-019-04212-x>

53. Zhang J., Ye L., Lai Y. (2023). Stock Price Prediction Using CNN-BiLSTM-Attention Model. *Mathematics*, 11(9), 1985. <https://doi.org/10.3390/math11091985>
54. Zhuangwei S., Yang H., Guangliang M., Jian W. (2023) Attention-based CNN-LSTM and XGBoost hybrid model for stock prediction. *ArXiv*, abs/2204.02623. <https://doi.org/10.48550/arXiv.2204.02623>

Anexo.

Anexo nro. 1.

Se presentan las tablas de resultados de testing de las métricas de los modelos tradicionales univariados AutoReg y ARIMA con parámetros train/test 80/20, epochs 40, batch size 32, para predicción de retornos de 5 instrumentos ETF: State Street SPDR US78462F1030, BlackRock iShares USA US4642872000, BlackRock iShares Germany US4642868065, Vanguard Group US9229087690 e Invesco IE00B3YCGJ38.

Tabla nro. 34 de Resultados de testing, métricas de modelos AR y ARIMA para 5 instrumentos ETF

FONDO DE INVERSIÓN	ETF	Código	MAE	MSE	RMSE	DA
INVESCO	IE00B3YCGJ38	AR	0,00657793	9,49E-05	0,0097406	57,335%
INVESCO	IE00B3YCGJ38	ARIMA	0,01024496	1,55E-04	0,0124428	57,335%
iSHARES GERMANY	US4642868065	AR	0,010946	2,44E-04	0,0156302	49,202%
iSHARES GERMANY	US4642868065	ARIMA	0,0110185	2,45E-04	0,0156559	31,884%
iSHARES USA	US4642872000	ARIMA	0,0092604	1,69E-04	0,012989	52,841%
iSHARES USA	US4642872000	AR	0,0080861	1,54E-04	0,012392	52,841%
SPDR	US78462F1030	AR	0,00780501	1,37E-04	0,01172238	54,715%
SPDR	US78462F1030	ARIMA	0,00934914	1,60E-04	0,01263275	54,651%
VANGUARD	US9229087690	AR	0,00848900	1,79E-04	0,01336179	56,349%
VANGUARD	US9229087690	ARIMA	0,00937403	2,00E-04	0,01414727	55,979%
Mínimo			0,00657793	9,49E-05	0,0097406	31,88%
Máximo			0,0110185	2,45E-04	0,0156559	57,34%
Promedio			0,009078563	1,66E-04	0,012773962	52,31%
Desviación estándar			0,001426792	4,60E-05	0,001751540	0,07594

Se presentan las tablas de resultados de las métricas de los modelos *deep learning univariados* y *multivariados* con parámetros train/test 90/10, epochs 40, batch size 32, para predicción de retornos de los 5 instrumentos ETF.

- **ETF State Street SPDR US78462F1030:** modelos univariados (tabla nro. 35) y multivariados (tabla nro. 40)
- **BlackRock iShares USA US4642872000:** modelos univariados (tabla nro. 36) y multivariados (tabla nro. 41)
- **BlackRock iShares Germany US4642868065:** modelos univariados (tabla nro. 37) y multivariados (tabla nro. 42)
- **Vanguard Group US9229087690:** modelos univariados (tabla nro. 38) y multivariados (tabla nro. 43)
- **Invesco IE00B3YCGJ38:** modelos univariados (tabla nro. 39) y multivariados (tabla nro. 44)

Tabla nro. 35 de Resultados de testing, métricas de Modelos Univariados del ETF SPDR - US78462F1030

ETF-SPDR	Código	MAE	MSE	RMSE	DA	MDAPE %
US78462F1030	UNI-10-Stacked LSTM	0,00234435	9,58E-06	0,00309571	76,641%	25,15483665
US78462F1030	UNI-20-Stacked LSTM	0,00234816	9,60E-06	0,00309903	76,834%	25,24008512
US78462F1030	UNI-30-CNN	0,00246399	1,06E-05	0,00325092	75,483%	26,45466478
US78462F1030	UNI-40-CNN	0,00234587	9,59E-06	0,00309741	76,448%	25,18934778
US78462F1030	UNI-51-BIGRU	0,00236487	9,61E-06	0,00310014	76,448%	25,61662695
US78462F1030	UNI-52-BILSTM	0,00235305	9,58E-06	0,00309565	77,027%	25,3727032
US78462F1030	UNI-53-BILSTM-LUONG	0,00232819	9,29E-06	0,00304764	77,606%	25,28179897
US78462F1030	UNI-54-BIGRU-LUONG	0,00233471	9,33E-06	0,00305430	78,378%	25,3422065
US78462F1030	UNI-55-BILSTM-BAHDANAU	0,00235096	9,26E-06	0,00304297	77,027%	25,96418315
US78462F1030	UNI-56-BIGRU-BAHDANAU	0,00232455	9,12E-06	0,00302030	77,413%	25,43069952
US78462F1030	UNI-57-BILSTM-MULTIHEAD	0,00235660	9,60E-06	0,00309815	76,641%	25,42029465
US78462F1030	UNI-60-CNN-LSTM-LUONG	0,00234414	9,58E-06	0,00309565	76,448%	25,14209272
US78462F1030	UNI-70-LSTM-LUONG	0,00235642	9,62E-06	0,00310239	75,869%	25,44045526
US78462F1030	UNI-71-LSTM-LUONG	0,00234559	9,58E-06	0,00309521	76,641%	25,11155246
US78462F1030	UNI-72-LSTM-LUONG	0,00235021	9,59E-06	0,00309620	76,641%	25,36785449
US78462F1030	UNI-73-LSTM-BAHDANAU	0,00234232	9,56E-06	0,00309118	76,641%	25,11908457
US78462F1030	UNI-74-LSTM-LOCAL SOFT	0,00235154	9,53E-06	0,00308740	76,641%	25,40274552
US78462F1030	UNI-75-LSTM-MULTIHEAD	0,00237836	9,77E-06	0,00312534	75,676%	25,80517004
US78462F1030	UNI-80-CNN-LUONG	0,00243848	1,04E-05	0,00322004	76,062%	26,05579559
Mínimo		0,00232455	9,12E-06	0,0030203	75,48%	25,11155246
Máximo		0,00246399	1,06E-05	0,00325092	78,38%	26,45466478
Promedio		0,002359072	9,62E-06	0,003100823	76,66%	25,46906305
Desviación estándar		0,000034884	0,000000348	0,000054056	0,006744108	0,362

Tabla nro. 36 de Resultados de testing, métricas de Modelos Univariados del ETF iShares USA - US4642872000

ETF-iSHARES	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
US4642872000	UNI-10-Stacked LSTM	0,0196291	6,71E-06	0,002591	78,38%	145,59785	23,207
US4642872000	UNI-20-Stacked LSTM	0,0198354	6,76E-06	0,002601	78,08%	147,12841	23,665
US4642872000	UNI-30-CNN	0,0196291	6,71E-06	0,002591	78,38%	145,59785	23,207
US4642872000	UNI-40-CNN	0,0195498	6,71E-06	0,002590	78,98%	145,00981	22,965
US4642872000	UNI-51-BIGRU	0,0207876	7,10E-06	0,002664	75,98%	154,19144	25,392
US4642872000	UNI-52-BILSTM	0,0204644	6,97E-06	0,002641	76,28%	151,79392	24,841
US4642872000	UNI-53-BILSTM-LUONG	0,0203257	6,96E-06	0,002639	75,98%	150,76530	24,432
US4642872000	UNI-54-BIGRU-LUONG	0,0198373	6,67E-06	0,002583	78,68%	147,14219	23,665
US4642872000	UNI-55-BILSTM-BAHDANAU	0,0200256	6,86E-06	0,002619	76,58%	148,53934	23,932
US4642872000	UNI-56-BIGRU-BAHDANAU	0,0211677	7,69E-06	0,002773	75,98%	157,01066	25,291
US4642872000	UNI-57-BILSTM-MULTIHEAD	0,0201723	6,87E-06	0,002621	76,58%	149,62735	24,306
US4642872000	UNI-60-CNN-LSTM-LUONG	0,0195291	6,71E-06	0,002591	78,38%	144,85663	22,915
US4642872000	UNI-70-LSTM-LUONG	0,0019526	6,78E-06	0,002603	78,38%	144,82925	22,698
US4642872000	UNI-71-LSTM-LUONG	0,0019613	6,70E-06	0,002589	78,38%	145,48112	23,192
US4642872000	UNI-72-LSTM-LUONG	0,0019612	6,70E-06	0,002588	78,38%	145,47392	23,196
US4642872000	UNI-73-LSTM-BAHDANAU	0,0019716	6,72E-06	0,002593	78,38%	146,24185	23,433
US4642872000	UNI-74-LSTM-LOCAL SOFT	0,0019454	6,630E-06	0,002575	78,98%	144,29777	22,834
US4642872000	UNI-75-LSTM-MULTIHEAD	0,0019569	6,81E-06	0,002610	79,28%	145,14986	22,707
US4642872000	UNI-80-CNN-LUONG	0,0020822	7,43E-06	0,002726	75,38%	154,44908	24,796
Mínimo		0,0019454	6,63E-06	0,002575	75,38%	144,29777	22,698
Máximo		0,0211677	7,69E-06	0,002773	79,28%	157,01066	25,392
Promedio		0,0134097	6,87E-06	0,0026204	77,65%	148,0622947	23,719
Desviación estándar		0,00898	2,75E-07	0,00005145	1,27%	3,841	0,876

Tabla nro. 37 de Resultados de testing, métricas de Modelos Univariados del ETF iShares Germany - US4642868065

ETF-GERMANY	Código	MAE	MSE	RMSE	DA	MAPE %
US4642868065	UNI-10-Stacked LSTM	0,0038139	2,683E-05	0,0051794	75,12%	31,86987
US4642868065	UNI-20-Stacked LSTM	0,0038055	2,674E-05	0,0051714	75,35%	31,74590
US4642868065	UNI-30-CNN	0,0042769	3,259E-05	0,0057092	72,35%	36,81861
US4642868065	UNI-40-CNN	0,0039852	2,885E-05	0,0053715	74,65%	33,45209
US4642868065	UNI-51-BIGRU	0,0038125	2,689E-05	0,0051858	75,58%	31,73374
US4642868065	UNI-52-BILSTM	0,0038222	2,701E-05	0,0051973	75,58%	31,83031
US4642868065	UNI-53-BILSTM-LUONG	0,0037166	2,519E-05	0,0050194	77,19%	31,07280
US4642868065	UNI-54-BIGRU-LUONG	0,0037536	2,601E-05	0,0051004	77,42%	31,33062
US4642868065	UNI-55-BILSTM-BAHDANAU	0,0037250	2,561E-05	0,0050602	76,04%	31,02111
US4642868065	UNI-56-BIGRU-BAHDANAU	0,0037612	2,619E-05	0,0051172	77,65%	31,23714
US4642868065	UNI-57-BILSTM-MULTIHEAD	0,0038429	2,723E-05	0,0052181	74,19%	32,10423
US4642868065	UNI-60-CNN-LSTM-LUONG	0,0038125	2,681E-05	0,0051783	74,88%	31,84658

US4642868065	UNI-70-LSTM-LUONG	0,0038085	2,677E-05	0,0051741	75,12%	31,76243
US4642868065	UNI-71-LSTM-LUONG	0,0038109	2,680E-05	0,0051767	75,58%	31,79301
US4642868065	UNI-72-LSTM-LUONG	0,0038558	2,696E-05	0,0051928	76,27%	32,60450
US4642868065	UNI-73-LSTM-BAHDANAU	0,0038042	2,666E-05	0,0051629	76,73%	31,73066
US4642868065	UNI-74-LSTM-LOCAL SOFT	0,0038210	2,692E-05	0,0051885	75,12%	31,89056
US4642868065	UNI-75-LSTM-MULTIHEAD	0,0038746	2,749E-05	0,0052431	74,42%	32,47656
US4642868065	UNI-80-CNN-LUONG	0,0043470	3,324E-05	0,0057655	70,51%	37,45092
Mínimo		0,0037612	2,62E-05	0,0051172	70,51%	31,23714
Máximo		0,004347	3,32E-05	0,0057655	76,73%	37,45092
Promedio		0,00387386	2,75E-05	0,00524172	75,05%	32,489659
Desviación estándar		0,000169144	2,04E-06	0,000186985	0,01919	1,785

Tabla nro. 38 de Resultados de testing, métricas de Modelos Univariados del ETF Vanguard - US9229087690

ETF-VANGUARD	Código	MAE	MSE	RMSE	DA	MDAPE %
US9229087690	UNI-10-Stacked LSTM	0,001909340	6,510E-06	0,002552320	76,027%	21,76685261
US9229087690	UNI-20-Stacked LSTM	0,001928490	6,560E-06	0,002562060	74,658%	22,11255632
US9229087690	UNI-30-CNN	0,001909340	6,510E-06	0,002552320	76,027%	21,76685261
US9229087690	UNI-40-CNN	0,001910480	6,510E-06	0,002552110	76,484%	21,78661609
US9229087690	UNI-51-BIGRU	0,001939180	6,590E-06	0,002567300	75,000%	22,33527083
US9229087690	UNI-52-BILSTM	0,001931560	6,550E-06	0,002558950	74,886%	22,24941083
US9229087690	UNI-53-BILSTM-LUONG	0,001939590	6,530E-06	0,002555700	75,000%	22,51856631
US9229087690	UNI-54-BIGRU-LUONG	0,001913820	6,490E-06	0,002546920	75,228%	21,9452875
US9229087690	UNI-55-BILSTM-BAHDANAU	0,001910090	6,420E-06	0,002533660	76,142%	21,96766628
US9229087690	UNI-56-BIGRU-BAHDANAU	0,001912760	6,490E-06	0,002547880	75,913%	21,87966637
US9229087690	UNI-57-BILSTM-MULTIHEAD	0,001927890	6,580E-06	0,002566430	75,571%	22,14075479
US9229087690	UNI-60-CNN-LSTM-LUONG	0,001914570	6,520E-06	0,002553520	76,484%	21,85943225
US9229087690	UNI-70-LSTM-LUONG	0,001916680	6,520E-06	0,002553370	75,799%	21,91622786
US9229087690	UNI-71-LSTM-LUONG	0,001911040	6,500E-06	0,002550260	76,598%	21,8193205
US9229087690	UNI-72-LSTM-LUONG	0,001909400	6,530E-06	0,002554880	75,913%	21,76153724
US9229087690	UNI-73-LSTM-BAHDANAU	0,001907020	6,500E-06	0,002549860	76,027%	21,73996981
US9229087690	UNI-74-LSTM-LOCAL SOFT	0,001907050	6,470E-06	0,002544110	75,685%	21,79823712
US9229087690	UNI-75-LSTM-MULTIHEAD	0,001910530	6,510E-06	0,002552120	76,256%	21,78965676
US9229087690	UNI-80-CNN-LUONG	0,003246790	2,125E-05	0,004609430	65,297%	35,39663754
Mínimo		0,00190702	6,42E-06	0,00253366	65,30%	21,73996981
Máximo		0,00324679	2,13E-05	0,00460943	76,60%	35,39663754
Promedio		0,001987137895	7,29E-06	0,0026608	75,21%	22,66055366
Desviación estándar		0,000305224	0,000003381	0,000471935	0,024675107	3,09

Tabla nro. 39 de Resultados de testing, métricas de Modelos Univariados del ETF Invesco - IE00B3YCGJ38

