




UNIVERSIDAD TÉCNICA FEDERICO SANTA MARÍA
DEPARTAMENTO DE INDUSTRIAS

**PREDICCIÓN DE RETORNOS FINANCIEROS MEDIANTE REDES
LSTM: COMPARACIÓN DE CONFIGURACIONES CON DISTINTAS
COMBINACIONES DE RETORNOS DENTRO Y FUERA DEL PERÍODO
BURSÁTIL**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

AUTOR

DANIEL PEDREROS MEZA

PROFESOR GUÍA

Dr. WERNER KRISTJANPOLLER RODRÍGUEZ

PROFESOR COREFERENTE

BERNARDO PINCHEIRA SARMIENTO

VALPARAÍSO, AGOSTO 2026



CONSTANCIA DE VALIDACIÓN Y CONFIDENCIALIDAD DE MONOGRAFÍA A REPOSITORIO ACADÉMICO

1.- IDENTIFICACIÓN DEL TRABAJO ACADÉMICO

Tipo de monografía (marcar una opción): ☒ Memoria o trabajo de título ☐ Tesis de Postgrado

Título del trabajo: PREDICCIÓN DE RETORNOS FINANCIEROS MEDIANTE REDES LSTM: COMPARACIÓN DE CONFIGURACIONES CON DISTINTAS COMBINACIONES DE RETORNOS DENTRO Y FUERA DEL PERÍODO BURSÁTIL

Nombre del candidato(a): Daniel Gustavo Pedreros Meza

Carrera / Grado: Ingeniería Civil Industrial

Campus: Casa Central Valparaíso Departamento: Departamento de Industrias

2.- VALIDACIÓN DEL PROFESOR GUÍA/DIRECTOR DE TESIS

Yo, Werner Kristjanpoller Rodríguez, en mi calidad de profesor(a) guía/director(a) del trabajo académico mencionado anteriormente **DEJO CONSTANCIA** que:

- He revisado esta versión del documento y corresponde a la versión final aprobada del trabajo.
- El trabajo cumple con los requisitos académicos y de formato establecidos por la institución.

3.- EVALUACIÓN DE CONFIDENCIALIDAD POR PROPIEDAD INDUSTRIAL (marcar una opción)

X El trabajo **NO contiene** información que amerite confidencialidad y puede ser publicado de inmediato en repositorio con acceso abierto.

☐ El trabajo **CONTIENE** información con potenciales implicancias de propiedad industrial o intelectual y requiere un periodo de confidencialidad (**embargo**) por (**marcar una opción**):

☐ 6 meses ☐ 12 meses ☐ 2 años ☐ 3 años ☐ 5 años ☐ 10 años

Fundamentación de la necesidad de confidencialidad (obligatorio si se solicita embargo):

4.- FIRMAS

Profesor(a) guía o director(a) de memoria o tesis:

Fecha: 21-09-2026

Firma:

Estudiante o Candidato(a):

Fecha: 21-09-2026 Firma:



Este formulario debe ser insertado como página 2 de la memoria o tesis, completado y firmado por estudiante y profesor(a) antes de la entrega en portal PRISMA de Biblioteca USM.

Resumen

Esta investigación evalúa cómo la incorporación de retornos generados dentro y fuera del período bursátil modifica la predicción mediante redes LSTM optimizadas con Optuna. Se analizan los retornos de cierre a cierre (CtC), nocturno (CtO) e intradiario (OtC) en una muestra aleatoria de 50 acciones del S&P 500, utilizando como parámetros de descarga el 1 de mayo de 2020 y el 15 de mayo de 2026. Se estiman 12 configuraciones por activo, con una, dos o tres variables de entrada. Los datos se dividen cronológicamente en aproximadamente 70 % para entrenamiento, 10 % para validación y 20 % para prueba; este último bloque corresponde a las 304 jornadas finales. Para los tres retornos objetivo se comparan primero las métricas por acción entre LSTM y sus conjuntos del *Model Confidence Set* (MCS). Posteriormente se contrastan las métricas con ARIMA y Random Forest y se presentan los conjuntos del MCS que incorporan ambos modelos de referencia. Las mejoras simultáneas respecto de las versiones de una variable abarcan entre 5 y 15 acciones según la configuración; la mayor frecuencia corresponde a V10, que utiliza OtC y CtO para predecir OtC. El MCS interno conserva las cuatro LSTM en 28 acciones para CtC, 39 para CtO y 30 para OtC. Aunque las LSTM presentan menor RMSE que Random Forest en 38–43 acciones, los resultados del MCS con modelos de referencia requieren verificar su correspondencia con las métricas consolidadas. La evidencia muestra un aporte heterogéneo de las entradas adicionales y no permite afirmar una mejora generalizada ni una ventaja económica.

Palabras clave: predicción de retornos, LSTM, Optuna, retorno nocturno, retorno intradiario, Model Confidence Set.

Abstract

This study evaluates how incorporating returns generated within and outside regular trading hours changes the predictive performance of LSTM networks optimized with Optuna. Close-to-close (CtC), overnight (CtO), and intraday (OtC) returns are examined for a random sample of 50 S&P 500 stocks, using May 1, 2020, and May 15, 2026, as the download parameters. Twelve configurations with one, two, or three input variables are estimated separately for each stock. The data are divided chronologically into approximately 70 % for training, 10 % for validation, and 20 % for testing; the test set comprises the final 304 trading sessions. For all three target returns, the evaluation first compares stock-specific RMSE, MAE, and Hit Ratio across LSTM configurations and presents the LSTM-only Model Confidence Set (MCS). It then compares their metrics with ARIMA and Random Forest and presents a separate MCS including both benchmark models. Simultaneous improvements over the single-input configurations occur in 5 to 15 stocks, depending on the configuration; V10, which uses OtC and CtO to predict OtC, records the highest frequency. The internal MCS retains all four LSTM configurations in 28 stocks for CtC, 39 for CtO, and 30 for OtC. Although the LSTM models achieve lower RMSE than Random Forest in 38–43 stocks, the MCS results including benchmark models require verification against the consolidated metrics. The evidence indicates a heterogeneous contribution from additional inputs and does not establish a widespread improvement or an economic advantage.

Keywords: return forecasting, LSTM, Optuna, overnight return, intraday return, Model Confidence Set.

Tabla de Contenidos

1	Introducción	9
2	Problema de Investigación	11
3	Objetivos	14
3.1	Objetivo General	14
3.2	Objetivos Específicos	14
4	Alcance y Delimitación	15
4.1	Delimitación de la Muestra y Activos Analizados	15
4.2	Delimitación Temporal y Frecuencia de los Datos	15
4.3	División Temporal de los Datos	15
4.4	Delimitación Metodológica	16
5	Marco Teórico	18
5.1	Redes de Memoria a Corto y Largo Plazo (LSTM)	18
5.2	Fundamentos de la Descomposición de Retornos: Overnight e Intradía	19
5.3	Optimización Bayesiana y Optuna	21
5.4	Modelos de Referencia	21
5.4.1	Modelo Autorregresivo Integrado de Media Móvil (ARIMA)	21
5.4.2	Random Forest	22
5.5	Model Confidence Set (MCS)	23
6	Metodología	25

6.1	Selección de la Muestra y Horizonte Temporal	25
6.2	Formulación Matemática de las Variables de Retorno	25
6.3	Esquema de Particionamiento de Datos y Fuga de Información	27
6.4	Mecanismos para Evitar el Sesgo de Anticipación	28
6.5	Normalización de Características	29
6.6	Espacio de Búsqueda de Hiperparámetros de la Red LSTM en Optuna	30
6.7	Especificación y Ajuste de los Modelos de Referencia	32
6.7.1	Ajuste del Modelo ARIMA	32
6.7.2	Ajuste del Modelo Random Forest (RF)	32
6.8	Métricas y Procedimiento de Evaluación	33
6.9	Model Confidence Set (MCS)	34
6.9.1	MCS entre Configuraciones LSTM	36
6.9.2	MCS con ARIMA y Random Forest	36
7	Resultados	37
7.1	Comparación entre Configuraciones LSTM	37
7.1.1	Retorno de Cierre a Cierre: V1–V4	37
7.1.2	Retorno Nocturno: V5–V8	38
7.1.3	Retorno Intradía: V9–V12	38
7.2	Comparación con ARIMA y Random Forest	39
7.2.1	Modelos con Objetivo CtC	40
7.2.2	Modelos con Objetivo CtO	40
7.2.3	Modelos con Objetivo OtC	41

8	Discusión	42
8.1	Interpretación Financiera de la Descomposición de Retornos	42
8.2	Comparación entre las Configuraciones LSTM	43
8.3	Contraste con ARIMA y Random Forest	44
9	Limitaciones	45
9.1	Tamaño, Selección y Representatividad de la Muestra	45
9.2	Alcance Exclusivamente Predictivo	46
9.3	Alcance de la Comparación con los Modelos de Referencia	46
9.4	Variabilidad del Entrenamiento y Estabilidad de las Diferencias	47
9.5	Restricción Temporal y Regímenes Estructurales	48
9.6	Requerimiento Computacional y Costo de Calibración	49
10	Conclusiones	50
	Referencias	52
11	Anexos	55
11.1	Anexo A: Desglose Individual de Variaciones entre las 12 Versiones LSTM	55
11.1.1	Retorno objetivo CtC (V1–V4)	55
11.1.2	Retorno objetivo CtO (V5–V8)	57
11.1.3	Retorno objetivo OtC (V9–V12)	59
11.2	Anexo B: MCS entre Configuraciones LSTM	61
11.2.1	Retorno objetivo CtC	61
11.2.2	Retorno objetivo CtO	63

11.2.3	Retorno objetivo OtC	65
11.3	Anexo C: Métricas de ARIMA y Random Forest	67
11.3.1	Retorno objetivo CtC	67
11.3.2	Retorno objetivo CtO	69
11.3.3	Retorno objetivo OtC	71
11.4	Anexo D: MCS Reportado con Modelos de Referencia	73
11.4.1	Retorno objetivo CtC	73
11.4.2	Retorno objetivo CtO	75
11.4.3	Retorno objetivo OtC	77

Lista de Tablas

1	Configuraciones LSTM según variable objetivo y variables de entrada	30
2	Espacio de búsqueda de hiperparámetros para la Red LSTM optimizada en Optuna	31
3	Resultados de las configuraciones LSTM con objetivo CtC	37
4	Resultados de las configuraciones LSTM con objetivo CtO	38
5	Resultados de las configuraciones LSTM con objetivo OtC	39
6	Comparación de las configuraciones CtC con ARIMA y Random Forest	40
7	Comparación de las configuraciones CtO con ARIMA y Random Forest	40
8	Comparación de las configuraciones OtC con ARIMA y Random Forest	41
9	Variaciones individuales para CtC (parte 1 de 2)	55
10	Variaciones individuales para CtC (parte 2 de 2)	56
11	Variaciones individuales para CtO (parte 1 de 2)	57
12	Variaciones individuales para CtO (parte 2 de 2)	58
13	Variaciones individuales para OtC (parte 1 de 2)	59
14	Variaciones individuales para OtC (parte 2 de 2)	60
15	MCS interno para CtC (parte 1 de 2)	61
16	MCS interno para CtC (parte 2 de 2)	62
17	MCS interno para CtO (parte 1 de 2)	63
18	MCS interno para CtO (parte 2 de 2)	64
19	MCS interno para OtC (parte 1 de 2)	65
20	MCS interno para OtC (parte 2 de 2)	66
21	Métricas de los modelos de referencia para CtC (parte 1 de 2)	67

22	Métricas de los modelos de referencia para CtC (parte 2 de 2)	68
23	Métricas de los modelos de referencia para CtO (parte 1 de 2)	69
24	Métricas de los modelos de referencia para CtO (parte 2 de 2)	70
25	Métricas de los modelos de referencia para OtC (parte 1 de 2)	71
26	Métricas de los modelos de referencia para OtC (parte 2 de 2)	72
27	MCS referencias para CtC (parte 1 de 2)	73
28	MCS referencias para CtC (parte 2 de 2)	74
29	MCS referencias para CtO (parte 1 de 2)	75
30	MCS referencias para CtO (parte 2 de 2)	76
31	MCS referencias para OtC (parte 1 de 2)	77
32	MCS referencias para OtC (parte 2 de 2)	78

1 Introducción

La predicción de retornos en los mercados de renta variable sigue siendo un problema relevante en finanzas cuantitativas (Barazandeh et al., 2025; Fischer & Krauss, 2018). La hipótesis de eficiencia de los mercados sostiene que los precios incorporan la información disponible, lo que limita la posibilidad de obtener pronósticos sistemáticos fuera de muestra (Fischer & Krauss, 2018; Jiang, 2021). Al mismo tiempo, la literatura ha documentado anomalías y regularidades que motivan el estudio empírico de posibles fuentes de predictibilidad (Fischer & Krauss, 2018; Lou et al., 2019).

Una práctica habitual consiste en modelar series de retornos diarios calculados de cierre a cierre (*Close-to-Close*, CtC). Esta medida reúne en una sola observación la negociación diurna y el periodo en que el mercado permanece cerrado. Sin embargo, durante las horas sin negociación regular se publican noticias macroeconómicas, resultados corporativos y otros antecedentes que pueden afectar el precio de apertura (Akbas et al., 2022; Stübinger & Schneider, 2019). Esta información puede reflejarse en las brechas de apertura y en los retornos de cierre a apertura (*Close-to-Open*, CtO) (Stübinger & Schneider, 2019).

La literatura de microestructura estudia esta separación mediante el retorno nocturno o *overnight* (CtO) y el retorno intradiario (*Open-to-Close*, OtC) (Akbas et al., 2022; Lou et al., 2019). Lou et al. (2019) describen una dinámica de “tira y afloja” (*tug of war*) entre grupos de inversores que participan en distintos momentos del ciclo de negociación. En este marco, las diferencias entre la actividad de apertura y la negociación diurna pueden generar persistencias dentro de cada período y reversiones entre períodos adyacentes (Akbas et al., 2022; Lou et al., 2019). Akbas et al. (2022), por ejemplo, relacionan los retornos nocturnos positivos seguidos de correcciones diurnas

con presiones de demanda y procesos posteriores de ajuste de precios.

En paralelo, el pronóstico financiero ha incorporado métodos de aprendizaje automático y aprendizaje profundo (Barazandeh et al., 2025; Jiang, 2021). Los modelos ARIMA representan dependencias lineales, mientras que algoritmos como *Random Forest* permiten capturar relaciones no lineales a partir de variables rezagadas (Breiman, 2001; Oliver Muncharaz, 2020). Sin embargo, *Random Forest* procesa la información como variables tabulares y no mantiene un estado recurrente entre pasos temporales.

Las redes de memoria a corto y largo plazo (LSTM) constituyen una alternativa para este tipo de datos secuenciales (Fischer & Krauss, 2018; Jiang, 2021). Sus celdas de memoria y compuertas de olvido, entrada y salida permiten representar dependencias de distinta extensión temporal (Fischer & Krauss, 2018; Hochreiter & Schmidhuber, 1997).

Esta investigación evalúa redes LSTM calibradas mediante Optuna para predecir CtC, CtO y OtC. Su contribución empírica consiste en comparar 12 configuraciones que, para cada retorno objetivo, contrastan una versión de una variable con modelos que incorporan otros retornos como entradas. Primero se examinan las variaciones de RMSE, MAE y Hit Ratio y se presenta el *Model Confidence Set* (MCS) entre las cuatro LSTM de cada grupo. Posteriormente se contrastan sus métricas con ARIMA y *Random Forest* y se presenta el MCS que incorpora ambos modelos de referencia. El análisis considera una muestra aleatoria de 50 acciones del S&P 500 y utiliza como parámetros de descarga el 1 de mayo de 2020 y el 15 de mayo de 2026. Con esta configuración, la última sesión potencialmente observable corresponde al 14 de mayo de 2026. Cada acción se modela por separado y no se construye un portafolio.

2 Problema de Investigación

El modelado clásico de retornos financieros descansa sobre la formulación del retorno de cierre a cierre (*Close-to-Close*, CtC), denotado formalmente para un activo s en el día t como:

$$R_{CtC,s}^t = \ln \left(\frac{P_{Close,s}^t}{P_{Close,s}^{t-1}} \right) \quad (1)$$

Donde $P_{Close,s}^t$ representa el precio de cierre oficial del activo en el día t . Esta variable reúne la información generada durante la sesión y durante el periodo en que el mercado permanece cerrado (Lou et al., 2019). La separación entre el cierre del día $t - 1$ y la apertura del día t permite descomponer el retorno logarítmico diario en el componente nocturno (*Close-to-Open*, CtO) y el componente intradiario (*Open-to-Close*, OtC) (Akbas et al., 2022; Lou et al., 2019; Stübinger & Schneider, 2019), definidos como:

$$R_{CtO,s}^t = \ln \left(\frac{P_{Open,s}^t}{P_{Close,s}^{t-1}} \right) \quad (2)$$

$$R_{OtC,s}^t = \ln \left(\frac{P_{Close,s}^t}{P_{Open,s}^t} \right) \quad (3)$$

A partir de estas ecuaciones, la relación aditiva se expresa como (Akbas et al., 2022; Lou et al., 2019):

$$R_{CtC,s}^t = R_{CtO,s}^t + R_{OtC,s}^t \quad (4)$$

El problema de investigación consiste en determinar si modelar CtC, CtO y OtC exclusiva-

mente a partir de su propia historia omite información predictiva contenida en los otros retornos. La literatura de microestructura relaciona CtO y OtC con participantes y condiciones de negociación diferentes, por lo que pueden presentar dinámicas distintas (Akbas et al., 2022; Lou et al., 2019).

Durante el periodo nocturno se acumula información que influye en la apertura y puede asociarse con presiones de inversionistas minoristas (Akbas et al., 2022). En la sesión regular aumenta la participación institucional y pueden corregirse desequilibrios previos (Akbas et al., 2022; Lou et al., 2019). Estas diferencias motivan el análisis separado de CtO y OtC.

Desde una perspectiva computacional, el problema presenta tres dificultades principales:

1. **No estacionariedad y ruido:** La baja relación señal-ruido, la varianza cambiante (*volatility clustering*) y las colas pesadas dificultan el uso de modelos con supuestos restrictivos (Fischer & Krauss, 2018; Oliver Muncharaz, 2020; Singh et al., 2024).
2. **Fuga de información y sesgo temporal:** El diseño de la tubería debe impedir el uso de observaciones futuras durante el escalamiento, la calibración y el entrenamiento (Nuñez Perez et al., 2026).
3. **Espacio de búsqueda de hiperparámetros:** La selección de la ventana, las neuronas, las capas, la tasa de aprendizaje y la regularización dificulta una búsqueda manual reproducible (Fischer & Krauss, 2018; Singh et al., 2024).

El estudio evalúa 12 configuraciones LSTM organizadas en tres grupos según la variable objetivo. Dentro de cada grupo se compara una versión univariada con tres versiones que añaden uno o ambos componentes restantes:

- **V1–V4:** predicen CtC. V1 utiliza únicamente CtC; V2 añade CtO; V3 añade OtC; y V4 incorpora CtC, CtO y OtC.
- **V5–V8:** predicen CtO. V5 utiliza únicamente CtO; V6 añade CtC; V7 añade OtC; y V8 incorpora CtO, CtC y OtC.
- **V9–V12:** predicen OtC. V9 utiliza únicamente OtC; V10 añade CtO; V11 añade CtC; y V12 incorpora OtC, CtO y CtC.

