



**UNIVERSIDAD
DE CHILE**



UNIVERSIDAD DE CHILE

FACULTAD DE ECONOMÍA Y NEGOCIOS

MAGÍSTER EN FINANZAS

**MODELANDO LA DIRECCIÓN DEL PRECIO Y RETORNOS DE LAS
ACCIONES CHILENAS USANDO
REDES NEURONALES RECURRENTE - LSTM**

TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN FINANZAS

**AUTOR
TOMÁS CARLOS PEÑA VARGAS**

**PROFESOR TUTOR
DAVID DIAZ, Ph.D.**

SANTIAGO, NOVIEMBRE 2022

RESUMEN DE LA TESIS
PARA OPTAR AL TITULO DE MAGISTER EN FINANZAS
POR: TOMÁS CARLOS PEÑA VARGAS
AÑO:2022
PROF.GUÍA: DAVID DIAZ

**MODELANDO LA DIRRECCIÓN DEL PRECIO Y RETORNOS DE LAS ACCIONES
CHILENAS USANDO REDES NEURONALES RECURRENTE-LSTM**

La predicción de los precios y la dirección del movimiento de las acciones ha sido un tópico interesante para entes de diferente formación tales como finanzas, economía, estadísticas, *data science*, inversionistas institucionales e inversionistas *retailers*. En Estados Unidos ya a contar del año 2012, el 85 % de las operaciones se ejecutaban a través de algoritmos computacionales.

Esta investigación propone la utilización de nuevas arquitecturas de redes neuronales empleando LSTM (*Long Short Term Memory*) para el modelamiento de los precios y retornos de las acciones del IPSA. Estos resultados son comparados con modelos tradicionalmente utilizados en la literatura, a saber, ARIMA (*Autoregressive integrated moving average*) y MLP (*Multilayer perceptron*).

La aplicación se lleva a cabo en acciones pertenecientes al IPSA durante el periodo 2010-2021, y los modelos son comparados tanto en la predicción del signo de la variación

de precio usando la métrica DA (*directional accuracy*) como través de la métrica de RMSE (*Root Mean Square Error*). Finalmente, los modelos son evaluados en su capacidad de generar rentabilidad al seguir diferentes estrategias de inversión. Para lo anterior se realiza un *backtesting* en el periodo del 2019 -2021

Con respecto a la capacidad de acierto (*directional accuracy*) de los modelos, en el 70% de las acciones modeladas se logra imponer la arquitectura LSTM, en un 20% el modelo ARIMA, y en el restante el modelo MLP. La acción con mayor capacidad de acierto (*directional accuracy*) corresponde a la acción SMU que logró la mayor capacidad de predicción con un 59.7% y 58.8% de modelo de precios y modelo de retornos, respectivamente.

A pesar de la destacada capacidad de acierto de los modelos, en términos del RMSE, en un 80% de las acciones la arquitectura de LSTM no logra mejores predicciones estadísticamente significativas que el modelo ARIMA de acuerdo con el *test* Diebold-Mariano. Incluso, el modelo ARIMA alcanza mejores predicciones estadísticamente significativas en un 20% de las acciones.

Al realizar simulación de *trading* y *backtesting*, y a pesar de que los modelos obtenidos son inferiores en capacidad predictiva a los mejores modelos de la literatura (capacidad predictiva por sobre el 80%), se obtiene en que todas las acciones superan en rentabilidad a su propia estrategia *buy-hold*, y además superan la estrategia *buy-hold* del IPSA.

Contenido

Introducción	5
Revisión Literaria	9
Metodología	23
Resultados	31
Análisis de resultados	40
Conclusiones	44
Bibliografía	47
Anexo 1: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de redes neuronales. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).	51
Anexo 2: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Support Vector Machines. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).	52
	52
Anexo 3: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Deep Learning. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).	53
Anexo 4: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Fuzzy Theory. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).	54
Anexo 5: Ecuaciones que rigen unidad de la red neuronal LSTM	55

Introducción

El mercado financiero es un actor clave en la economía global, y la predicción de la dirección de movimiento de las acciones ha sido un tópico interesante para investigadores y miembros de variadas disciplinas tales como: economía, ingeniería financiera, estadísticas, y *data science*.

Con el crecimiento de las nuevas tecnologías de *machine learning* y *deep learning*, el interés por la predicción de la dirección de movimientos de las acciones ha aumentado considerablemente (Hu, Tang Zhang and Wang 2018). En el año 2012, ya se estimaba que el 85% de las operaciones en Estados Unidos fueron realizadas por algoritmos (Nelson, Pereira, and De Oliveira 2017). La gran ventaja de los modelos de inteligencia artificial corresponde a que permiten manejar patrones no lineales, ruidosos, caóticos, y complejos por ende sus predicciones son más precisas. Así, no es sorprendente que a diario en las bolsas mundiales billones de dólares sean tranzados por robot *traders* (Kumbure, Lohrmann, Luukka, and Porras 2022).

Los primeros estudios de **redes neuronales artificiales** se remontan hacia el año 1990 centrado en la predicción de los precios de las acciones, sin embargo, el resultado no fue lo esperado debido a las limitaciones de poder de procesamiento y cálculo existentes en ese momento. Con la finalidad de mejorar esas limitaciones se propuso fusionarlas con otros modelos de predicción, comenzando por predecir sólo algunas acciones y en un rango de tiempo definido. A pesar de eso, las primeras redes neuronales carecían de generalidad y escalabilidad.

Paralelamente a los métodos de redes neuronales artificiales, la comunidad científica ha seguido trabajado con los métodos clásicos para poder predecir los precios. Uno de los métodos corresponde al **análisis fundamental** que nació en el 1928 impulsado por Benjamín Graham, centrado en indicadores relacionados a la compañía, y factores macroeconómicos, los cuales se utilizan como base para pronosticar el valor de la acción (Vanstone & Finnie, 2009). Entre los factores relacionados a la compañía destacan: retorno sobre el patrimonio, pronóstico de ventas y costos, crecimiento anual, y posicionamiento de la empresa en el mercado, estrategias de crecimiento, entre otros. Con respecto a los

factores macroeconómicos, éstos engloban al producto interno bruto, tasas de interés, tipo de cambio, y la inflación (Bustos and Pomares-Quimbaya 2020).

Una de las debilidades del análisis fundamental corresponde a que la información de la compañía podría ser confusa o tardía en ser entregada. Además, de acuerdo a la hipótesis de eficiencia de mercado semi-fuerte o fuerte, el análisis fundamental no debería generar un exceso de retorno (Zhang,Cui,Xu,Li and Li 2018).

Por otro lado, el **análisis técnico** se basa esencialmente en el uso de los precios y volúmenes pasados e indicadores de éstos para modelar los precios futuros, bajo el supuesto que el efecto de todas las variables macroeconómicas y de las noticias ya están reflejadas en el precio histórico de las acciones (Murphy, 1999). El análisis técnico se centra en los siguientes postulados: (1) Los precios son determinados exclusivamente por la oferta y la demanda de las acciones, (2) Los precios siguen tendencias de mercado, (3) Cambios en la oferta o demanda pueden provocar cambios en las tendencias, (4) Cambios en la oferta o demanda pueden ser identificados en los gráficos, (5) Los patrones en los gráficos tienden a repetirse (Nelson,Pereira, and De Oliveira 2017).

Adicionalmente dentro de los modelos clásicos, también están presentes los **modelos estadísticos de series de tiempo** empleados en la predicción de los precios de las acciones. Entre ellos destacan: ARMA (*auto-regressive moving average*), ARIMA (*autoregressive integrated moving average*), los modelos ARCH (*auto-regressive conditional heteroskedasticity*), los modelos GARCH (*generalized auto-regressive conditional heteroscedasticity*), el Filtro de Kalman, el suavizamiento exponencial, entre otros (Kumbure, Lohrmann, Luukka, and Porras 2022).

Con el transcurrir de los años a mediados del 2010, sacando provecho de los grandes avances en la capacidad de cómputo, emerge **Deep Learning** como un resurgimiento de las redes neuronales, ahora de gran tamaño, profundidad y escala, ofreciendo ventajas únicas en el tratamiento de datos no estructurados, y tiene una elevada capacidad de aprendizaje y adaptabilidad. Dentro del *deep learning* existe una amplia gama de diseño de redes neuronales profundas, las que, según la tarea a realizar, organizan sus capas ocultas, funciones de activación, y conexiones, de manera de resolver los problemas encomendados. En particular, centrado en el modelamiento de datos que sigan patrones de secuencias, las arquitecturas del tipo *Recurrent Neural Networks* (RNNs) han ganado

mucha tracción, dado sus excelentes resultados en este tipo de problemas (Peng, and Guo 2022). Notablemente, dentro de los problemas basados en patrones de secuencias encontramos, por ejemplo, problemas de entendimiento del lenguaje natural, análisis de ondas de audio, series de tiempo económicas y financieras, entre otros.

En particular, dentro de la familia de las RNNs, existe un sub-tipo denominado LSTM por las siglas de *Long Short Term Memory*, que se caracterizan porque el flujo de la información dentro de la red puede viajar en varias direcciones, tanto hacia adelante como hacia atrás, permitiendo la existencia de relaciones recurrentes que exploten patrones guardados en la memoria de corto plazo y de largo plazo del sistema. Dicho de otra manera, esta arquitectura le permite a la red “recordar” sus predicciones históricas, y de esa manera, no sólo predice en base al set de variables *inputs* que se entregan al modelo, sino que también, incorpora en sus nuevas predicciones las predicciones rezagadas, siendo un símil a los modelos ARIMA o GARCH en su forma de modelar.

Este tipo de redes está siendo ampliamente utilizado para modelar la predicción de precios y retornos en índices y acciones pertenecientes a países desarrollados. Bhandari y sus colaboradores en el año 2022 implementaron un modelo LSTM para la predicción diaria del S&P 500 (Bhandari et al., 2022), Peng empleó este tipo de red en la predicción de las acciones de bancos de China (Peng, and Guo 2022), y Nelson junto con sus colegas han predichos el índice Bovespa (Nelson,Pereira, and De Oliveira 2017). Sin embargo, de acuerdo a nuestra revisión literaria, todavía no existe evidencia de su capacidad predictiva en mercados emergentes como el chileno.

Esta tesis propone investigar la capacidad de dichos algoritmos en modelar la predicción de los precios y retornos de las acciones pertenecientes al IPSA entre los años 2010-2021. Para ello se **implementan modelos de tipo *deep learning***, específicamente la red neuronal LSTM (**Long Short Term Memory**) evaluando los modelos con la métrica **directional accuracy**, y **error cuadrático medio**. Los modelos son comparados con los modelos *Multilayer Perceptron* (MLP) -un tipo clásico de arquitectura de redes neuronales no recurrentes- y ARIMA. Además, se realiza una simulación de *trading* y *backtesting* a cada uno de los modelos, evaluándolos a través de diferentes estrategias de inversión de acuerdo con el retorno obtenido y a *calmar ratio*, una métrica de retorno financiero que controla por el riesgo asumido en la inversión. Finalmente, para el modelo con mayor

capacidad predictiva se realiza un *bootstrapping* con la finalidad de aproximar la varianza del análisis y construir intervalos de confianza de las métricas de bondad de ajuste analizadas, *directional accuracy* y error cuadrático medio.

Los principales resultados indican que efectivamente existe una mayor capacidad predictiva de los modelos LSTM en términos de predicción de la dirección de signo (*directional accuracy*), pero que dicha ganancia, no se ve reflejada en términos de reducción de magnitud del error.

La siguiente investigación se organiza de la siguiente forma, a continuación, se presenta una revisión literaria, la que muestra los principales métodos de predicción de los precios y retornos de las acciones, los tipos de variables empleadas, y la granularidad (periodicidad) de los datos de entrada, y los resultados de los modelos utilizados anteriormente para fines similares. Luego, la sección de metodología detalla los procesos empleados en este trabajo para modelar los precios y retornos de las acciones. La sección de resultados presenta los principales hallazgos de la investigación, los que son luego discutidos a la luz de la literatura previa. Finalmente, la sección de conclusiones, sintetiza las principales contribuciones del estudio, discute las limitantes y presenta ideas para el trabajo a futuro.

Revisión Literaria

Cómo se mencionó en la introducción, a pesar de la gran cantidad de esfuerzos dedicados a la predicción de retornos y precios accionarios, es todavía difícil y desafiante modelarlos, ya que éstos se ven afectados bajo todo tipo de influencia tales como: factores económicos, factores políticos, desarrollo industrial, y noticias del mercado, transformando el problema de predicción en un problema no lineal, multivariado, cambiante, y complejo.

No obstante, tanto inversionistas institucionales como *retailers*, están interesados en poder predecir el comportamiento del mercado (Hu, Tang, Zhang, and Wang 2018), con la finalidad de poder lograr un retorno ajustado por riesgo superior al del mercado. Sin embargo, este objetivo es contrario a lo planteado por la hipótesis de mercado eficiente establecida por Fama en 1970 (Khadjeh Nassirtoussi et al.,2014). Ésta indica que, en mercados eficientes, los precios de las acciones se mueven a través de una caminata aleatoria (*randow walk*), y que los precios futuros no pueden ser predichos usando información existente, y por ende sería imposible predecir tanto la dirección de los precios de las acciones como la magnitud de los cambios (Kumbure, Lohrmann, Luukka, and Porras 2022). Fama propuso tres niveles o formas de eficiencia de mercado:

Débil: Asume que la información contenida en las series de tiempo de los precios pasados ya está reflejada en el precio actual y por ende no es útil para poder predecir los precios futuros de las acciones. Por lo tanto, este nivel hipótesis de mercados eficientes, no supera a la estrategia *buy-hold* en términos de retorno ajustado por riesgo.

Semi-Fuerte: En este nivel de hipótesis de eficiencia de mercado, los precios de los activos reflejan toda la información pública disponible. Toda la información disponible engloba a los precios pasados de los activos, y además de eso incluye información relacionada con indicadores macroeconómicos tales como: condiciones económicas,

eventos políticos, tasas de interés, e información pública de la compañía que afecta los precios de las acciones de ésta. Sin embargo, este nivel de eficiencia de hipótesis de mercado no garantiza superar al mercado consistentemente. Es decir, una gestión activa de inversión que usa toda la información disponible no garantizaría superar la gestión pasiva (*buy-hold* de un índice del mercado) consistentemente.

Fuerte: Ningún tipo de información ya sea pública o privada de la compañía pueden ser usada para pronosticar el mercado. Por ende, ningún inversor puede alcanzar retornos esperados superiores al mercado.

En línea con lo descrito por Fama algunos resultados empíricos parecieran avalar la existencia de una eficiencia fuerte o semi-fuerte dado que los resultados predictivos no son tan auspiciosos como los inversionistas desearían. Por ejemplo, Gerlein, McGinnity, Belatreche, y Coleman en el año 2016, concluyó que la capacidad predicción de los modelos de *machine learning* en términos de si al menos eran capaces de predecir la dirección del cambio de precio en el corto plazo, oscilaban entre 48%- 54% (Zhang,Cui,Xu,Li and Li,2018), lo que los sitúa peligrosamente cerca de no ser más precisos que un lanzamiento de moneda.

Sin embargo, en la práctica varios inversores y fondos de inversión afirman haber empleado el análisis técnico para predecir el mercado con un éxito considerable (González, García-Crespo, Palacios, Guldrís-Iglesias, & Berbís, 2011). Sumado a lo anterior, existe una gran cantidad de evidencia científica que muestra que existe capacidad predictiva en ciertos mercados y activos, tanto en la predicción diaria de retornos como en la predicción *intraday*.

En la tabla 1 se resume algunas investigaciones en la literatura con las más altas capacidad predicativas (*directional accuracy*), empleando diferentes técnicas de predicción en los últimos 20 años.

La primera publicación (Leung et al.2000) pertenece a Leung en el año 2000, quien empleó modelos de clasificación *logit* y *probit* para predecir los excesos de retornos mensuales (por sobre T-bill de un mes) de los índices Nikkei 225, S&P 500, y FTSE100, empleando como modelos *benchmarks* a: Suavizamiento exponencial adaptativo, vector autoregresivo con filtro de Kalman, función de transferencia multivariada y red neuronal *feedforward*. La capacidad predictiva (*directional accuracy*) más elevada se alcanzó para el

Nikkei 225 alcanzando un 68%.

