



Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Facultad de Ingeniería de Sistemas e Informática

Escuela Profesional de Ingeniería de Sistemas

**Sistema predictivo del precio máximo y mínimo de las
acciones del día siguiente en la Bolsa de Valores**

TESIS

Para optar el Título Profesional de Ingeniero de Sistemas

AUTOR

Sebastián Gabriel TUESTA GONZALES

ASESOR

Dr. David Santos MAURICIO SÁNCHEZ

Lima, Perú

2025



Reconocimiento - No Comercial - Compartir Igual - Sin restricciones adicionales

<https://creativecommons.org/licenses/by-nc-sa/4.0/>

Usted puede distribuir, remezclar, retocar, y crear a partir del documento original de modo no comercial, siempre y cuando se dé crédito al autor del documento y se licencien las nuevas creaciones bajo las mismas condiciones. No se permite aplicar términos legales o medidas tecnológicas que restrinjan legalmente a otros a hacer cualquier cosa que permita esta licencia.

Referencia bibliográfica

Tuesta, S. (2025). *Sistema predictivo del precio máximo y mínimo de las acciones del día siguiente en la Bolsa de Valores*. [Tesis de pregrado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería de Sistemas e Informática, Escuela Profesional de Ingeniería de Sistemas]. Repositorio institucional Cybertesis UNMSM.

Metadatos complementarios autor/ asesor

Datos de autor	
Nombres y apellidos	Sebastián Gabriel Tuesta Gonzales
Tipo de documento de identidad	DNI
Número de documento de identidad	71001126
URL de ORCID	https://orcid.org/0000-0003-0158-0564
Datos de asesor	
Nombres y apellidos	David Santos Mauricio Sánchez
Tipo de documento de identidad	DNI
Número de documento de identidad	06445495
URL de ORCID	https://orcid.org/0000-0001-9262-626X
Datos del jurado	
Presidente del jurado	
Nombres y apellidos	Cesar Luza Montero
Tipo de documento	DNI
Número de documento de identidad	06111988
Miembro del jurado 1	
Nombres y apellidos	Ana María Huayna Dueñas
Tipo de documento	DNI
Número de documento de identidad	06017183
Datos de investigación	
Línea de investigación	Inteligencia Artificial

Grupo de investigación	Inteligencia Artificial
Agencia de financiamiento	Sin financiamiento
Ubicación geográfica de la investigación	País: Perú Departamento: Lima Provincia: Lima Distrito: Lima
Año o rango de años en que se realizó la investigación	2019 - 2024
URL de disciplinas OCDE	Ingeniería de sistemas y comunicaciones https://purl.org/pe-repo/ocde/ford#2.02.04 Ciencias de la computación https://purl.org/pe-repo/ocde/ford#1.02.01 Informática y Ciencias de la Información https://purl.org/pe-repo/ocde/ford#1.02.00



UNIVERSIDAD NACIONAL MAYOR DE SAN MARCOS
FACULTAD DE INGENIERIA DE SISTEMAS E INFORMATICA
Escuela Profesional de Ingeniería de Sistemas

Acta Virtual de Sustentación de Tesis

Siendo las 14:00 horas del día 24 de marzo del año 2025, se reunieron los docentes designados como miembros de Jurado de Tesis, presidido por el Mg. Cesar Luza Montero, Mg. Ana María Huayna Dueñas (Miembro) y el Dr. David Santos Mauricio Sánchez (Miembro Asesor), para la sustentación de la tesis Intitulada: **" SISTEMA PREDICTIVO DEL PRECIO MÁXIMO Y MÍNIMO DE LAS ACCIONES DEL DÍA SIGUIENTE EN LA BOLSA DE VALORES"**, del Bachiller: **Tuesta Gonzales, Sebastián Gabriel**; para obtener el Título Profesional de Ingeniero de Sistemas.

Acto seguido de la exposición de la Tesis, el Presidente invitó al Bachiller a responder las preguntas formuladas por los Miembros del Jurado.


El Bachiller, en el curso de sus intervenciones demostró pleno dominio del tema, al responder con acierto y fluidez las preguntas formuladas por los señores miembros del Jurado.


Finalmente habiéndose efectuado la calificación correspondiente por los miembros del Jurado, el bachiller obtuvo la nota de (19)

A continuación, el Presidente del Jurado Mg. Cesar Luza Montero, declara al Bachiller **Ingeniero de Sistemas.**

Siendo 2:45 horas, se levantó la sesión.