Cada configuración con variables adicionales se compara con la versión que utiliza únicamente el retorno objetivo mediante RMSE, MAE y Hit Ratio. Las frecuencias de mejora se calculan por acción para los tres grupos, sin seleccionar uno a partir de sus resultados. Primero se examina la habilidad predictiva relativa entre las cuatro LSTM de cada grupo mediante el *Model Confidence Set* (MCS). Posteriormente se contrastan sus métricas con ARIMA y *Random Forest* y se presenta el MCS integrado por las cuatro LSTM y ambos modelos de referencia. Así se distingue el aporte de las entradas adicionales de la comparación entre familias de modelos para CtC, CtO y OtC.

A partir de estas consideraciones, la pregunta de investigación es la siguiente:

¿Cómo cambia el desempeño predictivo de las redes LSTM al incorporar los retornos CtC, CtO y OtC como variables de entrada adicionales, según RMSE, MAE y Hit Ratio, y qué evidencia aporta el MCS sobre su habilidad predictiva relativa, primero entre las cuatro LSTM de cada retorno objetivo y luego al incorporar ARIMA y Random Forest?

3 Objetivos

3.1 Objetivo General

Evaluar cómo la incorporación de los retornos de cierre a cierre (CtC), nocturno (CtO) e intradiario (OtC) modifica el desempeño predictivo fuera de muestra de redes LSTM calibradas mediante Optuna para 50 acciones del S&P 500, comparando las 12 configuraciones organizadas en tres grupos según su retorno objetivo —CtC (V1–V4), CtO (V5–V8) y OtC (V9–V12)— y posteriormente su desempeño frente a ARIMA y *Random Forest*, mediante RMSE, MAE, Hit Ratio y el *Model Confidence Set* (MCS).

3.2 Objetivos Específicos

Para dar cumplimiento al objetivo general, se proponen los siguientes objetivos específicos:

1. Recopilar y preprocesar los precios diarios de apertura y cierre entre el 1 de mayo de 2020 y el 15 de mayo de 2026, asegurando la correcta alineación de CtC, CtO y OtC.
2. Implementar 12 configuraciones LSTM agrupadas según sus objetivos CtC, CtO y OtC, con una, dos o tres variables de entrada.
3. Calibrar con Optuna la longitud de ventana, el número de capas y neuronas ocultas, la tasa de *dropout* y la tasa de aprendizaje de las redes LSTM.
4. Comparar cada grupo mediante RMSE, MAE y Hit Ratio, utilizando V1, V5 y V9 como puntos de comparación.
5. Evaluar mediante el MCS la habilidad predictiva relativa entre las cuatro configuraciones LSTM de cada retorno objetivo e identificar las que permanecen en M^* .
6. Contrastar posteriormente las 12 configuraciones con ARIMA y *Random Forest* para el mismo retorno objetivo, mediante las métricas por acción y un segundo MCS que incorpore ambos modelos de referencia a las cuatro LSTM de cada grupo.

4 Alcance y Delimitación

4.1 Delimitación de la Muestra y Activos Analizados

El estudio analiza una muestra aleatoria de 50 acciones del S&P 500. Cada activo constituye una unidad de análisis independiente, por lo que no se construye una cartera ni se agregan los retornos entre empresas. La composición de la muestra se presenta en los anexos. Debido al procedimiento de selección, no se garantiza una representación proporcional por sector o capitalización.

4.2 Delimitación Temporal y Frecuencia de los Datos

El período analizado se configura desde el 1 de mayo de 2020 hasta el 15 de mayo de 2026. Como yfinance interpreta esta última de manera exclusiva, la última sesión potencialmente disponible corresponde al 14 de mayo de 2026. La ventana incluye el lapso asociado con la pandemia de COVID-19, la recuperación posterior y episodios de tensión geopolítica. Entre estos últimos se encuentra la escalada del conflicto en Irán y de las tensiones asociadas con Estados Unidos durante 2026, que coincidió con movimientos en los precios energéticos, las cotizaciones bursátiles, los rendimientos de los bonos y la volatilidad financiera (International Monetary Fund, 2026). Por ello, el período abarca condiciones de mercado heterogéneas.

Los datos tienen frecuencia diaria y comprenden los precios de apertura (*Open*) y cierre (*Close*) de cada sesión. Con ellos se calculan los retornos de cierre a cierre (*Close-to-Close*, CtC), cierre a apertura (*Close-to-Open*, CtO) y apertura a cierre (*Open-to-Close*, OtC).

4.3 División Temporal de los Datos

Los datos de cada activo se dividen cronológicamente y sin aleatorización siguiendo una distribución efectiva aproximada de 70 % para entrenamiento, 10 % para validación y 20 % para

prueba. En la implementación, la validación corresponde al 10 % de la serie, la prueba se fija en las 304 jornadas finales —equivalentes aproximadamente al 20 %— y el entrenamiento contiene las observaciones anteriores restantes, que representan cerca del 70 %.

- **Entrenamiento (aproximadamente 70 %):** Contiene las secuencias iniciales restantes después de reservar la validación y las 304 jornadas de prueba. Se utiliza para estimar los parámetros de escalamiento y ajustar los pesos de las redes durante la calibración.
- **Validación:** Comprende el 10 % siguiente. Permite comparar los 50 ensayos de Optuna, descartar configuraciones poco prometedoras y seleccionar los hiperparámetros. Posteriormente, se une al conjunto de entrenamiento para ajustar el modelo final.
- **Prueba (aproximadamente 20 %):** Está formado por las 304 jornadas bursátiles finales. Se mantiene separado del ajuste y se utiliza para obtener las predicciones fuera de muestra, calcular las métricas y efectuar las comparaciones entre modelos.

4.4 Delimitación Metodológica

El análisis comprende los tres retornos objetivo: CtC (V1–V4), CtO (V5–V8) y OtC (V9–V12). Primero, cada configuración con variables adicionales se compara con la versión de una variable de su grupo y se presenta el *Model Confidence Set* (MCS) integrado únicamente por las cuatro LSTM. Posteriormente, se comparan sus métricas con ARIMA y *Random Forest* y se presenta un segundo MCS con los seis modelos del mismo retorno objetivo. Este segundo conjunto incluye todas las LSTM originales y no solo las retenidas en el MCS interno. Su interpretación queda condicionada a verificar la correspondencia con las métricas consolidadas, según lo señalado en las limitaciones.

La evaluación se limita al desempeño predictivo medido mediante RMSE, MAE y Hit Ratio. No se construye una estrategia de inversión ni se simulan operaciones de compra y venta; por tanto, los resultados no permiten evaluar rentabilidad económica.

5 Marco Teórico

5.1 Redes de Memoria a Corto y Largo Plazo (LSTM)

Las series financieras pueden presentar no linealidad, cambios de distribución y una baja relación señal-ruido, lo que limita a los modelos que representan únicamente dependencias lineales (Fischer & Krauss, 2018; Oliver Muncharaz, 2020). Las redes neuronales recurrentes (RNN) incorporan conexiones que permiten utilizar estados pasados, aunque su entrenamiento puede verse afectado por el desvanecimiento o la explosión del gradiente en secuencias extensas (Jiang, 2021).

La arquitectura de Red de Memoria a Corto y Largo Plazo (LSTM), propuesta por Hochreiter y Schmidhuber (1997), aborda este problema mediante celdas de memoria y compuertas que regulan el flujo de información (Fjellström, 2022). Cada celda mantiene un estado interno (C_t), mientras tres compuertas controlan la adición, retención y eliminación de información.

El procesamiento temporal de una celda LSTM en el instante t , ante un vector de entrada de características x_t y un estado oculto previo h_{t-1} , se rige por el siguiente sistema de ecuaciones matemáticas (Fischer & Krauss, 2018):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (7)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (9)$$

$$h_t = o_t \odot \tanh(C_t) \quad (10)$$

Donde f_t , i_t y o_t representan los vectores de activación de las compuertas de olvido (*forget gate*), entrada (*input gate*) y salida (*output gate*), respectivamente. El operador σ denota la función sigmoide logística, definida como $\sigma(z) = (1 + e^{-z})^{-1}$, que transforma las señales al intervalo $(0, 1)$. Las matrices W_f , W_i , W_c y W_o contienen los pesos asociados a las entradas y estados pasados, mientras que b_f , b_i , b_c y b_o son los vectores de sesgo correspondientes (Fischer & Krauss, 2018).

La compuerta de olvido determina cuánto del estado anterior C_{t-1} se conserva. La compuerta de entrada controla la incorporación de la información candidata $\tilde{C}_t$ al nuevo estado C_t . La compuerta de salida define la parte del estado de celda que se transmite al estado oculto h_t (Fischer & Krauss, 2018). Esta estructura permite representar dependencias temporales que una especificación tabular no modela de forma explícita.

5.2 Fundamentos de la Descomposición de Retornos: Overnight e Intradiario

El retorno de cierre a cierre (*Close-to-Close*, CtC) resume en una sola observación la negociación diurna y el periodo nocturno. La literatura de microestructura señala que esta agregación puede ocultar diferencias en los participantes, la información y los flujos de órdenes presentes en

cada periodo (Akbas et al., 2022; Lou et al., 2019).

El retorno logarítmico diario se descompone de manera exacta en el retorno nocturno (*Close-to-Open*, CtO), acumulado entre el cierre previo y la apertura, y el retorno intradiario (*Open-to-Close*, OtC), generado durante la sesión regular (Akbas et al., 2022; Lou et al., 2019).

Una interpretación de esta descomposición es la dinámica de *tug of war* descrita por Lou et al. (2019), según la cual distintos grupos de inversores participan con diferente intensidad en ambos periodos:

1. **Inversores minoristas y periodo nocturno (CtO):** Durante el cierre del mercado se acumulan noticias y anuncios corporativos. Parte de las órdenes asociadas con esta información se ejecuta en la apertura, donde la participación minorista y los límites de atención pueden contribuir a presiones de demanda (Akbas et al., 2022; Lou et al., 2019).
2. **Inversores institucionales y periodo intradiario (OtC):** Durante la sesión regular aumenta la participación de creadores de mercado, fondos y arbitrajistas. Su actividad puede corregir parte de las presiones observadas en la apertura y generar patrones de reversión intradiaria (Akbas et al., 2022; Stübinger & Schneider, 2019).

Akbas et al. (2022) encuentran que las reversiones intradiarias contienen información sobre retornos futuros. Una explicación propuesta es que los límites de capital y la aversión al riesgo pueden llevar a ajustes incompletos o excesivos durante la sesión. Esta evidencia motiva la incorporación explícita de CtO y OtC como entradas de los modelos, sin presuponer que su aporte será uniforme entre activos.

5.3 Optimización Bayesiana y Optuna

El desempeño de una red depende de hiperparámetros como la tasa de aprendizaje, la regularización y la dimensión de las capas ocultas (Singh et al., 2024). La búsqueda en cuadrícula (*grid search*) y la búsqueda aleatoria (*random search*) pueden requerir numerosas evaluaciones y no utilizan los resultados previos para orientar la selección de nuevos puntos (Singh et al., 2024; Yilmaz & Tcrol, 2025).

La optimización bayesiana trata la función de validación como una caja negra y utiliza los resultados de ensayos anteriores para orientar la evaluación de nuevas configuraciones. Optuna implementa, entre otros métodos, el algoritmo *Tree-structured Parzen Estimator* (TPE), que concentra progresivamente el muestreo en regiones prometedoras del espacio de hiperparámetros sin abandonar su exploración (Akiba et al., 2019; Nuñez Perez et al., 2026). En comparación con una cuadrícula exhaustiva, este enfoque puede reducir el número de evaluaciones necesarias para encontrar configuraciones competitivas (Singh et al., 2024).

5.4 Modelos de Referencia

Para evaluar el aporte de las variantes LSTM, sus resultados se comparan con dos modelos de referencia: ARIMA como especificación lineal y Random Forest como alternativa no lineal tabular.

5.4.1. Modelo Autorregresivo Integrado de Media Móvil (ARIMA)

El modelo ARIMA(p,d,q) representa la aproximación paramétrica lineal clásica más difundida para el análisis y pronóstico de series temporales univariadas en finanzas cuantitativas (Oliver

Muncharaz, 2020). Un modelo ARIMA descompone la evolución de una variable estacionaria mediante un componente autorregresivo lineal de orden p (que captura la dependencia lineal de los rezagos históricos) y un componente de media móvil de orden q (que modela el impacto de los choques estocásticos pasados y errores de predicción) (Oliver Muncharaz, 2020).

Matemáticamente, la formulación de una variable univariada diferenciada $Y_t = (1 - B)^d X_t$ bajo un proceso ARIMA(p, d, q) se define como (Oliver Muncharaz, 2020):

$$Y_t = \phi_0 + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t - \sum_{j=1}^q \theta_j \varepsilon_{t-j} \quad (11)$$

En esta expresión, ϕ_i representa los coeficientes autorregresivos y θ_j los parámetros de media móvil. El operador B corresponde al rezago, de modo que $BX_t = X_{t-1}$, mientras que d es el orden de diferenciación. El término ε_t representa un proceso de ruido blanco con media cero, varianza constante y ausencia de autocorrelación lineal (Oliver Muncharaz, 2020).

La especificación ARIMA representa dependencias lineales y puede resultar limitada cuando la serie contiene relaciones no lineales, cambios de volatilidad o asimetrías que no se incorporan explícitamente (Oliver Muncharaz, 2020).

5.4.2. Random Forest

El algoritmo Random Forest, propuesto por Breiman (2001), es un método de ensamble que combina múltiples árboles de decisión entrenados con muestras y subconjuntos de variables aleatorios.

Random Forest introduce variación entre los árboles mediante dos mecanismos habituales:

- **Bagging (*Bootstrap Aggregating*):** Cada árbol se entrena con una muestra obtenida con

reemplazo a partir del conjunto de entrenamiento (Breiman, 2001).

- **Selección de variables:** El método puede restringir las variables consideradas en cada división para reducir la correlación entre árboles. La configuración concreta depende de los parámetros del estimador utilizado (Breiman, 2001).

Para una tarea de regresión sobre series financieras, el estimador final de *Random Forest*, $\tilde{g}(x)$, consolida el pronóstico mediante el promedio de las estimaciones de los q árboles individuales entrenados (Breiman, 2001):

$$\tilde{g}(x) = \frac{1}{q} \sum_{l=1}^q \hat{g}_l(x) \quad (12)$$

Donde $\hat{g}_l(x)$ denota la predicción del l -ésimo árbol de regresión (Breiman, 2001). Los modelos *Random Forest* pueden representar interacciones no lineales entre rezagos, pero procesan las observaciones como variables tabulares. A diferencia de una LSTM, no mantienen un estado recurrente entre pasos temporales (Fischer & Krauss, 2018; Oliver Muncharaz, 2020).

5.5 Model Confidence Set (MCS)

El *Model Confidence Set*, propuesto por Hansen et al. (2011), identifica dentro de un conjunto inicial de modelos M_0 el subconjunto M^* cuya habilidad predictiva no puede distinguirse al nivel de significancia seleccionado. Para ello, considera la variabilidad temporal de las diferencias de pérdida y no solo el error promedio.

Para dos modelos i y j , la pérdida diferencial en el periodo t se define como:

$$d_{ij,t} = L(Y_t, \hat{Y}_{i,t}) - L(Y_t, \hat{Y}_{j,t}), \quad (13)$$

donde $L(\cdot)$ representa la función de pérdida utilizada para evaluar los pronósticos. Sobre el conjunto de modelos vigente M , el procedimiento contrasta la hipótesis nula de habilidad predictiva equivalente:

$$H_{0,M} : E(d_{ij,t}) = 0, \quad \forall i, j \in M. \quad (14)$$

El algoritmo parte de M_0 . Si la hipótesis nula es rechazada, elimina el modelo con peor desempeño relativo y repite la prueba hasta que deja de rechazarse. Las especificaciones supervivientes conforman M^* (Hansen et al., 2011).

La distribución de las estadísticas de prueba se aproxima mediante remuestreo, lo que permite considerar la dependencia temporal de las pérdidas. La pertenencia a M^* indica que un modelo no fue eliminado por inferioridad predictiva relativa. No representa la probabilidad de que sea el mejor modelo ni demuestra rentabilidad económica (Hansen et al., 2011).

6 Metodología

6.1 Selección de la Muestra y Horizonte Temporal

La unidad de análisis corresponde a una acción individual. A partir del universo de acciones del S&P 500 se seleccionaron aleatoriamente 50 activos, los cuales se modelan de manera independiente y no como componentes de un portafolio. La investigación no define ponderaciones, reglas de formación de cartera ni agregación de retornos entre empresas. La lista resultante se mantiene fija durante el experimento y se documenta en el capítulo de Alcance y en los anexos de resultados.

Para cada activo se configura como fecha inicial de descarga el 1 de mayo de 2020 y como límite final el 15 de mayo de 2026. La diferencia entre ambos parámetros es de 2.205 días calendario, equivalentes a 6 años y 14 días. En yfinance, el parámetro final es exclusivo. Por ello, la última fecha potencialmente descargada es el 14 de mayo de 2026, siempre que corresponda a una sesión con datos disponibles. Se emplean los precios de apertura y cierre para construir los retornos CtC, CtO y OtC. Las diferencias en días negociados, fecha inicial de cotización, eventos corporativos o registros disponibles se gestionan separadamente para cada serie antes de formar las secuencias temporales, sin completar observaciones futuras ni mezclar información entre activos.

6.2 Formulación Matemática de las Variables de Retorno

Para capturar de manera desagregada el comportamiento de los activos durante las fases activas y pasivas de negociación bursátil, se calculan retornos logarítmicos para cada activo s y jornada de mercado t , en concordancia con el código ejecutado:

1. **Retorno tradicional de cierre a cierre (*Close-to-Close*, CtC):** Representa el retorno diario completo medido entre el precio oficial de cierre de la sesión actual ($P_{Close,s}^t$) y el precio de

cierre de la sesión inmediata anterior ($P_{Close,s}^{t-1}$):

$$R_{CtC,s}^t = \ln \left(\frac{P_{Close,s}^t}{P_{Close,s}^{t-1}} \right) \quad (15)$$

2. **Retorno nocturno o de no negociación (*Close-to-Open*, CtO):** Captura el retorno acumulado fuera del horario regular (periodo *overnight*), calculado entre el precio de apertura de la jornada actual ($P_{Open,s}^t$) y el precio de cierre de la jornada previa ($P_{Close,s}^{t-1}$):

$$R_{CtO,s}^t = \ln \left(\frac{P_{Open,s}^t}{P_{Close,s}^{t-1}} \right) \quad (16)$$

3. **Retorno intradiario o diurno (*Open-to-Close*, OtC):** Representa el retorno generado de manera exclusiva durante el horario regular de negociación activa del día t , medido entre el precio oficial de cierre ($P_{Close,s}^t$) y el precio de apertura oficial ($P_{Open,s}^t$):

$$R_{OtC,s}^t = \ln \left(\frac{P_{Close,s}^t}{P_{Open,s}^t} \right) \quad (17)$$

Debido al uso de logaritmos, la descomposición diaria es aditiva y exacta:

$$R_{CtC,s}^t = R_{CtO,s}^t + R_{OtC,s}^t \quad (18)$$

El código aplica `shift(-1)` a CtO únicamente en el grupo cuyo objetivo es OtC (V9–V12). Con este desplazamiento, la última posición de la ventana puede contener el CtO de la jornada cuyo OtC se pronostica. Sin embargo, esta información solo ingresa efectivamente en V10 y V12, porque son las configuraciones del grupo que incluyen CtO como variable de entrada. Por

ello, V10 y V12 representan pronósticos formulados después de observar la apertura de la jornada objetivo. V1–V8 no aplican el desplazamiento y emplean observaciones anteriores a la variable objetivo; V9 y V11 tampoco incorporan CtO como entrada.