En el año 2005, Huang y sus colaboradores (Huang et al.2005) predijeron la dirección semanal del Nikkei 225 usando la técnica *support vector machine*, y empleado como modelos *benchmarks*: análisis discriminante lineal, análisis discriminante cuadrático, y la red neuronal *elman backpropagation* logrando una capacidad predictiva (*directional accuracy*) de 75%.

En el año 2011, Kara (Kara et al.2011) predijo la dirección diaria del *Istanbul Stock Index* mediante las técnicas de redes neuronales logrando un nivel de capacidad predictiva de 75.74% y 71.52% empleando las redes neuronales y *support vector machine*, respectivamente.

Qiu en el año 2016 uso redes neuronales para la predicción de la dirección diaria del Nikkei 225, y optimizó los parámetros de la red neuronal a través de los modelos de algoritmos genéticos. Este modelo se probó para dos sets diferentes de variables de análisis técnico obteniéndose un 60.87% y 81.27% para set N°1 y set N°2 de capacidad predictiva (*directional accuracy*), respectivamente (Qiu et al.2016).

Más recientemente, Hu en el 2018 desarrolló un modelo para predecir el precio de apertura del índice SP500 y del Dow Jones 30 empleando la técnica *back propagation neural network* en conjunto el algoritmo (*improved sine cosine algorithm*) para optimizar los hiperparámetros de la red neuronal, y evaluó la incorporación datos no estructurados proveniente de *Google trend* en el modelo. Se obtuvo que para el S&P 500, la capacidad predictiva (*directional accuracy*) alcanzó 86.64% y 86.81% sin y con *Google Trend*, respectivamente. Por otro lado, para el Dow Jones 30, logró 88.81%y 88.98% sin y con *Google Trend*, respectivamente (Hu et al.2018).

Tabla 1: Publicaciones seleccionadas capacidad predictiva más elevada reportadas en la literatura. Fuente: (Hu,et al,2018)

Titulo de la publicación	Año	Autor	Técnica de Predicción	Mercados	Mejor hit ratio
Forecasting stock indices: a comparison of classification and level estimation models	2000	Leung et al.	Classification Model	US,UK,Japan	68% (Nikkei)
Forecasting stock market movement direction with support vector machine	2005	Huang et al.	Support Vector Machine	Japan	75%
Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange	2011	Kara et al.	Redes Neuronales	Istanbul	75.74%

Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model	2016	Qiu et al.	Genetic algorithm- Artificial Neural Network hybrid model	Japan	81.27%
Predicting the direction of stock markets using optimized neural networks with Google Trends	2018	Hu et al.	ISCA-BPNN hybrid model for Type II	USA -S&P 500	86.81%
Predicting the direction of stock markets using optimized neural networks with Google Trends	2018	Hu et al.	ISCA-BPNN hybrid model for Type I	USA -S&P 500	86.64%
Predicting the direction of stock markets using optimized neural networks with Google Trends	2018	Hu et al.	ISCA-BPNN hybrid model for Type II	USA- DJIA	88.98%
Predicting the direction of stock markets using optimized neural networks with Google Trends	2018	Hu et al.	ISCA-BPNN hybrid model for Type I	USA- DJIA	88.81%

Respecto de las metodologías empleadas para desarrollar los modelos predictivos descritos en la tabla 1, éstos se construyen usualmente siguiendo un proceso que considera varios pasos. Éstos se resumen en la figura 1:

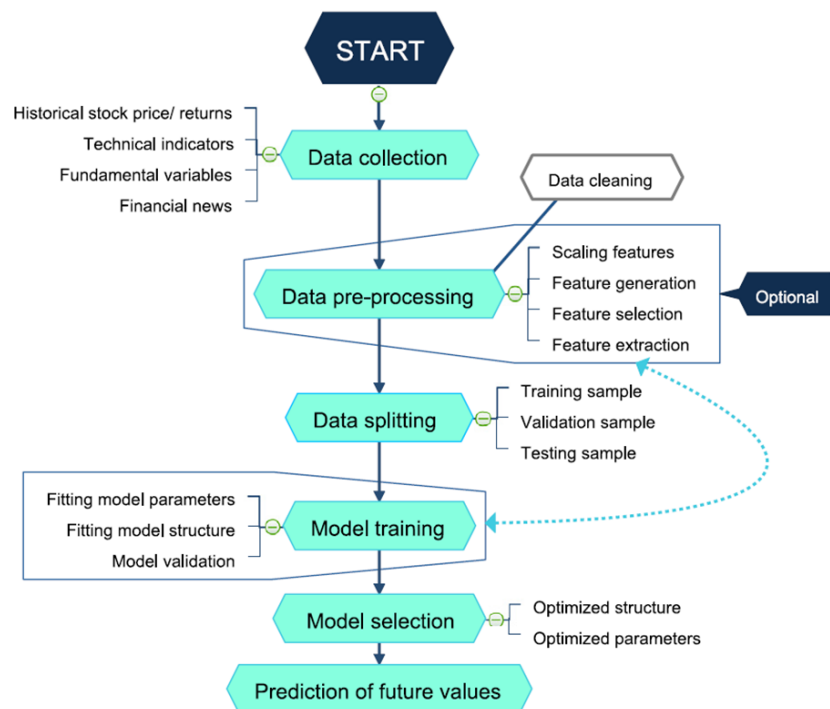


Figura 1: Etapas empleadas en la predicción de precio o retornos. Fuente: (Kumbure et al., 2022)

Respecto de la etapa *data collection*, es decir de los tipos de datos ocupados, la literatura los clasifica en datos estructurados y datos no estructurados.

Entre los **datos estructurados** se encuentran:

Datos de Mercado: Corresponden a los precios de cierre, precio de apertura, precio

mínimo, precio máximo, y volumen. Más del 65% de los estudios publicados en el año 2019 emplea este tipo de datos. (Jiang,2021).

Indicadores Técnicos: Los indicadores técnicos se clasifican en indicadores de tendencia y los indicadores osciladores. Los indicadores de tendencia más usados son la media móvil simple (*Moving Average*), promedio móvil ponderado (*Weighted Moving Average*), y el MACD (*Moving Average Converge Divergence*). Por otro lado, indicadores osciladores destacan: RSI (*Relative Strength Index*), CCI (Commodity Channel Index), y Índice Williams (Bustos and Pomares-Quimbaya 2020).

Datos fundamentales de la compañía: Corresponde a los datos que están presentes en el balance general, y estados de resultados de las compañías. Los indicadores más empleados corresponden a: deuda/patrimonio, precio/utilidad, precio/ventas, valor de mercado del patrimonio, y ganancias por acción. Sin embargo, son poco usados en *Deep Learning*, debido a su baja frecuencia de publicación y actualización (Bustos and Pomares-Quimbaya 2020).

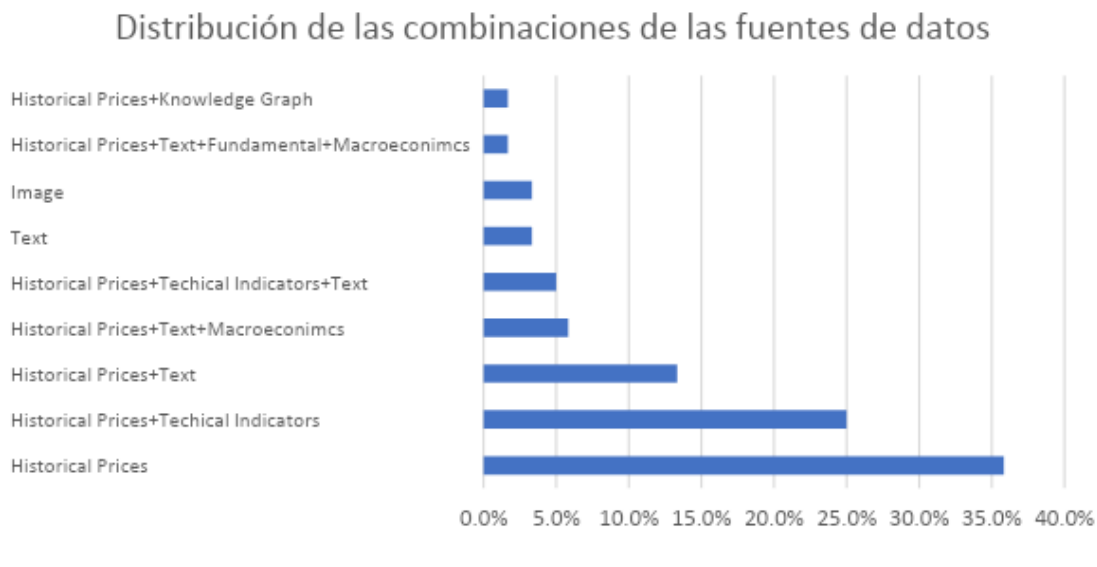
Datos macroeconómicos: Se refiere a toda la información que refleja la situación a de un país, región, o un sector económico. La información más usada corresponde a la inflación, producción industrial, y el producto interno bruto. Además, se consideran las tasas de interés, tasa de tipo de cambio, y las cotizaciones del precio del petróleo. Entre las tasas de interés más empleadas se consideran: bono del tesoro de Estados Unidos con madurez: a 3 meses, 6 meses, 5 años y 10 años. Mientras que en tasas de tipo de cambio destacan EUR/USD, BITCOIN/USD, AUD/USD, y USD/JPY (Bustos and Pomares-Quimbaya 2020).

Entre los **datos no estructurados** se encuentran:

Datos de texto: Este tipo de datos se refiere a la que está contenida en las noticias, noticias especializadas en finanzas, noticias generadas por las mismas compañías, redes sociales, y buscadores de Internet. Dada la naturaleza de este tipo de datos, éstos deben ser transformados a variable categórica o numérica para poder ser usada como variable en los modelos. Estos datos pueden ser procesados a través *sentiment analysis* transformando a una variable categórica. Diversos estudios han demostrado que la incorporación de este tipo de datos en los modelos aumentaría en 5.66% la precisión en modelos que emplean la técnica *deep learning* (Bustos and Pomares-Quimbaya 2020).

Datos de imágenes: Dado que el éxito de las redes neuronales convencionales en el procesamiento de imágenes en 2D, ya sea en la clasificación o detección de objetos. Por ende, los gráficos de velas japonesas podrían ser usados como variables en los modelos de predicción (Jiang, 2021).

En la figura 2 se muestra la distribución de combinaciones de tipos de variables de entrada utilizada (Bustos and Pomares-Quimbaya 2020):



Granularidad de los datos: Otra característica importante de los datos corresponde a la granularidad o frecuencia de la variable a modelar. En la figura 3 se muestra la granularidad de los datos utilizada en 138 artículos, reportada por Kumbure et al., 2022, de los cuales más del 50% de los artículos fueron publicados entre los años 2015-2019, y el resto fueron publicados en los últimos 20 años.




Figura 3: Granularidad de los datos de entrada. Fuente: (Kumbure et al., 2022)

En la figura 3 en el eje horizontal corresponde a la frecuencia de los datos, la cantidad de círculos corresponde al número de publicaciones que han empleado esa frecuencia, y el eje vertical corresponde a la extensión de los datos de las publicaciones. Por ejemplo, el círculo de color cian con frecuencia mensual corresponde a una investigación que emplea una base de datos que abarca 80 años.

También, se puede apreciar que la frecuencia más empleada es en formato diario, junto con mensual, trimestral, y cada 5 minutos en menor medida.

Respecto de los *data pre-processing techniques* o técnicas de pre-procesamiento utilizadas, a continuación, se discuten las más comunes y frecuentemente mencionadas en la literatura:

Feature Selection and Feature Extraction: El objetivo de ambos métodos se enfoca en la reducción de la cantidad de datos iniciales con la finalidad de disminuir los esfuerzos de cálculo computacionales y prevenir el *overfitting*. Específicamente, *feature selection* se encarga de identificar los datos irrelevantes para la modelación (Cavalcante et al., 2016). Por otro lado, *feature extraction* tiene por objetivo reducir las dimensiones de la base original. Tanto *feature selection* como *feature extraction* pueden ser considerados como métodos *filters* y *wrappers*. Los métodos *filters* pueden ser empleados en cualquier método de *machine learning*, ya que estos métodos trabajan directamente en los datos de entrada, estimando y calculando importantes características de la base de datos con la finalidad de encontrar la mejor composición de las variables de entrada a fin de mejorar la predicción del modelo. Por otra parte, los métodos *wrappers* buscan la mejor combinación

de variables de entrada optimizando la predicción del modelo, simultáneamente. Por ende, los resultados dependen están atados al modelo empleado, a diferencia de los métodos *filters* que actúan de manera independiente al modelo o algoritmo usado.

Dentro de los *filters*, los principales métodos más usados destacan: PCA (*Principal Component Analysis*), análisis del discriminante, y *step selection*. Por ejemplo, Zhong y Enke en el año 2017 pronosticaron la dirección diaria del S&P 500, y ellos concluyeron que PCA no sólo reduce el orden de las variables de entrada, sino que también aumenta la precisión de los modelos. Además, Singh y Srivastava en el año 2017 concluyeron que el PCA aumenta la velocidad de entrenamiento de los modelos sin perder la precisión de éste (Bustos and Pomares-Quimbaya 2020). Los *wrappers*, son menos utilizados, y por ende no son reportados tan frecuentemente en la literatura.

Detección de los *outliers* y eliminación del ruido: El ruido y los *outliers* son observaciones considerablemente distintas al resto de los datos. El ruido puede ser generado por varias razones, sin embargo, principalmente puede ser originado debido a errores en la recolección de datos debido a errores humanos o de instrumentos de medición. Por otro lado, los *outliers*, u observaciones con valores extremos, pueden aparecer en los datos debido a situaciones anormales. Tanto como el ruido como los *outliers* perjudican la predicción de los modelos. En la literatura, se ha investigado como tratar con el ruido y los *outliers*. Principalmente, se ha propuesto trabajar con los modelos ICA (Independent Component Analysis) y NICA (Nonlinear ICA), variante del modelo ICA que asume que los datos son una combinación no lineal de los factores latentes para poder identificar los componentes independientes. Lu y sus colaboradores en el año 2009, propusieron un modelo aplicando NICA a la data inicial, y luego los factores son empleados como variables de entradas para el modelo *Support Vector Machine*(SVM) (Cavalcante et al., 2016).

Respecto de las etapas de *data-splitting* y *model training*, las metodologías empleadas en la predicción de precios y retornos se clasifican se clasifican en modelos de regresión, clasificación y *clustering*.

Técnicas de Modelamiento: De acuerdo con un estudio, se especifica que el 55%

de las investigaciones han empleado modelos de regresión, un 44.5% de clasificación supervisado, y un 0.5% corresponde a *clustering* (Kumbure, Lohrmann, Luukka, and Porras 2022).


En la siguiente tabla 2 se muestran los métodos empleados en la predicción de precios de acción. La investigación abarcó 138 artículos, de los cuales más de la mitad de los artículos fue publicado entre los años 2015-2019. El restante de los artículos fue publicado entre los años 2000-2015.

Tabla2: Métodos más empleados en la predicción de acciones. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022)

Main Method	N° de artículos	% artículos
Neural Network	39	28%
SWM/SVR	24	17%
Fuzzy Theory	23	17%
Deep Learning	15	11%
Feature Selection	6	4%
Classifier Ensembles	5	4%
Text Mining	2	1%
Bayesian Network	2	1%
KNN	2	1%
Clustering	2	1%
PCA	1	1%
Others	17	12%
Total	138	100%


Como se puede apreciar de la tabla 2, los modelos más empleados corresponden a redes neuronales (1 sola capa) con un 28%, *Fuzzy Theory* y *Support Vector Machine* con un 17% cada una, y *Deep Learning* con un 11%.

A continuación, se muestra en la figura 4 la evolución y cantidad modelos de predicción desde el año 2000 hasta el año 2019.