ETF - INVESCO	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
IE00B3YCGJ38	UNI-10-Stacked LSTM	0,00109716	2,060E-06	0,00143554	75,6410%	93,024739	19,97068394
IE00B3YCGJ38	UNI-20-Stacked LSTM	0,00109716	2,060E-06	0,0014355	75,6410%	93,02474	19,97068
IE00B3YCGJ38	UNI-30-CNN	0,00109716	2,060E-06	0,00143554	75,6410%	93,024739	19,97068394
IE00B3YCGJ38	UNI-40-CNN	0,00104492	1,920E-06	0,00138523	76,9231%	88,59562286	18,75549473
IE00B3YCGJ38	UNI-51-BIGRU	0,00103430	1,920E-06	0,00138465	73,0769%	87,69521756	18,33500766
IE00B3YCGJ38	UNI-52-BILSTM	0,00112450	2,150E-06	0,00146539	70,5128%	95,34268416	20,77548081
IE00B3YCGJ38	UNI-53-BILSTM-LUONG	0,00107765	1,940E-06	0,00139191	71,7949%	91,37021394	19,6319491
IE00B3YCGJ38	UNI-54-BIGRU-LUONG	0,00102906	1,890E-06	0,00137646	71,7949%	87,25055538	18,01694816
IE00B3YCGJ38	UNI-55-BILSTM-BAHDANAU	0,00103914	1,900E-06	0,00137958	74,3590%	88,10529026	18,27376963
IE00B3YCGJ38	UNI-56-BIGRU-BAHDANAU	0,00106184	1,920E-06	0,00138695	69,2308%	90,02977425	19,06647104
IE00B3YCGJ38	UNI-57-BILSTM-MULTIHEAD	0,00107393	1,980E-06	0,00140703	69,2308%	91,05478101	19,73316622
IE00B3YCGJ38	UNI-60-CNN-LSTM-LUONG	0,00108117	2,010E-06	0,00141896	74,3590%	91,66868077	19,71051114
IE00B3YCGJ38	UNI-70-LSTM-LUONG	0,00108519	2,030E-06	0,00142532	76,9231%	92,01010065	19,71498491
IE00B3YCGJ38	UNI-71-LSTM-LUONG	0,00102826	1,870E-06	0,00136926	73,0769%	87,18319518	18,20892161
IE00B3YCGJ38	UNI-72-LSTM-LUONG	0,0010964	2,060E-06	0,0014359	75,6410%	92,96052037	19,96167699
IE00B3YCGJ38	UNI-73-LSTM-BAHDANAU	0,00106764	1,980E-06	0,00140855	76,9231%	90,52177609	19,25849619
IE00B3YCGJ38	UNI-74-LSTM-LOCAL SOFT	0,00103655	1,900E-06	0,00137921	76,9231%	87,88545103	18,46126735
IE00B3YCGJ38	UNI-75-LSTM-MULTIHEAD	0,00104093	1,910E-06	0,0013814	76,9231%	88,25720904	18,67441285
IE00B3YCGJ38	UNI-80-CNN-LUONG	0,00182885	4,820E-06	0,00219508	58,9744%	155,0624349	35,78430108
Mínimo		0,00102826	1,87E-06	0,00136926	58,97%	87,18319518	18,01694816
Máximo		0,00182885	4,82E-06	0,00219508	76,92%	155,0624349	35,78430108
Promedio		0,001107463	2,13E-06	0,0014472347	73,35%	93,89830134	20,11973197
Desviación estándar		0,000176982	0,000000657	0,000183124	0,043492972	15,005745385	3,871

Tabla nro. 40 de Resultados de testing, métricas de Modelos Multivariados del ETF SPDR - US78462F1030

ETF-SPDR	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
US78462F1030	MV-1-Stacked LSTM	0,02055541	4,33E-04	0,02080022	49,614%	18,86900633	18,71560289
US78462F1030	MV-2-Stacked LSTM	0,00237456	9,83E-06	0,00313486	76,448%	1,708948271	2,17060622
US78462F1030	MV-31-CNN	0,00261597	1,20E-05	0,00346923	73,552%	1,849993109	2,38861425
US78462F1030	MV-32-CNN	0,00250729	1,10E-05	0,00331374	75,097%	1,763885285	2,29059722
US78462F1030	MV-33-CNN-LSTM	0,00238635	9,89E-06	0,00314472	76,062%	1,7503909	2,17759008
US78462F1030	MV-40-CNN	0,00237533	9,84E-06	0,00313631	76,448%	1,712500034	2,17042152
US78462F1030	MV-41-CNN-LSTM	0,00237368	9,83E-06	0,00313454	76,641%	1,67819696	2,17071718
US78462F1030	MV-51-BIGRU	0,00241246	9,99E-06	0,00316030	76,255%	1,777253161	2,21243421
US78462F1030	MV-52-BILSTM	0,00239447	9,88E-06	0,00314325	76,834%	1,729025129	2,19426142
US78462F1030	MV-53-BILSTM-LUONG	0,00239971	9,52E-06	0,00308469	77,413%	1,751581244	2,19673647
US78462F1030	MV-54-BIGRU-LUONG	0,00234687	9,33E-06	0,00305422	77,799%	1,724844609	2,14470626
US78462F1030	MV-55-BILSTM-BAHDANAU	0,00236571	9,46E-06	0,00307494	77,027%	1,743223979	2,16550874
US78462F1030	MV-56-BIGRU-BAHDANAU	0,00239409	9,66E-06	0,00310785	75,869%	1,793706874	2,18347068
US78462F1030	MV-57-BILSTM-MULTIHEAD	0,00238688	9,83E-06	0,00313528	76,641%	1,738177344	2,18350277
US78462F1030	MV-60-CNN-LSTM-LUONG	0,00237520	9,84E-06	0,00313617	76,255%	1,716610291	2,17039208
US78462F1030	MV-70-STACK-LSTM-LUONG	0,00238929	9,90E-06	0,00314588	75,483%	1,769980978	2,17939776
US78462F1030	MV-71-STACK-LSTM-LUONG	0,00237520	9,82E-06	0,00313346	76,834%	1,711632815	2,16959925
US78462F1030	MV-72-STACK-LSTM-LUONG	0,00237901	9,84E-06	0,00313732	76,641%	1,701008143	2,17224170
US78462F1030	MV-73-STACK-LSTM-BAHDANAU	0,00238727	9,92E-06	0,00314937	76,834%	1,666130589	2,18977008
US78462F1030	MV-74-STACK-LSTM-LOCAL SOFT	0,00237086	9,72E-06	0,00311785	76,834%	1,719196101	2,16597699
US78462F1030	MV-75-STACK-LSTM-MULTIHEAD	0,00237788	9,86E-06	0,00314072	76,834%	1,6718424	2,17877578
US78462F1030	MV-80-CNN-LUONG	0,00251569	1,11E-05	0,00332846	72,394%	1,747606016	2,31045530
Mínimo		0,00234687	9,33E-06	0,00305422	49,61%	1,666130589	2,14470626
Máximo		0,02055541	4,33E-04	0,02080022	77,80%	18,86900633	18,71560289
Promedio		0,003229962727	2,92E-05	0,003962880909	74,99%	2,513397298	2,950062675
Desviación estándar		0,003870190	0,000090185	0,003761822	0,057960026	3,653316527	3,521747751

Tabla nro. 41 de Resultados de testing, métricas de Modelos Multivariados del ETF iShares USA - US4642872000

ETF-iSHARES	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
US4642872000	MV-1-Stacked LSTM	0,0019387	6,63E-06	0,002575	78,38%	1,68362	1,333
US4642872000	MV-2-Stacked LSTM	0,0019499	6,62E-06	0,002573	78,38%	1,69066	1,372
US4642872000	MV-31-CNN	0,0022765	8,796E-06	0,002966	75,98%	1,97146	1,730
US4642872000	MV-32-CNN	0,0022781	9,039E-06	0,003006	74,77%	1,96649	1,487
US4642872000	MV-33-CNN-LSTM	0,0019393	6,63E-06	0,002574	78,08%	1,68368	1,331
US4642872000	MV-40-CNN	0,0028190	1,268E-05	0,003560	64,86%	2,32233	1,986
US4642872000	MV-41-CNN-LSTM	0,0019518	6,722E-05	0,002593	78,38%	1,59432	1,262
US4642872000	MV-51-BIGRU	0,0020036	6,74E-06	0,002595	77,78%	1,73341	1,433
US4642872000	MV-52-BILSTM	0,0020836	7,14E-06	0,002672	75,08%	1,79736	1,555
US4642872000	MV-53-BILSTM-LUONG	0,0019757	6,733E-06	0,002595	80,78%	1,72027	1,311
US4642872000	MV-54-BIGRU-LUONG	0,0019698	6,637E-06	0,002576	78,08%	1,70430	1,315
US4642872000	MV-55-BILSTM-BAHDANAU	0,0019501	6,540E-06	0,002558	80,48%	1,69240	1,289
US4642872000	MV-56-BIGRU-BAHDANAU	0,0020125	6,730E-06	0,002594	76,58%	1,73906	1,429
US4642872000	MV-57-BILSTM-MULTIHEAD	0,0020702	7,040E-06	0,002653	75,68%	1,78533	1,526
US4642872000	MV-60-CNN-LSTM-LUONG	0,0019579	6,708E-06	0,002590	78,68%	1,59763	1,277
US4642872000	MV-70-STACK-LSTM-LUONG	0,0019507	6,729E-06	0,002594	78,98%	1,59409	1,264
US4642872000	MV-71-STACK-LSTM-LUONG	0,0019503	6,715E-06	0,002591	78,68%	1,59322	1,259
US4642872000	MV-72-STACK-LSTM-LUONG	0,0019515	6,760E-06	0,002600	78,98%	1,59569	1,245
US4642872000	MV-73-STACK-LSTM-BAHDANAU	0,0019373	6,625E-06	0,002574	78,38%	1,68231	1,328
US4642872000	MV-74-STACK-LSTM-LOCAL SOFT	0,0019299	6,549E-06	0,002559	79,58%	1,67620	1,306
US4642872000	MV-75-STACK-LSTM-MULTIHEAD	0,0019571	6,84E-06	0,002615	78,68%	1,70454	1,255
US4642872000	MV-80-CNN-LUONG	0,0023423	9,662E-06	0,003108	70,27%	2,04508	1,606
Mínimo		0,0019299	6,54E-06	0,002558	64,86%	1,59322	1,245
Máximo		0,002819	6,72E-05	0,00356	80,78%	2,32233	1,986
Promedio		0,002054354	1,01E-05	0,0026964090	77,07%	1,753338636	1,4045
Desviación estándar		0,000209851	0,000012847	0,000247778	0,035463461	0,177958061	0,184

Tabla nro. 42 de Resultados de testing, métricas de Modelos Multivariados del iShares Germany - US4642868065

ETF-GERMANY	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
US4642868065	MV-1-Stacked LSTM	0,0039024	2,814E-05	0,0053045	75,12%	2,43055	3,085986519
US4642868065	MV-2-Stacked LSTM	0,0039042	2,816E-05	0,0053063	75,12%	2,40530	3,086495835
US4642868065	MV-31-CNN	0,0043914	3,395E-05	0,0058264	70,74%	2,70341	3,497255063
US4642868065	MV-32-CNN	0,0045402	3,876E-05	0,0062257	70,05%	2,63592	3,601551566
US4642868065	MV-33-CNN-LSTM	0,0039041	2,816E-05	0,0053063	75,12%	2,38433	3,086040729
US4642868065	MV-40-CNN	0,0039029	2,814E-05	0,0053049	75,12%	2,41905	3,086027193
US4642868065	MV-41-CNN-LSTM	0,0039024	2,814E-05	0,0053045	75,12%	2,43055	3,085986519
US4642868065	MV-51-BIGRU	0,0040206	2,973E-05	0,0054527	74,88%	2,37665	3,158151328
US4642868065	MV-52-BILSTM	0,0039225	2,845E-05	0,0053338	75,81%	2,41940	3,096603091
US4642868065	MV-53-BILSTM-LUONG	0,0038399	2,689E-05	0,0051858	77,19%	2,16643	3,021880604
US4642868065	MV-54-BIGRU-LUONG	0,0039005	2,795E-05	0,0052864	76,04%	2,25245	3,077644603
US4642868065	MV-55-BILSTM-BAHDANAU	0,0038033	2,648E-05	0,0051460	76,50%	2,27129	3,006895244
US4642868065	MV-56-BIGRU-BAHDANAU	0,0039032	2,794E-05	0,0052862	76,04%	2,31765	3,102336422
US4642868065	MV-57-BILSTM-MULTIHEAD	0,0039157	2,842E-05	0,0053314	75,58%	2,34930	3,089894782
US4642868065	MV-60-CNN-LSTM-LUONG	0,003910	2,844E-05	0,0053328	75,12%	2,34921	3,098563355
US4642868065	MV-70-STACK-LSTM-LUONG	0,0039066	2,813E-05	0,0053036	76,27%	2,41190	3,095670286
US4642868065	MV-71-STACK-LSTM-LUONG	0,0039022	2,813E-05	0,0053033	75,58%	2,42325	3,08630945
US4642868065	MV-72-STACK-LSTM-LUONG	0,0040393	2,971E-05	0,0054503	73,50%	2,47827	3,16737459
US4642868065	MV-73-STACK-LSTM-BAHDANAU	0,0039022	2,813E-05	0,0053037	75,35%	2,43417	3,08580071
US4642868065	MV-74-STACK-LSTM-LOCAL SOFT	0,0039087	2,821E-05	0,0053112	75,81%	2,42383	3,091958928
US4642868065	MV-75-STACK-LSTM-MULTIHEAD	0,0039024	2,811E-05	0,0053020	75,81%	2,41532	3,089846705
US4642868065	MV-80-CNN-LUONG	0,0050539	4,131E-05	0,0064271	67,74%	3,35902	4,063875269
Mínimo		0,0038033	2,65E-05	0,005146	67,74%	2,16643	3,006895244
Máximo		0,0050539	4,13E-05	0,0064271	77,19%	3,35902	4,063875269
Promedio		0,0040136181	2,95E-05	0,0054243136	74,71%	2,448056818	3,175552218
Desviación estándar		0,000288480	0,000003701	0,000320040	0,022828376	0,232343574	0,2427

Tabla nro. 43 de Resultados de testing, métricas de Modelos Multivariados del ETF Vanguard - US9229087690