6.3 Esquema de Particionamiento de Datos y Fuga de Información

Los datos se dividen cronológicamente para limitar la fuga de información (*information leakage* o *look-ahead bias*) (Nuñez Perez et al., 2026). El código no baraja las observaciones. La distribución efectiva es aproximadamente 70 % para entrenamiento, 10 % para validación y 20 % para prueba. En particular, la validación se calcula como el 10 % de la serie disponible mediante `val_size = int(total_len * 0.10)`, el bloque final de prueba se fija en 304 jornadas equivalentes aproximadamente al 20 % y el entrenamiento contiene las secuencias anteriores restantes, cercanas al 70 %. Los porcentajes exactos pueden variar ligeramente según la cobertura del activo y la longitud de ventana seleccionada.

- **Conjunto de Entrenamiento (*Train Set*, aproximadamente 70 %):** Contiene las secuencias iniciales restantes después de reservar validación y test. Se utiliza para ajustar los pesos y sesgos de la red LSTM.
- **Conjunto de Validación (*Validation Set*, 10 %):** Segmento posterior al entrenamiento y anterior al test, empleado por Optuna para evaluar cada configuración. El código utiliza el mecanismo de poda de Optuna durante 80 épocas de optimización. Después de seleccionar los hiperparámetros, este bloque se incorpora al entrenamiento del modelo final. No implementa detención temprana por paciencia.
- **Conjunto de Prueba Final (*Test Set*, aproximadamente 20 %):** Comprende 304 días bur-

sátiles, mantenidos fijos entre los modelos. Permanece aislado de la selección de hiperparámetros y se utiliza para generar las predicciones fuera de muestra, calcular RMSE, MAE y Hit Ratio y obtener las pérdidas empleadas en las comparaciones mediante el MCS.

6.4 Mecanismos para Evitar el Sesgo de Anticipación

El control del *look-ahead bias* se aplica en cuatro etapas:

1. **Alineación temporal:** El desplazamiento `shift(-1)` de CtO se aplica únicamente cuando el objetivo es OtC. En V10 y V12, que incluyen CtO como entrada, la última posición de la ventana contiene el retorno nocturno de la jornada cuyo OtC se pronostica. Como ese retorno se conoce en la apertura, ambas versiones corresponden a pronósticos posteriores a la apertura. V1–V8 no aplican el desplazamiento, mientras que V9 y V11 no utilizan CtO como entrada.
2. **Partición cronológica:** Aproximadamente el 70 % inicial se destina al entrenamiento, el 10 % siguiente a la validación y el 20 % final a la prueba, representado por 304 jornadas. Ninguna observación posterior puede ingresar en un bloque anterior mediante muestreo aleatorio.
3. **Escalamiento estimado únicamente con entrenamiento:** El escalador `MinMaxScaler` se ajusta con el tramo anterior a la validación. Cuando CtO se desplaza mediante `shift(-1)`, el límite de ajuste se retrocede una fila para impedir que el valor alineado con el primer día de validación intervenga en los mínimos y máximos. Una vez estimado, el mismo transformador se aplica sin reajuste a toda la serie.

4. **Aislamiento del conjunto de prueba:** Optuna recibe solamente los tensores de entrenamiento y validación durante sus 50 ensayos. El test no participa en la función objetivo, en la poda ni en la selección de hiperparámetros. Después de la calibración, el modelo final se ajusta con la unión de entrenamiento y validación. Sus predicciones sobre las 304 observaciones de prueba, equivalentes aproximadamente al 20 % final, permiten calcular residuos, métricas y pérdidas para las comparaciones, sin volver a ajustar los modelos a partir de los resultados del test.

Con este procedimiento, la estimación del escalador, la optimización de hiperparámetros y el ajuste de los pesos utilizan información anterior al test. La única información de la jornada objetivo incorporada como entrada es CtO en V10 y V12, disponible después de la apertura de la jornada cuyo OtC se pronostica.

6.5 Normalización de Características

Las redes neuronales son sensibles a la escala de las variables de entrada, por lo que una normalización adecuada puede facilitar su entrenamiento (Passalis et al., 2020). En esta investigación se ajusta un único escalador Min–Max (*MinMaxScaler*) por activo s , con rango $[0, 1]$, utilizando conjuntamente las columnas CtC, CtO y OtC. Esto se realiza incluso cuando una configuración emplea solo una o dos de ellas como entradas.

La normalización matemática de la variable de retorno genérica X_s^t se realiza de la siguiente manera:

$$\tilde{X}_s^t = \frac{X_s^t - \min(X_s^{\text{Train}})}{\max(X_s^{\text{Train}}) - \min(X_s^{\text{Train}})} \quad (19)$$

Los límites mínimo y máximo ($\min(X_s^{\text{Train}})$ y $\max(X_s^{\text{Train}})$) se calculan exclusivamente con el conjunto de entrenamiento de cada activo (Nuñez Perez et al., 2026). Los mismos parámetros se aplican después a validación y test sin volver a ajustar el escalador. Así se evita que la distribución de los bloques posteriores influya en la normalización.

6.6 Espacio de Búsqueda de Hiperparámetros de la Red LSTM en Optuna

La calibración de la red LSTM se realiza mediante el muestreador *Tree-structured Parzen Estimator* (TPE) de Optuna. La búsqueda utiliza únicamente los conjuntos de entrenamiento y validación (Akiba et al., 2019; Nuñez Perez et al., 2026).

Se evalúan 12 versiones de redes LSTM organizadas en tres grupos según el retorno objetivo. Cada grupo contiene configuraciones con una, dos o tres variables de entrada. La Tabla 1 resume esta estructura.

Tabla 1: Configuraciones LSTM según variable objetivo y variables de entrada

Versión	Objetivo	Variables de entrada	N.º de variables
V1	CtC	CtC	1
V2	CtC	CtC y CtO	2
V3	CtC	CtC y OtC	2
V4	CtC	CtC, CtO y OtC	3
V5	CtO	CtO	1
V6	CtO	CtO y CtC	2
V7	CtO	CtO y OtC	2
V8	CtO	CtO, CtC y OtC	3
V9	OtC	OtC	1
V10	OtC	OtC y CtO	2
V11	OtC	OtC y CtC	2
V12	OtC	OtC, CtO y CtC	3

Las configuraciones con variables adicionales se comparan con la versión que utiliza únicamente el retorno objetivo: V2–V4 frente a V1, V6–V8 frente a V5 y V10–V12 frente a V9. Para cada acción se examinan las variaciones de RMSE y MAE y el cambio del Hit Ratio. Se informa cuántos activos presentan una mejora en cada métrica y cuántos mejoran simultáneamente en las

tres. Los conteos se utilizan como descripción de la muestra, no para seleccionar un único grupo ni como prueba de significancia estadística.

La evaluación sigue el mismo orden para los tres retornos objetivo. Primero se examinan las métricas entre configuraciones LSTM y se presenta el MCS interno de las cuatro versiones de cada grupo. Posteriormente se contrastan sus métricas con ARIMA y *Random Forest* y se presenta el MCS que incorpora ambos modelos de referencia. Esta segunda comparación parte de las cuatro LSTM originales y de los dos modelos de referencia, sin filtrar las configuraciones según su permanencia en el MCS interno. La correspondencia de los resultados reportados con las métricas consolidadas se considera expresamente en su interpretación.

Optuna explora el espacio de hiperparámetros presentado en la Tabla 2.

Tabla 2: Espacio de búsqueda de hiperparámetros para la Red LSTM optimizada en Optuna

Hiperparámetro	Límite Inferior	Límite Superior	Tipo de Muestreo
<i>time_step</i> (Rezagos de ventana)	10	40	Entero discreto (paso 1)
<i>hidden_dim</i> (Neuronas ocultas)	24	64	Entero discreto (paso 1)
<i>num_layers</i> (Capas LSTM)	2	4	Entero discreto (paso 1)
<i>dropout_rate</i> (Tasa de dropout)	0,05	0,15	Flotante continuo
<i>lr</i> (Tasa de aprendizaje)	0,005	0,02	Flotante logarítmico

Para cada acción y versión se ejecutan 50 ensayos de Optuna. Cada ensayo entrena durante un máximo de 80 épocas con Adam y minimiza el RMSE de validación, admitiendo la poda anticipada de ensayos poco prometedores. Con los mejores hiperparámetros se inicializa un modelo nuevo y se entrena durante 150 épocas sobre la unión de entrenamiento y validación. El código entrega el tensor completo en cada actualización, por lo que no utiliza mini-lotes ni optimiza un tamaño de lote.

6.7 Especificación y Ajuste de los Modelos de Referencia

Se ajustan modelos ARIMA y *Random Forest* de manera independiente para cada una de las 50 acciones y para cada retorno objetivo, CtC, CtO y OtC. Cada modelo utiliza únicamente la serie del retorno que se desea predecir, sin incorporar los otros retornos como variables de entrada.

6.7.1. Ajuste del Modelo ARIMA

El modelo $ARIMA(p, 0, q)$ se calibra de forma individual sobre la serie de retornos de cada activo. La especificación fija $d = 0$, por lo que el modelo opera como un proceso $ARMA(p, q)$ sobre los retornos en nivel (Oliver Muncharaz, 2020).

Los órdenes p y q se seleccionan en el espacio $p, q \in \{0, 1, 2, 3, 4\}$ mediante el Criterio de Información de Akaike (AIC) (Oliver Muncharaz, 2020). El procedimiento se ejecuta por separado para cada acción.

6.7.2. Ajuste del Modelo Random Forest (RF)

El modelo *Random Forest* se ajusta sobre una matriz de rezagos del retorno diario de cada activo. Sus hiperparámetros se seleccionan mediante una búsqueda en cuadrícula que minimiza el error de validación temporal:

- **Tamaño de rezago temporal (*window_size*):** Exploración discreta de rezagos acumulados desde $w \in [5, 30]$ días.
- **Densidad de árboles (*n_estimators*):** Evaluando conjuntos entre 50 y 200 estimadores independientes.

- **Profundidad máxima del bosque** (*max_depth*): Restringiendo el crecimiento de los árboles a un rango discreto de 3 a 10 niveles de profundidad para evitar sobreajuste.
- **Muestras mínimas para división** (*min_samples_split*): Ajustado discrecionalmente entre 2 y 10 muestras en nodos intermedios.

6.8 Métricas y Procedimiento de Evaluación

El desempeño fuera de muestra se evalúa por separado para cada acción mediante RMSE, MAE y Hit Ratio. Para una serie de prueba con N_s observaciones del activo s , sus valores reales $y_{s,t}$ y sus predicciones $\hat{y}_{s,t}$, las métricas se definen como:

$$RMSE_s = \sqrt{\frac{1}{N_s} \sum_{t=1}^{N_s} (y_{s,t} - \hat{y}_{s,t})^2} \quad (20)$$

$$MAE_s = \frac{1}{N_s} \sum_{t=1}^{N_s} |y_{s,t} - \hat{y}_{s,t}| \quad (21)$$

$$Hit\ Ratio_s = \frac{100}{N_s} \sum_{t=1}^{N_s} \mathbb{I}[\text{sign}(y_{s,t}) = \text{sign}(\hat{y}_{s,t})] \quad (22)$$

Las variaciones de RMSE y MAE respecto de la configuración de una variable de cada grupo se expresan porcentualmente como:

$$\Delta E_s = 100 \left(\frac{E_{\text{modelo},s} - E_{\text{ref},s}}{E_{\text{ref},s}} \right), \quad E \in \{RMSE, MAE\}. \quad (23)$$

Un valor negativo indica una reducción del error. El cambio del Hit Ratio se calcula mediante la diferencia directa entre ambas configuraciones y se informa en puntos porcentuales. El

RMSE y el MAE utilizados corresponden a la escala original de los retornos; el RMSE de validación o prueba en escala normalizada no se mezcla con las métricas de los modelos de referencia. Los conteos se calculan antes del redondeo y emplean desigualdades estrictas: menor error o mayor Hit Ratio. Las magnitudes de las variaciones se interpretan de manera descriptiva y no como prueba de significancia estadística.

6.9 Model Confidence Set (MCS)

Para comparar la habilidad predictiva relativa dentro de cada retorno objetivo se utiliza el *Model Confidence Set* (MCS) de Hansen et al. (2011).

El procedimiento busca determinar, a partir de un conjunto inicial de modelos competidores (M_0), el subconjunto (M^*) que no es eliminado por inferioridad predictiva relativa al nivel de significancia $\alpha = 0,15$. Se presentan primero los conjuntos integrados únicamente por LSTM y después los que incorporan ARIMA y Random Forest. Ambas comparaciones se realizan por acción y retorno objetivo, con conjuntos iniciales diferentes; la pertenencia a M^* se interpreta únicamente respecto de los competidores incluidos.

El algoritmo opera de manera iterativa a través de las siguientes etapas estadísticas (Hansen et al., 2011):

1. **Cálculo de la Pérdida Diferencial:** Para cada jornada de prueba t en el conjunto de test ($t = 1, \dots, N_t$), se calcula la pérdida cuadrática de cada modelo individual i . En concordancia con el código ejecutado, la matriz entregada al procedimiento contiene los residuos elevados al cuadrado. La pérdida diferencial entre cualquier pareja de modelos competidores i y j se define como:

$$d_{ij,t} = L \left(Y_t, \hat{Y}_{i,t} \right) - L \left(Y_t, \hat{Y}_{j,t} \right) \quad (24)$$

Donde la función utilizada es $L(Y_t, \hat{Y}_{i,t}) = (Y_t - \hat{Y}_{i,t})^2$.

2. **Evaluación de la Hipótesis Nula:** El test evalúa secuencialmente sobre el conjunto de modelos superviviente $M \subset M_0$ la hipótesis nula de Habilidad Predictiva Equivalente (EPA):

$$H_{0,M} : E(d_{ij,t}) = 0, \quad \forall i, j \in M \quad (25)$$

Frente a la hipótesis alternativa de que existe al menos un modelo estadísticamente inferior en el conjunto.

3. **Cálculo de la Estadística de Prueba:** La implementación se realiza con la clase MCS del paquete arch. Como el código no especifica el método, se utiliza la opción predeterminada R, correspondiente al estadístico de rango $T_{R,M}$ (Hansen et al., 2011):

$$T_{R,M} = \max_{i,j \in M} \frac{|\bar{d}_{ij}|}{\sqrt{\widehat{\text{var}}(\bar{d}_{ij})}} \quad (26)$$

Donde $\bar{d}_{ij} = \frac{1}{N_t} \sum_{t=1}^{N_t} d_{ij,t}$ denota el promedio muestral de la pérdida diferencial y $\widehat{\text{var}}(\bar{d}_{ij})$ representa una estimación consistente de la varianza asintótica de la media de pérdida diferencial (Hansen et al., 2011).

4. **Procedimiento de Remuestreo y Eliminación:** La distribución nula del estadístico se aproxima mediante el *stationary bootstrap*, opción predeterminada del paquete. La ejecución utiliza bloques de longitud 10 y 1.000 réplicas. Si el p-valor del conjunto es inferior a $\alpha = 0,15$, se rechaza la hipótesis nula EPA y el método de rango elimina iterativamente la especificación con peor desempeño relativo según los diferenciales estandarizados. El proceso con-

tinúa hasta que la hipótesis EPA deja de rechazarse. Los modelos restantes conforman el conjunto M^* con un nivel de confianza del 85 % (Hansen et al., 2011).

6.9.1. MCS entre Configuraciones LSTM

El conjunto inicial contiene las cuatro configuraciones del retorno objetivo: V1–V4 para CtC, V5–V8 para CtO y V9–V12 para OtC. Esta comparación examina si el procedimiento elimina alguna versión por inferioridad predictiva relativa frente a las demás LSTM del mismo grupo. Se informa la pertenencia de cada versión a M^* y cuántas acciones conservan una o varias configuraciones.

6.9.2. MCS con ARIMA y Random Forest

Posteriormente se presenta una comparación independiente cuyo conjunto inicial contiene las cuatro LSTM del grupo, ARIMA y Random Forest para el mismo retorno objetivo. No se reutiliza M^* del análisis interno como conjunto de partida. Esta distinción evita confundir la comparación entre variables de entrada de las LSTM con la comparación entre familias de modelos. Para interpretar conjuntamente sus resultados y las métricas, las pérdidas deben corresponder a las mismas jornadas, predicciones y escala del retorno.

Los conteos se obtienen de los conjuntos reportados por acción. La ausencia de residuos LSTM y del código de la ejecución actual limita la verificación de su correspondencia con las métricas consolidadas, según lo señalado en las limitaciones. La permanencia en M^* no demuestra equivalencia exacta, no representa la probabilidad de ser el mejor modelo ni prueba rentabilidad económica (Hansen et al., 2011). Los conjuntos de distintos retornos objetivo tampoco comparan directamente su precisión.

7 Resultados

Se evaluó el desempeño fuera de muestra de las 12 configuraciones LSTM para 50 acciones del S&P 500. El análisis se divide en tres grupos según el retorno objetivo: CtC (V1–V4), CtO (V5–V8) y OtC (V9–V12). Dentro de cada grupo, las versiones con variables adicionales se comparan con la configuración que utiliza únicamente el retorno objetivo. A continuación se presenta el MCS entre las cuatro LSTM del grupo y, posteriormente, la comparación con ARIMA y *Random Forest*. Los resultados individuales se encuentran en los Anexos A, B, C y D.

7.1 Comparación entre Configuraciones LSTM

El RMSE y el MAE se evalúan en la escala original de los retornos. Los conteos indican el número de acciones en que cada versión obtiene menor error o mayor Hit Ratio que la configuración de una variable de su mismo grupo. La última columna informa cuántas veces cada modelo pertenece a M^* en el MCS integrado únicamente por las cuatro LSTM correspondientes. Estos conteos pueden superponerse porque más de una configuración puede permanecer en M^* para una misma acción.

7.1.1. Retorno de Cierre a Cierre: V1–V4

V1 utiliza solamente CtC y constituye el punto de comparación de las otras tres versiones. La Tabla 3 presenta los resultados del grupo.

Tabla 3: Resultados de las configuraciones LSTM con objetivo CtC

Versión	Entradas	Menor RMSE	Menor MAE	Mayor Hit Ratio	Las tres	Pertenece a M^*
V1	CtC	–	–	–	–	42
V2	CtC y CtO	24	28	20	11	39
V3	CtC y OtC	19	27	12	6	35
V4	CtC, CtO y OtC	27	26	15	10	41

V4 registra la mayor frecuencia de reducción del RMSE, con 27 acciones, mientras que V2 presenta la mayor frecuencia de reducción del MAE y de mejora conjunta de las tres métricas, con 28 y 11 acciones. Sin embargo, ninguna de las tres versiones supera simultáneamente a V1 en la mayoría de los activos. En el MCS interno, las cuatro configuraciones permanecen conjuntamente en M^* en 28 acciones y solo una sobrevive en 7. Por tanto, el grupo no identifica una configuración dominante para toda la muestra.