Como se puede apreciar en las primeras publicaciones realizadas entre los años 2000 y 2001 se emplearon redes neuronales artificiales y *support vector machine* (SVM), ambos modelos han estado vigentes hasta el año 2019. Sin embargo, a partir desde el año 2017, el *deep learning* ha tenido un significativo incremento, transformándose en el método más usado el año 2019.

Paralelamente, en la figura 5, se muestra la evolución de los modelos de predicción desde los años 2014 hasta el 2018. Se puede apreciar que el modelo más empleado corresponde a *Support Vector Machine*, destacando que el modelo más usado en el año 2017 correspondió a *Deep Learning*.



A continuación, se muestran se describen los métodos más importantes de *machine learning*:

Redes Neuronales: Las redes neuronales artificiales están inspiradas en el funcionamiento del cerebro animal y el *Multilayer Perceptron* (MLP) es el algoritmo más conocido para predecir los precios y de retornos acciones. MLP es una red *feed-forward* con una capa de entrada, una de salida y varias capas intermedias. Cada capa incorpora capacidades de aprendizaje con datos no lineales, discontinuidades, y con componentes polinómicos. Adicionalmente, esta red usa la técnica denominada *back-propagation* en el set de *training* donde el error de predicción es propagado desde la capa de salida a la capa de entrada modificando los pesos de cada capa.

Por ejemplo, Dhar y sus pares en el año 2010 emplearon un MLP que contenía 3 capas optimizadas con el método *backpropagation* con la finalidad de predecir el precio de cierre del índice de la bolsa de India (Cavalcante et al., 2016). Paralelamente, Oliveria y sus colaboradores en el año 2011 emplearon MLP para predecir los precios de la empresa petrolera brasileña India (Cavalcante et al., 2016). También, Jasemi en el año 2011 empleó MLP para encontrar los patrones ocultos de las velas japonesas, enfocándose en aquellos que representan cambios de tendencia.

A pesar los buenos resultados obtenidos usando MLPs, éstas son altamente sensibles a los parametros de la arquitectura de la red: variables de entrada, variables de salida, número de capas ocultas, número de neuronas ocultas, tasa de aprendizaje, la función de transferencia, entre otros (Cavalcante et al., 2016).

Dado lo anterior, han surgido un sin número de variaciones de modelos que emplean otras arquitecturas de redes neuronales. Por ejemplo, Kim y Han en el año 2000 propusieron un modelo de redes neuronales combinado con los algoritmos genéticos, éstos fueron empleados para la optimización de parametros de la red. Qiu y Song en el año 2016, también emplearon la misma metodología para predecir la dirección diaria del Nikkei 225, obteniendo una capacidad predictiva de 81.27% (Kumbure, Lohrmann, Luukka, and Porras 2022). En el anexo 1 se muestran más arquitecturas de redes neuronales utilizadas en la literatura.

Support Vector Machine: A pesar que las redes neuronales han sido ampliamente usadas en la predicción de series de tiempo financiera, éstas presentan algunas limitaciones

en el los patrones de aprendizaje (Cavalcante et al., 2016). Además, éstas entregan soluciones locales en lugar de globales, y tienen la limitación del *overfitting* (Kumbure, Lohrmann, Luukka, and Porras 2022).

A raíz de lo anterior, surgen los metodos *support vector machines*, los que son también son usados para problemas de clasificación y regresión (*support vector regression*). Los metodos *support vector machines* son metodos estadísticos de aprendizaje inteligentes, y han sido ampliamente usado como alternativas a las redes neuronales.

Este algoritmo se enfoca en encontrar un hiperplano que maximiza la distancia entre dos conjuntos de datos, en un problema de clasificación, o minimiza la distancia a los puntos observados en un problema de regresión. Esta técnica es la más común entre los algoritmos de clasificación lineal debido a que ha logrado los mismos o mejores resultados que algoritmos más complejos (Bustos and Pomares-Quimbaya 2020).

Lu el año 2013 propuso un modelo de predicción que combinaba *nonlinear component analysis* con *support vector machine (SVM)*, y los parametros del SVM fueron optimizados a través de *particle swarm optimization (PSO)*. De forma similar, Rustam y Kintandani emplearon la misma metodología para predecir los precios del indice de Indonesia (Kumbure, Lohrmann, Luukka, and Porras 2022).

En el año 2005, Huang y sus colaboradores alcanzando una capacidad predictiva (directional accuracy) de 75% y Kara en el año 2011 alcanzó 71.52% prediciendo la dirección diaria del *Istanbul Stock Index*.

En el Anexo 2 se muestran una variedad de estudios que han empleado *support vector machine*.

Deep Learning: Este consiste en una red neuronal compuesta por una “cascada” de múltiples capas con unidades de procesamiento que permiten encontrar complejas relaciones no lineales entre los datos, y mejorar el rendimiento de aprendizaje de la *data* inicial. Además, ofrece mayor flexibilidad en la estructura de la red, parámetros del modelo, y funciones de activación.

En el marco de la predicción de precios y retornos de acciones, *deep learning* es un método novedoso, ya que recién en el año 2016/2017 aparecen los primeros estudios que emplean *deep learning* en la predicción de precios o retornos de las acciones. Según la

investigación realizada por Kumbure y sus colaboradores en el año 2022, la primera investigación correspondió a Chong en el año 2017.

Generalmente, *deep learning* es combinado con otras técnicas tales como PCA (*principal component analysis*) a modo de preprocesamiento de datos o *filters*. Por ejemplo, Singh y Srivastava en el año 2017 emplearon *deep learning* con PCA, y consiguieron un 4.8% en precisión comparado con una red neuronal con una función de Base Radial como función de activación (Bustos and Pomares-Quimbaya 2020). Otro estudio para destacar corresponde al realizado por Di Persio y Honchar en el año 2016, el cual comparó MLP, redes neuronales convolucionales, y LSTM en la predicción de los precios de cierre del S&P 500. El método que mejor predijo correspondió a las redes neuronales convolucionales (Bustos and Pomares-Quimbaya 2020). En el Anexo 3 se muestra un resumen con la variedad de los modelos que emplean *deep learning* en la literatura reciente.

Fuzzy Logic: Este algoritmo intenta imitar el razonamiento humano a través de la creación de reglas condiciones, las cuales usan variables categóricas en vez de variables continuas. El algoritmo más empleado corresponde a *adaptive neuro-fuzzy inference*, el cual consiste en una red de componentes *neuro-diffuse*, éstos a partir de un *set* de datos de *training* son capaces de interpretar las variables lingüísticas y retornar un conjunto de modelos lineales. Ghanavati y su equipo en el año 2016 propusieron un modelo híbrido que combinaba *Fuzzy Clustering con Support Vector Machines*. Se encontró que este modelo híbrido superaba a los modelos *Support Vector Machines* (Bustos and Pomares-Quimbaya 2020). En el Anexo 4 se muestra la variedad de los modelos que emplean *fuzzy logic*.

Algoritmos Genéticos: Este tipo de algoritmos imita los procesos de la evolución natural con la finalidad de encontrar una solución óptima, y por ende maximizar la precisión de los modelos. En este tipo de algoritmos, las soluciones son combinadas, mutadas, y alteradas en cada iteración con el objeto de encontrar la mejor solución. Hu and Li en el año 2017 usaron los algoritmos genéticos para predecir el movimiento de 10 acciones de la bolsa de Taiwan, y los compararon con los modelos *benchmarks* regresión lineal y regresión logística. Ellos concluyeron que los algoritmos genéticos obtuvieron mejor precisión que los modelos *benchmarks* (Bustos and Pomares-Quimbaya 2020). En el

Anexo 4 se muestra la variedad de los modelos que emplean *algoritmos genéticos*.

Por otro lado, con respecto al número de publicaciones de predicción de precios y retornos acorde a la zona geográfica se muestra en la figura 6




Figura 6: Publicaciones de predicciones de acuerdo a la zona geográfica Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).

En términos de región geográfica, Asia lidera con 119 apariciones, seguido por Norteamérica con 63 registros. En roles más secundarios, se encuentran Europa y Sudamérica con 12 y 7 publicaciones, respectivamente.

En términos de países, la mayor cantidad de publicaciones corresponde a Estados Unidos con 62 publicaciones, seguido por Taiwan y China con 28 y 25 publicaciones, respectivamente. Por otra parte, todas las publicaciones pertenecientes a América del Sur pertenecen a Brasil con 7 registros.

Con respecto, a las variables que son modeladas se muestran en la figura N°7




Figura 7: Variables modeladas de acuerdo con la zona geográfica. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).

En términos de regiones geográficas, Asia lidera con 108 publicaciones, seguido por Norte América con 89 referencias, y en tercer lugar se encuentra Europa con 28 referencias. En el cuarto lugar se encuentra Sudamérica con 7 publicaciones representados por el Bovespa de Brasil.

En términos de países, Estados Unidos es el país con mayor representación, el índice de mayor interés corresponde al S&P 500 con 50 menciones, seguido del Nasdaq y Dow Jones 30 con 14 y 13 apariciones, respectivamente. Con respecto Asia, los índices más modelados corresponden a Taiex, Sse, y Nikkei 225 con 24, 14 y 12 artículos, respectivamente.

La revisión literaria nos muestra que la hipótesis de mercado eficiente de Fama nos plantea que es imposible poder lograr retornos esperados superiores al mercado. Sin embargo, hay evidencia concreta que muestra que existen modelos que logran capacidad predictiva (*directional accuracy*) superior al 80%. Con respecto a las técnicas empleadas, se destaca que las redes neuronales y *support vector machine* han estado presente desde un comienzo en la predicción de los mercados, en conjunto con *fuzzy logic*, modelos genéticos, y la técnica *back propagation neural network* que presentó la capacidad predictiva más alta. A partir de los 2016-2017, irrumpió el *deep learning*, logrando ser la técnica más empleada en el año 2019. Las publicaciones descritas anteriormente, están enfocadas en índices de mercado en Asia y Norteamérica, concentradas en China y Estados Unidos.

Por otro lado, la revisión literaria revela la escasez de publicaciones en Sudamérica, y las publicaciones existentes pertenecen a Brasil, específicamente al índice BOVESPA. Además, varios investigadores han examinado el uso de sistemas computacionales para predecir los movimientos del mercado, sin embargo, no existe una metodología bien establecida y testeada que describa como crear un sistema autónomo de *trading* (Vanstone and Finnie ,2009). Dado lo anterior, esta investigación tiene la finalidad de proponer

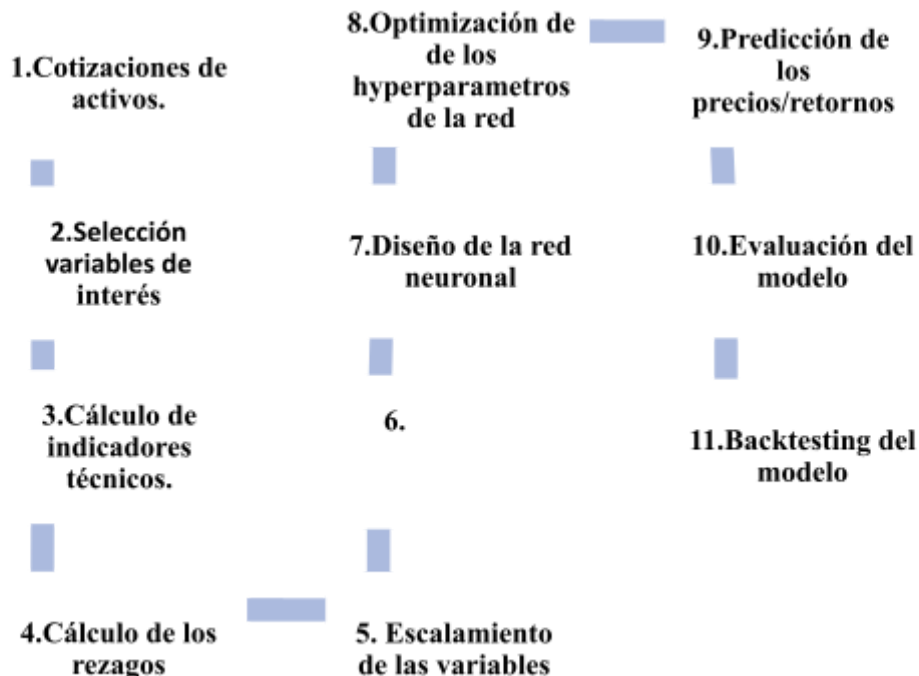
modelos de predicción pertenecientes al *deep learning* empleando LSTM en las acciones que pertenecen al IPSA (Índice de Precios Selectivos de Acciones). Además, se realiza un *backtesting* y *trading* para cada uno de los modelos obtenidos.

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

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

Metodología

Para el estudio de esta investigación se ha utilizado una compilación de metodologías de la literatura, y se ha propuesto lo que se detalla en la figura 8



1.Cotizaciones: Las cotizaciones de los activos son obtenidos de *Eikon - Refinitivy* entre Enero 2010 hasta 12 Abril del 2021. Los activos corresponden a todas las acciones pertenecientes al IPSA (Índice de Precios Selectivo de Acciones) durante el periodo de estudio.

2.Selección de Variables de interés: Para ambos modelos se seleccionaron como variables de interés:

- Precio cierre
- Precio apertura
- Precio mínimo
- Precio máximo
- Volumen de transacción.

3. Cálculo de indicadores técnicos: A través de la librería *Ta-Lib* de *Python* se calcula un set indicadores técnicos para las cotizaciones e índices. En la tabla 4 se muestran los indicadores técnicos y sus definiciones.

Tabla 4: Indicadores técnicos

Nombre Variable	Descripción de las variables
EMA30	Media móvil exponencial en una ventana de 30 periodos.
Bandas de Bollinger	Bandas Bollinger
ADX	índice de movimiento direccional promedio
MACD	Media Móvil de Convergencia/Divergencia
RSI 14	índice de fuerza relativa

4. Cálculo de los rezagos: Se calculó los rezagos para cada una de las variables explicativas. Para cada una de las acciones y para uno de los modelos tanto precios como retornos (con y sin variables de análisis técnico) se calcularon escenarios distintos con los siguientes números de rezagos: 1, 5, 15, 30, 60, 90, y 120 rezagos o lags. Es decir, se

evaluaron los escenarios descritos en la ecuación N°1:

$$n^{\circ} \text{ escenarios} = n^{\circ} \text{ acciones} \cdot \text{tipo modelo} \cdot \text{variables analisis tecnico} \cdot n^{\circ} \text{ rezagos} \quad (1)$$

$$n^{\circ} \text{ escenarios} = 30 \cdot 2 \cdot 2 \cdot 7 = 840 \text{ escenarios}$$

5. Escalamiento de variables: Para cada una de las variables explicativas, y rezagos de éstos se estandarizan con la siguiente ecuación N°2:

$$z_i = \frac{x_i - \min(x)}{(x) - \min(x)} \quad (2)$$

Donde:

z_i : Datos escalados

x_i : Datos a escalar

(x) : Valor máximo dentro de los datos a escalar.

(x) : Valor mínimos dentro de los datos a escalar.

Cabe hacer notar que para el cálculo de las estadísticas de min y max sólo se usó la porción de datos de *training* de manera de evitar el *information-leakage problem*.

6. Elección Muestra Traininig/Testing: Se trabajó con los siguientes periodos de *training*, validación y de *testing*. Como se mencionó, se destaca que los periodos de *training*, validación y *testing* no se cruzan, para evitar problemas de *data leakage*. *Data leakage* es el termino empleado para referirse a un conjunto de datos que no pertenece a la sección de *training*, y este conjunto es empleado en el proceso de aprendizaje del modelo (Saravanan et al. 2020). *Data Leakage* puede llevarse a cabo en las siguientes situaciones:

- Filtración de datos desde de la sección de *testing* a la sección *training*.
- Filtración de datos predichos hacia a la sección de *training*.
- Filtración de datos futuros a datos pasados.