ETF-VANGUARD	Código	MAE	MSE	RMSE	DA	MDAPE	MAPE
US9229087690	MV-1-Stacked LSTM	0,001798675	5,750E-06	0,002397816	75,913%	1,573336921	1,9078157650
US9229087690	MV-2-Stacked LSTM	0,001794272	5,740E-06	0,002395781	76,826%	1,544683418	1,9018244460
US9229087690	MV-31-CNN	0,001793426	5,740E-06	0,002395756	76,598%	1,531999451	1,9005080860
US9229087690	MV-32-CNN	0,001941754	6,872E-06	0,002621485	73,973%	1,56153109	2,0578766150
US9229087690	MV-33-CNN-LSTM	0,001792344	5,741E-06	0,002396089	76,027%	1,51213334	1,8982234360
US9229087690	MV-40-CNN	0,001793370	5,740E-06	0,002395745	76,598%	1,534054045	1,9004089510
US9229087690	MV-41-CNN-LSTM	0,001798675	5,750E-06	0,002397816	75,913%	1,573336921	1,9078157650
US9229087690	MV-51-BIGRU	0,001814032	5,823E-06	0,002412987	76,142%	1,543170446	1,9238979620
US9229087690	MV-52-BILSTM	0,001842933	5,873E-06	0,002423342	73,973%	1,568179010	1,9592730180
US9229087690	MV-53-BILSTM-LUONG	0,001773134	5,574E-06	0,002360839	76,027%	1,464492934	1,8828082760
US9229087690	MV-54-BIGRU-LUONG	0,001797968	5,716E-06	0,002390754	75,228%	1,465116763	1,9087753370
US9229087690	MV-55-BILSTM-BAHDANAU	0,001770324	5,587E-06	0,002363764	76,712%	1,431191003	1,8785909060
US9229087690	MV-56-BIGRU-BAHDANAU	0,001811562	5,763E-06	0,002400604	75,114%	1,507999908	1,9224828690
US9229087690	MV-57-BILSTM-MULTIHEAD	0,001835505	5,849E-06	0,002418550	73,744%	1,540699225	1,9514453950
US9229087690	MV-60-CNN-LSTM-LUONG	0,001804002	5,764E-06	0,002400926	75,457%	1,558972423	1,9146378360
US9229087690	MV-70-STACK-LSTM-LUONG	0,001836402	5,874E-06	0,002423605	74,201%	1,502907063	1,9534449900
US9229087690	MV-71-STACK-LSTM-LUONG	0,001796522	5,742E-06	0,002396205	76,370%	1,550116460	1,9048328290
US9229087690	MV-72-STACK-LSTM-LUONG	0,001808378	5,844E-06	0,002417484	75,685%	1,490564354	1,9092801310
US9229087690	MV-73-STACK-LSTM-BAHDANAU	0,001945925	6,341E-06	0,002518215	73,288%	1,606175283	2,0773284310
US9229087690	MV-74-STACK-LSTM-LOCAL SOFT	0,001786006	5,708E-06	0,002389041	76,484%	1,503268544	1,8912022300
US9229087690	MV-75-STACK-LSTM-MULTIHEAD	0,001796538	5,744E-06	0,002396740	76,598%	1,571726159	1,9049400750
US9229087690	MV-80-CNN-LUONG	0,004951862	3,408E-05	0,005837494	52,511%	4,749270727	5,2139330460
Mínimo		0,001770324	5,57E-06	0,002360839	52,51%	1,431191003	1,878590906
Máximo		0,004951862	3,41E-05	0,005837494	76,83%	4,749270727	5,213933046
Promedio		0,001958345	7,12E-06	0,002570501	74,52%	1,676587522	2,075970291
Desviación estándar		0,000670141	0,000006028	0,000731760	0,050318785	0,687596269	0,702

Tabla nro. 44 de Resultados de testing, métricas de Modelos Multivariados del ETF Invesco - IE00B3YCGJ38

ETF - INVESCO	Código	MAE	MSE	RMSE	DA	MAPE %	MDAPE %
IE00B3YCGJ38	MV-1-Stacked LSTM	0,00709516	5,218E-05	0,0072237	52,5641%	7,46744	7,47787
IE00B3YCGJ38	MV-2-Stacked LSTM	0,00103571	1,889E-06	0,0013744	76,9231%	1,09087	0,95654
IE00B3YCGJ38	MV-31-CNN	0,00157075	3,808E-06	0,0019514	73,0769%	1,64813	1,32297
IE00B3YCGJ38	MV-32-CNN	0,00103940	1,898E-06	0,0013776	76,9231%	1,09448	0,98096
IE00B3YCGJ38	MV-33-CNN-LSTM	0,00102664	1,865E-06	0,0013656	74,3590%	1,08203	0,92847

IE00B3YCGJ38	MV-40-CNN	0,00104008	1,899E-06	0,0013782	76,9231%	1,09516	0,98473
IE00B3YCGJ38	MV-41-CNN-LSTM	0,00102582	1,862E-06	0,0013645	73,0769%	1,08130	0,91533
IE00B3YCGJ38	MV-51-BIGRU	0,00115636	2,199E-06	0,0014828	70,5128%	1,22769	0,92740
IE00B3YCGJ38	MV-52-BILSTM	0,00107058	2,025E-06	0,0014232	70,5128%	1,13030	0,94791
IE00B3YCGJ38	MV-53-BILSTM-LUONG	0,00106139	1,861E-06	0,0013643	71,7949%	1,12200	0,86154
IE00B3YCGJ38	MV-54-BIGRU-LUONG	0,00101458	1,798E-06	0,0013408	71,7949%	1,07061	0,86765
IE00B3YCGJ38	MV-55-BILSTM-BAHDANAU	0,00119354	2,364E-06	0,0015375	69,2308%	1,26735	0,93186
IE00B3YCGJ38	MV-56-BIGRU-BAHDANAU	0,00102727	1,817E-06	0,0013479	76,9231%	1,08501	0,91628
IE00B3YCGJ38	MV-57-BILSTM-MULTIHEAD	0,00112680	2,082E-06	0,0014428	70,5128%	1,19522	0,89212
IE00B3YCGJ38	MV-60-CNN-LSTM-LUONG	0,00103101	1,880E-06	0,0013711	76,9231%	1,08637	0,95391
IE00B3YCGJ38	MV-70-STACK-LSTM-LUONG	0,00105989	1,955E-06	0,0013981	76,9231%	1,11492	0,94588
IE00B3YCGJ38	MV-71-STACK-LSTM-LUONG	0,00115417	2,225E-06	0,0014918	74,3590%	1,21143	0,86262
IE00B3YCGJ38	MV-72-STACK-LSTM-LUONG	0,00102284	1,850E-06	0,0013602	71,7949%	1,08029	0,86952
IE00B3YCGJ38	MV-73-STACK-LSTM-BAHDANAU	0,00105407	1,908E-06	0,0013813	69,2308%	1,11526	0,84486
IE00B3YCGJ38	MV-74-STACK-LSTM-LOCAL SOFT	0,00102041	1,851E-06	0,0013605	73,0769%	1,07709	0,90639
IE00B3YCGJ38	MV-75-STACK-LSTM-MULTIHEAD	0,00101963	1,847E-06	0,0013590	73,0769%	1,07594	0,90604
IE00B3YCGJ38	MV-80-CNN-LUONG	0,00171138	4,813E-06	0,0021939	73,0769%	1,81393	1,52662
Mínimo		0,00101458	1,80E-06	0,0013408	52,56%	1,07061	0,84486
Máximo		0,00709516	5,22E-05	0,0072237	76,92%	7,46744	7,47787
Promedio		0,001388976	4,45E-06	0,0017223	72,44%	1,465128182	1,260339545
Desviación estándar		0,001286934	0,000010685	0,00124630	0,051548505	1,353877217	1,397

Anexo nro. 2.

Se presentan las tablas de resultados de los modelos tradicionales AutoReg, ARIMA, ARIMAX y MLPK con epochs 40, batch size 32 y train/test entre 75/25 a 95/5, para ETF Vanguard.

Tabla nro. 45 de Resultados de testing, métricas para AR, ARIMA y ARIMAX para ETF Vanguard Group - US9229087690

Porcentaje	AUTOREG				ARIMA				ARIMAX			
	MAE	MSE	RMSE	DA	MAE	MSE	RMSE	DA	MAE	MSE	RMSE	DA
75-25	0,008239309	0,000155871	0,012484843	55,563%	0,008777133	0,000177452	0,013321127	55,493%	0,008776609	0,000177447	0,013320932	55,634%
76-24	0,008253572	0,000155834	0,012483368	55,720%	0,008946272	0,000183298	0,013538774	55,646%	0,008946386	0,000183300	0,013538839	55,720%
77-23	0,008213816	0,000153738	0,012399119	55,778%	0,009175666	0,000190449	0,013800341	55,778%	0,009175649	0,000190449	0,013800333	55,778%
78-22	0,008152965	0,000151589	0,012312131	55,797%	0,009144995	0,000191044	0,013821852	55,797%	0,009145270	0,000191036	0,013821578	55,797%
79-21	0,008274131	0,000155667	0,012476666	55,902%	0,009195453	0,000193398	0,013906773	55,818%	0,009195607	0,000193404	0,013906978	55,987%
80-20	0,008489004	0,000178538	0,013361796	56,349%	0,009374030	0,000200145	0,014147275	55,979%	0,009373325	0,000200123	0,014146704	55,979%
81-19	0,008260822	0,000155519	0,012470714	55,918%	0,009498885	0,000205927	0,014350172	55,825%	0,009499043	0,000205942	0,014350681	55,825%
82-18	0,008182825	0,000152723	0,012358117	55,004%	0,009716606	0,000214333	0,014640121	55,906%	0,009717698	0,000214337	0,014640241	56,004%
83-17	0,008260822	0,000155519	0,012470714	56,042%	0,009498854	0,000205927	0,014350172	55,938%	0,009499043	0,000205942	0,014350681	55,938%
84-16	0,008219877	0,000156864	0,012524538	55,703%	0,008843848	0,000138652	0,011775074	55,703%	0,009499043	0,000205942	0,014350681	55,482%
85-15	0,00820205862	0,000158684	0,012596975	56,080%	0,008592624	0,000130751	0,014346339	55,962%	0,008592624	0,000130755	0,011434639	55,962%
89-11	0,007786583	0,000132214	0,011498437	56,844%	0,008937930	0,000142079	0,011919670	56,844%	0,008937930	0,000142079	0,011919670	56,844%
89,5	0,007809943	0,000134185	0,011583835	55,987%	0,009155225	0,000147310	0,012137134	55,987%	0,009155225	0,000147310	0,012137134	55,987%
90-10	0,0078080303	0,000131736	0,011477628	55,575%	0,009773617	0,000163321	0,012779698	55,575%	0,009362195	0,000152383	0,012344345	55,575%
90,5	0,007681139	0,000129805	0,011393201	55,493%	0,009795500	0,000166122	0,012888227	55,307%	0,009795500	0,000166122	0,012888227	55,307%
91-9	0,007872138	0,000134344	0,011590704	55,709%	0,009773617	0,000163321	0,012779698	55,709%	0,009773617	0,000163321	0,012779698	55,709%
92-8	0,007681139	0,000129805	0,011393201	54,646%	0,009795500	0,000166122	0,012888227	54,425%	0,009795500	0,000166122	0,012888227	54,425%
93-7	0,007841636	0,000134980	0,011618098	55,303%	0,009448009	0,000159770	0,012640028	55,303%	0,009448009	0,000159770	0,012640028	55,303%
94-6	0,007824852	0,000133423	0,011550908	56,932%	0,008560438	0,000126988	0,01268906	56,637%	0,008560438	0,000126988	0,011268906	56,637%
95-5	0,008055181	0,000140273	0,011843710	55,477%	0,007926323	0,000107476	0,010367052	55,477%	0,007926323	0,000107476	0,010367052	55,477%
Mínimo	0,007681139	0,000129805	0,011393201	54,646%	0,007926323	0,000107476	0,010367052	54,425%	0,007926323	0,000107476	0,010367052	54,425%
Máximo	0,008489004	0,000178538	0,013361796	56,932%	0,009795500	0,000214333	0,014640121	56,844%	0,009795500	0,000214337	0,014640241	56,844%
Promedio	0,008055696	0,000146566	0,012094435	55,841%	0,009196522	0,000168694	0,012937808	55,755%	0,009208752	0,000171512	0,013044839	55,768%
Desviación estándar	0,0002406	0,0000135	0,0005528	0,0050183	0,0004999	0,0000298	0,0011732	0,0048919	0,0004817	0,0000303	0,0011897	0,0049414

Tabla nro. 46 de Resultados de testing, métricas de MLPK para ETF Vanguard Group - US9229087690

Código	Porcentaje	MAE	MSE	RMSE	DA (%)	MDAPE (%)
MLPK	75-25	0,000344425	1,940E-07	0,000440717	65,928%	140,2971924
	76-24	0,000155544	8,500E-08	0,000290708	65,810%	140,6332965

	77-23	0,00024704	1,450E-07	0,000380632	65,760%	140,6643114
	78-22	0,000407271	2,610E-07	0,000511227	65,849%	141,0343728
	79-21	0,000186425	1,680E-07	0,000409789	66,080%	140,3776845
	80-20	0,000173941	2,550E-07	0,000504489	66,022%	140,7519648
	81-19	0,000133266	9,000E-08	0,000300495	66,091%	140,7844261
	82-18	0,000154108	7,000E-08	0,000264821	66,216%	140,8809943
	83-17	0,000510891	3,970E-07	0,000630388	66,369%	140,5002423
	84-16	0,00072185	5,360E-07	0,000732159	66,103%	141,9878278
	85-15	0,000083803	1,200E-08	0,00010873	66,353%	140,991766
	89-11	0,002143404	4,613E-06	0,002147686	66,205%	145,3095083
	89.5	0,000744613	5,640E-07	0,000750832	66,771%	142,4216112
	90-10	0,0009288963	1,738E-06	0,000947063	66,938%	142,376514
	90.5	0,0008901375	8,690E-07	0,000896521	66,913%	141,9018955
	91-9	0,002095321	4,408E-06	0,002099524	66,939%	143,2367821
	92-8	0,001032077	1,083E-06	0,001040527	66,880%	141,8445683
	93-7	0,000143452	3,400E-08	0,000184181	67,837%	141,2053352
	94-6	0,000601906	3,790E-07	0,00061581	68,576%	141,1269224
	95-5	0,000089997	1,300E-08	0,000113226	69,245%	140,7839323
	Mínimo	0,000083803	1,20E-08	0,00010873	65,76%	140,2971924
	Máximo	0,002143404	4,61E-06	0,002147686	69,25%	145,3095083
	Promedio	0,000589418	7,96E-07	0,000668476	66,64%	141,4555574
	Desviación estándar	0,000605562	0,000001341	0,000565199	0,009375246	1,201954163

Anexo nro. 3.

Se presentan las tablas de resultados de las métricas de los modelos *deep learning multivariados* y *univariados* con parámetros train/test 90/10, epochs 40, batch size 32, para predicción de retornos del instrumento ETF Vanguard VTI. Los resultados por métricas en las siguientes tablas:

- métricas DA de los modelos *multivariados* (tabla nro. 47) y *untivariados* (tabla nro. 48)
- métricas MSE de los modelos *multivariados* (tabla nro. 49) y *untivariados* (tabla nro. 50)
- métricas RMSE de los modelos *multivariados* (tabla nro. 51) y *univariados* (tabla nro. 52)
- métricas MAE de los modelos *multivariados* (tabla nro. 53) y *untivariados* (tabla nro. 54)
- métricas MAPE de los modelos *multivariados* (tabla nro. 55)
- métricas MDAPE de los modelos *multivariados* (tabla nro. 56) y *untivariados* (tabla nro. 57)