7.1.2. Retorno Nocturno: V5–V8

V5 utiliza solamente CtO y constituye el punto de comparación de V6–V8. La Tabla 4 resume este grupo.

Tabla 4: Resultados de las configuraciones LSTM con objetivo CtO

Versión	Entradas	Menor RMSE	Menor MAE	Mayor Hit Ratio	Las tres	Pertenece a M^*
V5	CtO	–	–	–	–	48
V6	CtO y CtC	25	26	11	6	47
V7	CtO y OtC	21	27	12	8	41
V8	CtO, CtC y OtC	27	25	14	7	45

V8 reduce el RMSE en 27 acciones y aumenta el Hit Ratio en 14, mientras que V7 presenta la mayor frecuencia de reducción del MAE y de mejora conjunta, con 27 y 8 acciones. El MCS interno conserva las cuatro versiones en 39 acciones y una sola configuración en 2. La elevada permanencia conjunta indica que, al nivel de significancia utilizado, el procedimiento distingue poco entre las cuatro alternativas CtO.

7.1.3. Retorno Intradía: V9–V12

V9 utiliza únicamente OtC y constituye el punto de comparación de V10–V12. En este grupo, el código desplaza CtO mediante `shift(-1)`. Por ello, V10 y V12 incorporan el CtO de

la jornada objetivo, disponible en su apertura, mientras que V9 y V11 utilizan solamente variables observadas hasta la jornada anterior. La Tabla 5 presenta los resultados.

Tabla 5: Resultados de las configuraciones LSTM con objetivo OtC

Versión	Entradas	Menor RMSE	Menor MAE	Mayor Hit Ratio	Las tres	Pertenece a M^*
V9	OtC	–	–	–	–	40
V10	OtC y CtO	26	29	16	15	45
V11	OtC y CtC	24	26	15	9	39
V12	OtC, CtC y CtO	17	21	13	5	41

V10 presenta las mayores frecuencias del grupo en las cuatro comparaciones descriptivas: menor RMSE en 26 acciones, menor MAE en 29, mayor Hit Ratio en 16 y mejora simultánea en 15. También registra la mayor pertenencia individual a M^* , con 45 acciones. No obstante, las cuatro configuraciones permanecen conjuntamente en 30 acciones y una sola sobrevive en 4, por lo que estos resultados no establecen una superioridad uniforme de V10. Además, su interpretación corresponde a un pronóstico de OtC formulado después de observar la apertura de la jornada objetivo.

Las mayores reducciones puntuales frente a la versión de una variable fueron de 1,55 % en RMSE, obtenida por V2 frente a V1 para KO, y de 3,65 % en MAE, obtenida por V6 frente a V5 para CTAS. Estas magnitudes corresponden a casos individuales y no representan una mejora general para las configuraciones ni para el conjunto de acciones. Los p-valores individuales del MCS interno se presentan en el Anexo B.

7.2 Comparación con ARIMA y Random Forest

Después de la evaluación interna, las cuatro LSTM de cada grupo se comparan con ARIMA y *Random Forest* del mismo retorno objetivo. Las columnas de métricas informan en cuántas acciones la LSTM obtiene menor RMSE, menor MAE, mayor Hit Ratio y una mejora simultánea.

nea en las tres medidas. La última columna corresponde a la pertenencia de la LSTM al MCS independiente de seis competidores: las cuatro LSTM originales, ARIMA y *Random Forest*.

7.2.1. Modelos con Objetivo CtC

Tabla 6: Comparación de las configuraciones CtC con ARIMA y Random Forest

Modelo	Frente a ARIMA				Frente a Random Forest				En M^*
	RMSE	MAE	HR	Las tres	RMSE	MAE	HR	Las tres	
V1	28	26	33	14	41	36	31	24	1
V2	31	28	33	19	38	35	31	24	1
V3	20	25	30	10	38	35	30	22	0
V4	29	24	36	15	40	36	33	23	0

Las configuraciones CtC obtienen menor RMSE que *Random Forest* en 38–41 acciones y menor RMSE que ARIMA en 20–31. En el MCS con referencias, V1 y V2 permanecen en una acción cada una, mientras ARIMA y *Random Forest* pertenecen a M^* en 50 y 48 acciones, respectivamente.

7.2.2. Modelos con Objetivo CtO

Tabla 7: Comparación de las configuraciones CtO con ARIMA y Random Forest

Modelo	Frente a ARIMA				Frente a Random Forest				En M^*
	RMSE	MAE	HR	Las tres	RMSE	MAE	HR	Las tres	
V5	32	27	25	9	40	42	27	23	2
V6	37	25	30	11	41	43	27	22	2
V7	31	22	28	11	40	41	22	20	2
V8	33	26	26	11	39	39	27	22	2

Las configuraciones CtO presentan menor RMSE que *Random Forest* en 39–41 acciones y menor RMSE que ARIMA en 31–37. Cada LSTM permanece en el MCS con referencias en 2 acciones; ARIMA y *Random Forest* lo hacen en 48 y 35, respectivamente.

7.2.3. Modelos con Objetivo OtC

Tabla 8: Comparación de las configuraciones OtC con ARIMA y Random Forest

Modelo	Frente a ARIMA				Frente a Random Forest				En M^*
	RMSE	MAE	HR	Las tres	RMSE	MAE	HR	Las tres	
V9	19	20	45	15	43	41	25	21	0
V10	24	26	45	19	42	40	26	23	0
V11	21	24	45	18	43	42	29	21	0
V12	15	18	44	12	41	41	26	23	0

Las configuraciones OtC obtienen menor RMSE que *Random Forest* en 41–43 acciones, pero frente a ARIMA lo hacen en 15–24. Ninguna LSTM permanece en el MCS con referencias; ARIMA y *Random Forest* pertenecen a M^* en 49 y 30 acciones, respectivamente.

La comparación direccional con ARIMA requiere cautela cuando sus predicciones son nulas o prácticamente nulas, porque el Hit Ratio depende de la regla aplicada a los signos y a los empates. ARIMA(0, 0, 0) se selecciona en 39 acciones para CtC, 33 para CtO y 45 para OtC; este orden no implica por sí solo un pronóstico nulo.

Asimismo, la escasa permanencia de las LSTM en el MCS con referencias contrasta con sus frecuencias de menor RMSE frente a *Random Forest*. Los archivos disponibles no contienen los residuos LSTM ni el código de la ejecución posterior que construyó todas las pérdidas del MCS. Por ello, se informan los conjuntos reportados, pero no se extrae una conclusión definitiva de superioridad estadística entre familias de modelos hasta comprobar que las métricas y las pérdidas utilizan las mismas predicciones, fechas y escalas. Las métricas individuales de los modelos de referencia y los p-valores detallados se presentan en los Anexos C y D.

8 Discusión

Los resultados muestran que el efecto de incorporar variables de retorno adicionales depende del activo, del retorno objetivo y de la métrica evaluada. Los conteos describen la frecuencia de mejoras en esta muestra, pero no representan un efecto común a todas las acciones. La comparación abarca los tres grupos y no selecciona uno de ellos a partir de su desempeño observado.

8.1 Interpretación Financiera de la Descomposición de Retornos

La separación entre CtO y OtC se fundamenta en la dinámica de *tug of war* descrita por Lou et al. (2019). Los retornos nocturnos e intradiarios pueden reflejar información y participantes diferentes: durante el cierre se acumulan noticias que inciden en las órdenes de apertura, mientras que en la sesión regular pueden corregirse desequilibrios previos (Akbas et al., 2022; Chen et al., 2024; Lou et al., 2019). Esta literatura motiva la incorporación de ambos componentes como entradas, pero no implica que su inclusión deba mejorar cualquier pronóstico.

En la muestra analizada, las variables adicionales producen resultados heterogéneos en los tres horizontes. Para CtC, V2, V3 y V4 mejoran conjuntamente RMSE, MAE y Hit Ratio frente a V1 en 11, 6 y 10 acciones. Para CtO, V6, V7 y V8 lo hacen frente a V5 en 6, 8 y 7; para OtC, V10, V11 y V12 mejoran frente a V9 en 15, 9 y 5. Estos resultados no permiten atribuir una ventaja general a una variable específica ni identificar causalmente los mecanismos de microestructura planteados por la literatura.

El momento del pronóstico condiciona especialmente la interpretación del grupo OtC. El código desplaza CtO únicamente cuando OtC es la variable objetivo. En consecuencia, V10 y V12 pueden utilizar el CtO de la jornada objetivo, conocido en su apertura, para pronosticar el retorno intradiario posterior. V1–V8 utilizan información histórica hasta la jornada anterior, y V9 y V11

no incorporan CtO como entrada. Por ello, la ventaja descriptiva de V10 debe entenderse como evidencia sobre un pronóstico intradiario posterior a la apertura, no como una predicción realizada al cierre anterior.

8.2 Comparación entre las Configuraciones LSTM

La incorporación de dos o tres variables no produce una mejora sistemática respecto de las versiones de una variable. En CtC, V4 presenta la mayor frecuencia de reducción del RMSE, mientras V2 registra la mayor frecuencia de reducción del MAE y de mejora conjunta. En CtO, V8 destaca en RMSE y V7 en MAE y mejora conjunta. En OtC, V10 alcanza las mayores frecuencias en las cuatro comparaciones descriptivas. Estas diferencias no identifican un ganador común a los tres retornos y deben interpretarse dentro de cada grupo.

El MCS interno conserva las cuatro LSTM en 28 acciones para CtC, 39 para CtO y 30 para OtC. Esta permanencia conjunta indica que el procedimiento no elimina ninguna de las cuatro configuraciones en esos casos al nivel utilizado; no demuestra que sus pérdidas sean exactamente iguales. Asimismo, las versiones de una variable permanecen en M^* en 42, 48 y 40 acciones, respectivamente. Estos resultados no respaldan que un mayor número de entradas garantice una ventaja predictiva. La interpretación corresponde exclusivamente a la comparación entre LSTM y se distingue del contraste posterior que incorpora otras familias de modelos.

Las diferencias observadas también deben distinguirse de la variabilidad del entrenamiento. Sin múltiples ejecuciones por configuración con distintas semillas, no puede establecerse cuánto de los cambios corresponde a las entradas adicionales y cuánto a la inicialización, la optimización y la calibración de cada red. Esta cuestión resulta especialmente relevante cuando las variaciones de error son pequeñas.

8.3 Contraste con ARIMA y Random Forest

Las LSTM presentan menor RMSE que *Random Forest* en la mayoría de las acciones para los tres retornos objetivo, mientras que el contraste con ARIMA es menos uniforme. Sin embargo, una frecuencia elevada de menor error no informa por sí sola su magnitud ni constituye una prueba de significancia estadística. Además, las configuraciones de una variable también muestran resultados favorables frente a *Random Forest*, por lo que esa comparación no puede atribuirse exclusivamente a la incorporación de otros retornos.

La selección de ARIMA(0, 0, 0) en 39 acciones para CtC, 33 para CtO y 45 para OtC es compatible con una escasa necesidad de términos autorregresivos o de medias móviles según el criterio empleado. No demuestra ausencia de otras dependencias ni implica necesariamente un pronóstico nulo. Cuando las predicciones sí son nulas o prácticamente nulas, la comparación mediante Hit Ratio requiere considerar la regla utilizada para los signos.

El segundo MCS parte de las cuatro LSTM originales junto con ARIMA y *Random Forest*, no de las configuraciones retenidas en el análisis interno. Sus archivos conservan principalmente los modelos de referencia, en contraste con los conteos descriptivos de menor RMSE de las LSTM. Esta diferencia no puede resolverse únicamente con las métricas agregadas por activo. Es necesario verificar que las matrices de pérdidas correspondan a las mismas predicciones, fechas y escalas. Hasta completar esa comprobación, los conjuntos reportados no se utilizan para sostener una conclusión definitiva de superioridad estadística entre familias de modelos.

9 Limitaciones

Los resultados deben interpretarse dentro de las condiciones de la muestra, el periodo y el diseño experimental. Las principales restricciones corresponden a la representatividad de los activos, la evaluación temporal, la reproducibilidad de las comparaciones y el alcance exclusivamente predictivo.

9.1 Tamaño, Selección y Representatividad de la Muestra

La primera limitación corresponde al diseño muestral. Las 50 acciones fueron seleccionadas aleatoriamente del S&P 500 y se analizaron como series independientes. Aunque este procedimiento reduce la intervención subjetiva, una sola muestra puede presentar desequilibrios entre sectores, niveles de capitalización, volatilidad o liquidez. Las frecuencias de mejora describen esta selección y no deben extrapolarse directamente a todos los constituyentes del índice.

Asimismo, la composición del S&P 500 cambia a través del tiempo. Si el universo utilizado para realizar la selección corresponde a una composición observada en una fecha determinada, puede existir sesgo de supervivencia o de disponibilidad respecto de las empresas que integraron históricamente el índice entre 2020 y 2026. Una extensión futura debería repetir el muestreo con distintas semillas, aplicar estratificación sectorial y reconstruir la composición histórica del índice.

La ventana solicitada es común, pero la cobertura efectiva puede diferir entre acciones debido a fechas de inicio de cotización, cambios de símbolo, fusiones, escisiones u otras discontinuidades corporativas. Por esta razón, el número de observaciones y las fechas disponibles pueden variar entre los 50 activos. Esta heterogeneidad afecta principalmente el tamaño del conjunto de entrenamiento y debe considerarse al comparar la estabilidad de las estimaciones.

Por ello, los resultados no se generalizan de manera directa a:

- Acciones de mediana o pequeña capitalización (*mid-caps* y *small-caps*), cuyas condiciones de liquidez, volatilidad y formación de precios pueden diferir de las observadas en el S&P 500.
- Mercados emergentes o menos integrados, donde la liquidez, el volumen negociado y las restricciones que enfrentan los arbitrajistas pueden modificar los patrones analizados (Chen et al., 2024).

9.2 Alcance Exclusivamente Predictivo

La investigación evalúa la precisión de los pronósticos mediante RMSE, MAE y Hit Ratio, pero no define reglas de compra y venta, tamaños de posición ni criterios de entrada o salida. En consecuencia, no estima rentabilidad, riesgo financiero ni desempeño de una estrategia de inversión. Esta delimitación no afecta la comparación predictiva entre modelos, pero impide extraer conclusiones sobre la utilidad económica de los pronósticos. Una extensión orientada a inversión debería formular primero una estrategia y evaluarla por separado.

9.3 Alcance de la Comparación con los Modelos de Referencia

El MCS interno evalúa las cuatro LSTM de cada retorno objetivo. Posteriormente, la comparación con modelos de referencia considera las mismas cuatro LSTM junto con ARIMA y *Random Forest*, sin seleccionar previamente las versiones retenidas en el análisis interno. La permanencia de un modelo se interpreta dentro de su conjunto de competidores y no establece una superioridad absoluta. Los modelos de referencia cuentan con métricas individuales para las 50 acciones y los tres retornos objetivo, y sus residuos permiten reproducir los RMSE y MAE reportados.

La escasa permanencia de las LSTM en el MCS con modelos de referencia contrasta con

sus frecuencias de menor RMSE frente a *Random Forest*. Los archivos disponibles no incluyen los residuos LSTM ni el código de la ejecución actual, por lo que no permiten comprobar que las pérdidas del MCS y las métricas consolidadas provengan de las mismas predicciones, fechas y escalas. Esta restricción impide extraer una conclusión definitiva de superioridad estadística entre familias de modelos. Asimismo, las dos copias del MCS interno CtC conservan los mismos conjuntos retenidos, pero presentan diferencias en algunos p-valores; se utiliza el archivo sin el sufijo de copia para mantener una fuente única.

La comparación direccional con ARIMA requiere cautela si sus pronósticos son nulos o prácticamente nulos. En esos casos, el Hit Ratio depende de cómo se traten los signos y los empates. La selección de ARIMA(0, 0, 0) no implica por sí sola que el pronóstico sea nulo.

9.4 Variabilidad del Entrenamiento y Estabilidad de las Diferencias

Las métricas consolidadas contienen un resultado por acción y configuración, pero no una distribución de resultados obtenida mediante entrenamientos repetidos con distintas semillas. Por ello, no puede separarse de manera concluyente el efecto de incorporar variables del asociado a la inicialización, la búsqueda de hiperparámetros y la variabilidad del ajuste de cada red. Una extensión debería repetir el procedimiento bajo distintas semillas manteniendo las mismas ventanas de evaluación.

Los conteos de mejora no informan por sí solos la magnitud ni la estabilidad de las diferencias. Una configuración puede obtener menor error en varias acciones sin que ello establezca una ventaja estadística generalizada. Del mismo modo, la permanencia conjunta en el MCS no prueba equivalencia exacta. Los resultados se presentan para los tres retornos objetivo y no se utilizan para seleccionar uno como validación confirmatoria de los demás.

9.5 Restricción Temporal y Regímenes Estructurales

La descarga utiliza como fecha inicial el 1 de mayo de 2020 y como límite final exclusivo el 15 de mayo de 2026, por lo que la última fecha potencialmente observada es el 14 de mayo de 2026. La diferencia entre los parámetros es de 2.205 días calendario. Aunque esta ventana contiene cambios de régimen relevantes, comienza después de la fase inicial del desplome de febrero-marzo de 2020 y no representa ciclos históricos anteriores. Los resultados corresponden específicamente a las condiciones observadas durante la pandemia, la recuperación, los regímenes monetarios posteriores y episodios geopolíticos como la escalada del conflicto en Irán y de las tensiones asociadas con Estados Unidos durante 2026 (International Monetary Fund, 2026).

La investigación no identifica por separado el efecto de estos acontecimientos sobre cada retorno o modelo. En consecuencia, parte de las variaciones observadas puede reflejar respuestas transitorias de los mercados a cambios en los precios energéticos, la incertidumbre y la volatilidad financiera, además de las relaciones históricas que las redes buscan aprender.

Las relaciones aprendidas por una LSTM pueden cambiar cuando varían el régimen de volatilidad, las condiciones monetarias, la regulación o la estructura de negociación. En esos casos, los pesos estimados con el periodo 2020–2026 podrían perder capacidad predictiva y requerir una nueva calibración.

La evaluación utiliza un único corte cronológico con una distribución aproximada de 70 % para entrenamiento, 10 % para validación y 20 % para prueba; este último bloque contiene las 304 jornadas finales. Este diseño mantiene el orden temporal, pero no equivale a una validación *walk-forward* con múltiples ventanas. En el grupo OtC, V10 y V12 incorporan el CtO de la jornada objetivo, conocido en su apertura; por tanto, corresponden a pronósticos intradiarios posteriores a la

apertura y no a decisiones formuladas al cierre anterior. Esta diferencia temporal debe considerarse al compararlas con V9 y V11.

9.6 Requerimiento Computacional y Costo de Calibración

La estimación independiente de 12 versiones para 50 acciones, con 50 ensayos por configuración, supone 30.000 ensayos de calibración además del ajuste final de cada modelo. La poda puede reducir el entrenamiento realizado en los ensayos descartados, pero no elimina el requerimiento computacional del procedimiento. Repetir la evaluación con distintas semillas o múltiples ventanas temporales incrementaría ese requerimiento. Al no disponer de mediciones sistemáticas del tiempo de ejecución, no se cuantifica un costo de procesamiento ni se concluye sobre su viabilidad operativa en tiempo real.