En la tabla 5 se detalla a continuación los periodos de tiempo:

Tabla 5: Periodos de tiempo de training, validación y testing

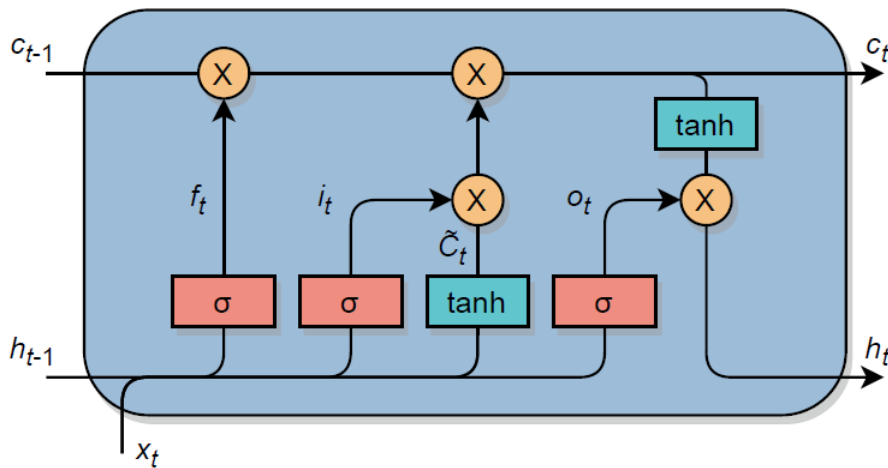
Número Ensayo	Tamaño Muestra	Fecha Inicio	Fecha Termino
Training	60%	5 de enero 2010	29 de septiembre 2016
Validación	20%	30 de septiembre 2016	10 de enero 2019
Testing	20%	11 de enero 2019	12 de abril 2021

Las siguientes acciones comenzaron a cotizar después de la fecha de inicio de la sección training:

- MALLPLAZA: 27 de Julio del 2018.
- SMU: 24 de Enero del 2017.
- ILC: 20 de Julio del 2012.
- ENELCHILE: 21 de Abril del 2016.

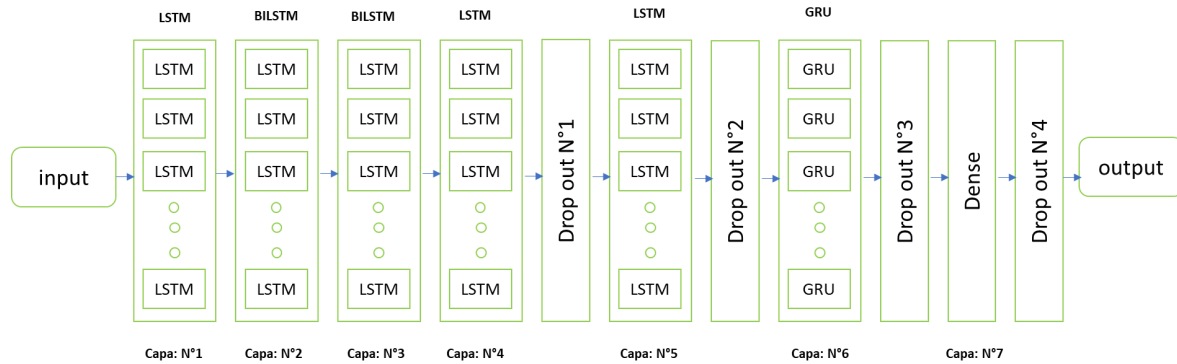
Dado lo anterior, sólo para estos casos se cuenta con una muestra con menos observaciones, pero se replicó la metodología manteniendo los porcentajes respectivo de training y testing.

7. Diseño de la red neuronal: La predicción de los precios se realizó usando la red neuronal *Long short term memory* (LSTM). Ésta fue creada y diseñada en el 1997 por Hochreiter and Schmidhuber con la finalidad de mejorar el problema de la explosión y desaparición de los gradientes en las redes neuronales recurrentes. Por ende, las redes LSTM es una versión mejorada de las redes neuronales recurrentes. En la figura 9 (Schumaker and Cheng 2021) se muestra la estructura de la red LSTM.



Las ecuaciones que rigen en la red neuronal LSTM se encuentran en el Anexo 5

Los modelos de predicción propuestos trabajan con la siguiente arquitectura que se muestra en la figura 10



8. Búsqueda del mejor modelo: Optimización de hiperparámetros: Con el sintonizador de la librería Keras se realiza la búsqueda de los hiperparámetros que optimizan la función objetivo del modelo, iterando cada uno de los siguientes hyper-parameters que se detallan en la siguiente tabla 6.

Tabla 6: Optimización de Hyper-parameters

Descripción del parámetro	Valores para evaluar
Dropout	[0, 0.1, 0.2, 0.3, 0.4, 0.5]
Cantidad neuronas	[min: 1 - max: 515]
Optimizador	[adam, SGD, rmsprop]
Función de optimización	mean squared error
<i>Learning rate</i>	[0.1, 0.01, 0.001, 0.0001]

Según la literatura, la calidad de los modelos predictivo depende críticamente de la optimización de los hiperparámetros de la red neuronal (Li et al.2018). La librería Keras cuenta con los siguientes: *RandomSearch Tuner*, *Bayesian Optimization Tuner*, y *HyperbandTuner*.

- **Random Search:** Este algoritmo comienza aleatoriamente en una solución dentro del espectro de las soluciones posibles. Luego se compara con otra solución

escogida aleatoriamente. Si esta solución es mejor que la inicial, el algoritmo escoge ésta, y así sucesivamente.

- **HyperbandTuner:** Este algoritmo es bastante similar al *random search*, pero se diferencia en que es capaz de identificar las configuraciones no óptimas a partir de un número determinado de iteraciones, ya que el algoritmo cuenta con un *early stopping*. El algoritmo continúa buscando configuraciones óptimas de acuerdo con el historial previo.
- **Bayesian Optimization Tuner:** Este algoritmo probabilístico está basado en el teorema de Bayes para encontrar un óptimo global de una de una función de optimización.

En esta investigación se escogió trabajar con Bayesian optimization Tuner, ya que según la literatura este *tuner* ha dominado el problema de optimización de los hiperparámetros, y además porque existe evidencia empírica que el *Bayesian Optimization tuner* superan al *random forest* (Li et al.2018).

9. Evaluación del modelo: La evaluación y selección de los modelos se realiza a través de las siguientes métricas:

- **RMSE:** Error cuadrático medido mide el error entre el precio observado y el precio predicho por el modelo). Se describe por la siguiente ecuación:

$$RMSE_i = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{p}_{t,i} - p_{t,i})^2} \quad \forall t \in 1 \dots \text{observaciones}, \quad \forall i \in 1 \dots N^\circ \text{ acciones} \quad (3)$$

Esta ecuación es válida para el cálculo de retornos.

- **DA (Directional Accuracy):** Mide dirección del precio predicho por el modelo versus la dirección real realizada por el precio observado. Se describe a través de la siguiente ecuación:

$$DA_i = \frac{1}{n} \sum_{t=1}^n a_{t,i} \quad \forall i \in 1 \dots N^\circ \text{ acciones (4)}$$

$$a_{t,i} \begin{cases} 1, & \text{si } (\hat{p}_t - \hat{p}_{t-1}) \cdot (p_t - p_{t-1}) > 0 \\ 0, & \text{si } (\hat{p}_t - \hat{p}_{t-1}) \cdot (p_t - p_{t-1}) < 0 \end{cases} \quad \forall i \in 1 \dots N^\circ \text{ acciones (5)}$$

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

$$DA_i = \frac{1}{n} \sum_{t=1}^{n-1} a_{t,i} \quad \forall i \in 1 \dots N^\circ \text{ acciones (6)}$$

$$a_{t,i} \begin{cases} 1, & \text{si } \hat{r}_t > 0 \\ 0, & \text{si } \hat{r}_t < 0 \end{cases} \quad (7)$$

10.Backtesting del modelo: En base al indicador de DA (*Directional Accuracy*), se elige el mejor modelo. Con la librería *Signal Backtester* se realiza el *backtesting* a cada uno de los modelos. Uno de los supuestos de la operación *backtesting*, corresponde a que en cada operación de compra o venta se invierte el 100% del patrimonio.

La librería requiere una función que active las de señales de venta y compra. A continuación, se declara la función crea señal:

$$s_t \begin{cases} 1 = \text{Venta} \\ 2 = \text{Compra} \\ 0 = \text{No opera} \end{cases} \quad (7)$$

$$s_t \begin{cases} 1, & \text{si } \hat{r}_{t-1} < \text{promedio}(\hat{r}) - 0.5 * \text{desviación estandar}(\hat{r}) \\ 2, & \text{si } \hat{r}_{t-1} > \text{promedio}(\hat{r}) + 0.5 * \text{desviación estandar}(\hat{r}) \\ 0, & \text{En otro caso} \end{cases} \quad (8)$$

Donde:

Promedio(\hat{r}): Promedio del retorno calculado a partir de los precios predichos por los modelos.
Desviación estandar(\hat{r}): Desviación del retorno calculado a partir de los precios predichos por los modelos.

Los parámetros de la librería se detallan a continuación

- Saldo inicial: 10,000,000
- Comisión: 0.05%
- Takeprofit:50%. Se escogió este valor elevado para evitar que la operación se cierre por el concepto *take profit*.
- Stoploss:50% Se escogió este valor elevado para evitar que la operación se

cierre por el concepto de *stop loss*.

- Trailing Stop:3%

La librería ofrece las siguientes estrategias para ser testeadas:

Two_side_sl_tp_reversed: Esta estrategia abre posiciones tanto para compra como para venta, y cierra una posición con *stoploss* o *take profit* para una posición abierta de compra. Adicionalmente, si una posición de compra está abierta, y se activa una señal de venta se cierra la posición abriendo otra nueva.

Two_side_sl_trailing_reversed: Esta estrategia abre posiciones tanto para compra como para venta, y cierra posición con *stoploss*. El *stoploss* es dinámico cambia a medida que el precio cambia. Adicionalmente, si una posición de compra está abierta, y se activa una señal de venta se cierra la posición abriendo otra nueva.

One_side_buy_sl_tp: Esta estrategia abre la posición sólo para compra. Esta posición se cierra sólo con la activación del *stoploss* o *takeprofit*.

One_side_sell_sl_tp: Esta estrategia abre la posición sólo para venta. Esta posición se cierra con sólo la activación del *stoploss* o *takeprofit*.

One_side_buy_sl_trailing: Esta estrategia abre la posición sólo para compra. Esta posición se cierra con la activación *stoploss*. Esta estrategia cierra posición con *stoploss*. El stoploss es dinámico cambia a medida que el precio cambia.

One_side_sell_sl_trailing: Esta estrategia abre la posición sólo para venta. Esta posición se cierra con el *stoploss*. Esta estrategia cierra posición con *stoploss*. El stoploss es dinámico cambia a medida que el precio cambia.

Análisis de rentabilidad: Con el fin de evaluar la capacidad predictiva del modelo, se realiza un análisis de rentabilidad para cada uno de los modelos propuestos y los respectivos *benchmarks*. Se utilizan las siguientes métricas para evaluar los modelos:

$$\text{Calmar Ratio} = \frac{\text{Retorno Anual}}{\text{Max Drawdown}} \quad (9)$$

$$\text{Sharp Ratio}^* = \frac{\text{Retorno Anual}}{\text{Volatilidad anual}} \quad (10)$$

Resultados

En la tabla 7 se muestran los resultados de la métrica *directional accuracy (DA)* para los modelos de retornos con y sin análisis técnico, y se comparan con los resultados de los modelos *benchmark*: ARIMA y MLP.

Tabla 7 Resultados de *directional accuracy* en el modelo retornos

stock	ARIMA_MODEL			AUTO MLP			Mejor Modelo LSTM RETORNOS			Mejor Modelo LSTM RETORNOS TA			Modelo Winner
	arima_model	train	promedio val-test	train	promedio	Nºlag s	train	promedio val-test	Nºlag s	train	promedio val-test	DA_winne r	
SMU	SARIMAX(1, 1, 1)	51.1 %	53.2%	48.1 %	57.1%	1	50%	58.8%	120	51.3 %	57.4%	58.8%	LSTM RETORNOS
IAM	SARIMAX(1, 1, 0)	48.9 %	46.6%	47.0 %	48.3%	1	51%	56.1%	15	52.2 %	50.8%	56.1%	LSTM RETORNOS
SONDA	SARIMAX(2, 1, 2)	52.0 %	52.7%			1	49%	56.0%	60	52.2 %	50.4%	56.0%	LSTM RETORNOS
MALLPLAZA	SARIMAX(0, 1, 0)	52.2 %	55.1%	50.5 %	50.4%	60	53%	52.8%	120	46.7 %	53.2%	55.1%	ARIMA
ENELCHILE	SARIMAX(2, 1, 1)	52.0 %	49.7%	51.5 %	51.4%	15	53%	54.6%	60	58.7 %	54.6%	54.6%	LSTM RETORNOS
LTM	SARIMAX(0, 1, 1)	54.1 %	53.7%	54.5 %	50.2%	1	54%	54.4%	1	53.3 %	51.9%	54.4%	LSTM RETORNOS
AESGENER	SARIMAX(1, 1, 3)	52.3 %	53.8%	51.6 %	52.2%	120	61%	53.9%	60	53.0 %	54.4%	54.4%	LSTM RETORNOS TA
ILC	SARIMAX(0, 1, 0)	55.0 %	48.4%	49.0 %	49.6%	90	50%	51.1%	90	49.8 %	54.3%	54.3%	LSTM RETORNOS TA
COLBUN	SARIMAX(1, 1, 1)	50.7 %	50.5%	50.9 %	50.5%	30	53%	52.2%	15	50.7 %	54.0%	54.0%	LSTM RETORNOS TA
ENELAM	SARIMAX(1, 1, 0)	51.3 %	53.3%	53.7 %	50.6%	30	50%	52.9%	1	49.4 %	53.8%	53.8%	LSTM RETORNOS TA
ANDINAB	SARIMAX(1, 1, 3)	51.3 %	49.3%	50.8 %	51.6%	15	50%	53.6%	5	50.9 %	52.2%	53.6%	LSTM RETORNOS
BCI	SARIMAX(1, 1, 3)	50.8 %	47.7%	52.1 %	48.3%	15	55%	53.6%	120	50.9 %	52.6%	53.6%	LSTM RETORNOS
SECURITY	SARIMAX(1, 1, 0)	53.2 %	52.3%	52.8 %	53.6%	5	50%	49.7%	90	49.7 %	51.0%	53.6%	AUTO MLP
CENCOSUD	SARIMAX(3, 1, 0)	55.2 %	51.0%	54.3 %	50.2%	30	55%	53.3%	120	56.5 %	53.5%	53.5%	LSTM RETORNOS TA
RIPLEY	SARIMAX(2, 1, 0)	52.2 %	53.2%	53.0 %	52.9%	120	44%	49.7%	1	45.2 %	50.6%	53.2%	ARIMA
COPEC	SARIMAX(0, 1, 3)	52.5 %	51.8%	52.6 %	50.3%	90	59%	53.1%	15	50.0 %	52.4%	53.1%	LSTM RETORNOS

CCU	SARIMAX(0, 1, 0)	54.4 %	48.6%	53.3 %	48.7%	15	50%	50.6%	60	50.2 %	53.0%	53.0%	LSTM RETORNOS TA
ITAUCORP	SARIMAX(0, 1, 0)	49.4 %	50.7%	49.6 %	48.4%	1	50%	52.9%	5	50.8 %	52.5%	52.9%	LSTM RETORNOS
CAP	SARIMAX(0, 1, 3)	54.4 %	51.3%	61.0 %	48.6%	90	48%	51.5%	120	51.2 %	52.9%	52.9%	LSTM RETORNOS TA
CONCHATORO	SARIMAX(1, 1, 1)	51.9 %	50.6%	50.9 %	50.5%	1	50%	49.6%	5	49.3 %	52.7%	52.7%	LSTM RETORNOS TA
BSANTANDER	SARIMAX(3, 1, 3)	52.6 %	52.6%	52.2 %	51.4%	60	50%	51.9%	1	49.6 %	51.4%	52.6%	ARIMA
SQMB	SARIMAX(0, 1, 0)	51.4 %	52.2%	50.6 %	49.9%	1	49%	50.8%	30	49.3 %	51.8%	52.2%	ARIMA
VAPORES	SARIMAX(3, 1, 3)	53.3 %	52.2%	54.4 %	52.0%	120	56%	51.0%	60	51.8 %	51.6%	52.2%	ARIMA
FALABELLA	SARIMAX(2, 1, 2)	53.1 %	52.2%			15	52%	52.2%	60	49.3 %	50.5%	52.2%	ARIMA
CMPC	SARIMAX(3, 1, 0)	53.0 %	50.8%	51.9 %	51.7%	90	58%	51.2%	30	48.0 %	52.2%	52.2%	LSTM RETORNOS TA
ENTEL	SARIMAX(2, 1, 1)	48.9 %	49.6%	49.0 %	48.1%	60	55%	51.2%	90	51.9 %	52.2%	52.2%	LSTM RETORNOS TA
ECL	SARIMAX(3, 1, 3)	53.0 %	47.3%	50.4 %	47.9%	90	58%	51.9%	90	48.2 %	52.2%	52.2%	LSTM RETORNOS TA
SALFACORP	SARIMAX(0, 1, 1)	51.6 %	50.0%	52.5 %	52.0%	90	57%	51.5%	120	49.0 %	50.1%	52.0%	AUTO MLP
PARAUCO	SARIMAX(5, 1, 2)	49.7 %	46.9%	51.8 %	48.4%	60	58%	51.8%	1	50.4 %	51.8%	51.8%	LSTM RETORNOS
AGUASA	SARIMAX(3, 1, 0)	49.5 %	47.4%	49.9 %	48.8%	5	49%	51.2%	30	51.9 %	51.1%	51.2%	LSTM RETORNOS

Del total de las 30 acciones estudiadas, en 22 de ellas (73%), los modelos de LSTM se imponen por sobre los modelos *benchmarks*. En 6 acciones (20%) se impone el modelo ARIMA, y en las acciones restantes el modelo MLP.