Mg. Cesar Luza Montero
Presidente


Mg. Ana María Huayna Dueñas
Miembro


Dr. David S. Mauricio Sánchez
Miembro Asesor



Anexo 1

CERTIFICADO DE SIMILITUD

Yo, David Santos Mauricio Sánchez en mi condición de asesor acreditado con el Dictamen de la UPG o de la EP N°000024-2024-EPISI-FISI/UNMSM de la **tesis**, cuyo título es

“SISTEMA PREDICTIVO DEL PRECIO MÁXIMO Y MÍNIMO DE LAS ACCIONES DEL DÍA SIGUIENTE EN LA BOLSA DE VALORES” presentado por el bachiller/ magíster/ egresado/ licenciado/ estudiante **TUESTA GONZALES, SEBASTIÁN GABRIEL** para optar el título de INGENIERO DE SISTEMAS, CERTIFICO que se ha cumplido con lo establecido en la Directiva de Originalidad y de Similitud de Trabajos Académicos, de Investigación y Producción Intelectual. Según la revisión, análisis y evaluación mediante la plataforma PIDS, el documento evaluado cuenta con el 16% de similitud, nivel PERMITIDO para continuar con los trámites correspondientes y para su **publicación en el repositorio institucional**.

Se emite el presente certificado en cumplimiento de lo establecido en las normas vigentes, como uno de los requisitos para la obtención del **título**.

Lima, 16 de julio de 2025

Firma del Asesor

Nombres y Apellidos del asesor: David Santos Mauricio Sánchez

DNI: 06445495

* Según corresponda: bachiller, magíster, doctor; título profesional o título de segunda especialidad

La vigencia del presente certificado corresponde a un período de noventa (90) días desde la fecha de su emisión; siempre que no haya observaciones en el texto durante el proceso de revisión por el jurado informante o surja alguna contingencia.

DEDICATORIA

A mi familia, en especial a mi madre.

AGRADECIMIENTOS

Al profesor Dr. David Mauricio Sánchez, por su apoyo, orientación, esfuerzo y consejos desinteresados, gracias a todo ello fue posible culminar este trabajo de investigación y cumplir con los objetivos trazados.

A la Universidad Nacional Mayor de San Marcos y a la Facultad de Ingeniería de Sistemas e Informática, por haberme permitido realizar y concluir mis estudios superiores.

A cada uno de los profesores en el pregrado, quienes ciclo a ciclo me inculcaron no solo conocimientos académicos, sino la perseverancia, el poder superarnos como persona, gracias por haberme guiado en mi desarrollo profesional.

A mi familia, por su gran apoyo incondicional, por transmitirnos su fortaleza y perseverancia.

RESUMEN

Predecir los precios de una acción en la Bolsa de Valores es un problema complejo, debido a que el comportamiento del mercado de valores es no lineal y no estacionario. Conocer en particular los precios máximos y mínimos diarios es particularmente útil para aquellos inversores que desean obtener la mayor cantidad posible de ganancia en cada operación de compra y venta diaria. En este trabajo, se presenta un modelo para la predicción del precio máximo y mínimo del día siguiente de una acción determinada. La propuesta consiste en un modelo híbrido basado en tres técnicas: redes neuronales artificiales, regresión de soporte vectorial y bosques aleatorios. Se realizaron pruebas con dos conjuntos de datos de la literatura, ambos para el precio máximo y para el precio mínimo. El modelo híbrido propuesto supera los resultados de la literatura, obteniendo un MAPE de 0.125 para el precio mínimo y un MAPE de 0.174 para el precio máximo del conjunto de datos CSRN3, y para el conjunto de datos CPFE3 un MAPE de 0.791 para el precio mínimo y un MAPE de 0.693 para el precio máximo. También se realizó un experimento adicional con el índice bursátil Dow Jones, obteniéndose un MAPE de 0.351 y de 0.339 para el precio mínimo y máximo respectivamente, lo cual evidencia que el modelo propuesto es útil en distintos contextos. Los resultados de los experimentos también muestran que el modelo híbrido presenta errores menores que los modelos singulares, esto demuestra que el modelo híbrido propuesto es una alternativa viable para la predicción del precio máximo y mínimo de las acciones del día siguiente.

Palabras clave: Modelo híbrido, Redes neuronales Artificiales, Regresión de Soporte Vectorial, Bosques aleatorios, Predicción de precios de acciones, Bolsa de Valores.