10 Conclusiones

La investigación evaluó 12 configuraciones LSTM calibradas mediante Optuna para una muestra aleatoria de 50 acciones del S&P 500. Las comparaciones abarcaron CtC, CtO y OtC. Primero se analizaron las métricas respecto de las versiones de una variable y el *Model Confidence Set* (MCS) entre las cuatro LSTM de cada grupo. Posteriormente se contrastaron las métricas con ARIMA y *Random Forest* y se examinaron los conjuntos reportados por el MCS que incorpora ambos modelos de referencia.

La incorporación de variables de retorno adicionales produjo mejoras en algunas acciones, pero no mostró una ventaja uniforme. Para CtC, V2, V3 y V4 mejoraron simultáneamente RMSE, MAE y Hit Ratio en 11, 6 y 10 acciones, respectivamente. En CtO, V6, V7 y V8 lo hicieron en 6, 8 y 7 acciones; en OtC, V10, V11 y V12, en 15, 9 y 5. Aunque V10 registró la mayor frecuencia de mejora conjunta, este conteo no establece una superioridad estadística ni justifica generalizar el resultado a otros activos o periodos.

El MCS integrado únicamente por LSTM conservó las cuatro configuraciones en 28 acciones para CtC, 39 para CtO y 30 para OtC. Las versiones de una variable pertenecieron a M^* en 42, 48 y 40 acciones, respectivamente. En consecuencia, la comparación interna no identifica una configuración única para gran parte de la muestra ni respalda que aumentar el número de entradas garantice un mejor desempeño. La permanencia en el conjunto indica que el modelo no fue eliminado por inferioridad predictiva relativa, no que sea superior en términos absolutos.

Frente a *Random Forest*, las LSTM obtuvieron menor RMSE en 38–43 acciones, según la configuración y el retorno objetivo. La comparación con ARIMA fue menos uniforme, con frecuencias de 15–37 acciones. Estos resultados son descriptivos. Los conjuntos reportados por el

MCS que incorpora ambos modelos de referencia requieren verificar su correspondencia con las métricas consolidadas antes de extraer una conclusión definitiva de superioridad estadística entre familias de modelos.

La interpretación también depende de la información disponible al formular el pronóstico. V10 y V12 utilizan el CtO de la jornada objetivo, conocido en su apertura, para predecir OtC; por ello, corresponden a pronósticos intradiarios posteriores a la apertura. Las demás configuraciones emplean variables históricas hasta la jornada anterior. Asimismo, la investigación evalúa precisión predictiva y no rentabilidad de una estrategia de inversión.

En conjunto, el aporte de las variables adicionales es heterogéneo y no permite afirmar una mejora generalizada. Futuras investigaciones podrían evaluar la estabilidad mediante ventanas independientes o una evaluación *walk-forward*, repetir el entrenamiento con distintas semillas y replicar el análisis en un período de mercado más regular, con menor presencia de perturbaciones extraordinarias. También sería pertinente ampliar la muestra a otros índices o aplicar la metodología en mercados distintos, con el fin de examinar si los resultados se mantienen bajo otras condiciones de negociación y estructuras de mercado.

Disponibilidad del Código y los Datos

El código utilizado y los datos adicionales que respaldan los hallazgos de este estudio, incluidos los residuos de los modelos, están disponibles a través del autor, Daniel Pedreros Meza, previa solicitud razonable.

Referencias

- Akbas, F., Boehmer, E., Jiang, C., & Koch, P. D. (2022). Overnight returns, daytime reversals, and future stock returns. *Journal of Financial Economics*, 145(3), 850-875. <https://doi.org/10.1016/j.jfineco.2021.09.019>
- Akiba, T., Sano, S., Yanase, T., Ohta, T., & Koyama, M. (2019). Optuna: A next-generation hyperparameter optimization framework. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2623-2631. <https://doi.org/10.1145/3292500.3330701>
- Barazandeh, I., Haratizadeh, S., & Sermpinis, G. (2025). A temporal graph-based contrastive approach for financial time series forecasting. *Engineering Applications of Artificial Intelligence*, 153, 110834. <https://doi.org/10.1016/j.engappai.2025.110834>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, J., Haboub, A., & Khan, A. (2024). Limits of arbitrage and their impact on market efficiency: Evidence from China. *Global Finance Journal*, 59, 100916. <https://doi.org/10.1016/j.gfj.2023.100916>
- Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669. <https://doi.org/10.1016/j.ejor.2017.11.054>
- Fjellström, C. (2022). Long short-term memory neural network for financial time series. 2022 *IEEE International Conference on Big Data (Big Data)*, 3496-3504. <https://doi.org/10.1109/BigData55660.2022.10020784>

- Hansen, P. R., Lunde, A., & Nason, J. M. (2011). The model confidence set. *Econometrica*, 79(2), 453-497. <https://doi.org/10.3982/ECTA5771>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- International Monetary Fund. (2026, abril). *Global financial markets confront the war in the Middle East and amplification risks*. International Monetary Fund. <https://doi.org/10.5089/9798229035910.082>
- Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184, 115537. <https://doi.org/10.1016/j.eswa.2021.115537>
- Lou, D., Polk, C., & Skouras, S. (2019). A tug of war: Overnight versus intraday expected returns. *Journal of Financial Economics*, 134(1), 192-213. <https://doi.org/10.1016/j.jfineco.2019.03.011>
- Núñez Perez, F. A., Aguilar Mosqueda, F. J., Ramos Cuevas, A., Muñoz Beltran, J., & Núñez Perez, J. C. (2026). Leakage-controlled horizon-specific model selection for daily equity forecasting: An automated multi-model pipeline. *Forecasting*, 8(2), Artículo 34. <https://doi.org/10.3390/forecast8020034>
- Oliver Muncharaz, J. (2020). Comparing classic time series models and the LSTM recurrent neural network: An application to S&P 500 stocks. *Finance, Markets and Valuation*, 6(2), 137-148. <https://doi.org/10.46503/ZVBS2781>
- Passalis, N., Tefas, A., Kannianen, J., Gabbouj, M., & Iosifidis, A. (2020). Deep adaptive input normalization for time series forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 31(10), 3778-3790. <https://doi.org/10.1109/TNNLS.2019.2944933>

- Singh, U., Tamrakar, S., Saurabh, K., Vyas, R., & Vyas, O. P. (2024). Optimizing hyperparameters of deep learning models for stock price prediction. *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1-7. <https://doi.org/10.1109/ICCCNT61001.2024.10724813>
- Stübinger, J., & Schneider, L. (2019). Statistical arbitrage with mean-reverting overnight price gaps on high-frequency data of the S&P 500. *Journal of Risk and Financial Management*, 12(2), Artículo 51. <https://doi.org/10.3390/jrfm12020051>
- Yilmaz, E., & Tcrol, E. (2025). Comparison of LSTM and LSTM with grid search optimization for stock price prediction of Saudi Arabian Oil Company (Aramco). *International Journal of Artificial Intelligent and Informatics*, 3(2), 52-59. <https://doi.org/10.33292/ijarlit.v3i2.47>

11 Anexos

11.1 Anexo A: Desglose Individual de Variaciones entre las 12 Versiones LSTM

Las tablas utilizan las métricas consolidadas en la escala original de los retornos. El RMSE y el MAE de la versión de una variable se presentan en nivel; los de las demás versiones se expresan como variación porcentual respecto de ella. Un valor negativo indica menor error. El Hit Ratio se informa en porcentaje. Los conteos del cuerpo del informe utilizan valores sin redondear: una variación mostrada como 0,00 % no implica necesariamente un empate exacto.

11.1.1. Retorno objetivo CtC (V1–V4)

Tabla 9: Variaciones individuales para CtC (parte 1 de 2)

Activo	RMSE V1	Δ V2	Δ V3	Δ V4	MAE V1	Δ V2	Δ V3	Δ V4	HR V1	HR V2	HR V3	HR V4
AAPL	0,01927	-0,03 %	0,04 %	0,01 %	0,01237	-0,01 %	-0,03 %	-0,01 %	52,63 %	52,63 %	52,63 %	52,63 %
ADBE	0,02187	0,30 %	0,28 %	-0,06 %	0,01515	-0,20 %	-0,17 %	-0,16 %	50,33 %	50,33 %	50,33 %	50,33 %
ADSK	0,02020	0,11 %	0,11 %	0,08 %	0,01411	-0,04 %	-0,04 %	-0,03 %	49,34 %	50,66 %	50,66 %	50,66 %
AMAT	0,03066	0,08 %	-0,18 %	-0,20 %	0,02200	0,10 %	-0,34 %	-0,39 %	56,25 %	51,32 %	56,25 %	56,25 %
AMZN	0,02155	-0,23 %	0,06 %	-0,06 %	0,01537	0,03 %	0,29 %	0,07 %	54,28 %	57,24 %	54,28 %	54,28 %
BA	0,02338	-0,33 %	-0,30 %	0,04 %	0,01583	-0,63 %	-0,57 %	0,08 %	47,04 %	52,96 %	52,96 %	47,04 %
BAC	0,01725	-0,25 %	0,00 %	-0,06 %	0,01183	-0,75 %	-0,53 %	-0,16 %	43,09 %	55,59 %	55,92 %	56,58 %
C	0,02078	0,12 %	-0,02 %	0,03 %	0,01454	0,28 %	-0,07 %	0,07 %	56,25 %	42,76 %	56,25 %	56,25 %
CAT	0,02212	-0,26 %	0,12 %	-0,10 %	0,01571	-0,30 %	-0,01 %	-0,23 %	53,95 %	55,59 %	52,30 %	55,59 %
CDNS	0,02484	0,01 %	-0,01 %	-0,02 %	0,01707	0,01 %	-0,03 %	-0,01 %	53,62 %	53,62 %	53,62 %	53,62 %
CSCO	0,01764	-0,11 %	0,33 %	-0,00 %	0,01197	-0,23 %	0,65 %	-0,01 %	52,30 %	55,26 %	43,75 %	54,93 %
CTAS	0,01386	-0,06 %	-0,22 %	0,11 %	0,01000	-0,07 %	-0,23 %	0,15 %	48,36 %	48,36 %	48,36 %	48,36 %
CVX	0,01613	-0,01 %	0,13 %	-0,06 %	0,01148	-0,20 %	0,20 %	0,05 %	55,26 %	55,26 %	54,28 %	56,58 %
DE	0,01907	0,79 %	0,16 %	0,35 %	0,01349	0,35 %	0,20 %	1,02 %	49,34 %	50,66 %	49,34 %	49,34 %
DELL	0,03590	-0,12 %	0,32 %	-0,09 %	0,02479	-0,08 %	0,20 %	-0,03 %	51,97 %	51,97 %	49,01 %	51,97 %
DIS	0,01946	-0,08 %	-0,03 %	0,12 %	0,01266	-0,08 %	-0,12 %	0,61 %	46,05 %	46,71 %	48,36 %	46,05 %
EBAY	0,02388	0,04 %	-0,12 %	-0,10 %	0,01567	0,10 %	-0,39 %	-0,30 %	46,05 %	43,42 %	56,25 %	56,25 %
F	0,02175	-0,10 %	0,01 %	-0,12 %	0,01530	-0,00 %	0,16 %	0,01 %	48,36 %	49,67 %	50,00 %	49,67 %
FDX	0,02076	0,73 %	-0,11 %	0,04 %	0,01415	1,27 %	-0,20 %	0,09 %	53,62 %	46,38 %	53,62 %	46,38 %
FISV	0,04289	1,24 %	0,16 %	0,15 %	0,01809	0,53 %	-0,05 %	0,08 %	51,32 %	49,34 %	50,66 %	49,34 %
FITB	0,01841	0,06 %	-0,01 %	-0,05 %	0,01283	0,15 %	0,03 %	0,03 %	51,64 %	51,64 %	51,64 %	51,64 %
GILD	0,01747	-0,20 %	-0,08 %	0,02 %	0,01345	-0,21 %	-0,09 %	0,02 %	48,36 %	50,99 %	50,99 %	48,36 %
GIS	0,01540	0,06 %	0,07 %	0,29 %	0,01161	0,06 %	0,07 %	0,29 %	53,95 %	53,95 %	52,96 %	45,07 %
GLW	0,03143	-0,18 %	-0,10 %	-0,01 %	0,02127	-0,27 %	-0,15 %	-0,02 %	58,22 %	58,22 %	58,22 %	58,22 %
GM	0,02229	-0,06 %	0,04 %	-0,06 %	0,01503	-0,05 %	0,04 %	-0,08 %	52,63 %	52,63 %	52,63 %	52,63 %

Tabla 10: Variaciones individuales para CtC (parte 2 de 2)

Activo	RMSE V1	$\Delta V2$	$\Delta V3$	$\Delta V4$	MAE V1	$\Delta V2$	$\Delta V3$	$\Delta V4$	HR V1	HR V2	HR V3	HR V4
GOOGL	0,02002	-0,21 %	0,59 %	0,32 %	0,01456	-0,19 %	0,35 %	0,26 %	53,95 %	53,95 %	53,29 %	53,95 %
GS	0,02020	0,07 %	0,25 %	0,04 %	0,01432	0,47 %	1,02 %	0,22 %	58,22 %	58,55 %	47,04 %	58,22 %
HSIC	0,01760	0,01 %	0,07 %	-0,08 %	0,01315	0,01 %	0,00 %	0,05 %	50,00 %	49,34 %	49,34 %	50,00 %
INTC	0,04483	-0,01 %	-0,14 %	-0,30 %	0,03094	-0,06 %	-0,09 %	-0,23 %	49,34 %	49,34 %	50,00 %	50,33 %
ISRG	0,02183	0,09 %	0,29 %	-1,35 %	0,01430	0,53 %	0,92 %	-0,47 %	50,99 %	49,01 %	49,01 %	49,67 %
JPM	0,01605	0,02 %	0,01 %	-0,15 %	0,01131	0,07 %	0,11 %	-0,09 %	54,28 %	54,28 %	54,28 %	54,28 %
KHC	0,01607	0,70 %	0,26 %	-0,11 %	0,01208	0,05 %	0,15 %	-0,08 %	49,67 %	50,00 %	48,03 %	49,67 %
KMB	0,01598	0,13 %	0,23 %	0,05 %	0,01051	0,16 %	0,27 %	0,09 %	52,63 %	52,63 %	47,37 %	52,63 %
KO	0,01076	-1,55 %	-0,00 %	0,02 %	0,00822	-1,22 %	0,27 %	-0,04 %	48,68 %	60,53 %	48,68 %	48,68 %
LLY	0,02634	-0,24 %	-0,05 %	0,08 %	0,01787	-0,19 %	0,07 %	0,11 %	53,29 %	53,29 %	53,29 %	53,29 %
MCD	0,01142	0,08 %	0,15 %	0,01 %	0,00857	0,10 %	0,21 %	0,01 %	49,34 %	49,01 %	49,01 %	49,01 %
MCHP	0,03562	0,01 %	0,44 %	0,18 %	0,02265	-0,02 %	1,03 %	0,17 %	50,00 %	50,00 %	46,71 %	48,03 %
MMM	0,01916	0,01 %	0,02 %	0,02 %	0,01369	-0,02 %	-0,01 %	0,05 %	50,00 %	50,99 %	50,99 %	48,68 %
MNST	0,01626	-0,47 %	0,05 %	0,01 %	0,01090	-1,28 %	0,06 %	-0,44 %	43,75 %	57,89 %	43,09 %	54,93 %
MRK	0,01787	-0,23 %	-0,32 %	-0,27 %	0,01304	-0,32 %	-0,24 %	-0,34 %	48,68 %	53,95 %	50,66 %	51,32 %
MSFT	0,01679	0,05 %	0,06 %	-0,02 %	0,01127	-0,15 %	-0,10 %	-0,17 %	50,33 %	51,64 %	51,64 %	51,97 %
MSI	0,01584	-0,26 %	0,11 %	-0,96 %	0,00983	-0,18 %	-0,05 %	-0,31 %	53,62 %	52,63 %	53,62 %	54,61 %
ORCL	0,03660	-0,07 %	-0,07 %	-0,06 %	0,02508	-0,03 %	-0,03 %	-0,03 %	50,66 %	50,66 %	50,66 %	50,66 %
PAYX	0,01713	0,02 %	-0,14 %	-0,84 %	0,01213	0,04 %	-0,15 %	-0,64 %	46,38 %	46,38 %	46,38 %	54,28 %
QCOM	0,02797	0,04 %	-0,38 %	0,01 %	0,01731	0,06 %	-0,49 %	0,03 %	52,30 %	52,63 %	49,67 %	52,30 %
STLD	0,02329	-0,06 %	0,16 %	-0,09 %	0,01741	-0,07 %	0,19 %	-0,06 %	53,95 %	53,95 %	53,95 %	54,28 %
T	0,01484	-0,04 %	0,01 %	0,09 %	0,01097	-0,05 %	-0,10 %	-0,07 %	48,03 %	49,67 %	48,03 %	48,36 %
VRTX	0,02206	0,15 %	-0,20 %	-0,05 %	0,01380	0,25 %	-0,23 %	-0,06 %	49,67 %	49,67 %	49,67 %	49,67 %
WBD	0,03353	0,15 %	0,44 %	0,64 %	0,01948	0,04 %	0,27 %	0,56 %	50,66 %	50,99 %	48,36 %	48,36 %
WYNN	0,02454	0,13 %	0,20 %	-0,03 %	0,01783	0,34 %	-0,07 %	0,12 %	52,96 %	50,00 %	54,61 %	46,71 %

11.1.2. Retorno objetivo CtO (V5-V8)

Tabla 11: Variaciones individuales para CtO (parte 1 de 2)