En las 22 acciones en las cuales los modelos ganadores pertenecen a los modelos LSTM, 11 de éstas (50%) corresponden a LSTM sin análisis técnico. Por ende, el análisis técnico no mejoraría el DA. Es más, los mejores cinco modelos corresponden LSTM retornos sin análisis técnico, con la excepción de la acción MallPlaza que es modelado de mejor forma por el método ARIMA.

Con respecto al efecto que puede generar los *lags* en *directional accuracy(DA)*, en la tabla 8 se muestra la distribución de los *lags*.

Tabla 8 Distribución de los lags en modelo de retornos

N°Lags	N° modelos LSTM RETORNOS	%	N° modelos LSTM RETORNOS TA	%
1	5	45%	1	9%
5	1	9%	1	9%
15	3	27%	1	9%
30	0	0%	1	9%
60	1	9%	2	18%
90	1	9%	3	27%
120	0	0%	2	18%
Total Modelos	11	100%	11	100%

No se puede afirmar que a medida que aumentan los *lags* aumentan *directional accuracy*. En los modelos LSTM retornos sin análisis técnico, 8 de los 11 modelos tienen quince o menos *lags*. Incluso, el *lag* N°1 es el más repetitivo. Por otro lado, los modelos LSTM con retornos con análisis técnico el número de *lags* está más distribuido uniformemente, salvo en los *lags* N°90 y *lags* N°120.

En la tabla 9 se muestran los resultados de la métrica *directional accuracy* (DA) para los modelos de precios con y sin variables de análisis técnico, y se comparan con los resultados de los modelos *benchmark* ARIMA y MLP.

Tabla 9 Resultados de *directional accuracy* en el modelo precios

Stock	ARIMA_MODEL	AUTO MLP		Mejor Modelo LSTM PRECIOS			Mejor Modelo LSTM PRECIOS TA			Modelo Winner			
	arima_model	Train	promedio val-test	train	promedio val-test	N°lags	train	promedio val-test	N°lags	train	Promedio val-test	DA_winner	Modelo_winner
SMU	SARIMAX(1, 1, 1)	51.1%	53.2%	48.1%	57.1%	120	54%	56.1%	90	58.0%	59.7%	59.7%	LSTM PRECIOS TA
SECURITY	SARIMAX(1, 1, 0)	53.2%	52.3%	52.8%	53.6%	120	49%	55.9%	30	49.6%	53.2%	55.9%	LSTM PRECIOS
MALLPLAZA	SARIMAX(0, 1, 0)	52.2%	55.1%	50.5%	50.4%	1	51%	53.4%	120	54.5%	54.7%	55.1%	ARIMA
IILC	SARIMAX(0, 1, 0)	55.0%	48.4%	49.0%	49.6%	120	51%	55.0%	30	49.7%	52.9%	55.0%	LSTM PRECIOS
RIPLEY	SARIMAX(2, 1, 0)	52.2%	53.2%	53.0%	52.9%	5	51%	53.7%	1	53.2%	54.6%	54.6%	LSTM PRECIOS TA
SALFACORP	SARIMAX(0, 1, 1)	51.6%	50.0%	52.5%	52.0%	60	53%	54.4%	30	51.5%	52.1%	54.4%	LSTM PRECIOS
AESGENER	SARIMAX(1, 1, 3)	52.3%	53.8%	51.6%	52.2%	60	56%	53.1%	1	51.1%	53.5%	53.8%	ARIMA
LTM	SARIMAX(0, 1, 1)	54.1%	53.7%	54.5%	50.2%	90	63%	52.3%	30	53.7%	52.6%	53.7%	ARIMA
ENELAM	SARIMAX(1, 1, 0)	51.3%	53.3%	53.7%	50.6%	90	53%	53.5%	90	52.4%	53.2%	53.5%	LSTM PRECIOS
ENELCHILE	SARIMAX(2, 1, 1)	52.0%	49.7%	51.5%	51.4%	60	53%	53.3%	60	55.8%	52.8%	53.3%	LSTM PRECIOS
SONDA	SARIMAX(2, 1, 2)	52.0%	52.7%			5	49%	52.7%	15	49.7%	53.0%	53.0%	LSTM PRECIOS TA
VAPORES	SARIMAX(3, 1, 3)	53.3%	52.2%	54.4%	52.0%	30	52%	52.1%	90	53.4%	52.8%	52.8%	LSTM PRECIOS TA
BSANTANDER	SARIMAX(3, 1, 3)	52.6%	52.6%	52.2%	51.4%	1	52%	51.3%	1	52.1%	52.6%	52.6%	LSTM PRECIOS TA
IAM	SARIMAX(1, 1, 0)	48.9%	46.6%	47.0%	48.3%	120	50%	52.5%	30	47.1%	51.2%	52.5%	LSTM PRECIOS
CENCOSUD	SARIMAX(3, 1, 0)	55.2%	51.0%	54.3%	50.2%	120	53%	52.4%	120	54.8%	51.5%	52.4%	LSTM PRECIOS
ITAUCORP	SARIMAX(0, 1, 0)	49.4%	50.7%	49.6%	48.4%	90	53%	52.4%	120	50.7%	51.1%	52.4%	LSTM PRECIOS

FALABELLA	SARIMAX(2, 1, 2)	53.1%	52.2%			90	52%	52.3%	5	49.0%	51.5%	52.3%	LSTM PRECIOS
SQMB	SARIMAX(0, 1, 0)	51.4%	52.2%	50.6%	49.9%	5	51%	50.7%	30	50.8%	50.9%	52.2%	ARIMA
CAP	SARIMAX(0, 1, 3)	54.4%	51.3%	61.0%	48.6%	5	49%	52.2%	15	51.9%	52.0%	52.2%	LSTM PRECIOS
AGUASA	SARIMAX(3, 1, 0)	49.5%	47.4%	49.9%	48.8%	15	50%	52.1%	90	51.9%	51.2%	52.1%	LSTM PRECIOS
CMPC	SARIMAX(3, 1, 0)	53.0%	50.8%	51.9%	51.7%	60	52%	52.0%	1	53.1%	50.2%	52.0%	LSTM PRECIOS
COLBUN	SARIMAX(1, 1, 1)	50.7%	50.5%	50.9%	50.5%	1	49%	51.8%	1	50.8%	50.2%	51.8%	LSTM PRECIOS
COPEC	SARIMAX(0, 1, 3)	52.5%	51.8%	52.6%	50.3%	60	50%	51.3%	1	51.3%	50.3%	51.8%	ARIMA
CCU	SARIMAX(0, 1, 0)	54.4%	48.6%	53.3%	48.7%	30	51%	51.0%	30	49.6%	51.7%	51.7%	LSTM PRECIOS TA
ANDINAB	SARIMAX(1, 1, 3)	51.3%	49.3%	50.8%	51.6%	60	51%	51.1%	60	50.1%	50.2%	51.6%	AUTO MLP
ENTEL	SARIMAX(2, 1, 1)	48.9%	49.6%	49.0%	48.1%	15	51%	50.2%	90	51.9%	51.4%	51.4%	LSTM PRECIOS TA
PARAUCO	SARIMAX(5, 1, 2)	49.7%	46.9%	51.8%	48.4%	90	51%	51.3%	120	49.7%	48.2%	51.3%	LSTM PRECIOS
CONCHATORO	SARIMAX(1, 1, 1)	51.9%	50.6%	50.9%	50.5%	1	51%	50.5%	1	49.7%	50.1%	50.6%	ARIMA
ECL	SARIMAX(3, 1, 3)	53.0%	47.3%	50.4%	47.9%	60	53%	50.5%	30	52.5%	49.3%	50.5%	LSTM PRECIOS
BCI	SARIMAX(1, 1, 3)	50.8%	47.7%	52.1%	48.3%	15	48%	49.2%	30	49.6%	48.2%	49.2%	LSTM PRECIOS

Del total de las 30 acciones estudiadas, en 23 de ellas (77%) los modelos de LSTM se imponen por sobre los modelos *benchmarks*, en 6 acciones (20%) se impone el modelo ARIMA, y en el restante el modelo MLP.

En las 23 acciones en las cuales los modelos ganadores pertenecen a los modelos LSTM, 16 de éstas (70%) corresponden a modelos LSTM sin análisis técnico. Por ende, las variables provenientes de análisis técnico no mejoran el DA (*directional accuracy*).

Con respecto al efecto que puede generar los *lags* en *directional accuracy*(DA), en la tabla 10 se muestra la distribución de los *lags*.

Tabla 10 Distribución de los lags en modelo de precios

Lags	LSTM PRECIOS	%	LSTM PRECIOS TA	%
1	1	6%	2	29%
5	1	6%	0	0%
15	2	13%	1	14%
30	0	0%	1	14%
60	4	25%	0	0%
90	4	25%	3	43%
120	4	25%	0	0%
Total Modelos	16	100%	7	100%

Dada la tabla anterior, si bien para los modelos LSTM precios los mejores modelos se concentran entre los *lags* entre 60-120. A pesar de esa relación potencial, no podría afirmar que existe una relación directa entre los *lags* y la variable *directional accuracy*.

En la tabla 11 se compara los resultados de la métrica *directional accuracy* para los modelos de precios y retornos con y sin análisis técnico.

Tabla 11 Comparación de *directional accuracy* entre modelos precios y retornos

Stock	Mejor Modelo LSTM PRECIOS		Mejor Modelo LSTM retornos		Mejor Modelo LSTM PRECIOS TA		Mejor Modelo LSTM retornos TA		Mejor Modelo Global LSTM	
	Nºlags	promedio val-test	Nºlags	promedio val-test	Nºlags	promedio val-test	Nºlags	promedio val-test	DA_winner	Modelo_winner
SMU	120	56.1%	1	58.8%	90	59.7%	120	57.4%	59.7%	LSTM PRECIOS TA
IAM	120	52.5%	1	56.1%	30	51.2%	15	50.8%	56.1%	LSTM RETORNOS
SONDA	5	52.7%	1	56.0%	15	53.0%	60	50.4%	56.0%	LSTM RETORNOS
SECURITY	120	55.9%	5	49.7%	30	53.2%	90	51.0%	55.9%	LSTM PRECIOS
ILC	120	55.0%	90	51.1%	30	52.9%	90	54.3%	55.0%	LSTM PRECIOS
MALLPLAZA	1	53.4%	60	52.8%	120	54.7%	120	53.2%	54.7%	LSTM PRECIOS TA
ENELCHILE	60	53.3%	15	54.6%	60	52.8%	60	54.6%	54.6%	LSTM RETORNOS
RIPLEY	5	53.7%	120	49.7%	1	54.6%	1	50.6%	54.6%	LSTM PRECIOS TA
LTM	90	52.3%	1	54.4%	30	52.6%	1	51.9%	54.4%	LSTM RETORNOS
SALFACORP	60	54.4%	90	51.5%	30	52.1%	120	50.1%	54.4%	LSTM PRECIOS
AESGENER	60	53.1%	120	53.9%	1	53.5%	60	54.4%	54.4%	LSTM RETORNOS TA
COLBUN	1	51.8%	30	52.2%	1	50.2%	15	54.0%	54.0%	LSTM RETORNOS TA
ENELAM	90	53.5%	30	52.9%	90	53.2%	1	53.8%	53.8%	LSTM RETORNOS TA
ANDINAB	60	51.1%	15	53.6%	60	50.2%	5	52.2%	53.6%	LSTM RETORNOS
BCI	15	49.2%	15	53.6%	30	48.2%	120	52.6%	53.6%	LSTM RETORNOS
CECOSUD	120	52.4%	30	53.3%	120	51.5%	120	53.5%	53.5%	LSTM RETORNOS TA

COPEC	60	51.3%	90	53.1%	1	50.3%	15	52.4%	53.1%	LSTM RETORNOS
CCU	30	51.0%	15	50.6%	30	51.7%	60	53.0%	53.0%	LSTM RETORNOS TA
ITAUICORP	90	52.4%	1	52.9%	120	51.1%	5	52.5%	52.9%	LSTM RETORNOS
CAP	5	52.2%	90	51.5%	15	52.0%	120	52.9%	52.9%	LSTM RETORNOS TA
VAPORES	30	52.1%	120	51.0%	90	52.8%	60	51.6%	52.8%	LSTM PRECIOS TA
CONCHATORO	1	50.5%	1	49.6%	1	50.1%	5	52.7%	52.7%	LSTM RETORNOS TA
BSANTANDER	1	51.3%	60	51.9%	1	52.6%	1	51.4%	52.6%	LSTM PRECIOS TA
FALABELLA	90	52.3%	15	52.2%	5	51.5%	60	50.5%	52.3%	LSTM PRECIOS
CMPC	60	52.0%	90	51.2%	1	50.2%	30	52.2%	52.2%	LSTM RETORNOS TA
ENTEL	15	50.2%	60	51.2%	90	51.4%	90	52.2%	52.2%	LSTM RETORNOS TA
ECL	60	50.5%	90	51.9%	30	49.3%	90	52.2%	52.2%	LSTM RETORNOS TA
AGUASA	15	52.1%	5	51.2%	90	51.2%	30	51.1%	52.1%	LSTM PRECIOS
PARAUCO	90	51.3%	60	51.8%	120	48.2%	1	51.8%	51.8%	LSTM RETORNOS
SQMB	5	50.7%	1	50.8%	30	50.9%	30	51.8%	51.8%	LSTM RETORNOS TA

En la tabla 12 se muestra la frecuencia de los mejores modelos de precios y retornos con y sin análisis técnico

Tabla 12 Frecuencia de modelos precios y retornos.

Modelo	Frecuencia	%
LSTM PRECIOS	5	17%
LSTM RETORNOS	9	30%
LSTM PRECIOS_TA	5	17%
LSTM RETORNOS_TA	11	37%
Todos los modelos	30	100%

De la tabla anterior se puede apreciar que el 67% de los mejores modelos corresponden a aquellos que modelan retornos por sobre precios.

En la tabla 13 se compara los resultados de la métrica *RMSE* para los modelos de precios para el promedio de validación y *testing*, y sólo *testing*.