Tabla nro. 47 de Resultados testing de métricas DA de modelos Multivariados para ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesvSt	
MV-1-Stacked LSTM	74,525%	74,773	%	75,311%	75,531%	75,670%	75,913%	75,488%	76,016%	76,379%	76,615%	76,431%	79,076%	80,294%	80,449%	79,397%	80,000%	79,397%	76,923%	79,070%	80,000%	77,363%	0,0207
MV-12-Stacked GRU	74,525%	74,773	%	75,311%	75,531%	75,670%	75,913%	75,488%	76,016%	76,379%	76,615%	76,431%	79,076%	80,294%	80,449%	79,397%	80,000%	79,397%	76,923%	79,070%	80,000%	77,363%	0,0207
MV-2-Stacked LSTM	75,043%	75,408	75,598	%	75,935%	76,313%	76,826%	76,220%	76,671%	77,086%	77,231%	76,936%	78,533%	79,118%	79,167%	78,894%	78,824%	78,392%	76,923%	79,070%	80,000%	77,409%	0,0147
MV-22-Stacked GRU	75,043%	75,136	75,694	%	75,834%	75,456%	75,685%	74,878%	76,016%	77,086%	76,615%	76,936%	78,533%	79,412%	79,487%	77,889%	79,608%	77,889%	76,923%	77,907%	80,000%	77,101%	0,0166
MV-31-CNN	71,675%	71,234	71,388	%	73,509%	76,313%	76,598%	76,220%	72,215%	73,975%	77,077%	74,579%	79,076%	75,000%	80,128%	73,869%	74,510%	74,372%	76,923%	76,744%	76,667%	75,104%	0,0245
MV-32-CNN	75,302%	72,595	73,014	%	76,340%	71,383%	73,973%	72,073%	73,788%	77,086%	73,385%	76,599%	72,011%	75,000%	75,000%	73,367%	76,471%	73,869%	73,427%	72,093%	80,000%	74,339%	0,0215
MV-33-CNN-LSTM	73,143%	75,318	75,694	%	76,340%	75,670%	76,027%	76,220%	76,278%	77,086%	76,462%	77,104%	79,348%	79,412%	79,167%	78,392%	79,608%	79,899%	78,322%	79,070%	80,000%	77,428%	0,0190
MV-40-CNN	75,216%	68,603	76,172	%	76,441%	76,313%	76,598%	76,220%	76,802%	77,086%	77,077%	76,599%	79,076%	80,588%	80,128%	70,854%	80,000%	78,392%	57,343%	79,070%	83,333%	77,026%	0,0248
MV-41-CNN-LSTM	74,525%	74,773	%	75,311%	75,531%	75,670%	75,913%	75,488%	76,016%	76,379%	76,615%	76,431%	79,076%	80,294%	80,449%	79,397%	80,000%	79,397%	76,923%	79,070%	80,000%	76,068%	0,0251
MV-42-CNN-LSTM	74,957%	75,408	75,502	%	75,632%	75,670%	76,370%	75,854%	76,933%	77,228%	77,538%	77,441%	77,446%	79,118%	78,846%	77,889%	78,824%	77,387%	76,923%	77,907%	83,333%	77,027%	0,0271

MV-43-CNN-BIGRU	75,302%	75,227%	71,388%	68,150%	74,491%	74,087%	76,585%	74,443%	74,257%	70,615%	72,559%	73,641%	80,294%	72,756%	72,362%	75,686%	65,327%	62,238%	69,767%	76,667%	76,714%	0,0217
MV-44-CNN-BIGRU-LUONG	74,784%	%	%	75,430%	75,884%	75,000%	74,878%	76,016%	76,803%	77,077%	75,758%	77,717%	79,412%	78,846%	76,382%	79,608%	76,884%	75,524%	77,907%	80,000%	76,674%	0,0223
MV-45-CNN-LSTM-LUONG	73,575%	%	%	74,924%	75,884%	76,370%	75,732%	76,671%	76,521%	76,154%	75,758%	79,076%	80,294%	79,808%	77,387%	80,784%	76,382%	76,923%	76,744%	80,000%	77,085%	0,0220
MV-51-BIGRU	74,784%	%	%	73,812%	74,277%	76,142%	75,244%	75,098%	75,813%	75,538%	76,094%	77,989%	78,824%	79,808%	77,889%	77,255%	74,874%	67,832%	76,744%	83,333%	77,194%	0,0259
MV-52-BILSTM	75,734%	%	%	73,711%	74,491%	73,973%	75,732%	75,623%	76,096%	76,154%	75,758%	75,543%	77,353%	80,128%	75,377%	78,431%	75,377%	71,329%	75,581%	80,000%	77,518%	0,0190
MV-53-BILSTM-LUONG	75,130%	%	%	74,216%	75,563%	76,027%	77,073%	77,851%	77,652%	75,231%	76,768%	77,446%	80,882%	80,128%	79,577%	78,824%	79,397%	72,727%	75,581%	46,667%	61,921%	0,0814
MV-530-BILSTM-LUONG-AutoKeras	75,681%	76,651%	%	74,823%	76,313%	76,370%	77,317%	76,278%	75,955%	76,462%	76,263%	79,620%	80,882%	78,526%	80,106%	79,608%	78,392%	73,427%	80,233%	60,000%	74,929%	0,0626
MV-531-BILSTM-LUONG-AutoKeras	75,499%	76,077%	%	76,340%	75,563%	75,913%	76,098%	76,933%	76,379%	76,308%	76,094%	79,348%	79,412%	79,808%	80,634%	79,608%	77,889%	76,923%	79,070%	80,000%	77,363%	0,0207
MV-532-BILSTM-LUONG-AutoKeras	75,316%	75,789%	%	74,520%	75,563%	76,256%	77,073%	76,933%	76,238%	76,154%	77,609%	77,989%	81,471%	79,808%	79,577%	79,608%	79,397%	71,329%	80,233%	80,000%	77,144%	0,0139
MV-54-BIGRU-LUONG	74,784%	%	%	76,138%	75,884%	75,228%	76,098%	76,671%	75,955%	77,077%	77,104%	79,891%	78,824%	80,021%	80,986%	80,392%	77,387%	75,524%	75,581%	63,333%	72,125%	0,0451
MV-55-BILSTM-BAHDANAU	75,993%	%	%	75,025%	77,385%	76,712%	77,073%	76,278%	76,945%	76,692%	77,104%	80,163%	79,706%	78,846%	78,873%	81,961%	77,889%	72,028%	81,395%	76,667%	76,532%	0,0151
MV-550-BILSTM-BAHDANAU-AutoKeras	75,681%	76,746%	%	75,733%	75,348%	76,598%	76,951%	76,671%	76,662%	76,923%	78,283%	77,174%	80,294%	80,342%	79,225%	80,000%	78,392%	73,427%	80,233%	76,667%	76,709%	0,0198
MV-551-BILSTM-BAHDANAU-AutoKeras	75,499%	75,502%	%	76,036%	76,313%	76,370%	76,098%	76,147%	76,803%	76,462%	76,599%	78,533%	80,294%	79,808%	79,930%	79,608%	78,894%	76,224%	79,070%	76,667%	75,704%	0,0244
MV-552-BILSTM-BAHDANAU-AutoKeras	75,953%	76,555%	%	75,632%	75,670%	75,685%	77,073%	76,278%	76,803%	77,385%	77,946%	79,891%	81,471%	79,701%	79,225%	80,392%	78,894%	73,427%	80,233%	80,000%	75,893%	0,0200
MV-56-BIGRU-BAHDANAU	75,648%	%	%	74,317%	75,884%	75,114%	74,512%	75,885%	75,530%	75,231%	76,599%	78,804%	80,294%	80,128%	77,465%	78,039%	78,894%	76,224%	76,744%	76,667%	76,950%	0,0209
MV-57-BILSTM-MULTIHEAD	75,408%	75,120%	%	73,913%	73,955%	73,744%	76,098%	74,836%	75,955%	76,000%	74,916%	76,630%	79,118%	80,449%	80,986%	78,039%	73,367%	69,231%	75,581%	73,333%	77,121%	0,0225
MV-58-BILSTM-LUONG	76,339%	%	%	72,599%	76,313%	73,744%	76,829%	76,278%	76,521%	76,462%	77,273%	76,630%	78,824%	81,517%	80,986%	78,431%	74,372%	72,727%	80,233%	80,000%	77,477%	0,0178
MV-59-BIGRU-LUONG	75,820%	%	%	73,509%	75,348%	72,032%	76,341%	76,409%	76,238%	75,385%	76,263%	73,913%	76,471%	80,021%	80,106%	79,608%	78,392%	75,524%	80,233%	73,333%	76,970%	0,0255
MV-60-CNN-LSTM-LUONG	75,043%	%	75,311%	75,025%	74,384%	75,457%	75,488%	75,229%	74,399%	76,615%	76,936%	78,804%	79,412%	80,128%	77,889%	80,000%	79,397%	75,524%	77,907%	76,667%	77,094%	0,0205
MV-70-STACK-LSTM-LUONG	73,230%	%	%	73,509%	73,633%	74,201%	73,659%	75,229%	76,803%	75,077%	76,431%	77,446%	80,294%	80,449%	77,387%	79,216%	76,382%	72,028%	76,744%	73,333%	77,175%	0,0249
MV-71-STACK-LSTM-LUONG	72,107%	%	%	73,509%	75,348%	76,370%	75,366%	76,147%	76,662%	75,385%	75,421%	79,076%	78,824%	80,288%	79,397%	80,392%	78,894%	78,322%	74,419%	76,667%	77,304%	0,0170
MV-72-STACK-LSTM-LUONG	74,611%	%	%	75,632%	72,669%	75,685%	73,659%	75,754%	76,379%	76,923%	76,936%	78,533%	79,706%	80,288%	79,397%	78,431%	78,392%	76,923%	79,070%	73,333%	77,345%	0,0231
MV-73-STACK-LSTM-BAHDANAU	75,130%	%	%	72,902%	74,062%	73,288%	73,293%	76,671%	75,106%	77,538%	76,936%	78,533%	79,412%	79,647%	77,889%	78,431%	78,894%	76,923%	77,907%	73,333%	77,164%	0,0215
MV-74-STACK-LSTM-LOCAL SOFT	75,499%	75,502%	%	73,913%	75,027%	76,484%	73,902%	75,623%	75,248%	75,538%	76,263%	78,804%	80,000%	79,647%	78,392%	80,000%	77,387%	79,021%	80,233%	76,667%	76,717%	0,0174
MV-75-STACK-LSTM-MULTIHEAD	73,503%	75,407%	%	76,340%	75,777%	76,598%	75,244%	76,016%	76,521%	75,538%	74,747%	77,717%	79,412%	80,449%	79,397%	80,392%	79,397%	79,021%	75,581%	80,000%	75,906%	0,0278
MV-76-BIGRU-LOCAL SOFT	75,820%	%	%	74,014%	75,670%	76,484%	76,098%	77,588%	77,086%	75,538%	76,936%	79,076%	79,118%	80,449%	79,397%	80,000%	79,397%	76,923%	79,070%	73,333%	76,580%	0,0256
MV-80-CNN-LUONG	67,789%	%	%	67,947%	51,340%	52,511%	67,805%	64,482%	71,429%	59,692%	58,586%	76,630%	59,118%	65,705%	62,312%	71,373%	49,246%	62,937%	52,326%	73,333%	76,430%	0,0256
Mínimo	67,79%	66,79%	63,73%	67,95%	51,34%	52,51%	67,80%	64,48%	71,43%	59,69%	58,59%	72,01%	59,12%	65,71%	62,31%	71,37%	49,25%	57,34%	52,33%	46,67%		
Máximo	76,34%	75,95%	77,22%	76,44%	77,38%	76,83%	77,32%	77,85%	77,65%	77,54%	78,28%	80,16%	81,47%	81,52%	80,99%	81,96%	79,90%	79,02%	81,40%	83,33%		
Promedio	74,62%	74,53%	75,12%	74,55%	74,65%	74,93%	75,44%	75,70%	76,18%	75,66%	75,93%	78,00%	78,86%	79,21%	77,78%	78,97%	76,65%	73,99%	77,12%	76,31%		
Desviación estándar	0,0153	0,0191	0,0233	0,0191	0,0409	0,0396	0,0175	0,0215	0,0116	0,0298	0,0311	0,0179	0,0364	0,0274	0,0352	0,0192	0,0536	0,0482	0,0483	0,0693		

Tabla nro. 48 de Resultados testing de métricas DA de modelos Univariados para ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesvSt	
U51	73,834%	74,955%	%	76,077%	73,407%	75,777%	76,027%	75,366%	76,933%	76,662%	75,077%	75,589%	78,533%	79,118%	79,216%	78,392%	80,392%	77,889%	77,622%	76,744%	76,667%	76,211%	0,0208
U52	75,216%	75,318%	%	75,789%	76,036%	75,027%	74,658%	75,000%	76,016%	77,228%	77,077%	76,936%	78,804%	79,412%	79,608%	78,392%	78,824%	78,894%	77,622%	80,233%	76,667%	75,848%	0,0239
U53	73,834%	75,681%	%	76,172%	72,902%	72,669%	76,027%	75,366%	76,933%	72,843%	73,231%	75,589%	78,533%	75,588%	79,216%	78,392%	73,725%	72,362%	75,524%	79,070%	73,333%	77,205%	0,0237
U54	75,302%	75,681%	%	76,172%	76,340%	76,313%	76,484%	76,220%	76,802%	77,086%	77,077%	76,599%	79,076%	80,588%	69,804%	78,392%	79,608%	78,392%	76,923%	79,070%	76,667%	77,180%	0,0182
U55	74,525%	75,681%	%	76,459%	75,025%	75,456%	75,000%	75,610%	76,802%	75,530%	75,077%	76,263%	76,902%	79,412%	80,128%	78,392%	80,000%	74,372%	71,329%	75,581%	76,667%	77,167%	0,0229
U56	74,525%	74,955%	%	75,981%	74,419%	74,241%	74,886%	76,098%	77,064%	76,379%	76,000%	76,936%	75,815%	78,529%	79,808%	76,884%	79,608%	75,377%	68,531%	73,256%	80,000%	77,237%	0,0250
U57	75,130%	75,681%	%	77,799%	74,924%	75,777%	75,000%	76,951%	77,326%	77,086%	76,000%	77,104%	77,989%	80,294%	82,372%	80,810%	80,392%	76,884%	74,126%	80,233%	73,333%	76,404%	0,0226
U575	76,073%	75,590%	%	76,459%	75,531%	74,920%	75,228%	76,098%	76,409%	75,813%	76,154%	77,778%	79,348%	80,588%	80,662%	80,106%	79,608%	78,392%	76,224%	76,744%	76,667%	76,237%	0,0223
U10	75,043%	75,953%	%	75,311%	74,823%	75,563%	76,142%	76,220%	77,588%	77,369%	76,308%	77,778%	78,533%	80,000%	82,372%	80,810%	80,784%	77,387%	72,727%	76,744%	80,000%	76,881%	0,0197
U20	75,130%	76,044%	%	75,694%	73,913%	75																	

U73	74,52E-0%	75,40E-0%	75,789E-0%	75,329E-0%	75,134E-0%	76,027E-0%	75,366E-0%	76,802E-0%	76,662E-0%	75,846E-0%	75,758E-0%	77,174E-0%	79,412E-0%	79,487E-0%	76,884E-0%	79,608E-0%	78,894E-0%	76,923E-0%	74,419E-0%	83,333E-0%	76,939E-0%	0,0220
U74	74,180E-0%	74,592E-0%	75,789E-0%	76,138E-0%	75,348E-0%	75,685E-0%	76,463E-0%	76,933E-0%	76,521E-0%	75,385E-0%	75,928E-0%	78,533E-0%	76,471E-0%	79,808E-0%	78,392E-0%	79,608E-0%	78,894E-0%	79,021E-0%	77,907E-0%	83,333E-0%	77,246E-0%	0,0219
U75	74,266E-0%	75,318E-0%	75,885E-0%	75,834E-0%	75,027E-0%	76,256E-0%	75,488E-0%	75,360E-0%	75,248E-0%	77,538E-0%	68,687E-0%	79,076E-0%	80,882E-0%	80,769E-0%	78,392E-0%	80,392E-0%	78,894E-0%	74,825E-0%	79,070E-0%	83,333E-0%	77,027E-0%	0,0320
U80	66,32E-0%	70,145E-0%	64,498E-0%	60,061E-0%	60,557E-0%	65,297E-0%	60,976E-0%	69,332E-0%	74,257E-0%	68,308E-0%	59,764E-0%	64,674E-0%	74,118E-0%	75,641E-0%	60,804E-0%	75,294E-0%	74,372E-0%	64,336E-0%	62,791E-0%	70,000E-0%	67,077E-0%	0,0554
Mínimo	66,32E-0%	70,15E-0%	64,50E-0%	60,06E-0%	60,56E-0%	65,30E-0%	60,98E-0%	69,33E-0%	72,84E-0%	68,31E-0%	59,76E-0%	64,67E-0%	74,12E-0%	69,80E-0%	60,80E-0%	73,73E-0%	72,36E-0%	64,34E-0%	62,79E-0%	80,000E-0%		
Máximo	76,08E-0%	76,04E-0%	77,80E-0%	76,34E-0%	76,31E-0%	76,60E-0%	77,44E-0%	77,59E-0%	77,37E-0%	77,54E-0%	77,78E-0%	79,35E-0%	80,88E-0%	82,37E-0%	81,16E-0%	80,78E-0%	79,40E-0%	79,02E-0%	81,40E-0%	70,00E-0%		
Promedio	74,29E-0%	75,05E-0%	75,27E-0%	74,40E-0%	74,50E-0%	75,19E-0%	74,96E-0%	76,21E-0%	76,15E-0%	75,45E-0%	75,20E-0%	77,45E-0%	79,13E-0%	79,57E-0%	77,65E-0%	79,33E-0%	77,51E-0%	73,99E-0%	76,92E-0%	83,33E-0%		
Desviación estándar	0,0196	0,0130	0,0271	0,0350	0,0337	0,0240	0,0341	0,0179	0,0113	0,0206	0,0408	0,0316	0,0177	0,0267	0,0419	0,0174	0,0194	0,0370	0,0400	78,17E-0%		