Activo	RMSE V5	$\Delta V6$	$\Delta V7$	$\Delta V8$	MAE V5	$\Delta V6$	$\Delta V7$	$\Delta V8$	HR V5	HR V6	HR V7	HR V8
AAPL	0,01210	-0,05 %	-0,01 %	0,04 %	0,00676	0,15 %	-0,00 %	1,00 %	50,00 %	48,36 %	50,33 %	47,04 %
ADBE	0,01239	0,17 %	1,21 %	0,57 %	0,00769	0,01 %	0,52 %	-0,04 %	51,32 %	50,66 %	48,03 %	48,03 %
ADSK	0,01233	-0,07 %	0,18 %	0,02 %	0,00716	-0,11 %	0,56 %	0,06 %	47,37 %	47,04 %	47,37 %	47,37 %
AMAT	0,02181	0,02 %	0,00 %	-0,00 %	0,01400	0,08 %	-0,01 %	-0,01 %	52,30 %	52,30 %	52,30 %	52,63 %
AMZN	0,01720	0,01 %	0,08 %	0,01 %	0,00978	-0,02 %	0,85 %	-0,02 %	55,59 %	55,59 %	43,75 %	55,59 %
BA	0,01270	-0,21 %	-0,24 %	-0,48 %	0,00781	-0,53 %	-0,57 %	-0,48 %	41,78 %	57,57 %	57,57 %	57,57 %
BAC	0,01083	-0,20 %	-0,19 %	0,17 %	0,00675	0,12 %	0,07 %	0,27 %	53,62 %	53,95 %	54,28 %	53,29 %
C	0,01252	-1,27 %	4,07 %	-0,23 %	0,00795	-0,39 %	3,56 %	0,34 %	54,93 %	54,61 %	51,64 %	52,96 %
CAT	0,01305	-0,04 %	0,11 %	-0,12 %	0,00863	-0,27 %	0,16 %	-0,37 %	55,92 %	56,91 %	51,32 %	56,91 %
CDNS	0,01322	-0,08 %	-0,07 %	-0,08 %	0,00907	-0,09 %	-0,10 %	-0,12 %	48,36 %	48,36 %	48,36 %	48,36 %
CSCO	0,01239	-0,26 %	0,03 %	0,07 %	0,00621	-0,07 %	-0,00 %	0,01 %	49,01 %	50,66 %	49,34 %	49,01 %
CTAS	0,00681	-1,13 %	-0,38 %	-0,39 %	0,00433	-3,65 %	-1,37 %	-1,10 %	42,11 %	42,11 %	42,11 %	42,11 %
CVX	0,00985	-0,04 %	-0,02 %	-0,13 %	0,00628	0,06 %	0,12 %	0,18 %	56,58 %	56,91 %	56,58 %	56,25 %
DE	0,00994	-0,05 %	0,03 %	0,01 %	0,00601	-0,08 %	0,05 %	0,01 %	50,99 %	50,99 %	50,99 %	50,99 %
DELL	0,02099	-0,02 %	0,05 %	-0,00 %	0,01375	-0,29 %	-0,06 %	-0,28 %	54,61 %	55,26 %	55,26 %	54,61 %
DIS	0,01213	0,09 %	0,10 %	-0,12 %	0,00592	0,36 %	0,53 %	0,01 %	54,28 %	44,41 %	48,36 %	54,28 %
EBAY	0,01404	-0,04 %	0,03 %	-0,01 %	0,00626	-0,32 %	0,20 %	-0,10 %	48,68 %	48,68 %	48,68 %	48,68 %
F	0,00950	0,56 %	0,15 %	0,09 %	0,00622	0,52 %	0,24 %	0,05 %	50,00 %	50,00 %	49,67 %	49,34 %
FDX	0,01306	0,00 %	0,04 %	-0,17 %	0,00760	0,02 %	-2,87 %	-2,99 %	49,67 %	49,67 %	48,68 %	43,42 %
FISV	0,03664	0,02 %	-0,17 %	0,04 %	0,00921	0,06 %	-0,10 %	0,17 %	48,03 %	48,03 %	48,68 %	48,03 %
FITB	0,00955	0,33 %	1,14 %	0,03 %	0,00625	0,56 %	2,32 %	-0,35 %	47,70 %	46,38 %	46,38 %	46,05 %
GILD	0,00844	0,12 %	0,15 %	0,00 %	0,00553	-0,14 %	-0,13 %	-0,02 %	52,96 %	52,96 %	52,96 %	52,96 %
GIS	0,00639	-0,02 %	0,09 %	-0,04 %	0,00444	-0,31 %	-0,52 %	-0,29 %	46,38 %	46,38 %	43,42 %	47,37 %
GLW	0,01991	-0,08 %	-0,03 %	-0,02 %	0,01242	-0,17 %	-0,08 %	-0,06 %	56,58 %	56,58 %	56,58 %	56,58 %
GM	0,01365	0,02 %	0,10 %	0,20 %	0,00831	0,05 %	0,18 %	0,43 %	51,97 %	51,97 %	51,97 %	49,67 %

Tabla 12: Variaciones individuales para CtO (parte 2 de 2)

Activo	RMSE V5	$\Delta V6$	$\Delta V7$	$\Delta V8$	MAE V5	$\Delta V6$	$\Delta V7$	$\Delta V8$	HR V5	HR V6	HR V7	HR V8
GOOGL	0,01370	-0,06 %	0,07 %	-0,16 %	0,00895	-0,05 %	0,05 %	-0,12 %	47,04 %	50,00 %	49,34 %	51,97 %
GS	0,01219	0,13 %	-0,46 %	-0,14 %	0,00768	0,17 %	-0,28 %	-0,00 %	52,63 %	52,96 %	54,28 %	52,96 %
HSIC	0,00940	0,05 %	-0,00 %	-0,06 %	0,00524	0,26 %	-0,09 %	0,40 %	47,04 %	47,04 %	48,03 %	47,37 %
INTC	0,02964	0,30 %	0,13 %	0,07 %	0,01688	0,63 %	0,36 %	0,20 %	47,37 %	46,05 %	47,04 %	48,68 %
ISRG	0,01392	-0,09 %	-0,24 %	0,04 %	0,00715	-0,28 %	-0,76 %	0,07 %	47,04 %	48,68 %	52,96 %	47,37 %
JPM	0,00958	-0,19 %	0,08 %	0,04 %	0,00607	-0,07 %	0,05 %	0,05 %	53,95 %	53,95 %	53,95 %	53,95 %
KHC	0,00710	0,26 %	0,16 %	0,50 %	0,00399	0,82 %	1,04 %	0,36 %	49,67 %	44,08 %	44,08 %	50,00 %
KMB	0,01049	0,09 %	0,02 %	0,03 %	0,00440	-0,11 %	-0,22 %	-0,17 %	47,70 %	45,72 %	47,70 %	49,34 %
KO	0,00641	0,07 %	-0,08 %	0,09 %	0,00363	0,20 %	-0,46 %	0,26 %	48,03 %	48,03 %	48,03 %	48,03 %
LLY	0,01541	-0,25 %	0,02 %	-0,00 %	0,00804	-0,86 %	0,07 %	-0,03 %	51,64 %	51,64 %	51,64 %	51,64 %
MCD	0,00540	-0,12 %	-0,04 %	-0,07 %	0,00373	-0,14 %	-0,03 %	-0,09 %	50,33 %	50,33 %	50,33 %	50,33 %
MCHP	0,02094	0,24 %	-0,06 %	-0,09 %	0,01367	-0,14 %	-0,04 %	-0,16 %	52,96 %	53,29 %	53,29 %	53,29 %
MMM	0,00949	-0,10 %	-0,03 %	0,10 %	0,00609	0,50 %	-0,03 %	0,19 %	47,04 %	50,66 %	47,04 %	47,04 %
MNST	0,01025	0,00 %	0,01 %	-0,05 %	0,00469	-0,01 %	-0,08 %	0,22 %	49,01 %	49,01 %	49,01 %	49,01 %
MRK	0,00766	-0,11 %	-0,01 %	-0,10 %	0,00493	0,00 %	0,87 %	0,11 %	53,29 %	53,29 %	45,07 %	52,96 %
MSFT	0,01225	0,03 %	-0,07 %	-0,14 %	0,00700	0,10 %	-0,14 %	-0,26 %	51,97 %	51,97 %	56,58 %	51,32 %
MSI	0,00730	0,13 %	-0,24 %	-0,24 %	0,00426	0,38 %	-0,74 %	-0,75 %	47,70 %	47,70 %	47,70 %	47,70 %
ORCL	0,02724	-0,00 %	0,15 %	-0,05 %	0,01525	0,06 %	0,31 %	0,02 %	53,62 %	53,29 %	46,71 %	52,96 %
PAYX	0,00782	-0,52 %	-0,47 %	-0,74 %	0,00464	-1,21 %	-1,12 %	-1,73 %	41,45 %	41,45 %	41,45 %	41,45 %
QCOM	0,01705	0,09 %	0,11 %	0,57 %	0,00996	0,37 %	0,46 %	1,34 %	47,70 %	47,70 %	47,70 %	50,00 %
STLD	0,01325	-0,40 %	-0,31 %	-0,46 %	0,00832	-2,34 %	-1,56 %	-2,07 %	49,34 %	48,68 %	49,34 %	49,34 %
T	0,00817	0,20 %	0,48 %	0,09 %	0,00486	-1,15 %	-1,78 %	-0,72 %	45,39 %	45,39 %	45,39 %	45,39 %
VRTX	0,01132	0,01 %	0,15 %	0,25 %	0,00543	-3,09 %	-3,13 %	0,84 %	49,67 %	49,67 %	47,70 %	49,67 %
WBD	0,01479	1,20 %	0,63 %	0,30 %	0,00828	2,12 %	1,06 %	0,87 %	46,71 %	46,71 %	46,71 %	46,05 %
WYNN	0,01218	0,08 %	-0,41 %	-0,19 %	0,00801	0,46 %	1,12 %	1,05 %	46,38 %	46,38 %	44,08 %	47,37 %

11.1.3. Retorno objetivo OtC (V9-V12)

Tabla 13: Variaciones individuales para OtC (parte 1 de 2)

Activo	RMSE V9	Δ V10	Δ V11	Δ V12	MAE V9	Δ V10	Δ V11	Δ V12	HR V9	HR V10	HR V11	HR V12
AAPL	0,01641	-0,35 %	-0,35 %	-0,37 %	0,01040	-0,20 %	-0,19 %	-0,22 %	51,64 %	52,30 %	52,30 %	52,30 %
ADBE	0,01723	-0,00 %	-0,00 %	0,17 %	0,01269	0,03 %	0,02 %	0,01 %	49,01 %	49,01 %	49,01 %	48,36 %
ADSK	0,01629	-0,16 %	0,08 %	-0,07 %	0,01170	-0,15 %	0,05 %	-0,10 %	47,37 %	51,64 %	48,03 %	51,32 %
AMAT	0,02420	-0,13 %	0,03 %	-0,08 %	0,01670	-0,21 %	0,05 %	-0,08 %	44,08 %	55,26 %	44,08 %	51,64 %
AMZN	0,01716	-0,09 %	0,12 %	0,63 %	0,01233	-0,10 %	-0,17 %	0,25 %	48,68 %	48,68 %	51,32 %	48,03 %
BA	0,01920	-0,03 %	-0,09 %	0,01 %	0,01309	-0,24 %	-0,36 %	-0,21 %	49,67 %	50,33 %	50,33 %	50,33 %
BAC	0,01380	0,11 %	-0,02 %	0,00 %	0,00996	0,09 %	0,03 %	0,00 %	48,68 %	48,68 %	48,03 %	48,68 %
C	0,01771	0,05 %	-0,18 %	0,05 %	0,01287	0,10 %	-0,35 %	0,09 %	42,76 %	42,76 %	44,08 %	42,76 %
CAT	0,01750	0,15 %	-0,02 %	-0,12 %	0,01242	0,07 %	-0,00 %	-0,12 %	54,61 %	54,28 %	54,61 %	54,61 %
CDNS	0,02113	0,50 %	-0,02 %	0,07 %	0,01461	1,11 %	-0,06 %	0,20 %	46,05 %	46,05 %	53,29 %	46,05 %
CSCO	0,01448	-0,10 %	-0,09 %	0,06 %	0,01039	-0,05 %	-0,04 %	0,03 %	52,63 %	52,63 %	52,63 %	52,63 %
CTAS	0,01346	0,01 %	0,19 %	0,05 %	0,00968	-0,01 %	0,28 %	0,07 %	51,64 %	51,64 %	50,99 %	48,36 %
CVX	0,01328	0,07 %	-0,02 %	0,01 %	0,00914	0,11 %	-0,06 %	0,07 %	46,71 %	46,71 %	46,71 %	46,71 %
DE	0,01623	0,03 %	0,12 %	0,00 %	0,01182	-0,00 %	0,20 %	-0,00 %	53,62 %	49,34 %	48,03 %	52,96 %
DELL	0,02831	0,14 %	0,02 %	0,38 %	0,01998	0,17 %	0,03 %	0,50 %	52,96 %	52,96 %	52,96 %	47,70 %
DIS	0,01466	0,04 %	-0,23 %	-0,01 %	0,01023	0,03 %	-0,13 %	-0,02 %	50,66 %	50,66 %	50,99 %	50,66 %
EBAY	0,01824	0,07 %	0,01 %	0,05 %	0,01385	0,09 %	0,05 %	0,03 %	54,61 %	54,61 %	54,28 %	54,28 %
F	0,01978	0,00 %	-0,26 %	0,13 %	0,01336	-0,00 %	-0,09 %	0,01 %	49,34 %	49,01 %	54,28 %	49,01 %
FDX	0,01810	-0,35 %	0,02 %	0,01 %	0,01286	-0,52 %	0,03 %	0,01 %	44,41 %	55,59 %	44,41 %	44,41 %
FISV	0,02114	-0,01 %	0,23 %	0,12 %	0,01391	-0,25 %	0,09 %	-0,07 %	45,72 %	47,37 %	45,07 %	45,72 %
FITB	0,01658	-0,53 %	-0,40 %	-0,53 %	0,01174	-0,76 %	-0,55 %	-0,74 %	48,36 %	50,66 %	48,03 %	50,33 %
GILD	0,01587	0,01 %	0,02 %	0,01 %	0,01222	0,02 %	0,01 %	0,00 %	51,97 %	51,97 %	51,97 %	51,97 %
GIS	0,01409	0,06 %	0,20 %	0,12 %	0,01086	0,05 %	0,17 %	0,10 %	53,29 %	53,29 %	46,05 %	53,29 %
GLW	0,02492	-0,08 %	0,04 %	-0,12 %	0,01735	-0,12 %	-0,02 %	0,01 %	41,45 %	43,75 %	41,45 %	45,39 %
GM	0,01734	-0,04 %	0,10 %	0,03 %	0,01240	-0,03 %	0,16 %	0,00 %	46,38 %	47,37 %	46,38 %	47,04 %

Tabla 14: Variaciones individuales para OtC (parte 2 de 2)

Activo	RMSE V9	Δ V10	Δ V11	Δ V12	MAE V9	Δ V10	Δ V11	Δ V12	HR V9	HR V10	HR V11	HR V12
GOOGL	0,01699	-0,06 %	0,04 %	-0,01 %	0,01264	-0,06 %	0,05 %	-0,03 %	54,28 %	54,28 %	54,28 %	54,28 %
GS	0,01737	0,04 %	-0,01 %	0,06 %	0,01220	-0,22 %	-0,22 %	-0,13 %	57,89 %	57,89 %	57,57 %	56,91 %
HSIC	0,01475	-0,00 %	0,22 %	0,02 %	0,01141	-0,05 %	0,21 %	-0,01 %	47,04 %	52,30 %	48,36 %	51,32 %
INTC	0,03416	-0,10 %	-0,03 %	-0,12 %	0,02514	-0,27 %	-0,02 %	-0,12 %	48,68 %	49,67 %	47,37 %	50,00 %
ISRG	0,01938	-0,03 %	-0,13 %	-0,01 %	0,01313	-0,03 %	-0,11 %	-0,01 %	48,36 %	48,36 %	51,64 %	48,36 %
JPM	0,01403	0,03 %	0,04 %	-0,01 %	0,01023	-0,01 %	0,00 %	-0,06 %	52,63 %	52,63 %	52,63 %	51,64 %
KHC	0,01501	-0,07 %	0,08 %	0,19 %	0,01120	-0,00 %	0,13 %	0,31 %	50,33 %	49,67 %	48,68 %	48,03 %
KMB	0,01217	0,08 %	-0,04 %	0,29 %	0,00929	0,11 %	-0,08 %	0,34 %	54,28 %	46,05 %	53,29 %	47,37 %
KO	0,00948	0,23 %	-0,04 %	0,16 %	0,00728	0,18 %	-0,03 %	0,16 %	48,36 %	48,36 %	51,32 %	48,36 %
LLY	0,01898	0,07 %	-0,02 %	-0,00 %	0,01448	0,05 %	-0,01 %	0,04 %	53,29 %	53,95 %	53,29 %	53,29 %
MCD	0,01028	0,20 %	0,08 %	0,07 %	0,00776	0,23 %	0,09 %	0,08 %	50,99 %	46,38 %	48,68 %	48,68 %
MCHP	0,02878	-0,10 %	-0,08 %	-0,10 %	0,01893	-0,06 %	-0,00 %	0,00 %	50,00 %	49,01 %	50,33 %	50,00 %
MMM	0,01599	-0,12 %	0,25 %	0,41 %	0,01182	-0,10 %	0,04 %	0,54 %	48,36 %	49,67 %	51,64 %	48,36 %
MNST	0,01277	-0,11 %	-0,40 %	-0,23 %	0,00958	-0,17 %	-0,59 %	-0,34 %	46,05 %	46,05 %	46,05 %	46,05 %
MRK	0,01688	0,01 %	0,03 %	-0,01 %	0,01205	0,00 %	0,03 %	-0,01 %	49,01 %	49,01 %	49,01 %	49,01 %
MSFT	0,01315	-0,01 %	-0,00 %	0,02 %	0,00936	-0,11 %	-0,00 %	-0,11 %	45,07 %	51,32 %	45,07 %	51,32 %
MSI	0,01263	-0,08 %	0,03 %	0,13 %	0,00861	-0,29 %	-0,24 %	0,66 %	46,38 %	55,59 %	53,29 %	50,33 %
ORCL	0,02619	0,36 %	0,02 %	0,28 %	0,01949	0,17 %	0,02 %	0,14 %	48,36 %	46,05 %	48,36 %	49,01 %
PAYX	0,01488	0,23 %	0,14 %	0,12 %	0,01074	0,40 %	0,32 %	0,28 %	50,33 %	47,70 %	53,29 %	52,30 %
QCOM	0,02167	-0,03 %	0,01 %	0,57 %	0,01450	-0,00 %	0,00 %	0,45 %	51,32 %	51,32 %	51,32 %	51,32 %
STLD	0,01978	-0,28 %	-0,08 %	-0,15 %	0,01480	-0,36 %	-0,06 %	-0,21 %	47,70 %	54,93 %	46,05 %	46,38 %
T	0,01426	-0,02 %	-0,01 %	0,38 %	0,01021	-0,05 %	-0,03 %	0,56 %	54,93 %	54,93 %	54,93 %	42,76 %
VRTX	0,01586	-0,04 %	0,09 %	0,01 %	0,01203	0,01 %	-0,02 %	-0,06 %	49,01 %	49,01 %	47,70 %	49,01 %
WBD	0,03054	0,43 %	-0,02 %	0,43 %	0,01721	0,79 %	0,02 %	0,79 %	51,64 %	46,71 %	51,64 %	46,71 %
WYNN	0,02140	0,09 %	0,01 %	-0,03 %	0,01527	0,41 %	-0,03 %	-0,04 %	50,99 %	50,66 %	50,99 %	50,99 %

11.2 Anexo B: MCS entre Configuraciones LSTM

Las tablas presentan los p-valores y los conjuntos retenidos en los archivos de MCS interno para CtC, CtO y OtC. Se utiliza el archivo CtC sin el sufijo de copia; ambas copias conservan los mismos conjuntos, aunque algunos p-valores difieren. La pertenencia se transcribe del conjunto reportado y se destaca en negrita el p-valor de cada modelo retenido. N indica el número de modelos en M^* . Un p-valor igual a 1,000 no representa una probabilidad de superioridad.