Tabla 13 Resultados de RSME en el modelo precios

stock	ARIMA		MLP		LSTM PRECIOS		LSTM PRECIOS TA		Test		Promedio val-test	
	test	promedi o val-test	test	promedi o val-test	Test	promedi o val-test	test	promedi o val-test	RMSE_ winner	Modelo_ Winner	RMSE_ winner	Modelo_ winner
LTM.SN	169.2	178.3	1344.8	753.2	216.1	185.6	281.3	213.9	169.2	ARIMA	178.30	ARIMA
BSANTANDER.SN	0.7	0.6	0.8	0.7	0.9	0.7	0.9	0.7	0.7	ARIMA	0.59	ARIMA
SECURITY.SN	3.2	3.0	3.2	3.3	4.0	3.8	3.8	3.7	3.2	AUTO MLP	2.99	ARIMA
VAPORES.SN	0.5	2.5	0.6	0.6	0.5	0.5	0.7	0.7	0.5	ARIMA	0.55	LSTM PRECIOS
MALLPLAZA.SN	30.4	48.4	47.9	54.8	30.9	39.2	36.8	42.0	30.4	ARIMA	39.21	LSTM PRECIOS
SQMB.SN	686.6	538.8	794.8	685.0	1166.4	879.5	923.4	789.1	686.6	ARIMA	538.84	ARIMA
ENELAM.SN	2.4	2.1	17.0	9.5	3.9	2.6	4.2	2.8	2.4	ARIMA	2.06	ARIMA
SONDA.SN	13.8	17.2	208.8	138.8	30.5	23.0	20.6	18.3	13.8	ARIMA	17.20	ARIMA
COPEC.SN	149.7	147.2	159.0	141.0	159.8	139.8	210.0	171.7	149.7	ARIMA	139.79	LSTM PRECIOS
CMPC.SN	41.0	40.4	46.8	40.1	45.2	38.6	47.1	39.6	41.0	ARIMA	38.56	LSTM PRECIOS
CONCHATORO.SN	24.1	21.2	30.8	24.3	31.4	22.8	27.9	22.0	24.1	ARIMA	21.17	ARIMA
ITAUCORPSN	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	ARIMA	0.07	LSTM PRECIOS
SMU.SN	2.1	3.3	3.2	3.4	2.4	2.9	5.4	5.0	2.1	ARIMA	2.86	LSTM PRECIOS
CENCOSUD.SN	26.9	32.1	111.7	68.0	29.6	26.4	39.6	32.1	26.9	ARIMA	26.39	LSTM PRECIOS
AESGENER.SN	2.2	2.3	2.4	2.3	2.4	2.3	2.7	2.4	2.2	ARIMA	2.30	LSTM PRECIOS
ANDINAB.SN	36.5	36.6	40.6	39.5	38.3	36.6	39.1	37.3	36.5	ARIMA	36.64	ARIMA

CAPSN	158.6	210.4	347.1	381.1	179.0	177.0	181.4	177.9	158.6	ARIMA	177.03	LSTM PRECIOS
FALABELLA.SN	69.6	71.7	931.2	512.2	78.2	71.8	160.6	113.9	69.6	ARIMA	71.70	ARIMA
COLBUN.SN	2.3	2.1	2.5	2.0	2.6	2.2	3.2	2.4	2.3	ARIMA	2.03	AUTO MLP
ENTEL.SN	123.7	124.8	388.9	243.1	178.4	139.8	263.7	191.0	123.7	ARIMA	124.79	ARIMA
ENELCHILE.SN	1.2	1.7	2.1	1.8	1.2	1.2	1.3	1.4	1.2	ARIMA	1.23	LSTM PRECIOS
RIPLEY.SN	8.2	8.7	9.6	9.5	9.2	9.0	12.3	10.9	8.2	ARIMA	8.66	ARIMA
AGUASA.SN	5.5	4.4	6.1	5.2	6.2	5.2	7.5	6.0	5.5	ARIMA	4.42	ARIMA
BCI.SN	627.6	467.3	735.5	598.3	689.8	565.1	745.4	596.6	627.6	ARIMA	467.27	ARIMA
ILC.SN	180.1	163.8	994.7	578.0	237.9	218.2	296.4	237.5	180.1	ARIMA	163.81	ARIMA
IAM.SN	13.0	11.7	13.4	13.1	14.7	13.9	17.9	16.5	13.0	ARIMA	11.70	ARIMA
ECL.SN	22.2	18.2	23.1	18.7	23.3	18.8	24.7	19.3	22.2	ARIMA	18.22	ARIMA
CCU.SN	127.5	104.7	129.8	111.7	136.7	116.0	165.0	128.0	127.5	ARIMA	104.73	ARIMA
SALFACORP.SN	12.8	18.7	17.5	19.8	15.6	18.7	15.7	19.1	12.8	ARIMA	18.67	LSTM PRECIOS
PARAUCO.SN	34.0	24.1	39.5	30.8	39.6	30.8	47.8	35.1	34.0	ARIMA	24.13	ARIMA

En la tabla 14 se muestra la frecuencia de los modelos de acuerdo con el RMSE (Error cuadrático medio).

Tabla 14 Frecuencia de los modelos de acuerdo al RMSE

Modelos	prom val-test		Testing	
ARIMA	18	60%	29	97%
MLP	1	3%	1	3%
LSTM PRECIOS	11	37%		0%
TOTAL	30	100%	30	100%

De la tabla 14 se deduce que en la métrica RMSE, el modelo ARIMA es ampliamente dominador, ya que se impone con un 60% y 97% en las acciones en el promedio de validación y *testing* y sólo *testing*, respectivamente.

Dado lo anterior, los modelos ARIMA se imponen bajo la métrica RMSE (Error cuadrático de medio), mientras que los modelos LSTM dominan en la métrica DA (*directional accuracy*).

Usando la librería Signal Backtester se realizó *backtesting* de los modelos. En la tabla 15 se muestra la estrategia de inversión ganadora con las respectivas métricas de inversión. Además, de eso muestran los resultados de la métrica para la estrategia *one-side-buy-sl-tp* (Esta estrategia abre la posición sólo para compra).

Tabla 15: Resultados del backtesting

DA Winner			Estrategia Winner					Estrategia : one_side_buy_sl_tp				
Stock	DA_winner	Modelo_winner DA	Estrategia	Calmar Ratio	Sharp Ratio	Returno	Buy-Hold	Modelo Winner Calmar Ratio	Calmar Ratio	Shar p Ratio	Returno	Buy-Hold
MALLPLAZA	56.1%	ARIMA	two side sl tp reversed	16.72	1.81	71.6%	28.2%	LSTM RETORNOS TA	11.7	1.8	50.3%	28.2%
SMU	60.5%	LSTM RETORNOS	one side sell sl tp	12.45	2.33	18.0%	-22.7 %	LSTM RETORNOS TA	0.9	0.6	-8.6%	-22.7 %
SECURITY	53.6%	LSTM PRECIOS	two side sl tp reversed	9.71	1.68	224.2%	-27.2 %	ARIMA	2.4	1.2	62.0%	-27.2 %
LTM	54.6%	LSTM PRECIOS TA	one side sell sl trailing	7.86	1.00	144.6%	-84.4 %	LSTM PRECIOS	1.1	0.6	-0.3%	-84.4 %
ILC	55.7%	LSTM PRECIOS	one side sell sl trailing	6.37	1.89	90.7%	-48.2 %	LSTM RETORNOS TA	0.2	0.2	11.8%	-48.2 %
VAPORES	54.7%	AUTO MLP	one side buy sl tp	5.28	1.66	205.2%	118.3 %	LSTM PRECIOS TA	5.3	1.7	205.2%	118.3 %
RIPLEY	56.6%	LSTM PRECIOS TA	one side sell sl tp	4.75	1.63	108.5%	-51.5 %	LSTM RETORNOS TA	0.5	0.4	22.8%	-51.5 %
FALABELLA	56.0%	LSTM PRECIOS	one side sell sl trailing	4.71	1.32	132.5%	-31.3 %	LSTM PRECIOS	0.8	0.7	53.2%	-31.3 %
ENELCHILE	55.9%	LSTM RETORNOS TA	one side sell sl trailing	4.60	1.02	29.2%	-6.8%	LSTM RETORNOS TA	1.6	0.9	22.6%	-6.8%

ENELAM	53.9%	LSTM PRECIOS TA	two_side_sl_tp_reversed	3.74	1.41	258.9%	3.8%	LSTM RETORNOS TA	2.2	1.2	106.8%	3.8%
SALFACORP	55.9%	AUTO MLP	two_side_sl_trailing_reversed	3.72	1.38	251.8%	-39.3%	MLP	1.7	0.9	69.8%	%
ITAUCORP	52.6%	LSTM RETORNOS	one_side_sell_sl_tp	3.33	1.78	68.7%	-54.0%	LSTM RETORNOS TA	0.2	0.3	-5.9%	-54.0%
SONDA	57.0%	LSTM RETORNOS	one_side_sell_sl_trailing	3.32	1.45	126.5%	-57.5%	LSTM RETORNOS	0.0	0.0	-17.0%	%
AESGENER	57.4%	LSTM RETORNOS TA	two_side_sl_tp_reversed	3.29	1.14	160.4%	-6.0%	LSTM RETORNOS TA	1.8	0.8	67.8%	-6.0%
BCI	54.2%	LSTM RETORNOS	two_side_sl_tp_reversed	3.22	1.10	170.9%	0.1%	LSTM RETORNOS TA	1.6	0.9	74.2%	0.1%
CAP	53.1%	LSTM RETORNOS	one_side_buy_sl_tp	2.74	1.27	143.4%	107.9%	LSTM PRECIOS	2.7	1.3	143.4%	107.9%
BSANTANDER	52.5%	ARIMA	one_side_sell_sl_tp	2.57	1.20	53.1%	-8.1%	LSTM RETORNOS TA	0.7	0.6	49.9%	-8.1%
PARAUCO	52.3%	LSTM RETORNOS	two_side_sl_tp_reversed	2.51	1.15	255.3%	-18.3%	MLP	1.6	1.0	106.4%	%
ANDINAB	54.3%	LSTM PRECIOS	one_side_sell_sl_tp	2.48	1.05	44.5%	-23.6%	LSTM RETORNOS TA	0.3	0.3	17.8%	-23.6%
IAM	54.3%	LSTM RETORNOS	one_side_sell_sl_tp	2.34	1.07	62.0%	-37.9%	LSTM RETORNOS TA	0.1	0.1	6.4%	-37.9%
CENCOSUD	54.4%	LSTM RETORNOS TA	two_side_sl_tp_reversed	2.27	0.95	162.9%	32.0%	LSTM RETORNOS TA	1.7	1.0	94.1%	32.0%
AGUASA	52.6%	LSTM PRECIOS	one_side_sell_sl_trailing	2.24	1.10	58.7%	-39.0%	LSTM PRECIOS TA	0.2	0.2	6.9%	%
SOMB	51.4%	ARIMA	two_side_sl_tp_reversed	2.19	0.87	179.6%	47.7%	LSTM RETORNOS	1.5	0.8	110.8%	47.7%
COLBUN	55.5%	LSTM PRECIOS	one_side_buy_sl_trailing	2.13	0.98	63.6%	9.1%	LSTM RETORNOS TA	0.8	0.6	22.4%	9.1%
ECL	52.1%	LSTM PRECIOS	one_side_sell_sl_trailing	1.97	0.88	44.0%	-30.6%	LSTM RETORNOS TA	0.4	0.3	25.6%	%
COPEC	55.6%	LSTM RETORNOS	one_side_buy_sl_tp	1.89	0.84	74.8%	1.7%	LSTM RETORNOS TA	1.9	0.8	74.8%	1.7%
ENTEL	51.9%	LSTM RETORNOS	two_side_sl_tp_reversed	1.65	0.86	110.0%	-29.9%	LSTM RETORNOS TA	0.7	0.5	40.0%	-29.9%
CCU	51.9%	LSTM PRECIOS TA	two_side_sl_tp_reversed	1.60	0.94	104.1%	-21.9%	LSTM PRECIOS TA	0.7	0.6	32.0%	%
CONCHATORO	52.0%	LSTM PRECIOS	one_side_sell_sl_trailing	1.43	0.65	26.0%	4.0%	LSTM RETORNOS	0.7	0.6	26.3%	4.0%
CMPC	53.6%	AUTO MLP	one_side_buy_sl_tp	0.80	0.51	37.6%	-3.1%	LSTM PRECIOS	0.8	0.5	37.6%	-3.1%

Análisis de resultados

A partir de la tabla anteriores se puede analizar que los modelos LSTM obtienen mejores resultados que los modelos *benchmarks*. En el 70% de las acciones, los modelos LSTM se imponen en términos de capacidad predictiva.

Por otro lado, con respecto a la conveniencia de modelar retornos o precios, se comprueba que el 67% de los resultados se obtienen modelando retornos en lugar de precios.

El efecto de los *lags* en la variable *directional accuracy*, no se puede determinar si existe una relación directa entre estas variables.

Con respecto las variables de provenientes de análisis técnico, si bien en los modelos de precios no generan un efecto significativo, no obstante, si se puede apreciar levemente a nivel de retornos. En el *backtesting*, las variables provenientes del análisis técnico juegan un rol bastante significativo, ya que en el 67% de los casos está

involucradas éstas. Es razonable considerar como significativo el efecto de las variables del análisis técnico en el análisis, ya que en la investigación *Predicting the direction of stock market index movement using an optimized artificial neural network model*, un conjunto particular de variables del análisis técnico puede marcar una diferencia entre 60.87% a 81.27% en capacidad predictiva (Qiu et al.2016).

Finalmente, se realizó la prueba estadística *diebold y mariano* entre el modelo *benchmark* ARIMA y mejor modelo LSTM (retornos TA) exclusivamente en la serie de *test* de los datos. El test diebold y mariano permite comparar estadísticamente si ambos los modelos de predicción son estadísticamente diferentes en términos del RMSE.

Los resultados del *test* arrojaron que si existe diferencia significativa con un nivel de un 5% de significancia a favor del modelo ARIMA en las siguientes acciones: Mallplaza, Ripley, Bsantander, Itaucorp, Ilc, y Bci. Al analizar la tabla 13, se puede deducir que para todas las acciones en la sección de *testing* se impone el modelo ARIMA. Incluso, para las acciones Mallplaza, Ripley, y Bsantander el modelo ARIMA se impone en la métrica *directional accuracy*.

Estos resultados están acordes a lo planteado en la literatura en el en el estudio publicado *Comparison of ARIMA and Artificial Neural Networks Models for Stock Price Prediction*, en el cual se destacó que en las predicciones realizadas por ambos modelos no existe una diferencia estadísticamente significante (Adebiyi et al.2014). Paralelamente, en el estudio titulado *Forecasting Stock Index Volatility: A comparison between GARCH and LSTM* modelos al analizar los resultados en términos de los errores MSE y RMSE entre el modelo GARCH(1,1) y el modelo LSTM no existe una diferencia significativa.

Por otro lado, la acción que obtuvo el mayor DA (*Directional Accuracy*) promedio corresponde al modelo LSTM PRECIOS TA con 90 *lags* para la acción SMU obteniendo un 59.7% empleando un 60%, 20%, y un 20% de los datos para la sección *training*, validación, y *testing*, respectivamente como caso base. Se realizó una simulación, en la cual se corrieron 104 escenarios con diferentes proporciones para *training*, validación, y *testing*. La muestra de *training* varió entre 30%-82%, la de validación varió entre 10%-25%, y la de *testing* entre 0% y 53%.

En la tabla 16 se muestra una estadística descriptiva de la simulación:

Tabla 16: Estadística descriptiva de los escenarios de la simulación

Métrica	% train	% val	% test	rmse train	rmse val	rmse test	DA train	DA val	DA test	promedio DA val-test
Media	62%	16%	22%	12.8	7.0	19.6	52.9%	52.3%	52.0%	52.1%
Mediana	64%	15%	19%	6.8	5.8	18.6	52.1%	52.8%	51.9%	52.0%
Mínimo	30%	10%	0%	2.8	2.3	2.5	46.6%	41.6%	41.2%	45.6%
Máximo	82%	25%	53%	40.5	18.6	44.3	63.4%	63.8%	63.2%	61.0%

En la tabla 16 se puede apreciar que los valores de la media y mediana son cercanos a los 52% para todos los segmentos de los datos (*traininig*, validación y *testing*). Este valor es muy cercano a los mencionados por la literatura, la predicción de los modelos de *machine learning* oscilaban entre 48%- 54% (Zhang,Cui,Xu,Li and Li 2018).