Tabla nro. 49 de Resultados testing, métricas MSE de modelos multivariados ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesSt	
MV-1-Stacked LSTM	8,323E-06	8,612E-06	1,773E-05	1,854E-05	8,887E-06	5,750E-06	1,891E-05	5,502E-06	1,139E-05	1,377E-05	7,316E-06	7,044E-06	6,417E-06	1,259E-05	3,537E-06	4,232E-06	3,537E-06	3,051E-06	3,34E-06	4,50E-06	8,549E-06	0,0000044994	
MV-12-Stacked GRU	8,323E-06	8,612E-06	1,773E-05	1,854E-05	8,887E-06	5,750E-06	1,691E-05	5,502E-06	1,139E-05	1,377E-05	7,316E-06	7,044E-06	6,417E-06	1,259E-05	3,537E-06	4,232E-06	3,537E-06	3,051E-06	3,34E-06	4,50E-06	8,549E-06	0,0000044994	
MV-2-Stacked LSTM	8,333E-06	8,637E-06	1,773E-05	1,853E-05	8,877E-06	5,740E-06	1,689E-05	5,497E-06	1,138E-05	1,377E-05	7,320E-06	7,088E-06	6,412E-06	1,272E-05	3,560E-06	4,257E-06	3,550E-06	3,031E-06	3,38E-06	4,49E-06	8,558E-06	0,0000044994	
MV-22-Stacked GRU	8,331E-06	8,617E-06	1,772E-05	1,853E-05	8,892E-06	5,755E-06	1,694E-05	5,504E-06	1,138E-05	1,378E-05	7,316E-06	7,184E-06	6,498E-06	1,277E-05	3,569E-06	4,305E-06	3,567E-06	3,031E-06	3,34E-06	4,50E-06	8,577E-06	0,0000044993	
MV-31-CNN	1,212E-06	1,146E-06	2,641E-05	1,996E-05	8,875E-06	5,740E-06	1,690E-05	6,857E-06	1,290E-05	1,378E-05	7,929E-06	7,043E-06	7,636E-06	1,260E-05	4,046E-06	5,395E-06	4,227E-06	3,030E-06	3,65E-06	5,07E-06	9,781E-06	0,000006079	
MV-32-CNN	8,316E-06	1,422E-06	2,579E-05	1,853E-05	1,612E-05	6,872E-06	2,190E-05	6,022E-05	1,139E-05	1,620E-05	7,322E-06	8,406E-06	6,994E-06	1,468E-05	4,369E-06	4,862E-06	4,397E-06	3,562E-06	4,38E-06	4,95E-06	1,046E-06	0,000006535	
MV-33-CNN-LSTM	8,716E-06	8,606E-06	1,771E-05	1,853E-05	8,877E-06	5,741E-06	1,690E-05	5,500E-06	1,139E-05	1,385E-05	7,316E-06	7,043E-06	6,409E-06	1,263E-05	3,529E-06	4,220E-06	3,531E-06	3,053E-06	3,37E-06	4,49E-06	8,570E-06	0,0000044996	
MV-60-CNN-LSTM-LUO	NG	8,314E-06	8,628E-06	1,783E-05	1,856E-05	8,927E-06	5,764E-06	1,690E-05	5,587E-06	1,159E-05	1,391E-05	7,319E-06	7,059E-06	6,479E-06	1,259E-05	3,567E-06	4,219E-06	3,529E-06	3,144E-06	3,38E-06	4,45E-06	8,587E-06	0,000005007
MV-70-STACK-LSTM-LUO	NG	8,498E-06	8,890E-06	1,770E-05	1,871E-05	8,953E-06	5,874E-06	1,715E-05	5,514E-06	1,137E-05	1,393E-05	7,319E-06	7,215E-06	6,396E-06	1,260E-05	3,545E-06	4,222E-06	3,666E-06	3,486E-06	3,36E-06	4,53E-06	8,646E-06	0,000005000
MV-71-STACK-LSTM-LUO	NG	8,613E-06	8,612E-06	1,769E-05	1,868E-05	8,929E-06	5,742E-06	1,703E-05	5,493E-06	1,141E-05	1,404E-05	7,366E-06	7,045E-06	6,601E-06	1,373E-05	3,551E-06	4,227E-06	3,547E-06	3,073E-06	3,44E-06	4,42E-06	8,661E-06	0,000005078
MV-72-STACK-LSTM-LUO	NG	8,517E-06	8,812E-06	1,779E-05	1,859E-05	9,662E-06	5,844E-06	1,718E-05	5,592E-06	1,136E-05	1,378E-05	7,309E-06	7,221E-06	6,403E-06	1,382E-05	3,566E-06	4,429E-06	3,807E-06	3,035E-06	3,37E-06	4,86E-06	8,727E-06	0,000005061
MV-73-STACK-LSTM-BAHDANA	NG	8,359E-06	8,725E-06	1,769E-05	1,929E-05	8,943E-06	6,341E-06	1,783E-05	5,489E-06	1,183E-05	1,378E-05	7,320E-06	7,220E-06	6,417E-06	1,387E-05	3,622E-06	4,439E-06	3,666E-06	3,036E-06	3,34E-06	4,44E-06	8,783E-06	0,000005191
MV-74-STACK-LSTM-LC-SOFT	NG	8,294E-06	8,600E-06	1,778E-05	1,859E-05	8,996E-06	5,708E-06	1,690E-05	5,539E-06	1,168E-05	1,414E-05	7,286E-06	7,024E-06	6,352E-06	1,379E-05	3,691E-06	4,300E-06	3,523E-06	3,035E-06	3,51E-06	4,47E-06	8,661E-06	0,000005077
MV-75-STACK-LSTM-MU-LTHIAD	NG	8,465E-06	8,648E-06	1,778E-05	1,853E-05	8,875E-06	5,744E-06	1,693E-05	5,505E-06	1,142E-05	1,403E-05	7,612E-06	7,146E-06	6,409E-06	1,384E-05	3,529E-06	4,232E-06	3,558E-06	3,042E-06	3,50E-06	4,42E-06	8,661E-06	0,000005065
MV-76-BIGRU-LOCAL	SOFT	8,229E-06	8,548E-06	1,629E-05	1,862E-05	8,748E-06	5,708E-06	1,688E-05	5,272E-06	1,116E-05	1,382E-05	7,131E-06	7,044E-06	6,445E-06	1,259E-05	3,537E-06	4,232E-06	3,537E-06	3,051E-06	3,34E-06	4,50E-06	8,434E-06	0,000004875
MV-80-CNN-LUONG	1,509E-06	1,832E-06	8,097E-05	5,191E-05	1,884E-04	3,408E-05	2,722E-05	1,168E-05	1,643E-05	3,032E-05	2,231E-05	8,011E-05	1,879E-05	3,152E-05	6,878E-05	5,905E-05	4,346E-05	5,511E-05	1,45E-05	3,23E-05	3,327E-05	0,0000040772	
MV-40-CNN	8,316E-06	1,324E-06	1,771E-05	1,852E-05	8,875E-06	5,740E-06	1,690E-05	5,498E-06	1,139E-05	1,378E-05	7,322E-06	7,043E-06	6,403E-06	1,259E-05	4,654E-06	4,219E-06	3,530E-06	3,048E-06	3,36E-06	7,09E-06	9,332E-06	0,000004768	
MV-41-CNN-LSTM	8,323E-06	8,612E-06	1,773E-05	1,854E-05	8,887E-06	5,750E-06	1,691E-05	5,502E-06	1,139E-05	1,377E-05	7,316E-06	7,044E-06	6,417E-06	1,259E-05	3,537E-06	4,232E-06	3,537E-06	3,051E-06	3,45E-06	8,549E-06	0,0000044994		
MV-42-CNN-LSTM	8,338E-06	8,623E-06	1,775E-05	1,856E-05	8,880E-06	5,737E-06	1,690E-05	5,499E-06	1,138E-05	1,378E-05	7,321E-06	7,077E-06	6,440E-06	1,266E-05	3,556E-06	4,228E-06	3,556E-06	3,027E-06	3,35E-06	4,52E-06	8,559E-06	0,000004998	
MV-43-CNN-BIGRU-LUONG	8,591E-06	8,816E-06	1,959E-05	2,303E-05	9,192E-06	5,990E-06	1,764E-05	5,876E-06	1,203E-05	1,665E-05	8,295E-06	7,924E-06	6,610E-06	1,515E-05	4,810E-06	4,889E-06	7,373E-06	7,242E-06	6,09E-06	7,73E-06	1,018E-05	0,000005322	
MV-44-CNN-BIGRU-LUONG	NG	8,204E-06	8,411E-06	1,816E-05	1,844E-05	8,914E-06	5,724E-06	1,706E-05	5,493E-06	1,153E-05	1,380E-05	7,381E-06	7,076E-06	6,424E-06	1,261E-05	3,584E-06	4,240E-06	3,472E-06	3,094E-06	3,26E-06	4,99E-06	8,592E-06	0,000005025
MV-45-CNN-LSTM-LUO	NG	8,553E-06	8,884E-06	1,798E-05	1,887E-05	8,909E-06	5,738E-06	1,685E-05	5,499E-06	1,143E-05	1,377E-05	7,297E-06	7,031E-06	6,412E-06	1,261E-05	3,554E-06	4,231E-06	3,569E-06	3,050E-06	3,40E-06	4,60E-06	8,611E-06	0,000005038
MV-51-BIGRU	8,426E-06	8,532E-06	1,767E-05	1,856E-05	9,008E-06	5,823E-06	1,745E-05	5,649E-06	1,164E-05	1,428E-05	7,575E-06	7,298E-06	6,610E-06	1,279E-05	3,843E-06	4,666E-06	4,207E-06	4,029E-06	3,57E-06	4,98E-06	8,831E-06	0,000004908	
MV-52-BILSTM	8,414E-06	8,606E-06	1,780E-05	1,891E-05	9,027E-06	5,873E-06	1,706E-05	5,626E-06	1,161E-05	1,415E-05	7,410E-06	7,48											

UNI-60-CNN-LSTM-LUONG	9.570E-06	9.770E-06	1.009E-05	1.066E-06	1.008E-05	6.520E-06	1.278E-05	6.370E-06	6.480E-06	8.070E-06	8.650E-06	8.410E-06	7.500E-06	1.474E-05	4.130E-06	4.990E-06	4.160E-06	4.030E-06	3.96E-06	5.76E-06	7.836E-06	0.0000030
UNI-70-LSTM-LUONG	9.470E-06	9.760E-06	1.003E-05	1.049E-05	1.013E-05	6.520E-06	1.306E-05	6.270E-06	6.460E-06	8.120E-06	8.620E-06	8.390E-06	7.500E-06	1.472E-05	4.240E-06	5.150E-06	4.130E-06	3.540E-06	4.06E-06	5.47E-06	7.807E-06	0.0000030
UNI-71-LSTM-LUONG	9.430E-06	9.810E-06	1.003E-05	1.056E-05	1.009E-05	6.500E-06	6.390E-06	6.240E-06	6.440E-06	8.670E-06	8.600E-06	8.240E-06	7.500E-06	1.480E-05	4.190E-06	4.940E-06	4.140E-06	3.910E-06	4.01E-06	5.61E-06	7.505E-06	0.0000028
UNI-72-LSTM-LUONG	9.610E-06	9.840E-06	1.035E-05	1.051E-05	1.015E-05	6.530E-06	1.306E-04	6.220E-06	6.440E-06	8.080E-06	8.560E-06	8.300E-06	7.490E-06	1.472E-05	4.570E-06	4.960E-06	4.170E-06	3.560E-06	4.18E-06	5.34E-06	7.832E-06	0.0000030
UNI-73-LSTM-BAHDANAU	9.440E-06	9.780E-06	1.007E-05	1.059E-05	1.024E-05	6.500E-06	1.282E-05	6.220E-06	6.450E-06	8.080E-06	8.690E-06	8.500E-06	7.500E-06	1.490E-05	4.280E-06	4.940E-06	4.130E-06	3.570E-06	4.24E-06	5.19E-06	7.807E-06	0.0000030
UNI-74-LSTM-LOCAL SOFT	9.420E-06	9.740E-06	9.960E-06	1.047E-05	1.010E-05	6.470E-06	6.380E-06	6.190E-06	6.420E-06	8.070E-06	8.760E-06	8.230E-06	7.860E-06	1.502E-05	4.300E-06	5.100E-06	4.120E-06	3.560E-06	3.97E-06	5.38E-06	7.476E-06	0.0000028
UNI-75-LSTM-MULTIHEAD	9.450E-06	9.970E-06	1.005E-05	1.052E-05	1.011E-05	6.510E-06	1.286E-05	6.440E-06	6.660E-06	8.060E-06	1.097E-05	8.250E-06	7.500E-06	1.474E-05	4.340E-06	4.950E-06	4.150E-06	3.800E-06	3.97E-06	5.18E-06	7.924E-06	0.0000031
UNI-80-CNN-LUONG	4.783E-05	1.750E-05	4.846E-05	3.064E-05	4.182E-05	2.125E-05	1.881E-05	1.701E-05	1.032E-05	1.129E-05	2.293E-05	1.465E-05	8.780E-05	1.644E-05	1.311E-05	6.500E-05	5.800E-05	6.160E-05	1.04E-05	7.50E-05	1.886E-05	0.00000133
UNI-30-CNN	9.470E-06	9.760E-06	1.005E-05	1.467E-05	1.327E-05	6.510E-06	1.280E-05	6.240E-06	7.820E-06	9.140E-06	8.610E-06	8.300E-06	8.960E-06	1.012E-05	4.130E-06	5.790E-06	5.040E-06	4.540E-06	4.85E-06	5.66E-06	8.287E-06	0.0000030
Mínimo	9.190E-06	9.510E-06	9.430E-06	1.005E-05	1.002E-05	6.420E-06	6.260E-06	5.980E-06	6.350E-06	8.010E-06	8.140E-06	8.050E-06	7.320E-06	1.008E-05	4.130E-06	4.900E-06	4.080E-06	3.540E-06	3.910E-06	5.180E-06		
Máximo	9.190E-06	9.510E-06	9.430E-06	1.005E-05	1.002E-05	6.420E-06	6.260E-06	5.980E-06	6.350E-06	8.010E-06	8.140E-06	8.050E-06	7.320E-06	1.008E-05	4.130E-06	4.900E-06	4.080E-06	3.540E-06	3.910E-06	5.180E-06		
Promedio	1.145E-05	1.015E-05	1.202E-05	1.175E-05	1.193E-05	7.289E-06	1.206E-05	6.787E-06	6.745E-06	8.349E-06	9.441E-06	8.711E-06	7.685E-06	1.551E-05	6.478E-06	5.107E-06	4.324E-06	4.087E-06	4.485E-06	5.729E-06		
Desviación Standar	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	