11.2.1. Retorno objetivo CtC

Tabla 15: MCS interno para CtC (parte 1 de 2)

Activo	Modelos en M^*	N	p V1	p V2	p V3	p V4
AAPL	V1, V2, V3, V4	4	0,922	1,000	0,922	0,990
ADBE	V1, V2, V3, V4	4	1,000	0,215	0,392	0,392
ADSK	V1, V2, V3, V4	4	1,000	0,504	0,504	0,541
AMAT	V2, V4	2	0,109	1,000	0,109	0,824
AMZN	V1, V2, V3, V4	4	0,932	0,830	0,680	1,000
BA	V1, V2, V3, V4	4	0,537	1,000	0,998	0,322
BAC	V1, V2, V3, V4	4	0,444	1,000	0,301	0,481
C	V1, V2, V3, V4	4	0,319	0,229	1,000	0,274
CAT	V2	1	0,090	1,000	0,007	0,090
CDNS	V1, V2, V3, V4	4	0,637	0,637	0,791	1,000
CSCO	V1, V2, V4	3	0,254	1,000	0,053	0,254
CTAS	V3	1	0,015	0,103	1,000	0,126
CVX	V1, V2, V3, V4	4	0,974	0,974	0,317	1,000
DE	V1, V2, V4	3	1,000	0,279	0,053	0,279
DELL	V1, V2, V4	3	0,397	0,397	0,041	1,000
DIS	V1, V2, V3, V4	4	0,811	0,931	1,000	0,811
EBAY	V1, V3, V4	3	0,197	0,037	1,000	0,294
F	V1, V2, V3, V4	4	0,528	0,528	0,528	1,000
FDX	V1, V3, V4	3	0,486	0,064	1,000	0,393
FISV	V1	1	1,000	0,062	0,043	0,043
FITB	V1, V2, V3, V4	4	0,740	0,159	0,740	1,000
GILD	V1, V2, V3, V4	4	0,738	0,706	1,000	0,394
GIS	V1	1	1,000	0,013	0,040	0,013
GLW	V2, V3	2	0,011	1,000	0,497	0,011
GM	V1, V2, V3, V4	4	0,672	1,000	0,269	0,672

Tabla 16: MCS interno para CtC (parte 2 de 2)

Activo	Modelos en M^*	N	p V1	p V2	p V3	p V4
GOOGL	V2, V3	2	0,012	1,000	0,216	0,039
GS	V1, V2, V3, V4	4	1,000	0,418	0,199	0,553
HSIC	V1, V2, V3, V4	4	0,923	1,000	0,724	0,724
INTC	V1, V4	2	0,159	0,043	0,055	1,000
ISRG	V1, V4	2	0,270	0,084	0,037	1,000
JPM	V1, V2, V3, V4	4	1,000	0,960	0,960	0,960
KHC	V4	1	0,055	0,108	0,024	1,000
KMB	V1, V4	2	1,000	0,129	0,119	0,239
KO	V1, V2, V3, V4	4	0,974	0,446	1,000	0,542
LLY	V1, V2, V3, V4	4	0,728	0,728	1,000	0,403
MCD	V1, V2, V3, V4	4	1,000	0,309	0,343	0,552
MCHP	V1, V2, V3	3	1,000	0,572	0,243	0,066
MMM	V1, V2, V3, V4	4	1,000	0,835	0,835	0,835
MNST	V1, V2, V4	3	0,228	0,988	0,058	1,000
MRK	V1, V2, V3, V4	4	0,398	0,736	1,000	0,757
MSFT	V1, V2, V3, V4	4	1,000	0,875	0,874	0,988
MSI	V1, V2, V3, V4	4	0,427	0,427	0,427	1,000
ORCL	V1, V2, V3, V4	4	0,935	1,000	0,951	0,979
PAYX	V4	1	0,008	0,008	0,008	1,000
QCOM	V1, V2, V3, V4	4	0,565	0,565	1,000	0,565
STLD	V1, V2, V4	3	0,245	1,000	0,076	0,245
T	V1, V2, V3, V4	4	0,975	1,000	0,957	0,395
VRTX	V3	1	0,093	0,104	1,000	0,104
WBD	V1, V2	2	1,000	0,256	0,119	0,060
WYNN	V1, V2, V3, V4	4	0,928	1,000	0,580	0,964

11.2.2. Retorno objetivo CtO

Tabla 17: MCS interno para CtO (parte 1 de 2)

Activo	Modelos en M^*	N	p V5	p V6	p V7	p V8
AAPL	V5, V6, V7, V8	4	0,971	1,000	0,971	0,971
ADBE	V5, V6, V8	3	1,000	0,540	0,068	0,187
ADSK	V5, V6, V7, V8	4	0,796	1,000	0,436	0,796
AMAT	V5, V6, V7, V8	4	0,984	0,980	0,984	1,000
AMZN	V5, V6, V7, V8	4	1,000	0,944	0,944	0,944
BA	V5, V6, V7, V8	4	0,179	0,278	0,670	1,000
BAC	V5, V6, V7, V8	4	0,465	1,000	0,930	0,465
C	V5, V6, V7, V8	4	0,207	1,000	0,207	0,207
CAT	V5, V6, V7, V8	4	0,706	0,594	0,594	1,000
CDNS	V5, V6, V7, V8	4	0,478	0,952	0,868	1,000
CSCO	V5, V6, V7, V8	4	0,319	1,000	0,319	0,319
CTAS	V6	1	0,000	1,000	0,002	0,003
CVX	V5, V6, V7, V8	4	0,864	0,864	0,864	1,000
DE	V5, V6, V7, V8	4	0,318	1,000	0,318	0,318
DELL	V5, V6, V7, V8	4	0,983	1,000	0,873	0,983
DIS	V5, V6, V7, V8	4	0,673	0,673	0,673	1,000
EBAY	V5, V6, V7, V8	4	0,680	1,000	0,668	0,786
F	V5, V6, V7, V8	4	1,000	0,240	0,593	0,815
FDX	V5, V6, V7, V8	4	0,814	0,227	0,455	1,000
FISV	V5, V6, V7	3	0,194	0,194	1,000	0,137
FITB	V5, V6, V8	3	1,000	0,529	0,145	0,853
GILD	V5, V6, V7, V8	4	1,000	0,478	0,701	0,986
GIS	V5, V6, V7, V8	4	0,934	0,934	0,788	1,000
GLW	V5, V6, V7, V8	4	0,583	1,000	0,583	0,583
GM	V5, V6	2	1,000	0,572	0,147	0,133

Tabla 18: MCS interno para CtO (parte 2 de 2)

Activo	Modelos en M^*	N	p V5	p V6	p V7	p V8
GOOGL	V5, V6, V7, V8	4	0,185	0,185	0,185	1,000
GS	V5, V6, V7, V8	4	0,322	0,322	1,000	0,322
HSIC	V5, V6, V7, V8	4	0,859	0,859	0,859	1,000
INTC	V5, V7, V8	3	1,000	0,062	0,350	0,566
ISRG	V5, V6, V7, V8	4	0,276	0,497	1,000	0,276
JPM	V5, V6	2	0,196	1,000	0,127	0,110
KHC	V5, V6, V7, V8	4	1,000	0,585	0,585	0,515
KMB	V5, V6, V7, V8	4	1,000	0,871	0,904	0,904
KO	V5, V6, V7, V8	4	0,731	0,454	1,000	0,454
LLY	V5, V6, V7, V8	4	0,496	1,000	0,496	0,496
MCD	V5, V6, V7, V8	4	0,362	1,000	0,263	0,520
MCHP	V5, V6, V7, V8	4	0,698	0,480	0,769	1,000
MMM	V5, V6, V7, V8	4	0,415	1,000	0,881	0,371
MNST	V5, V6, V7, V8	4	0,660	0,660	0,660	1,000
MRK	V5, V6, V7, V8	4	0,646	1,000	0,922	0,922
MSFT	V5, V6, V7, V8	4	0,243	0,243	0,719	1,000
MSI	V5, V6, V7, V8	4	0,221	0,221	0,871	1,000
ORCL	V5, V6, V7, V8	4	0,633	0,438	0,438	1,000
PAYX	V8	1	0,004	0,009	0,009	1,000
QCOM	V5, V6, V7, V8	4	1,000	0,610	0,610	0,610
STLD	V5, V6, V7, V8	4	0,364	0,836	0,364	1,000
T	V5, V6, V8	3	1,000	0,305	0,129	0,525
VRTX	V5, V6	2	1,000	0,980	0,150	0,150
WBD	V5, V8	2	1,000	0,014	0,098	0,312
WYNN	V5, V6, V7, V8	4	0,833	0,693	1,000	0,833

11.2.3. Retorno objetivo OtC

Tabla 19: MCS interno para OtC (parte 1 de 2)

Activo	Modelos en M^*	N	p V9	p V10	p V11	p V12
AAPL	V9, V10, V11, V12	4	0,488	0,606	0,837	1,000
ADBE	V9, V10, V11, V12	4	0,932	0,932	1,000	0,335
ADSK	V9, V10, V11, V12	4	0,341	1,000	0,341	0,341
AMAT	V10, V12	2	0,087	1,000	0,087	0,614
AMZN	V9, V10, V11, V12	4	0,436	1,000	0,481	0,415
BA	V9, V10, V11, V12	4	0,719	0,719	1,000	0,719
BAC	V9, V10, V11, V12	4	0,772	0,405	1,000	0,772
C	V11	1	0,072	0,072	1,000	0,072
CAT	V10, V12	2	0,009	0,354	0,022	1,000
CDNS	V9, V10, V11, V12	4	0,589	0,230	1,000	0,589
CSCO	V10	1	0,070	1,000	0,104	0,104
CTAS	V9, V10, V11, V12	4	1,000	0,887	0,887	0,887
CVX	V9, V10, V11, V12	4	0,504	0,504	1,000	0,535
DE	V9, V10, V11, V12	4	1,000	0,610	0,610	0,610
DELL	V9, V10, V11	3	1,000	0,249	0,337	0,122
DIS	V11	1	0,055	0,110	1,000	0,110
EBAY	V9, V10, V11, V12	4	1,000	0,261	0,817	0,267
F	V9, V10, V11, V12	4	0,313	0,313	1,000	0,313
FDX	V10	1	0,081	1,000	0,023	0,042
FISV	V9, V10	2	0,929	1,000	0,057	0,034
FITB	V9, V10, V11, V12	4	0,364	1,000	0,728	0,975
GILD	V9, V10, V11, V12	4	1,000	0,702	0,702	0,287
GIS	V9, V10, V12	3	1,000	0,370	0,037	0,160
GLW	V9, V10, V12	3	0,162	0,599	0,040	1,000
GM	V10, V11, V12	3	0,063	1,000	0,500	0,500

Tabla 20: MCS interno para OtC (parte 2 de 2)

Activo	Modelos en M^*	N	p V9	p V10	p V11	p V12
GOOGL	V10, V12	2	0,133	1,000	0,130	0,339
GS	V9, V10, V11, V12	4	0,910	0,425	1,000	0,219
HSIC	V9, V10, V11, V12	4	0,952	1,000	0,261	0,950
INTC	V9, V10, V11, V12	4	0,236	0,873	0,200	1,000
ISRG	V9, V10, V11, V12	4	0,400	0,775	1,000	0,400
JPM	V9, V10, V11, V12	4	0,771	0,686	0,686	1,000
KHC	V9, V10, V11, V12	4	0,279	1,000	0,325	0,343
KMB	V9, V10, V11, V12	4	0,718	0,284	1,000	0,284
KO	V9, V11, V12	3	0,389	0,105	1,000	0,347
LLY	V9, V10, V11, V12	4	0,579	0,656	1,000	0,762
MCD	V9, V11, V12	3	1,000	0,150	0,840	0,840
MCHP	V9, V10, V11, V12	4	0,621	0,990	0,810	1,000
MMM	V9, V10, V11	3	0,488	1,000	0,488	0,144
MNST	V11, V12	2	0,069	0,110	1,000	0,176
MRK	V9, V10, V11, V12	4	0,849	0,622	0,496	1,000
MSFT	V9, V10, V11, V12	4	0,975	1,000	0,980	0,892
MSI	V9, V10, V11, V12	4	0,719	1,000	0,354	0,719
ORCL	V9, V10, V11	3	1,000	0,191	0,191	0,128
PAYX	V9, V10, V11, V12	4	1,000	0,321	0,687	0,689
QCOM	V9, V10	2	0,168	1,000	0,128	0,083
STLD	V10, V12	2	0,051	1,000	0,135	0,156
T	V9, V10, V11, V12	4	0,598	1,000	0,308	0,179
VRTX	V9, V10, V12	3	0,227	1,000	0,051	0,401
WBD	V9, V10, V11, V12	4	0,638	0,434	1,000	0,434
WYNN	V9, V10, V11, V12	4	0,445	0,445	0,445	1,000

11.3 Anexo C: Métricas de ARIMA y Random Forest

Las tablas presentan los resultados de los modelos de referencia para cada retorno objetivo y cada acción. RMSE y MAE se expresan en la escala original de los retornos; el Hit Ratio se informa en porcentaje. Las series de residuos suministradas contienen las 304 observaciones por activo del conjunto de prueba, equivalente aproximadamente al 20 % final, y reproducen los valores de RMSE y MAE reportados.

11.3.1. Retorno objetivo CtC

Tabla 21: Métricas de los modelos de referencia para CtC (parte 1 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
AAPL	0,01928	0,01237	52,63 %	(0, 0, 0)	0,01852	0,01201	57,24 %
ADBE	0,02195	0,01513	0,33 %	(0, 0, 0)	0,02190	0,01494	54,93 %
ADSK	0,02021	0,01411	0,00 %	(0, 0, 0)	0,02013	0,01406	48,36 %
AMAT	0,03041	0,02176	52,63 %	(1, 0, 0)	0,03050	0,02197	55,59 %
AMZN	0,02156	0,01542	0,00 %	(0, 0, 0)	0,02159	0,01546	47,70 %
BA	0,02333	0,01576	0,00 %	(0, 0, 0)	0,02386	0,01616	50,99 %
BAC	0,01725	0,01183	0,99 %	(0, 0, 0)	0,01710	0,01171	54,28 %
C	0,02080	0,01456	0,33 %	(0, 0, 0)	0,02105	0,01468	49,67 %
CAT	0,02201	0,01562	56,25 %	(0, 0, 0)	0,02308	0,01618	50,99 %
CDNS	0,02485	0,01707	53,62 %	(0, 0, 0)	0,02472	0,01701	50,99 %
CSCO	0,01765	0,01197	0,99 %	(0, 0, 0)	0,01907	0,01237	52,63 %
CTAS	0,01387	0,00999	48,36 %	(1, 0, 0)	0,01390	0,01001	47,37 %
CVX	0,01614	0,01151	0,00 %	(0, 0, 0)	0,01598	0,01143	52,96 %
DE	0,01906	0,01349	49,34 %	(0, 0, 0)	0,01940	0,01392	48,03 %
DELL	0,03593	0,02484	51,64 %	(1, 0, 0)	0,03700	0,02562	51,32 %
DIS	0,01945	0,01265	0,00 %	(0, 0, 0)	0,01951	0,01264	54,61 %
EBAY	0,02394	0,01570	50,00 %	(0, 0, 1)	0,02352	0,01541	54,93 %
F	0,02174	0,01530	1,97 %	(0, 0, 0)	0,02278	0,01611	46,38 %
FDX	0,02077	0,01416	0,00 %	(0, 0, 0)	0,02164	0,01492	53,62 %
FISV	0,04309	0,01821	50,33 %	(1, 0, 0)	0,04327	0,01827	49,67 %
FITB	0,01840	0,01285	0,33 %	(0, 0, 0)	0,01839	0,01280	50,66 %
GILD	0,01747	0,01344	0,66 %	(0, 0, 0)	0,01747	0,01338	55,26 %
GIS	0,01543	0,01163	0,99 %	(0, 0, 0)	0,01565	0,01178	51,97 %
GLW	0,03135	0,02119	58,22 %	(0, 0, 0)	0,03161	0,02134	50,33 %
GM	0,02231	0,01505	0,33 %	(0, 0, 0)	0,02253	0,01523	49,34 %

Tabla 22: Métricas de los modelos de referencia para CtC (parte 2 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
GOOGL	0,02000	0,01456	53,95 %	(0, 0, 0)	0,02014	0,01459	50,66 %
GS	0,02021	0,01432	58,22 %	(0, 0, 0)	0,02018	0,01425	55,92 %
HSIC	0,01760	0,01315	0,66 %	(0, 0, 0)	0,01796	0,01344	53,62 %
INTC	0,04466	0,03089	0,66 %	(0, 0, 0)	0,04719	0,03266	49,34 %
ISRG	0,02183	0,01435	49,01 %	(0, 0, 0)	0,02210	0,01451	49,67 %
JPM	0,01606	0,01132	54,28 %	(0, 0, 0)	0,01649	0,01167	50,66 %
KHC	0,01608	0,01206	0,33 %	(0, 0, 0)	0,01611	0,01208	48,68 %
KMB	0,01600	0,01053	0,00 %	(0, 0, 0)	0,01609	0,01058	47,04 %
KO	0,01076	0,00822	0,33 %	(0, 0, 0)	0,01104	0,00853	48,03 %
LLY	0,02635	0,01788	53,29 %	(0, 0, 0)	0,02641	0,01799	54,93 %
MCD	0,01141	0,00857	0,00 %	(0, 0, 0)	0,01150	0,00872	50,00 %
MCHP	0,03572	0,02283	48,03 %	(1, 0, 0)	0,03590	0,02343	47,04 %
MMM	0,01916	0,01370	0,33 %	(0, 0, 0)	0,01941	0,01393	49,34 %
MNST	0,01622	0,01094	52,96 %	(1, 0, 0)	0,01645	0,01110	45,39 %
MRK	0,01783	0,01300	0,00 %	(0, 0, 0)	0,01891	0,01358	48,68 %
MSFT	0,01691	0,01141	48,36 %	(1, 0, 1)	0,01687	0,01136	47,70 %
MSI	0,01590	0,00987	54,28 %	(1, 0, 1)	0,01631	0,01014	53,29 %
ORCL	0,03659	0,02508	50,66 %	(0, 0, 0)	0,03787	0,02631	48,68 %
PAYX	0,01713	0,01213	46,38 %	(0, 0, 0)	0,01714	0,01208	47,70 %
QCOM	0,02786	0,01719	51,32 %	(1, 0, 0)	0,02842	0,01749	51,97 %
STLD	0,02328	0,01740	53,95 %	(0, 0, 0)	0,02332	0,01743	57,24 %
T	0,01484	0,01095	0,99 %	(0, 0, 0)	0,01492	0,01100	49,01 %
VRTX	0,02196	0,01373	49,67 %	(1, 0, 0)	0,02221	0,01398	49,01 %
WBD	0,03359	0,01949	0,66 %	(0, 0, 0)	0,03525	0,02006	53,62 %
WYNN	0,02453	0,01784	0,33 %	(0, 0, 0)	0,02467	0,01783	50,99 %