Con respecto al *backtesting*, se evaluó para todas las estrategias. Las estrategias más empleadas son: *two_side_sl_tp_reversed* (33%), *one_side_sell_sl_trailing* (27%), *one_side_sell_sl_tp* (20%), y *one_side_buy_sl_tp* (13%).

Es esperable que en la gran mayoría de los casos (80%) incorpore la venta corta, ya que el periodo de *testing* (11 de Enero 2019 al 12 de Abril del 2021) abarca la pandemia COVID-19.

Por otro lado, el 90% de las acciones que presentan un mejor *calmar ratio* pertenecen a los modelos LSTM, de los cuales el 67% pertenece a la modelación de retornos. Dado que, en la bolsa de chilena, la venta corta es poco común se evaluó la estrategia *one_side_buy_sl_tp* (Esta estrategia abre la posición sólo para compra).

Para todas las estrategias de inversión de ganadoras, y *one_side_buy_sl_tp* el retorno obtenido ambas estrategias es superior a la estrategia *buy-hold* para cada una de las acciones.

Además, los retornos obtenidos para la estrategia de inversión *winner* como para la estrategia *one_side_buy_sl_tp* son superiores al retorno del índice IPSA (-9.6%) durante el periodo de *testing*. Con la excepción de la acción SONDA, para la estrategia

one_side_buy_sl_tp es el único caso que la estrategia *buy-hold* del índice IPSA supera a SONDA.

Conclusiones

La principal contribución de este trabajo corresponde a que se encontró evidencia a favor de que existe capacidad predictiva en la dirección del precio o retorno, para la clase de activos y periodo analizado.

En términos de rentabilidad expresada mediante *calmar ratio*, los modelos LSTM superan en el 90% de los casos a los modelos *benchmarks* (ARIMA y MLP). Esto se ve reflejado en que todas las acciones superan en rentabilidad a la estrategia *buy-hold* de cada una ellas y la estrategia *buy-hold* del IPSA, tanto al evaluar la estrategia *winner* como la estrategia *one_side_buy_sl_tp*. A excepción de la acción SONDA, al evaluar la estrategia *one_side_buy_sl_tp* no logra vencer la estrategia *buy-hold* del IPSA.

En términos de capacidad predictiva medida a través de *directional accuracy* (DA), los modelos LSTM se imponen sobre los modelos *benchmarks* (ARIMA y MLP) en el 74% y en el 77% en los modelos de retornos y precios, respectivamente. El mejor resultado en capacidad predictiva corresponde a la acción SMU con 59.7%, y 58.8% en los modelos de precios y retornos, respectivamente.

En términos de RMSE el modelo ARIMA domina en la sección *testing*, para el 97% de las acciones. Incluso, el modelo ARIMA logra alcanzar diferencias estadísticamente significativas, comprobadas con el test estadístico Diebold y Mariano. El test ARIMA obtiene mejores resultados que los modelos LSTM para las siguientes acciones: MallPlaza, Ripley, Bsantander, Itaucorp, Ilc, y Bci.

Con respecto, al efecto de las variables técnicas y de los *lags* de las variables, no se encontró evidencia que avale el uso de estas podría mejorar la capacidad predictiva o la disminución del error.

Para el trabajo futuro se sugiere en acortar la brecha existente entre la capacidad predictiva lograda por la investigación y la literatura. Dado lo anterior, el trabajo futuro se sugiere enfocar en el uso de otras técnicas de predicción tales como *Back Propagation Neural Network* (BPNN), Algoritmos Genéticos, *Support Vector Machine*, y *Fuzzy Logic*. Además, estas técnicas se pueden combinar con otras técnicas de preprocesamiento de los datos de entrada tales: ICA (Independent component analysis), NICA (Nonlinear independent component analysis), y *stepwise*. Como una segunda derivada a lo dicho

anteriormente, se podrían evaluar modelos de predicción con una ventana móvil (modelos *Rolling*).

Otro elemento crucial es la optimización de los hiperparámetros de la red neuronal. Según la literatura, la calidad de un modelo predictivo depende críticamente de la optimización de los hiperparámetros de la red neuronal (Li et al.2018). En la investigación titulada Predicting the direction of stock markets using optimized neural networks with Google Trends (Hu et al.2018), en la cual los hiperparámetros de la red neuronal son optimizados a través del método ISCA (*improved sine cosine algorithm*). Por ende, sería útil probar una nueva forma de optimizar los hiperparámetros.

Otra manera de poder de incrementar la exactitud del modelo tiene relación con la función de costo u optimización de la red neuronal. En esta tesis, se trabajó con la función de optimización del error cuadrático. Sin embargo, se podría proponer una función personalizada que se enfoque en la optimización de la dirección (*directional accuracy*).

Acerca de las variables de entrada, se podrían agregar o cambiar los indicadores técnicos que se usaron en la investigación. Según, en el estudio “Predicting the direction of stock market index movement using an optimized artificial neural network model”, sólo al modificar el conjunto de variables de análisis técnico influyó en la capacidad predictiva desde de 60.87% a 81.27% (Qiu et al.2016). Por otro lado, se podrían incluir en el modelamiento aquellas velas japonesas que indican cambios de tendencia tales como estrella del amanecer, estrella del atardecer, harami, envolventes, entre otras. Adicionalmente, se podría incorporar datos no estructurados tales como noticias financieras y los sentimientos de los inversores con la finalidad de mejorar la capacidad de predicción.

En cuanto a los activos a ser modelados, se podrían trabajar con activos menos volátiles que acciones, tales como ETFs (*Exchange trade fund*), y analizar cómo se comporta la capacidad de predicción (*directional accuracy*) en éstos. Se sugiere esto, debido a que los estudios que muestran mayor capacidad predictiva en la literatura emplearon ETFs en su análisis.

Con respecto a la granularidad (frecuencia de las variables de entrada) si bien se trabajó con las cotizaciones de los activos en forma diaria, por ende, se podría probar con

una menor frecuencia de tiempo, ya sea 30 minutos, 1 hora, 2 horas. Sería de gran interés poder analizar el comportamiento a través de la capacidad de predicción y el error cuadrático medio.

Finalmente, se recomienda testear el modelo en otro periodo de *testing*, ya que este periodo abarca desde el 11 de Enero 2019 hasta el 12 Abril 2021, incluye el periodo de la crisis COVID-19.

Bibliografía

1. Adebisi, A. A., Adewumi, A. O., & Ayo, C. K. (2014). Comparison of ARIMA and artificial neural networks models for stock price prediction. *Journal of Applied Mathematics*, 2014, 9–11. <https://doi.org/10.1155/2014/614342>
2. Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. C. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9(February), 100320. <https://doi.org/10.1016/j.mlwa.2022.100320>
3. Bustos, O., & Pomares-Quimbaya, A. (2020). Stock market movement forecast: A Systematic review. In *Expert Systems with Applications* (Vol. 156). <https://doi.org/10.1016/j.eswa.2020.113464>
4. Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., & Oliveira, A. L. I. (2016). Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55, 194–211. <https://doi.org/10.1016/j.eswa.2016.02.00>
5. D. M. Q. Nelson, A. C. M. Pereira and R. A. de Oliveira, "Stock market's price movement prediction with LSTM neural networks," 2017 International Joint Conference on Neural Networks (IJCNN), 2017, pp. 1419-1426, doi: 10.1109/IJCNN.2017.7966019.
6. Gandhmal, D. P., & Kumar, K. (2019). Systematic analysis and review of stock market prediction techniques. *Computer Science Review*, 34, 100190. <https://doi.org/10.1016/j.cosrev.2019.08.001>
7. González, A. R. , García-Crespo, Á. , Palacios, R. C. , Guldrís-Iglesias, F. ,

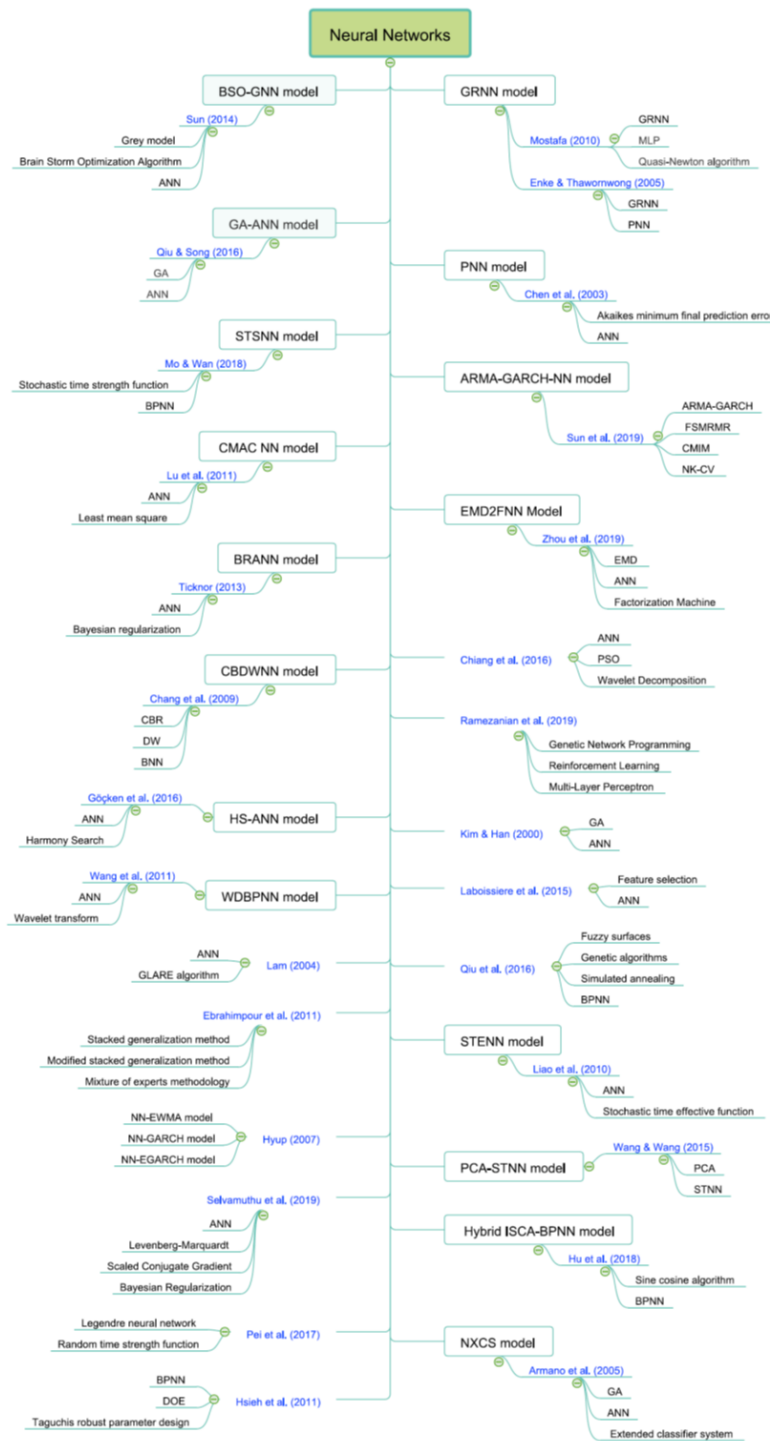
- & Berbís, J. M. G. (2011). CAST: Using neural networks to improve trading systems based on technical analysis by means of the RSI financial indicator. *Expert Systems with Applications*, 38 (9), 11489–11500 .
8. Hu, H., Tang, L., Zhang, S., & Wang, H. (2018). Predicting the direction of stock markets using optimized neural networks with Google Trends. *Neurocomputing*, 285, 188–195. <https://doi.org/10.1016/j.neucom.2018.01.038>
 9. Huang, W., Nakamori, Y., & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers and Operations Research*, 32(10), 2513–2522. <https://doi.org/10.1016/j.cor.2004.03.016>
 10. Jiang, W. (2021). Applications of deep learning in stock market prediction: Recent progress. *Expert Systems with Applications*, 184(June), 115537. <https://doi.org/10.1016/j.eswa.2021.115537>
 11. Kara, Y., Acar Boyacioglu, M., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, 38(5), 5311–5319. <https://doi.org/10.1016/j.eswa.2010.10.027>
 12. Khadjeh Nassirtoussi, A., Aghabozorgi, S., Ying Wah, T., & Ngo, D. C. L. (2014). Text mining for market prediction: A systematic review. *Expert Systems with Applications*, 41(16), 7653–7670. <https://doi.org/10.1016/j.eswa.2014.06.009>
 13. Kumbure, M. M., Lohrmann, C., Luukka, P., & Porras, J. (2022). Machine learning techniques and data for stock market forecasting: A literature review. *Expert Systems with Applications*, 197(February), 116659. <https://doi.org/10.1016/j.eswa.2022.116659>
 14. Lawi, A., Mesra, H., & Amir, S. (2022). Implementation of Long Short-Term Memory and Gated Recurrent Units on grouped time-series data to predict stock prices accurately. *Journal of Big Data*, 9(1).