Tabla nro. 51 de Resultados testing, métricas RMSE de modelos Multivariados ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesSt
MV-1-Stacked LSTM	0.002885	0.002938	0.005954	0.006089	0.002981	0.002398	0.007124	0.002346	0.002549	0.002765	0.002654	0.002533	0.005019	0.001881	0.002057	0.001881	0.001747	0.001828	0.002122	0.003395	0.001675231	
MV-12-Stacked GRU	0.002885	0.002938	0.005954	0.006089	0.002981	0.002398	0.007124	0.002346	0.002549	0.002765	0.002654	0.002533	0.005019	0.001881	0.002057	0.001881	0.001747	0.001828	0.002122	0.003358	0.001675321	
MV-2-Stacked LSTM	0.002887	0.002938	0.005959	0.006087	0.002979	0.002398	0.007119	0.002345	0.002547	0.002768	0.002662	0.002532	0.005043	0.001887	0.002063	0.001884	0.001744	0.001833	0.002116	0.00335965	0.001675295	
MV-22-Stacked GRU	0.002888	0.002938	0.005952	0.006088	0.002982	0.002398	0.007113	0.002346	0.002549	0.002765	0.002668	0.002548	0.005053	0.001888	0.002075	0.001889	0.001744	0.001828	0.002122	0.00336355	0.001675353	
MV-31-CNN	0.003462	0.003384	0.007268	0.006516	0.002979	0.002398	0.007121	0.002619	0.005025	0.002816	0.002654	0.002763	0.005019	0.002011	0.002323	0.002055	0.001744	0.001911	0.002255	0.00357215	0.001775180	
MV-32-CNN	0.002884	0.003377	0.007182	0.006087	0.004014	0.002621	0.008108	0.002454	0.005062	0.002708	0.002699	0.002654	0.005419	0.002020	0.002097	0.001887	0.002088	0.002229	0.00369215	0.001677623		
MV-33-CNN-LSTM	0.002958	0.002934	0.005952	0.006087	0.002979	0.002398	0.007121	0.002345	0.002772	0.002705	0.002654	0.002552	0.005026	0.001879	0.002054	0.001879	0.001747	0.001835	0.002118	0.0033615	0.001675055	
MV-60-CNN-LSTM-LUONG	0.002883	0.002931	0.005972	0.006092	0.002988	0.002398	0.007121	0.002364	0.004814	0.002574	0.002657	0.002545	0.005017	0.001886	0.002054	0.001886	0.001773	0.001839	0.002109	0.0033656	0.001675729	
MV-70-STACK-LSTM-LUONG	0.002915	0.002982	0.005599	0.006118	0.002992	0.002394	0.007173	0.002348	0.004769	0.002705	0.002686	0.002529	0.005020	0.001883	0.002058	0.001915	0.001867	0.001834	0.002127	0.00337855	0.001674440	
MV-71-STACK-LSTM-LUONG	0.002933	0.002938	0.005948	0.006112	0.002988	0.002398	0.007147	0.002344	0.004776	0.002599	0.002654	0.002569	0.005235	0.001884	0.002056	0.001883	0.001753	0.001853	0.002102	0.0033792	0.001691804	
MV-72-STACK-LSTM-LUONG	0.002918	0.002968	0.005964	0.006099	0.003108	0.002417	0.007173	0.002365	0.004768	0.002704	0.002687	0.002523	0.005254	0.001888	0.002104	0.001899	0.001742	0.001835	0.00216	0.003391	0.001687474	
MV-73-STACK-LSTM-BAHDANAU	0.002691	0.002954	0.005947	0.006121	0.002959	0.002395	0.007124	0.002343	0.004866	0.002705	0.002667	0.002553	0.005263	0.001915	0.002107	0.001915	0.001743	0.001826	0.002108	0.00340385	0.001717101	
MV-74-STACK-LSTM-LOCAL SOFT	0.002881	0.002933	0.005964	0.006098	0.002979	0.002397	0.007127	0.002346	0.004778	0.002598	0.002659	0.002599	0.005259	0.001879	0.002057	0.001886	0.001744	0.001807	0.002103	0.0033794	0.001697092	
MV-76-BIGRU-LOCAL SOFT	0.002866	0.002924	0.005993	0.006143	0.002985	0.002395	0.007108	0.002345	0.005025	0.002705	0.002657	0.002652	0.005252	0.001885	0.002057	0.001881	0.001747	0.001828	0.002122	0.0033371	0.001678639	
MV-80-CNN-LUONG	0.003885	0.004248	0.012728	0.010189	0.013726	0.005837	0.009036	0.003417	0.005732	0.007787	0.004723	0.002899	0.004334	0.001764	0.002482	0.002433	0.001878	0.002348	0.0033814	0.00065683	0.0016598352	
MV-40-CNN	0.002884	0.003638	0.005952	0.006085	0.002979	0.002398	0.007122	0.002345	0.004772	0.002706	0.002654	0.002503	0.005019	0.002157	0.002054	0.001879	0.001832	0.002022	0.0033782	0.001655155		
MV-41-CNN-LSTM	0.002888	0.002938	0.005954	0.006088	0.002981	0.002398	0.007124	0.002346	0.004772	0.002705	0.002654	0.002533	0.005019	0.001881	0.002057	0.001881	0.001747	0.001828	0.002122	0.003358	0.001675321	
MV-42-CNN-LSTM	0.002884	0.002931	0.005959	0.006093	0.002988	0.002395	0.007122	0.002345	0.004772	0.002705	0.002666	0.002538	0.005032	0.001886	0.002056	0.001888	0.001742	0.001835	0.00216	0.00335985	0.001675781	
MV-43-CNN-BIGRU	0.002933	0.002968	0.005628	0.006078	0.003032	0.002447	0.007273	0.002344	0.004908	0.005771	0.002819	0.002571	0.005059	0.001921	0.002074	0.001921	0.001861	0.001848	0.002232	0.00336860	0.001688860	
MV-44-CNN-BIGRU-LUONG	0.002864	0.002901	0.005944	0.006085	0.002979	0.002395	0.007123	0.002341	0.004772	0.002742	0.002694	0.002542	0.005016	0.002338	0.002055	0.001879	0.001743	0.001834	0.002187	0.00337825	0.001651710	
MV-51-BIGRU	0.002903	0.002921	0.005945	0.006093	0.003001	0.002413	0.007272	0.00237														

UNI-30-CNN	0.003077	0.003125	0.00317	0.00383	0.003642	0.002552	0.005059	0.002498	0.002797	0.003023	0.002935	0.00288	0.002994	0.004501	0.002033	0.002407	0.002244	0.00213	0.002203	0.002375	0.002974	0.000787337
Mínimo	0.003032	0.003085	0.003071	0.003171	0.003166	0.002534	0.002502	0.002445	0.002519	0.00283	0.002854	0.002837	0.002705	0.004489	0.002032	0.002213	0.002019	0.001883	0.001978	0.002277		
Máximo	0.006916	0.004183	0.006961	0.005535	0.006467	0.004609	0.005112	0.004124	0.003212	0.003361	0.004788	0.003827	0.002994	0.008075	0.005031	0.00255	0.002407	0.002482	0.003228	0.002738		
Promedio	0.003261	0.003174	0.003352	0.0033792	0.0033645	0.002656	0.0045105	0.0025759	0.0025910	0.002869	0.0030384	0.0029446	0.0027714	0.0058259	0.0027329	0.0022585	0.002083	0.002021	0.002099	0.002397		
Desviación estándar	0.000860	0.000237	0.000849	0.0005251	0.0007376	0.00045974	0.0010312	0.0003649	0.0001572	0.0001209	0.0004214	0.0002105	0.0000740	0.0011513	0.0012185	0.0000800	0.000097	0.000161	0.000273	0.0001139		

Tabla nro. 53 de Resultados testing, métricas MAE de modelos Multivariados ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesvSt
MV-1-Stacked LSTM	0.001915	0.0019508	0.0039567	0.0040686	0.0020169	0.0017987	0.005361	0.0017566	0.0035752	0.0039235	0.0020417	0.0019977	0.0019236	0.0038062	0.0014808	0.0016211	0.0014806	0.0014006	0.0014587	0.001704	0.00246209	0.001172601
MV-12-Stacked GRU	0.001915	0.0019508	0.0039567	0.0040686	0.0020169	0.0017987	0.005361	0.0017566	0.0035756	0.0039235	0.0020417	0.0019977	0.0019236	0.0038062	0.0014808	0.0016211	0.0014806	0.0014006	0.0014587	0.001704	0.00246209	0.001172601
MV-2-Stacked LSTM	0.0019098	0.0019446	0.0039393	0.0040545	0.0020108	0.0017943	0.0053494	0.0017546	0.0035735	0.0039232	0.002041	0.0020123	0.0019797	0.0038466	0.0014815	0.0016287	0.0014797	0.0013987	0.0014625	0.0016998	0.00246157	0.00117187
MV-22-Stacked GRU	0.0019084	0.0019427	0.0039401	0.0040541	0.0020188	0.0018006	0.0053719	0.0017573	0.0035754	0.0039246	0.0020415	0.0020347	0.0019532	0.003856	0.0014847	0.0016406	0.0014835	0.0013987	0.001458	0.001704	0.00246757	0.001172901
MV-31-CNN	0.002211	0.0022716	0.0046782	0.0042001	0.0020108	0.0017934	0.0053491	0.0019717	0.0038366	0.0039215	0.002041	0.0019991	0.0021013	0.0038101	0.0018501	0.0016167	0.0013986	0.0015146	0.0017933	0.00260283	0.00120248	
MV-32-CNN	0.0019092	0.0023189	0.0046668	0.0040456	0.0025852	0.0019418	0.006175	0.0018527	0.0035712	0.0042804	0.002041	0.0021757	0.0020088	0.0041452	0.0016627	0.0017576	0.0016416	0.0016666	0.001798	0.00268696	0.00131457	
MV-33-CNN-LSTM	0.0019744	0.0019433	0.0039401	0.0040557	0.0020091	0.0017922	0.0053491	0.0017598	0.0035712	0.0042804	0.002041	0.0019985	0.0021682	0.003802	0.0016165	0.0014786	0.0014049	0.001704	0.0024627	0.00169826		
MV-60-CNN-LSTM-LUONG	0.0019098	0.0019578	0.0039498	0.0040407	0.002003	0.001804	0.0053475	0.0017712	0.0036322	0.0039344	0.0020412	0.0020002	0.0019331	0.0038066	0.0014835	0.0016162	0.0014747	0.0014226	0.0014675	0.0016944	0.00246868	0.001173143
MV-70-STACK-LSTM-LUONG	0.0019725	0.0019861	0.0039368	0.0040134	0.0020376	0.0018364	0.0053487	0.0017605	0.0035716	0.0039675	0.0020406	0.0020245	0.0019207	0.0038112	0.0014781	0.0016176	0.0015186	0.0014973	0.001713	0.00248647	0.001178127	
MV-71-STACK-LSTM-LUONG	0.0020030	0.0019418	0.0039397	0.0040116	0.0020149	0.0017965	0.0053674	0.0017567	0.0035744	0.0039704	0.0020541	0.0019994	0.0019525	0.0039798	0.0014873	0.0016197	0.0014831	0.0014162	0.0016909	0.00248265	0.001184822	
MV-72-STACK-LSTM-LUONG	0.0019362	0.0019708	0.0039897	0.0040577	0.0021982	0.0018084	0.0054437	0.0017735	0.0035751	0.0039216	0.0020402	0.0020425	0.0019241	0.0040053	0.0014921	0.0016675	0.0015034	0.0013984	0.0014641	0.0017423	0.00249763	0.001186664
MV-73-STACK-LSTM-BADHAN																						
MV-74-STACK-LSTM-LOCAL-SOFT	0.001911	0.0019567	0.0039338	0.0040475	0.0020303	0.001804	0.0053475	0.0017712	0.0036322	0.0039344	0.0020412	0.0020002	0.0019331	0.0038066	0.0014835	0.0016162	0.0014747	0.0014226	0.0014675	0.0016944	0.00246868	0.001173143
MV-75-STACK-LSTM-MULTIL-EAC	0.0019634	0.0019655	0.0039433	0.0040588	0.0020201	0.0017965	0.0053669	0.0017542	0.0035762	0.0039696	0.002103	0.0020267	0.0019265	0.0041476	0.0016211	0.0014888	0.0014042	0.0015081	0.001692	0.00248303	0.001182685	
MV-76-BIGRU-LOCAL-SOFT	0.001892	0.0019337	0.0038191	0.0040941	0.0020057	0.0017986	0.0053474	0.0017346	0.0035712	0.0039215	0.0020277	0.0019977	0.0019431	0.0038082	0.0014808	0.0016211	0.00140405	0.00144675	0.001704	0.00245588	0.001171664	
MV-80-CNN-LUONG	0.0026375	0.0028938	0.0037883	0.0040553	0.00132616	0.0049516	0.0068302	0.0026765	0.0042086	0.0036362	0.0020231	0.0036351	0.00204065	0.0019421	0.0026243	0.0019084	0.0015073	0.0014583	0.0016946	0.00251280	0.001122592	
MV-40-CNN	0.001915	0.0025277	0.0039421	0.0040511	0.0020105	0.0017007	0.0053478	0.0017346	0.0035712	0.0039215	0.0020277	0.0019977	0.0019227	0.0038098	0.0014756	0.0016216	0.00140405	0.00144675	0.001704	0.00245860	0.00111564	
MV-41-CNN-LSTM	0.001915	0.0019508	0.0039567	0.0040683	0.0020168	0.0017987	0.005361	0.0017566	0.0035756	0.0039235	0.0020417	0.0019977	0.0019232	0.0038082	0.0014808	0.0016211	0.00140405	0.00144675	0.001704	0.00245860	0.00111564	
MV-42-CNN-LSTM	0.0019073	0.0019427	0.0039383	0.0040507	0.0020071	0.0017903	0.0053463	0.0017553	0.0035725	0.0039231	0.0020424	0.0020026	0.0019375	0.0038288	0.0014802	0.0016194	0.0014796	0.0014596	0.001704	0.00245977	0.001169710	
MV-43-CNN-BIGRU	0.0019362	0.0019426	0.0039401	0.0040568	0.0020212	0.0017994	0.0054128	0.0017674	0.0035933	0.0039126	0.0020538	0.0020192	0.0019337	0.0038513	0.0014623	0.0016234	0.0014056	0.0014461	0.001704	0.0024756	0.001178388	
MV-45-CNN-LSTM-LUONG	0.0019474	0.0019194	0.0039475	0.0040497	0.0020156	0.0017088	0.0053529	0.0017555	0.0035908	0.0039254	0.0020398	0.0019958	0.0019228	0.0038098	0.0014777	0.0016184	0.00140405	0.00144675	0.001704	0.00246830	0.001170905	
MV-51-BIGRU	0.001919	0.0019501	0.0039598	0.00404215	0.0020794	0.001814	0.0054584	0.0017834	0.0036347	0.0040483	0.0020246	0.0019906	0.0019311	0.0038098	0.0014756	0.0016211	0.00140405	0.00144675	0.001704	0.00246830	0.001172135	
MV-52-BILSTM	0.0019101	0.0019378	0.0039392	0.0040159	0.0020126	0.0017986	0.0053708	0.0017784	0.0036323	0.0040597	0.0020721	0.0020086	0.0019886	0.0038501	0.0015120	0.0016246	0.0014056	0.0015120	0.00172601	0.00248735	0.001141978	
MV-55-BILSTM-BADHANAU	0.0018923	0.0019138	0.0039116	0.0040124	0.0019946	0.0017703	0.0053035	0.0017361	0.0035851	0.004018	0.0020147	0.0019913	0.0019452	0.0038223	0.0016702	0.0016186	0.0014947	0.0014973	0.0016050	0.002076	0.001146683	
MV-56-BILSTM-BADHANAU	0.0019036	0.0019212	0.0039214	0.0040237	0.0020156	0.0017986	0.0053486	0.0017723	0.0036013	0.0040233	0.0020109	0.0019688	0.0019108	0.0038514	0.0015120	0.0016186	0.0014056	0.00144675	0.001704	0.00246830	0.001141978	
MV-57-BILSTM-MULTIHEAD	0.0019101	0.0019048	0.0039415	0.00401216	0.0020412	0.0017968	0.0053485	0.0017723	0.0036014	0.0040233	0.0020147	0.0019913	0.0019452	0.0038223	0.0016702	0.0016186	0.0014056	0.00144675	0.001704	0.00246830	0.001141978	
MV-58-BILSTM-LUONG	0.001882	0.0019323	0.0039214	0.0040237	0.0020086	0.0017944	0.0053456	0.0017496	0.0035724	0.0040237	0.0020097	0.0019806	0.0019324	0.0038097	0.0015120	0.0016186	0.0014056	0.00144675	0.001704	0.00246830	0.001141978	
MV-59-BIGRU-LUONG	0.001882	0.0019494	0.0039464	0.0040259	0.0020246	0.0017944	0.0053213	0.0017553	0.0036194	0.0041237	0.0020668	0.0019968	0.0019342	0.0037442	0.0015120	0.0016186	0.0014056	0.00144675	0.001704	0.0024		