11.3.2. Retorno objetivo CtO

Tabla 23: Métricas de los modelos de referencia para CtO (parte 1 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
AAPL	0,01210	0,00676	0,00 %	(0, 0, 0)	0,01228	0,00705	48,03 %
ADBE	0,01246	0,00768	1,32 %	(0, 0, 0)	0,01291	0,00793	49,01 %
ADSK	0,01231	0,00712	3,29 %	(0, 0, 0)	0,01250	0,00738	48,36 %
AMAT	0,02194	0,01413	50,00 %	(1, 0, 0)	0,02201	0,01437	43,75 %
AMZN	0,01721	0,00979	55,59 %	(0, 0, 0)	0,01745	0,00990	52,30 %
BA	0,01269	0,00781	0,66 %	(0, 0, 0)	0,01266	0,00777	58,88 %
BAC	0,01084	0,00674	53,62 %	(0, 0, 0)	0,01109	0,00681	51,64 %
C	0,01252	0,00796	54,93 %	(0, 0, 0)	0,01217	0,00794	52,30 %
CAT	0,01304	0,00859	56,91 %	(0, 0, 0)	0,01327	0,00874	51,97 %
CDNS	0,01324	0,00905	50,66 %	(0, 0, 3)	0,01318	0,00903	47,37 %
CSCO	0,01239	0,00621	2,30 %	(0, 0, 0)	0,01230	0,00631	50,00 %
CTAS	0,00676	0,00431	43,42 %	(0, 0, 2)	0,00674	0,00426	42,11 %
CVX	0,00985	0,00629	56,58 %	(0, 0, 0)	0,00997	0,00636	50,99 %
DE	0,01003	0,00606	51,97 %	(1, 0, 0)	0,01011	0,00613	52,96 %
DELL	0,02100	0,01372	54,61 %	(0, 0, 0)	0,02139	0,01412	52,63 %
DIS	0,01215	0,00594	1,64 %	(0, 0, 0)	0,01281	0,00621	52,30 %
EBAY	0,01403	0,00624	3,62 %	(0, 0, 0)	0,01410	0,00654	46,38 %
F	0,00949	0,00622	44,74 %	(1, 0, 0)	0,00950	0,00629	49,67 %
FDX	0,01305	0,00736	0,99 %	(0, 0, 0)	0,01365	0,00781	58,55 %
FISV	0,03680	0,00939	48,03 %	(1, 0, 0)	0,03665	0,00945	48,36 %
FITB	0,00986	0,00644	46,05 %	(1, 0, 0)	0,00966	0,00635	48,68 %
GILD	0,00848	0,00553	0,99 %	(0, 0, 0)	0,00862	0,00566	54,28 %
GIS	0,00639	0,00441	4,28 %	(0, 0, 0)	0,00629	0,00449	50,99 %
GLW	0,01994	0,01242	54,93 %	(0, 0, 1)	0,02035	0,01270	52,30 %
GM	0,01367	0,00831	51,97 %	(0, 0, 0)	0,01368	0,00831	54,93 %

Tabla 24: Métricas de los modelos de referencia para CtO (parte 2 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
GOOGL	0,01369	0,00894	0,99 %	(0, 0, 0)	0,01371	0,00897	50,33 %
GS	0,01219	0,00769	52,96 %	(0, 0, 0)	0,01209	0,00766	52,63 %
HSIC	0,00944	0,00526	44,74 %	(1, 0, 0)	0,00947	0,00530	50,66 %
INTC	0,02959	0,01694	51,97 %	(0, 0, 1)	0,03058	0,01809	48,68 %
ISRG	0,01394	0,00717	47,04 %	(0, 0, 0)	0,01427	0,00746	50,00 %
JPM	0,00958	0,00607	53,95 %	(0, 0, 0)	0,01006	0,00638	53,62 %
KHC	0,00712	0,00401	5,92 %	(0, 0, 0)	0,00715	0,00407	42,76 %
KMB	0,01049	0,00438	6,58 %	(0, 0, 0)	0,01052	0,00452	46,05 %
KO	0,00642	0,00364	48,03 %	(0, 0, 0)	0,00644	0,00362	48,36 %
LLY	0,01540	0,00802	51,64 %	(0, 0, 0)	0,01569	0,00836	51,64 %
MCD	0,00541	0,00373	50,33 %	(0, 0, 0)	0,00535	0,00369	52,96 %
MCHP	0,02112	0,01376	50,66 %	(1, 0, 0)	0,02131	0,01408	43,42 %
MMM	0,00950	0,00610	47,04 %	(0, 0, 0)	0,00972	0,00633	47,37 %
MNST	0,01024	0,00472	49,01 %	(0, 0, 0)	0,01023	0,00475	52,30 %
MRK	0,00772	0,00501	49,34 %	(1, 0, 0)	0,00813	0,00528	48,68 %
MSFT	0,01225	0,00700	0,33 %	(0, 0, 0)	0,01246	0,00713	49,01 %
MSI	0,00734	0,00431	48,03 %	(1, 0, 1)	0,00741	0,00435	47,04 %
ORCL	0,02723	0,01524	52,96 %	(0, 0, 0)	0,02858	0,01643	49,34 %
PAYX	0,00779	0,00463	42,11 %	(1, 0, 0)	0,00790	0,00476	40,79 %
QCOM	0,01711	0,00997	47,70 %	(1, 0, 0)	0,01709	0,01007	49,34 %
STLD	0,01323	0,00819	52,96 %	(0, 0, 2)	0,01334	0,00827	48,68 %
T	0,00824	0,00475	7,24 %	(0, 0, 0)	0,00842	0,00499	41,45 %
VRTX	0,01134	0,00523	2,96 %	(0, 0, 0)	0,01153	0,00545	45,72 %
WBD	0,01475	0,00824	8,88 %	(0, 0, 0)	0,01500	0,00862	45,39 %
WYNN	0,01225	0,00807	46,71 %	(1, 0, 0)	0,01222	0,00803	48,36 %

11.3.3. Retorno objetivo OtC

Tabla 25: Métricas de los modelos de referencia para OtC (parte 1 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
AAPL	0,01636	0,01038	52,30 %	(0, 0, 0)	0,01674	0,01059	47,70 %
ADBE	0,01724	0,01267	0,00 %	(0, 0, 0)	0,01742	0,01285	49,34 %
ADSK	0,01628	0,01169	0,33 %	(0, 0, 0)	0,01661	0,01188	47,70 %
AMAT	0,02419	0,01669	0,66 %	(0, 0, 0)	0,02475	0,01709	49,67 %
AMZN	0,01713	0,01230	0,00 %	(0, 0, 0)	0,01723	0,01222	50,99 %
BA	0,01918	0,01305	0,00 %	(0, 0, 0)	0,01923	0,01310	51,97 %
BAC	0,01380	0,00996	0,33 %	(0, 0, 0)	0,01380	0,00998	54,93 %
C	0,01767	0,01282	0,00 %	(0, 0, 0)	0,01776	0,01285	50,99 %
CAT	0,01751	0,01242	0,33 %	(0, 0, 0)	0,01753	0,01232	56,25 %
CDNS	0,02113	0,01461	0,66 %	(0, 0, 0)	0,02119	0,01466	50,66 %
CSCO	0,01450	0,01041	1,32 %	(0, 0, 0)	0,01460	0,01054	49,67 %
CTAS	0,01353	0,00971	49,34 %	(1, 0, 1)	0,01356	0,00974	47,04 %
CVX	0,01327	0,00911	0,33 %	(0, 0, 0)	0,01342	0,00929	46,71 %
DE	0,01623	0,01182	0,00 %	(0, 0, 0)	0,01645	0,01195	49,67 %
DELL	0,02835	0,02001	0,00 %	(0, 0, 0)	0,02819	0,01981	53,62 %
DIS	0,01464	0,01022	0,00 %	(0, 0, 0)	0,01460	0,01023	50,66 %
EBAY	0,01827	0,01388	0,00 %	(0, 0, 0)	0,01836	0,01403	49,67 %
F	0,01977	0,01336	1,32 %	(0, 0, 0)	0,02045	0,01370	51,64 %
FDX	0,01809	0,01285	0,00 %	(0, 0, 0)	0,01835	0,01297	48,03 %
FISV	0,02115	0,01388	0,33 %	(0, 0, 0)	0,02116	0,01401	48,36 %
FITB	0,01650	0,01166	0,99 %	(0, 0, 0)	0,01664	0,01190	45,39 %
GILD	0,01587	0,01222	51,97 %	(0, 0, 0)	0,01594	0,01223	50,99 %
GIS	0,01412	0,01088	0,66 %	(0, 0, 0)	0,01441	0,01113	51,64 %
GLW	0,02490	0,01729	0,33 %	(0, 0, 0)	0,02499	0,01718	47,70 %
GM	0,01733	0,01239	0,33 %	(0, 0, 0)	0,01733	0,01245	47,70 %

Tabla 26: Métricas de los modelos de referencia para OtC (parte 2 de 2)

Activo	RMSE ARIMA	MAE ARIMA	HR ARIMA	Orden ARIMA	RMSE RF	MAE RF	HR RF
GOOGL	0,01699	0,01264	54,28 %	(0, 0, 0)	0,01711	0,01275	52,63 %
GS	0,01739	0,01222	0,00 %	(0, 0, 0)	0,01700	0,01204	51,97 %
HSIC	0,01475	0,01141	0,66 %	(0, 0, 0)	0,01492	0,01158	48,03 %
INTC	0,03404	0,02493	50,99 %	(2, 0, 1)	0,03522	0,02583	50,33 %
ISRG	0,01937	0,01312	0,00 %	(0, 0, 0)	0,01965	0,01333	52,96 %
JPM	0,01403	0,01024	0,33 %	(0, 0, 0)	0,01405	0,01023	50,00 %
KHC	0,01501	0,01120	0,66 %	(0, 0, 0)	0,01528	0,01149	43,09 %
KMB	0,01217	0,00929	0,33 %	(0, 0, 0)	0,01214	0,00930	50,00 %
KO	0,00948	0,00728	0,33 %	(0, 0, 0)	0,00952	0,00726	50,99 %
LLY	0,01898	0,01449	0,00 %	(0, 0, 0)	0,01902	0,01454	49,34 %
MCD	0,01029	0,00776	0,33 %	(0, 0, 0)	0,01045	0,00786	50,33 %
MCHP	0,02867	0,01902	48,36 %	(1, 0, 1)	0,02923	0,01926	48,36 %
MMM	0,01598	0,01181	0,00 %	(0, 0, 0)	0,01652	0,01226	46,71 %
MNST	0,01271	0,00951	0,66 %	(0, 0, 0)	0,01281	0,00965	47,04 %
MRK	0,01687	0,01205	0,33 %	(0, 0, 0)	0,01716	0,01238	46,05 %
MSFT	0,01328	0,00950	44,74 %	(0, 0, 3)	0,01331	0,00944	48,68 %
MSI	0,01263	0,00860	0,33 %	(0, 0, 0)	0,01280	0,00882	45,39 %
ORCL	0,02617	0,01948	0,00 %	(0, 0, 0)	0,02660	0,02001	46,71 %
PAYX	0,01491	0,01077	0,00 %	(0, 0, 0)	0,01492	0,01071	51,64 %
QCOM	0,02165	0,01451	0,00 %	(0, 0, 0)	0,02163	0,01459	50,33 %
STLD	0,01972	0,01474	0,00 %	(0, 0, 0)	0,01988	0,01480	54,28 %
T	0,01428	0,01024	0,66 %	(0, 0, 0)	0,01441	0,01037	49,67 %
VRTX	0,01584	0,01202	49,34 %	(0, 0, 1)	0,01599	0,01209	48,68 %
WBD	0,03058	0,01723	1,64 %	(0, 0, 0)	0,03091	0,01743	49,01 %
WYNN	0,02136	0,01525	0,66 %	(0, 0, 0)	0,02175	0,01558	50,00 %

11.4 Anexo D: MCS Reportado con Modelos de Referencia

Las tablas transcriben los archivos que incorporan ARIMA y Random Forest al MCS de cada retorno objetivo. Su correspondencia con las métricas consolidadas queda pendiente de verificar con los residuos LSTM y el código de la ejecución actual. Los p-valores en negrita corresponden a los modelos incluidos en el conjunto reportado. RF identifica a Random Forest.

11.4.1. Retorno objetivo CtC

Tabla 27: MCS referencias para CtC (parte 1 de 2)

Activo	Modelos en M^*	N	p V1	p V2	p V3	p V4	p ARIMA	p RF
AAPL	ARIMA, RF	2	0,045	0,045	0,045	0,045	0,469	1,000
ADBE	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,939	1,000
ADSK	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,872	1,000
AMAT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,914
AMZN	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,966
BA	ARIMA, RF	2	0,004	0,004	0,004	0,004	1,000	0,537
BAC	ARIMA, RF	2	0,005	0,005	0,005	0,005	0,728	1,000
C	ARIMA, RF	2	0,002	0,001	0,002	0,002	1,000	0,668
CAT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,180
CDNS	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,851	1,000
CSCO	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,405
CTAS	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,956
CVX	ARIMA, RF	2	0,004	0,004	0,004	0,004	0,718	1,000
DE	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,555
DELL	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,440
DIS	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,929
EBAY	ARIMA, RF	2	0,001	0,001	0,001	0,001	0,650	1,000
F	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,201
FDX	ARIMA, RF	2	0,001	0,000	0,001	0,001	1,000	0,299
FISV	V1, V2, ARIMA, RF	4	0,223	0,223	0,053	0,043	1,000	0,829
FITB	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,988	1,000
GILD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,991
GIS	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,524
GLW	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,795
GM	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,745

Tabla 28: MCS referencias para CtC (parte 2 de 2)

Activo	Modelos en M^*	N	p V1	p V2	p V3	p V4	p ARIMA	p RF
GOOGL	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,793
GS	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,970	1,000
HSIC	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,496
INTC	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,126
ISRG	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,714
JPM	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,359
KHC	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,940
KMB	ARIMA, RF	2	0,007	0,007	0,007	0,007	1,000	0,756
KO	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,315
LLY	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,950
MCD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,730
MCHP	ARIMA, RF	2	0,022	0,022	0,022	0,022	1,000	0,874
MMM	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,620
MNST	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,607
MRK	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,095
MSFT	ARIMA, RF	2	0,002	0,002	0,002	0,002	0,917	1,000
MSI	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,560
ORCL	ARIMA, RF	2	0,005	0,005	0,005	0,005	1,000	0,249
PAYX	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,991
QCOM	ARIMA, RF	2	0,007	0,007	0,007	0,007	1,000	0,591
STLD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,931
T	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,842
VRTX	ARIMA, RF	2	0,039	0,039	0,039	0,039	1,000	0,607
WBD	ARIMA, RF	2	0,019	0,019	0,019	0,019	1,000	0,407
WYNN	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,863

11.4.2. Retorno objetivo CtO

Tabla 29: MCS referencias para CtO (parte 1 de 2)

Activo	Modelos en M^*	N	p V5	p V6	p V7	p V8	p ARIMA	p RF
AAPL	ARIMA, RF	2	0,075	0,075	0,075	0,075	1,000	0,201
ADBE	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,106
ADSK	ARIMA	1	0,002	0,002	0,002	0,002	1,000	0,095
AMAT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,446
AMZN	ARIMA, RF	2	0,005	0,005	0,005	0,005	1,000	0,161
BA	RF	1	0,002	0,002	0,002	0,002	0,139	1,000
BAC	ARIMA, RF	2	0,028	0,028	0,028	0,028	1,000	0,224
C	ARIMA, RF	2	0,016	0,016	0,016	0,016	0,451	1,000
CAT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,239
CDNS	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,506	1,000
CSCO	ARIMA, RF	2	0,066	0,066	0,066	0,066	0,529	1,000
CTAS	ARIMA, RF	2	0,000	0,002	0,001	0,001	0,672	1,000
CVX	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,350
DE	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,353
DELL	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,201
DIS	ARIMA	1	0,037	0,037	0,037	0,037	1,000	0,125
EBAY	ARIMA, RF	2	0,067	0,067	0,067	0,067	1,000	0,456
F	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,907
FDX	ARIMA	1	0,006	0,006	0,006	0,006	1,000	0,048
FISV	V5, V6, V7, V8, ARIMA, RF	6	0,216	0,216	0,216	0,170	0,408	1,000
FITB	ARIMA, RF	2	0,003	0,003	0,003	0,003	0,512	1,000
GILD	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,103
GIS	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,582	1,000
GLW	ARIMA, RF	2	0,009	0,009	0,009	0,009	1,000	0,225
GM	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,886

Tabla 30: MCS referencias para CtO (parte 2 de 2)

Activo	Modelos en M^*	N	p V5	p V6	p V7	p V8	p ARIMA	p RF
GOOGL	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,725
GS	ARIMA, RF	2	0,019	0,019	0,019	0,019	0,324	1,000
HSIC	ARIMA, RF	2	0,003	0,003	0,003	0,003	1,000	0,608
INTC	ARIMA	1	0,005	0,005	0,005	0,005	1,000	0,009
ISRG	ARIMA	1	0,073	0,073	0,073	0,073	1,000	0,073
JPM	ARIMA	1	0,007	0,007	0,008	0,008	1,000	0,016
KHC	ARIMA, RF	2	0,014	0,014	0,014	0,014	1,000	0,607
KMB	V5, V6, V7, V8, ARIMA, RF	6	0,230	0,230	0,230	0,230	1,000	0,623
KO	ARIMA, RF	2	0,013	0,013	0,013	0,013	1,000	0,504
LLY	ARIMA	1	0,030	0,030	0,030	0,030	1,000	0,111
MCD	RF	1	0,000	0,000	0,000	0,000	0,049	1,000
MCHP	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,347
MMM	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,210
MNST	ARIMA, RF	2	0,092	0,092	0,092	0,092	0,904	1,000
MRK	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,006
MSFT	ARIMA	1	0,002	0,002	0,002	0,002	1,000	0,127
MSI	ARIMA, RF	2	0,007	0,007	0,007	0,007	1,000	0,268
ORCL	ARIMA	1	0,022	0,022	0,022	0,022	1,000	0,022
PAYX	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,058
QCOM	ARIMA, RF	2	0,007	0,007	0,006	0,007	0,745	1,000
STLD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,252
T	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,057
VRTX	ARIMA	1	0,124	0,124	0,124	0,124	1,000	0,101
WBD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,167
WYNN	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,596	1,000

11.4.3. Retorno objetivo OtC

Tabla 31: MCS referencias para OtC (parte 1 de 2)

Activo	Modelos en M^*	N	p V9	p V10	p V11	p V12	p ARIMA	p RF
AAPL	ARIMA	1	0,046	0,046	0,046	0,046	1,000	0,118
ADBE	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,106
ADSK	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,033
AMAT	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,079
AMZN	ARIMA, RF	2	0,010	0,010	0,010	0,010	1,000	0,215
BA	ARIMA, RF	2	0,005	0,005	0,005	0,005	1,000	0,289
BAC	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	1,000
C	ARIMA, RF	2	0,001	0,001	0,001	0,001	1,000	0,353
CAT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,777
CDNS	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,521
CSCO	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,325
CTAS	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,890
CVX	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,007
DE	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,061
DELL	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,625	1,000
DIS	ARIMA, RF	2	0,020	0,020	0,020	0,020	0,510	1,000
EBAY	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,473
F	ARIMA	1	0,004	0,004	0,004	0,004	1,000	0,033
FDX	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,452
FISV	ARIMA, RF	2	0,002	0,002	0,002	0,002	1,000	0,930
FITB	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,143
GILD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,356
GIS	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,116
GLW	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,445
GM	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,971	1,000

Tabla 32: MCS referencias para OtC (parte 2 de 2)

Activo	Modelos en M^*	N	p V9	p V10	p V11	p V12	p ARIMA	p RF
GOOGL	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,447
GS	RF	1	0,002	0,003	0,003	0,003	0,114	1,000
HSIC	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,158
INTC	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,064
ISRG	ARIMA	1	0,005	0,005	0,005	0,005	1,000	0,108
JPM	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,825
KHC	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,035
KMB	ARIMA, RF	2	0,000	0,000	0,000	0,000	0,590	1,000
KO	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,526
LLY	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,789
MCD	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,017
MCHP	ARIMA	1	0,039	0,039	0,039	0,039	1,000	0,137
MMM	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,004
MNST	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,263
MRK	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,036
MSFT	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,784
MSI	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,067
ORCL	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,117
PAYX	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,799
QCOM	ARIMA, RF	2	0,001	0,001	0,001	0,001	0,923	1,000
STLD	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,215
T	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,314
VRTX	ARIMA, RF	2	0,000	0,000	0,000	0,000	1,000	0,213
WBD	ARIMA	1	0,017	0,017	0,017	0,017	1,000	0,084
WYNN	ARIMA	1	0,000	0,000	0,000	0,000	1,000	0,027