<https://doi.org/10.1186/s40537-022-00597-0>

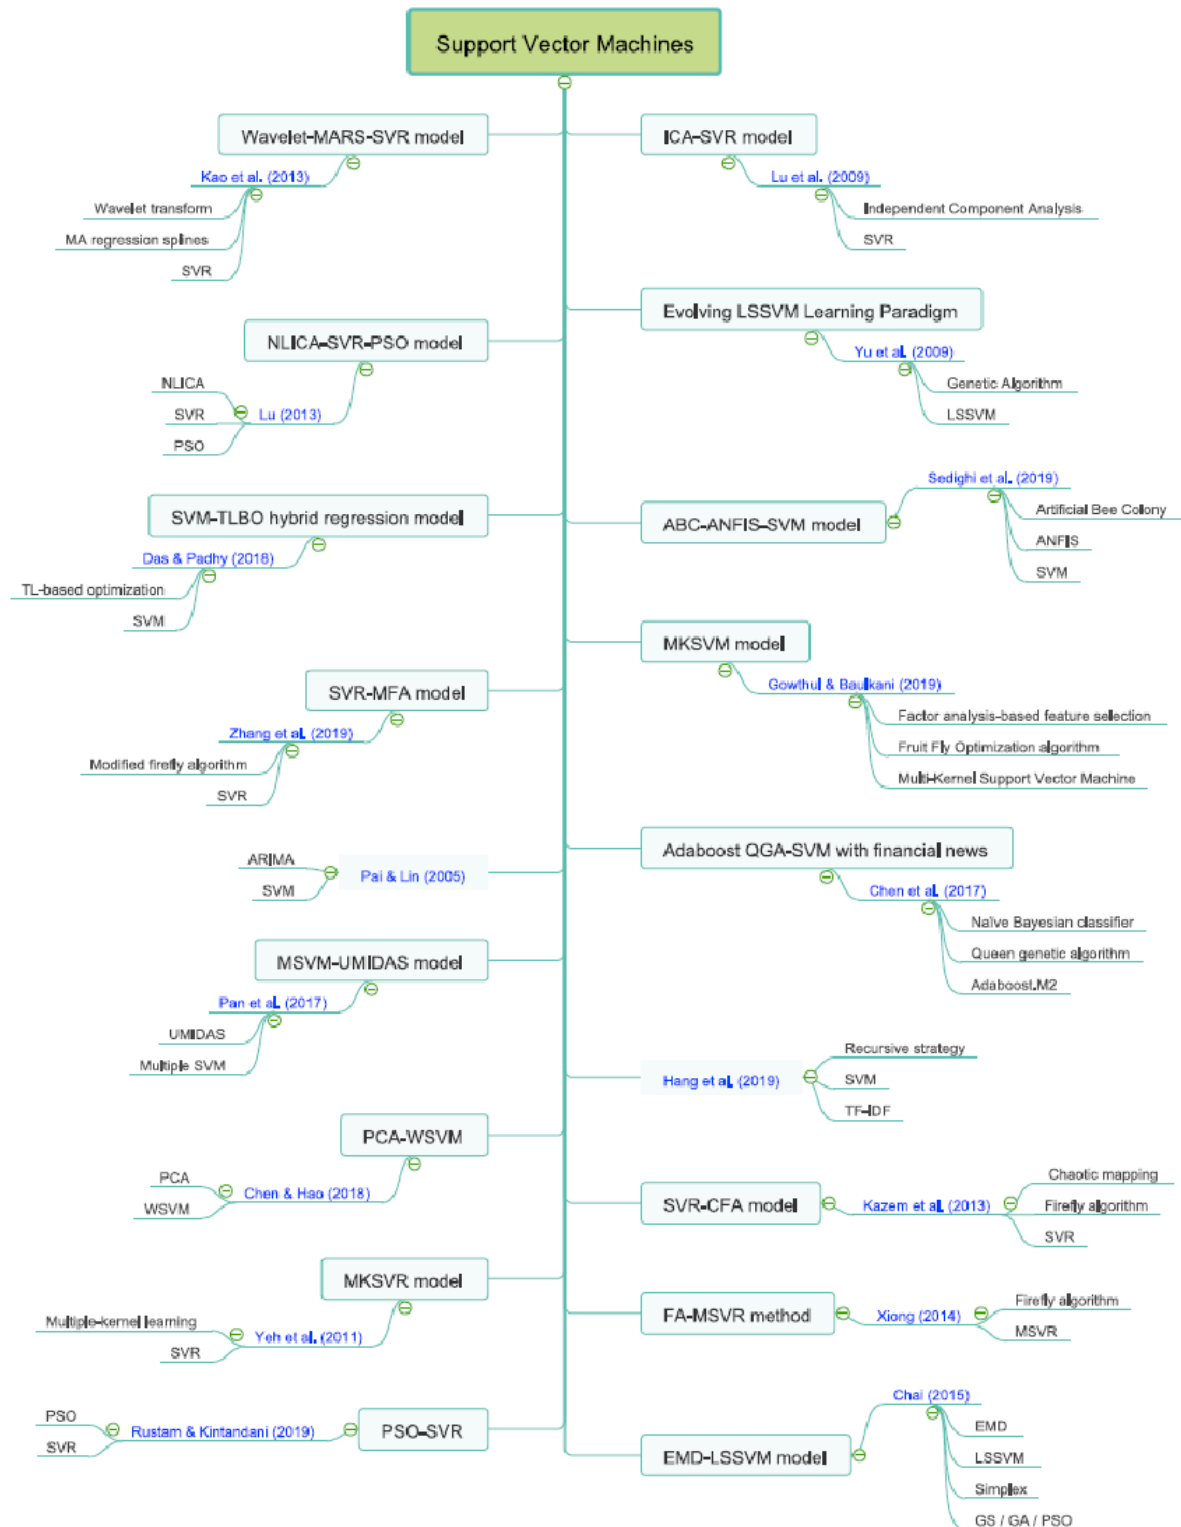
15. Leung, M. T., Daouk, H., & Chen, A. S. (2000). Forecasting stock indices: A comparison of classification and level estimation models. *International Journal of Forecasting*, 16(2), 173–190. [https://doi.org/10.1016/S0169-2070\(99\)00048-5](https://doi.org/10.1016/S0169-2070(99)00048-5)
16. Li, L., Jamieson, K., DeSalvo, G., Rostamizadeh, A., & Talwalkar, A. (2018). Hyperband: A novel bandit-based approach to hyperparameter optimization. *Journal of Machine Learning Research*, 18, 1–52.
17. Murphy, J. J. (1999). *Technical analysis of the financial markets*. New York Institute of Finance.
18. Nelson, D. M. Q., Pereira, A. C. M., & Oliveira, R. A. De. (2010). 2011 International Joint Conference on Neural Networks. *IEEE Transactions on Neural Networks*, 21(8), 1378–1378. <https://doi.org/10.1109/tnn.2010.2063350>
19. 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>
20. Peng, Y., Albuquerque, P. H. M., Kimura, H., & Saavedra, C. A. P. B. (2021). Feature selection and deep neural networks for stock price direction forecasting using technical analysis indicators. *Machine Learning with Applications*, 5(May), 100060. <https://doi.org/10.1016/j.mlwa.2021.100060>
21. Peng, Z. Y., & Guo, P. C. (2022). A Data Organization Method for LSTM and Transformer When Predicting Chinese Banking Stock Prices. *Discrete Dynamics in Nature and Society*, 2022. <https://doi.org/10.1155/2022/7119678>
22. Qiu, M., & Song, Y. (2016). Predicting the direction of stock market index movement using an optimized artificial neural network model. *PLoS ONE*, 11(5), 1–11. <https://doi.org/10.1371/journal.pone.0155133>
23. Rezaei, H., Faaljoui, H., & Mansourfar, G. (2021). Stock price prediction

- using deep learning and frequency decomposition. *Expert Systems with Applications*, 169(November 2020), 114332. <https://doi.org/10.1016/j.eswa.2020.114332>
24. Saravanan, N., Satish, G., & Balajee, J. (2020). Data Wrangling and Data Leakage in Machine Learning for Healthcare. *Issn:2349-5162*, 5(September), 553–557. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3708142
25. Thakkar, A., & Chaudhari, K. (2021). A comprehensive survey on deep neural networks for stock market: The need, challenges, and future directions. *Expert Systems With Applications*, 177(October 2020), 114800. <https://doi.org/10.1016/j.eswa.2021.114800>
26. Vanstone, B., & Finnie, G. (2009). An empirical methodology for developing stock-market trading systems using artificial neural networks. *Expert Systems with Applications*, 36 (3), 6668–6680.
27. Vitali, G. (2019). “Forecasting Stock Index Volatility: A comparison between GARCH and LSTM models.”
28. Wang, J., Zhuang, Z., & Feng, L. (2022). Intelligent Optimization Based Multi-Factor Deep Learning Stock Selection Model and Quantitative Trading Strategy. *Mathematics*, 10(4). <https://doi.org/10.3390/math10040566>.
29. Yun, H., Lee, M., Kang, Y. S., & Seok, J. (2020). Portfolio management via two-stage deep learning with a joint cost. *Expert Systems with Applications*, 143, 113041. <https://doi.org/10.1016/j.eswa.2019.113041>
30. Zhang, J., Cui, S., Xu, Y., Li, Q., & Li, T. (2018). A novel data-driven stock price trend prediction system. *Expert Systems with Applications*, 97, 60–69. <https://doi.org/10.1016/j.eswa.2017.12.026>

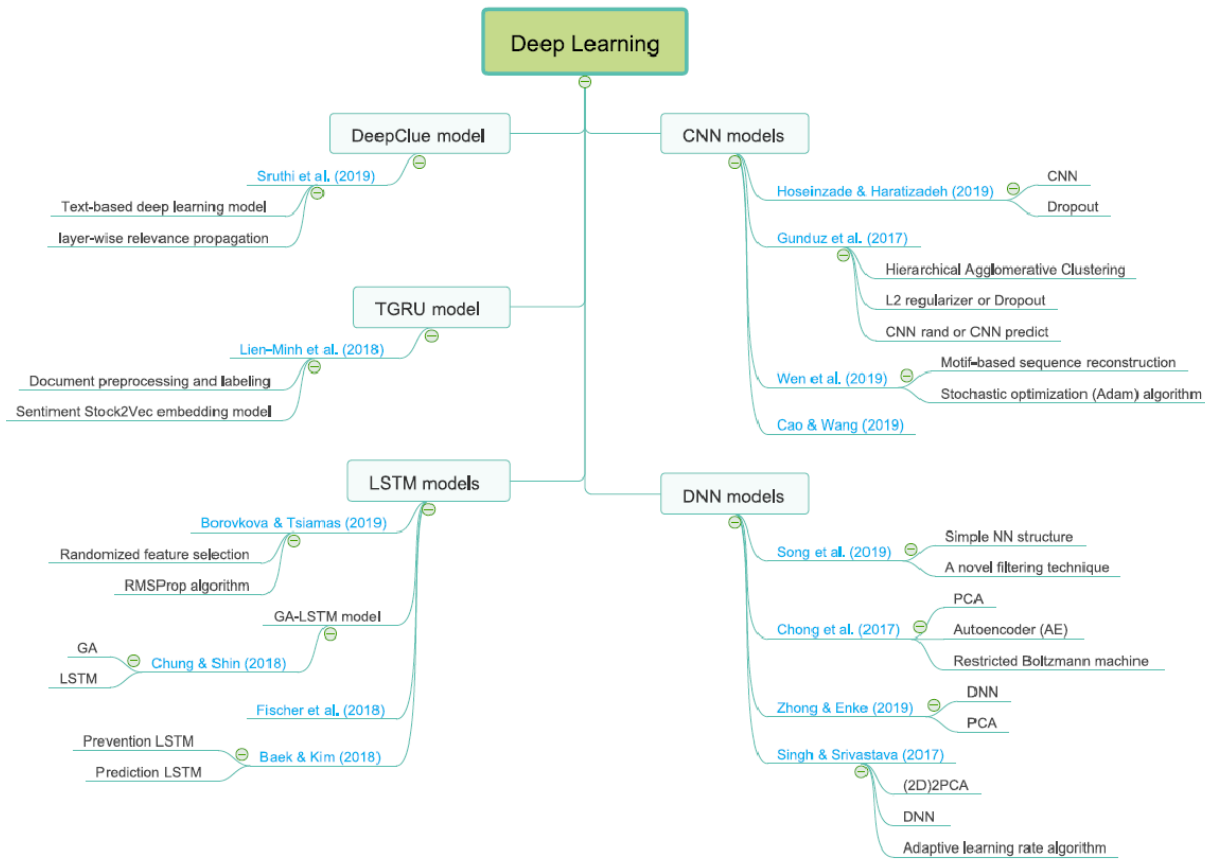
Anexo 1: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de redes neuronales. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).



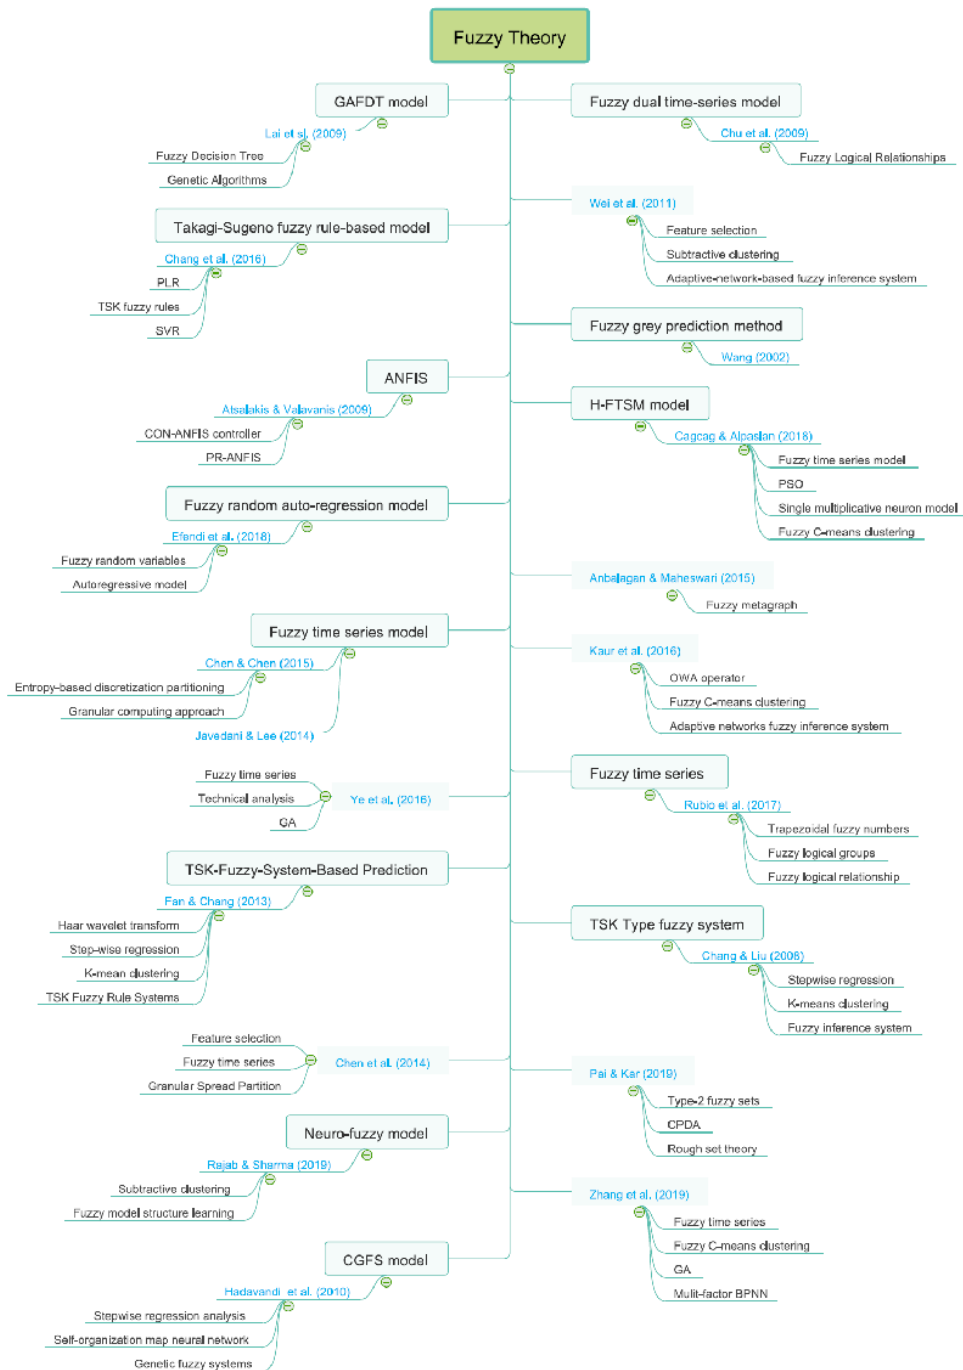
Anexo 2: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Support Vector Machines. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).



Anexo 3: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Deep Learning. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).



Anexo 4: Publicaciones del modelamiento y predicción de precios y retornos realizadas a través de Fuzzy Theory. Fuente: (Kumbure, Lohrmann, Luukka, and Porras 2022).



Anexo 5: Ecuaciones que rigen unidad de la red neuronal LSTM

A continuación, se muestran las ecuaciones que rigen la red neuronal LSTM

Puerta de ingreso:

$$i_t = \sigma \cdot (W_i \cdot x_t + U_i \cdot h_{t-1} + b_i)$$

Puerta del olvido:

$$f_t = \sigma \cdot (W_f \cdot x_t + U_f \cdot h_{t-1} + b_f)$$

Puerta de salida:

$$o_t = \sigma \cdot (W_o \cdot x_t + U_o \cdot h_{t-1} + b_o), h_t = \sigma_t \cdot \tanh(C_t)$$

Calculo del vector de memoria:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot u_t \quad u_t = \tanh(W_u \cdot [h_{t-1}, x_t] + b_u)$$

Calculo del vector escondido:

$$h_t = \sigma_t \cdot \tanh(C_t)$$

Donde:

x_t : Vector de entradas de la red en el tiempo t.

h_{t-1} : Vector escondido de la red en el tiempo $t-1$.

C_{t-1} : Vector memoria de la red en el tiempo $t-1$.

W: Matriz de pesos del vector entrada.

U: Matriz de pesos del vector escondido.

σ : Función logística sigmodial.

\tanh : Función tangente hiperbólica.

i_t : Vector resultante de la puerta entrada de la red en el tiempo t.

f_t : Vector resultante de la puerta olvidada de la red en el tiempo t.

o_t : Vector resultante de la puerta salida de la red en el tiempo t.

C_t : Vector memoria de la red en el tiempo t.

h_t : Vector escondido de la red en el tiempo t.