Desviación estándar	0,00037 95	0,0001462 86	0,000438 688	0,00044569 7	0,0004840 47	0,00029728 1	0,0007764 19	0,0001960 72	0,0000761 8	0,0001053 5	0,0004228 5	0,0002027 2	0,0000536 4	0,0002366 4	0,0003397 6	0,0000700 0	0,0000801 4	0,0001370 1	0,0002316 9	0,0001226 4
---------------------	---------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	-----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------	----------------

Tabla nro. 55 de Resultados de métricas MAPE de modelos ETF Vanguard Group - US9229087690

Código	75-25	76-24	77-23	78-22	79-21	80-20	81-19	82-18	83-17	84-16	85-15	89-11	89.5	90-10	90.5	91-9	92-8	93-7	94-6	95-5	Promedio	DesSt		
MV-1-Stacked LSTM	2,031733	2,068716	2,098415	2,157482	2,142066	1,907816	1,896247	1,864406	1,897108	1,75177	1,822855	1,787478	1,724463	1,704816	1,323845	1,450595	1,323845	1,254162	1,302352	1,513155	1,75207635	0,29552461		
MV-12-Stacked GRU	2,01932	2,056413	2,08493	2,146975	2,133443	1,901824	1,890501	1,861638	1,895132	1,751321	1,821094	1,795967	1,724847	1,717196	1,321595	1,453347	1,319402	1,251038	1,304432	1,527042	1,74889065	0,29225033		
MV-2-Stacked LSTM	2,019211	2,055676	2,086443	2,146923	2,144613	1,910368	1,901056	1,865398	1,895933	1,752359	1,822507	1,813474	1,744279	1,72197	1,323761	1,462964	1,323147	1,251087	1,30146	1,513155	1,75369925	0,29285715		
MV-22-Stacked GRU	2,343142	2,339743	2,474967	2,215173	2,133598	1,900508	1,890165	2,088887	2,034052	1,749293	1,90961	1,786627	1,878349	1,710425	1,413368	1,658555	1,444082	1,251106	1,350623	1,610501	1,86213845	0,35074404		
MV-31-CNN	2,022412	2,45631	2,477413	2,148762	2,743718	2,057877	2,180776	1,966256	1,892968	1,907206	1,820812	1,943489	1,800747	1,851274	1,484158	1,569384	1,464891	1,327072	1,488634	1,616202	1,9101815	0,37044689		
MV-32-CNN	2,078445	2,058021	2,086584	2,148578	2,130094	1,898223	1,890207	1,85886	1,892948	1,751995	1,822402	1,768554	1,723937	1,707401	1,316791	1,445363	1,321538	1,258307	1,305188	1,528497	1,75051495	0,29570477		
MV-33-CNN-LSTM	2,021342	2,077516	2,087027	2,163119	2,15862	1,914638	1,888768	1,872631	1,932737	1,756285	1,861247	1,790886	1,73534	1,712355	1,323107	1,444769	1,319723	1,275432	1,307735	1,521546	1,75625275	0,29630346		
MV-60-CNN-LSTM-LUONG	2,096514	2,092512	2,08406	2,196026	2,167802	1,953445	1,928206	1,869615	1,894615	1,775365	1,817241	1,720654	1,705291	1,318594	1,445208	1,361089	1,346046	1,311581	1,530943	1,7718413	0,29640474			
MV-70-STACK-LSTM-LUONG	2,133525	2,054753	2,084903	2,187104	2,132133	1,904833	1,89285	1,864871	1,892963	1,764649	1,837378	1,768612	1,755162	1,698591	1,330408	1,449128	1,326096	1,263858	1,335191	1,516313	1,76065335	0,29789598		
MV-71-STACK-LSTM-LUONG	2,041376	2,078003	2,11208	2,144564	2,151466	1,90928	1,930092	1,874762	1,89712	1,748713	1,821008	1,819586	1,722302	1,719491	1,335154	1,484639	1,346172	1,251207	1,305252	1,516281	1,77327915	0,30999041		
MV-72-STACK-LSTM-LUONG	2,019855	2,065615	2,082074	2,272282	2,16444	2,077328	1,991046	1,858368	1,934089	1,749118	1,821702	1,819381	1,725651	1,728615	1,349937	1,497398	1,324211	1,252047	1,301516	1,516276	1,7787494	0,31056394		
MV-73-STACK-LSTM-BAHDAANU	2,012448	2,05012	2,080659	2,181066	2,137266	1,891202	1,904645	1,864942	1,920314	1,775216	1,821006	1,783817	1,715867	1,706785	1,347861	1,464039	1,317298	1,254703	1,332343	1,518083	1,7539887	0,29051483		
MV-74-STACK-LSTM-LOCAL-SOFT	2,086444	2,087071	2,085083	2,150963	2,131916	1,904944	1,89886	1,858866	1,893955	1,766129	1,881684	1,807096	1,723897	1,707652	1,319418	1,450576	1,321851	1,254261	1,305235	1,516281	1,76081655	0,29528089		
MV-75-STACK-LSTM-MULTIHEAD	1,997468	2,049552	2,022274	2,173755	2,125963	1,91202	1,890276	1,838598	1,901638	1,788223	1,809398	1,787478	1,736587	1,704816	1,323845	1,450595	1,324162	1,302352	1,513155	1,74499845	0,28740943			
MV-76-BIGRU-LOCAL-SOFT	2,82004	3,09136	2,022074	3,460712	4,175307	5,213933	2,401098	2,814486	2,224935	2,807816	3,660858	9,093978	3,34119	3,737447	2,130348	5,548391	1,72374	3,548391	4,730114	3,7349103	2,6922477			
MV-80-CNN-LUONG	2,024251	2,660664	2,088368	2,142652	2,133541	1,904009	1,890806	1,859304	1,892969	1,749293	1,820816	1,766633	1,712661	1,701627	1,345097	1,447488	1,317646	1,2453569	1,303609	1,901159	1,86767585	0,33786619		
MV-40-CNN	2,031733	2,068716	2,098415	2,157482	2,142066	1,907816	1,896247	1,864606	1,897108	1,75177	1,822855	1,787478	1,724463	1,703935	1,323845	1,450595	1,323845	1,254162	1,302352	1,513155	1,75202323	0,29552039		
MV-41-CNN-LSTM	2,012275	2,055181	2,082077	2,140007	2,128033	1,896362	1,886863	1,862266	1,894385	1,750545	1,822372	1,79344	1,731957	1,751916	1,320263	1,446388	1,319982	1,202275	1,513347	1,75178175	0,29156884			
MV-42-CNN-LSTM	2,046611	2,124982	2,023424	2,662764	2,174686	1,9865	1,917085	1,919086	1,976416	2,048397	2,022853	1,91507	1,749042	1,880057	1,597452	1,525806	2,047538	2,024448	1,83231	2,071506	1,991281	2,0403342		
MV-43-CNN-BIGRU	2,016156	2,047018	2,108477	2,148141	2,145956	1,90926	1,91514	1,871388	1,902209	1,746397	1,829223	1,779938	1,723708	1,70509	1,346386	1,448074	1,319667	1,259651	1,306233	1,5161685	1,7595468	0,28938462		
MV-44-CNN-BIGRU-LUONG	2,055074	2,099662	2,099652	2,099308	2,165301	2,13614	1,893757	1,883375	1,902323	1,757238	1,821118	1,786467	1,720593	1,703933	1,319259	1,474225	1,322277	1,257574	1,309153	1,5156118	1,7517455	0,29726290		
MV-45-CNN-LSTM-LUONG	2,028163	2,662536	2,122463	2,440923	2,21313	1,923898	1,932693	1,881637	1,921546	1,828742	1,897757	1,841181	1,787278	1,751456	1,408283	1,550588	1,448604	1,348735	1,3176409	1,247787	1,304019	1,598848	1,76131895	0,27448418
MV-51-BIGRU	2,020551	2,045994	2,081548	2,096886	2,170304	1,959273	1,984484	1,879222	1,914778	1,818368	1,853803	1,858491	1,77302	1,736556	1,463222	1,553804	1,456693	1,350147	1,5165492	1,1865119	1,606933	1,4560604	0,25757801	
MV-52-BILSTM	1,982551	2,041808	2,039508	2,22231	2,112194	2,128808	1,882808	1,845824	1,838456	1,886176	1,801982	1,838299	1,801889	1,718485	1,698998	1,655258	1,472941	1,357735	1,439546	1,1972349	1,2772345	0,25697470		
MV-53-BILSTM-LUONG	2,022366	2,199114	2,022588	2,152728	2,133098	1,900505	1,837691	1,836585	1,901007	1,730908	1,821879	1,751175	1,717185	1,724525	1,643944	1,455111	1,335585	1,277036	1,304019	1,689023	1,76130754	0,25983318		
MV-530-BILSTM-LUONG-AutoKeras	2,008696	2,053477	2,081376	2,137188	2,122997	1,899688	1,88626	1,855965	1,892733	1,748496	1,819267	1,782017	1,597868	1,445122	1,319799	1,248801	1,301135	1,536112	1,76251315	0,27477562				
MV-531-BILSTM-LUONG-AutoKeras	1,995036	2,050594	2,054574	2,161723	2,122997	1,872243	1,838165	1,838866	1,902852	1,737887	1,787588	1,79434	1,694863	1,678033	1,616667	1,442781	1,329081	1,329501	1,52852493	1,75287634	0,25342693			
MV-532-BILSTM-LUONG-AutoKeras	2,026342	2,058948	2,093028	2,142074	2,136207	1,908795	1,870092	1,859527	1,948712	1,824847	1,797786	1,797786	1,709425	1,595914	1,450591	1,336429	1,283387	1,352214	1,356773	1,746822	0,26871610			
MV-54-BIGRU-LUONG	1,989664	2,024946	2,067771	2,174275	2,144661	1,878591	1,868222	1,840771	1,894929	1,799227	1,800402	1,776822	1,744992	1,714934	1,682412	1,446561	1,338071	1,346639	1,303830	1,308363	1,37674	1,80717995	0,28805561	
MV-55-BILSTM-BAHDAANU-AutoKeras	2,014066	2,051537	2,082155	2,149836	2,133374	1,887914	1,861846	1,863911	1,987108	1,75177	1,822855	1,787478	1,724463	1,703966	1,450595	1,323845	1,254162	1,302352	1,513155	1,75203485	0,29551316			
Mínimo	1,9825	1,9991	2,014515	2,137187	2,10939	5	1,872243	1,837691	1,834856	1,886716	1,786365	1,75211	1,694468	1,668891	1,317697	1,442781	1,303749	1,238337	1,301135	1,516276				
Máximo	2,8200	3,0913	4,220774	2,348071	2,14753	07	5,213933	2,401093	2,811448	2,224935	2,807816	3,660858	1,964757	3,34119	3,773467	2,130348	1,72374	5,548391	2,453569	2,943955	4,730114			
Promedio	2,0562	2,1216	2,159689	2,22331	2,48756	21	2,0145695	1,912392	1,895455</															

MV-80-CNN-LUONG	1,962100 000	2,1898500 00	2,6713650 00	2,193378 000	13,940745 000	4,7492710 00	1,8887980 00	2,358468 000	1,658284 000	2,504737 000	3,334645 000	1,589595 000	3,201615 000	14,80816 8000	1,969722 000	1,531527 000	5,583316 000	1,493516 000	2,690841 000	4,762384 000	3,8441162 50	3,748313 064
MV-40-CNN	1,463350 000	1,9542840 00	1,5106480 00	1,557718 00	1,8091810 00	1,5340540 00	1,5223820 00	1,473884 000	1,489824 000	1,388218 000	1,460724 000	1,463231 000	1,405619 000	1,397412 000	1,355171 000	1,181667 000	1,092752 000	2,190683 000	1,150576 000	1,633284 000	1,491733 100	0,247519 344
MV-41-CNN-LSTM	1,495541 000	1,5291160 00	1,5565480 00	1,599188 00	1,6193880 00	1,5733370 00	1,5596760 00	1,497373 000	1,530631 000	1,418780 000	1,469495 000	1,478353 000	1,447797 000	1,440638 000	1,077438 000	1,204466 000	1,077438 000	1,099705 000	1,177356 000	1,516756 000	1,418451 000	0,181855 269
MV-42-CNN-LSTM	1,442768 000	1,4608820 00	1,4700650 00	1,535041 00	1,56339300 00	1,5373740 00	1,5264960 00	1,485022 000	1,507733 000	1,399197 000	1,490303 000	1,453108 000	1,424924 000	1,377541 000	1,075302 000	1,159929 000	1,071033 000	1,153983 000	1,186691 000	1,535423 000	1,392837 250	0,164793 943
MV-43-CNN-BIGRU	1,449265 000	1,5710480 00	1,7200940 00	2,098374 00	1,6240830 00	1,6100990 00	1,5052840 00	1,481302 000	1,558278 000	1,652106 000	1,614669 000	1,564444 000	1,382478 000	1,557658 000	1,313786 000	1,342849 000	1,765590 000	1,754286 000	1,540883 000	1,750431 000	1,592850 350	0,176145 258
MV-44-CNN-BIGRU-LUONG	1,417496 000	1,4982090 00	1,5220010 00	1,516052 00	1,6269050 00	1,5127210 00	1,5494810 00	1,489163 000	1,460036 000	1,305379 000	1,472637 000	1,480998 000	1,455370 000	1,398578 000	1,179706 000	1,169644 000	1,063689 000	1,082706 000	1,203963 000	1,309721 750	1,385722 303	0,165136 000
MV-45-CNN-LSTM-LUONG	1,483492 000	1,5225480 00	1,4632590 00	1,542537 00	1,5655310 00	1,4804060 00	1,4913730 00	1,449353 000	1,523914 000	1,403885 000	1,448832 000	1,508074 000	1,441683 000	1,4411530 000	1,085235 000	1,202367 000	1,100203 000	1,101410 000	1,1511840 000	1,479585 000	1,393286 700	0,163109 650
MV-51-BIGRU	1,435573 000	1,5058410 00	1,5575140 00	1,662465 00	1,6348080 00	1,5431700 00	1,5306740 00	1,489202 000	1,525198 000	1,375919 000	1,494888 000	1,518037 000	1,493965 000	1,488339 000	1,142349 000	1,235692 000	1,227259 000	1,219042 000	1,0852110 000	1,519097 150	1,434212 678	0,163592 000
MV-52-BILSTM	1,444248 000	1,4402690 00	1,4624480 00	1,566144 00	1,6019580 00	1,5681790 00	1,4512000 00	1,475334 000	1,487624 000	1,367724 000	1,473088 000	1,516986 000	1,458618 000	1,438286 000	1,183632 000	1,278197 000	1,175275 000	1,157192 000	1,229667 000	1,421539 400	1,409880 578	0,134503 000
MV-53-BILSTM-LUONG	1,411861 000	1,4492520 00	1,4427380 00	1,632482 00	1,5522340 00	1,4644930 00	1,4221790 00	1,423676 000	1,490660 000	1,400564 000	1,451335 000	1,468396 000	1,372627 000	1,293822 000	1,292802 000	1,197251 000	1,142273 000	1,235003 000	1,132869 000	1,557822 950	1,391716 066	0,136791 000
MV-530-BILSTM-LUON-G-AutoKeras	1,461440 000	1,3792590 00	1,4079640 00	1,570302 00	1,6021480 00	1,5393440 00	1,4164990 00	1,367871 000	1,537251 000	1,324737 000	1,477658 000	1,363408 000	1,383306 000	1,360431 000	1,304877 000	1,169359 000	1,120300 000	1,1168250 000	1,141076 000	1,435690 000	1,373987 250	0,145822 311
MV-531-BILSTM-LUON-G-AutoKeras	1,427402 000	1,4661890 00	1,4849860 00	1,567186 00	1,5258570 00	1,5396300 00	1,5119460 00	1,475662 000	1,486810 000	1,415800 000	1,449893 000	1,455465 000	1,415701 000	1,390169 000	1,322071 000	1,171271 000	1,070249 000	1,132259 000	1,179355 000	1,342010 550	1,391495 966	0,144550 000
MV-532-BILSTM-LUON-G-AutoKeras	1,427790 000	1,4720720 00	1,4656440 00	1,587671 00	1,5258570 00	1,4654360 00	1,4081980 00	1,407822 000	1,533435 000	1,348572 000	1,435986 000	1,496056 000	1,301857 000	1,270700 000	1,309785 000	1,147254 000	1,066206 000	1,161748 000	1,010445 000	1,539448 000	1,369099 100	0,164696 169
MV-54-BIGRU-LUONG	1,484828 000	1,4823420 00	1,5244820 00	1,613339 00	1,5754520 00	1,4651170 00	1,4506230 00	1,477943 000	1,487207 000	1,351763 000	1,478344 000	1,397221 000	1,469297 000	1,367189 000	1,310495 000	1,121960 000	1,127234 000	0,991630 000	1,255313 000	1,369723 100	0,160093 462	
MV-55-BILSTM-BAHDA-NAU	1,397634 000	1,4268320 00	1,4632750 00	1,595238 00	1,6030070 00	1,4311910 00	1,4180190 00	1,388941 000	1,555091 000	1,383766 000	1,434778 000	1,390392 000	1,363327 000	1,360603 000	1,412502 000	1,250448 000	1,097433 000	1,158240 000	1,156380 000	1,713228 250	1,389989 187	0,152870 000
MV-551-BILSTM-BAHD-ANAU-AutoKeras	1,429073 000	1,4841210 00	1,4854120 00	1,570987 00	1,6096150 00	1,5390110 00	1,5413740 00	1,495306 000	1,491789 000	1,396970 000	1,463878 000	1,423486 000	1,382465 000	1,393504 000	1,316937 000	1,167431 000	1,081332 000	1,149643 000	1,122983 000	1,4144110 400	1,397986 556	0,154286 000
MV-552-BILSTM-BAHD-ANAU-AutoKeras	1,429024 000	1,4179300 00	1,40632200 00	1,570707 00	1,5379030 00	1,4552690 00	1,4068530 00	1,406969 000	1,493956 000	1,322274 000	1,410003 000	1,407052 000	1,306433 000	1,370023 000	1,426025 000	1,148460 000	1,046240 000	1,150825 000	1,127881 000	1,508735 100	1,367444 875	0,143827 000
MV-550-BILSTM-BAHD-ANAU-AutoKeras	1,458289 000	1,4631750 00	1,4390080 00	1,576459 00	1,5111480 00	1,5341220 00	1,4111880 00	1,424226 000	1,504344 000	1,338547 000	1,399787 000	1,505899 000	1,324576 000	1,354900 000	1,328621 000	1,203238 000	1,066757 000	1,186997 000	1,146819 000	1,536988 450	1,385754 68	0,142162 000
MV-56-BIGRU-BAHDA-NAU	1,406425 000	1,4409210 00	1,4173010 00	1,607221 00	1,5797640 00	1,5080000 00	1,5231380 00	1,427726 000	1,518690 000	1,397174 000	1,453914 000	1,4113720 000	1,453854 000	1,412480 000	1,418594 000	1,310404 000	1,125970 000	1,123135 000	1,141795 000	1,362739 850	1,401580 251	0,136666 000
MV-57-BILSTM-MULTIHEAD-EAD	1,431535 000	1,4520680 00	1,4818290 00	1,602742 00	1,6038450 00	1,5406990 00	1,4848750 00	1,452764 000	1,480940 000	1,349309 000	1,458373 000	1,526758 000	1,443865 000	1,390507 000	1,333409 000	1,253814 000	1,171942 000	1,167845 000	1,151618 000	1,055964 000	1,524506 700	0,155281 532
MV-58-BILSTM-LUONG	1,393228 000	1,4372690 00	1,4081670 00	1,624795 00	1,5836540 00	1,5273740 00	1,4635960 00	1,409988 000	1,478877 000	1,333737 000	1,404201 000	1,513240 000	1,469278 000	1,310005 000	1,293398 000	1,174650 000	1,149813 000	1,151618 000	1,055964 000	1,524506 700	0,155281 532	
MV-59-BIGRU-LUONG	1,430144 000	1,4431300 00	1,4296560 00	1,698967 00	1,6100510 00	1,7359430 00	1,4519490 00	1,445377 000	1,491691 000	1,427284 000	1,510979 000	1,650367 000	1,413790 000	1,314022 000	1,323488 000	1,268663 000	1,147789 000	1,170819 000	1,074537 000	1,441466 600	1,419005 640	0,183818 540
Mínimo	1,393228 000	1,3792590 00	1,3810240 00	1,516052 00	1,5111480 00	1,4311910 00	1,4068530 00	1,367871 000	1,460036 000	1,305379 000	1,375962 000	1,363408 000	1,301857 000	1,270700 000	1,047901 000	1,121960 000	1,046240 000	0,991630 000	0,997546 000	1,308902 000		
Máximo	1,962100 000	2,1898500 00	2,6713650 00	2,193378 000	13,940745 000	4,7492710 00	1,8887980 00	2,358468 000	1,658284 000	2,504737 000	3,334645 000	1,650367 000	3,201615 000	14,60816 8000	1,969722 000	1,531527 000	5,583316 000	2,190683 000	2,690841 000	4,762384 000		
Promedio	1,463719 270	1,5159920 54	1,5273414 32	1,6155527 351	1,9334252 70	1,6213458 11	1,5158126 22	1,489868 946	1,513800 081	1,420502 730	1,513846 081	1,472666 081	1,463094 081	3,303589 757	1,217435 811	1,217536 378	1,239088 162	1,183103 378	1,202348 108	1,564752 243		
Desviación estándar	0,090942 265	0,1487265 04	0,2065390 04	0,133637 774	0,20296701 19	0,5312706 86	0,0874071 52	0,153236 601	0,037649 665	0,191672 204	0,310080 764	0,058398 619	0,297341 421	4,387763 387	0,180992 634	0,076997 805	0,743251 784	0,215190 804	0,266762 609	0,548946 708		

Tabla nro. 57 de Resultados testing, métricas MDAPE de modelos univariados ETF Vanguard Group VTI

<

UNI-72-LSTM-LU ONG	22,068140 000	23,38858000 0	23,55128 0000	21,696540 000	22,254290 000	21,761540 000	22,581140 000	21,84154 0000	21,85679 0000	24,31237 0000	24,13652 0000	24,48904 0000	24,10391 0000	24,115900 000	26,21487 0000	24,24795 0000	24,18269 0000	24,120110 000	25,01905 0000	24,34792 0000	23,46450 8500	1,297339 903
UNI-73-LSTM-BA HDANAU	21,908120 000	21,67874000 0	21,66248 000	21,819070 000	22,073890 000	21,739970 000	21,841930 000	21,82299 0000	21,88730 0000	24,311070 000	24,56573 0000	24,58476 0000	24,23444 0000	24,32718 0000	25,05109 0000	24,02649 0000	23,96621 0000	24,20199 0000	25,76766 0000	24,04814 0000	23,27596 0000	1,402497 315
UNI-74-LSTM-LO CAL SOFT	21,960390 000	21,83069000 0	21,69416 0000	21,682150 000	21,725820 000	21,798240 000	21,711980 000	21,74698 0000	21,842110 000	24,34646 0000	24,73981 0000	24,12281 0000	25,63638 0000	24,51828 0000	25,26672 0000	24,92107 0000	24,03672 0000	24,38574 0000	24,39146 0000	24,61929 0000	23,34886 3000	1,501430 247
UNI-75-LSTM-MU LTHHEAD	21,968840 000	22,10611000 0	21,81072 000	21,733640 000	22,023560 000	21,789860 000	21,861900 000	22,54516 0000	22,55377 0000	24,13120 0000	29,76193 0000	24,16959 0000	24,13178 0000	24,14721 0000	24,811530 0000	24,08810 0000	24,22602 0000	24,95229 0000	24,20897 0000	23,92608 0000	23,54740 368	1,864836 368
UNI-80-CNN-LUO NG	29,840320 000	27,062171000 0	34,93152 0000	47,675810 000	42,528670 000	35,396640 000	40,406650 000	29,80180 0000	24,10045 0000	30,75572 0000	50,93398 0000	37,10025 0000	26,69228 0000	25,64379 0000	51,60623 0000	28,92797 0000	28,99754 0000	32,41882 0000	41,40917 0000	31,25597 0000	34,87428 7500	8,351441 636
UNI-30-CNN	22,103230 000	21,72260000 0	21,71676 0000	23,932950 000	24,125990 000	21,766850 000	21,825100 000	21,83173 0000	23,89162 0000	25,85606 0000	24,34202 0000	24,46835 0000	25,19186 0000	24,62865 0000	24,03938 0000	26,29709 0000	25,04622 0000	26,82789 0000	25,23016 0000	22,71841 1500	23,89814 1,670867 723	
Minimo	21,19711	20,99814	21,09634	21,68215	21,72582	21,73997	21,35251	21,729	21,84211	24,12079	24,02511	24,06999	24,10391	23,78268	23,98585	24,02184	23,96621	24,10297	24,19038	22,71841		
Máximo	29,84032	27,06217	34,93152	47,67581	42,52867	35,39664	40,40665	29,8018	24,10045	30,75572	50,93398	37,10025	26,69228	29,93742	51,60623	28,92797	28,99754	32,41882	41,40917	31,25597		
Promedio	22,232524	21,966357	22,41553	95	23,405429	23,07639	22,645807	5	22,806762	22,31905	22,24175	25,03185	25,97944	25,36333	24,73029	24,77764	26,09798	24,76369	25,00718	26,20761	26,17270	26,02598
Desviación estándar	1,8072183 80	2,980601 820	5,7360701 09	4,6060902 78	3,0103323 11	4,1547264 78	1,772375 185	0,605077 947	1,4665657 904	6,0011718 50	2,828843 335	0,667686 557	1,300651 010	6,042804 691	1,1100748 83	1,394356 193	2,363541 795	3,766245 517	2,103668 986			

Anexo nro. 4.

Se presentan los modelos con parámetros epochs 1.000, con early stopping y patience 30, train/test 90/10 y 90,5/9,5, para predicción del ETF Vanguard.

Tabla nro. 58 de Resultados de métricas con epochs 1.000 modelos ETF Vanguard Group - US9229087690

MODELOS	TRAIN/TEST	EPOCHS o EARLY STOPPING	MAE	MSE	RMSE	DA	MDAPE (%)	MAPE (%)
UNI-56-BIGRU-BAHDANAU	90-10	249	0,00201262	6,82E-06	0,00261175	83,01%	23,93519047	inf
	90.5	1.000	0,00191967	6,21E-06	0,00249137	80,63%	24,34175542	inf
UNI-55-BILSTM-BAHDANAU	90-10	501	0,00199375	6,73E-06	0,00259345	84,30%	23,61746511	inf
	90.5	568	0,00191254	6,17E-06	0,0024836	81,69%	24,14690857	inf
UNI-54-BIGRU-LUONG	90-10	1.000	0,00200707	6,88E-06	0,00262303	80,45%	23,65703378	inf
	90.5	912	0,00191826	6,22E-06	0,00249426	80,99%	24,17932479	inf
UNI-53-BILSTM-LUONG	90-10	453	0,00199513	6,76E-06	0,00259937	82,37%	23,57354072	inf
	90.5	556	0,00190684	6,09E-06	0,00246723	81,69%	24,17510977	inf
MV-59-BIGRU-LUONG	90-10	1.000	0,001884421	6,15E-06	0,002480345	79,17%	1,300348687	1,682884229
	90.5	1000	0,001866042	5,94E-06	0,002436105	77,82%	1,346651082	1,663072509
MV-58-BILSTM-LUONG	90-10	32	0,001911709	6,28E-06	0,002506022	80,45%	1,371995552	1,70604979
	90.5	658	0,001864955	5,82E-06	0,002412427	80,28%	1,314232163	1,668327426
MV-552KS-BILSTM-LUONG-AutoKeras-y-Scikeras	90-10	162	0,001916334	6,23E-06	0,002495204	80,13%	1,432119222	1,708298665
	90.5	32	0,001787492	5,47E-06	0,002337888	79,58%	1,297087939	1,600463414
MV-552-BILSTM-BAHDANAU-AutoKeras	90-10	805	0,002183218	8,48E-06	0,002912681	75,64%	1,416972147	1,95015872
	90.5	545	0,001943461	6,21E-06	0,002492487	79,17%	1,569313913	1,739724033
MV-550-BILSTM-BAHDANAU-AutoKeras	90-10	490	0,002149653	7,83E-06	0,002797334	78,21%	1,336825522	1,777203171
	90.5	32	0,001855877	5,86E-06	0,002421326	77,82%	1,359674247	1,671558434
MV-54-BIGRU-LUONG	90-10	1.000	0,001869646	5,99E-06	0,002446844	79,17%	1,376223443	1,668907314
	90.5	1.000	0,001813257	5,51E-06	0,002348134	79,93%	1,296644781	1,622685726
MV-532-BILSTM-LUONG-AutoKeras	90-10	497	0,001924003	6,44E-06	0,002538285	75,96%	1,261517403	1,721140579
	90.5	924	0,001910018	6,36E-06	0,002521399	78,52%	1,291046234	1,708229136
MV-530-BILSTM-LUONG-AutoKeras	90-10	651	0,002033919	7,36E-06	0,002713552	75,32%	1,353860206	1,817799065
	90.5	32	0,001790717	5,47E-06	0,002338265	79,58%	1,289191006	1,606951426
Mínimo			0,001787492	5,47E-06	0,002337888	75,32%	1,261517403	1,600463414
Máximo			0,002183218	8,48E-06	0,002912681	84,30%	24,34175542	1,95015872
Promedio			0,001932108417	6,39E-06	0,002523431583	79,62%	8,884968007	1,707093052
Desviación estándar			0,000097630	0,000000718	0,000137922	0,022311858	10,885513380	0,086713464