ABSTRACT

Predicting the prices of a stock on the Stock Market is a complex problem, because the behavior of the stock market is non-linear and non-stationary. Knowing the daily high and low prices in particular is particularly useful for those investors who want to make the greatest possible amount of profit on each daily buy and sell operation. In this work, a model is presented for predicting the next day's maximum and minimum price of a given stock. The proposal consists of a hybrid model based on three techniques: artificial neural networks, support vector regression and random forests. Tests were performed with two sets of data from the literature, both for the maximum price and for the minimum price. The proposed hybrid model surpasses the results of the literature, obtaining a MAPE of 0.125 for the minimum price and a MAPE of 0.174 for the maximum price of the CSRN3 data set, and for the CPFE3 data set a MAPE of 0.791 for the minimum price and a MAPE of 0.693 for the maximum price. An additional experiment was also carried out with the Dow Jones stock index, obtaining a MAPE of 0.351 and 0.339 for the minimum and maximum price respectively, which shows that the proposed model is useful in different contexts. The results of the experiments also show that the hybrid model presents smaller errors than the singular models, this demonstrates that the proposed hybrid model is a viable alternative for predicting the maximum and minimum price of stocks for the next day.

Keywords: Hybrid model, Artificial Neural Networks, Support Vector Regression, Random Forest, Stock price prediction, Stock exchange

Lista de Tablas

Tabla 1. Palabras clave y el periodo de búsqueda. Fuente: Elaboración propia.	26
Tabla 2. Criterios de inclusión y exclusión. Fuente: Elaboración propia	27
Tabla 3. Iteraciones de las cadenas de búsqueda. Fuente: Elaboración propia...	28
Tabla 4. Artículos elegidos de WOS (Web of Knowledge).....	31
Tabla 5. Diferencias entre modelos. Mahji y Anish (2015).....	35
Tabla 6. Características usadas en Malqui y Fernandez (2018).....	63
Tabla 7. Modelos existentes para predecir precios en la Bolsa de Valores	69
Tabla 8. Variables usadas para predecir precios en la Bolsa de Valores	71
Tabla 9. Herramientas usadas para predecir precios en la Bolsa de Valores.....	72
Tabla 10. Backlog	82
Tabla 11. Descripción de los conjuntos de datos (Elaboración propia).....	88
Tabla 12. Coeficiente de Pearson de las características de cada conjunto de datos (Elaboración propia)	90
Tabla 13. Características Seleccionadas (Elaboración propia)	90
Tabla 14. Hiperparámetros usados para la calibración de los modelos (Elaboración propia)	92
Tabla 15. Hiperparámetros calibrados para cada conjunto de datos y cada modelo (Elaboración propia)	94
Tabla 16. MAPE de la predicción de los modelos singulares para el precio mínimo y máximo de CSRN3, CPFE3 e Índice Dow Jones	95
Tabla 17. MAPE de la predicción de los modelos híbridos para el precio mínimo y máximo de CSRN3, CPFE3 e Índice Dow Jones	96

Lista de Figuras

Figura 1. Esquema general de la propuesta	18
Figura 2. Flujograma utilizado para la búsqueda. Fuente: Elaboración propia ..	28
Figura 3. Evolución de artículos en los años (2001-2024)	29
Figura 4. Modelo propuesto en Laboissiers et al. (2015)	33
Figura 5. Modelo propuesto en Mahji y Anish (2015)	34
Figura 6. Modelo propuesto en Chiang et al. (2016).....	36
Figura 7. Modelo propuesto en Li et al. (2016).....	37
Figura 8. Modelo propuesto en Mirzaei et al. (2016)	39
Figura 9. Modelo propuesto en Prasanna y Ezhilmaran (2016).....	40
Figura 10. Modelo propuesto en Sadadei et al. (2016).....	42
Figura 11. Modelo propuesto por Túfecki (2016).....	43
Figura 12. Modelo propuesto por Wei (2016)	45
Figura 13. Modelo propuesto por Yang y Lin (2016).....	46
Figura 14. Framework propuesto por Chong et al. (2017)	47
Figura 15. Modelo propuesto en Göçken et al. (2017)	48
Figura 16. Modelo propuesto por Liu y Yeh (2017).....	49
Figura 17. Salidas del modelo propuesto por Liu y Yeh (2017).....	50
Figura 18. Modelo propuesto en Pan et al. (2017).....	51
Figura 19. Modelo propuesto por Ahmadi et al. (2018)	53
Figura 20. Optimización de SVM con ICA propuesto en Ahmadi et al. (2018)	53
Figura 21. Optimización de SVM con ICA propuesto en Ahmadi et al. (2018)	54
Figura 22. Modelo propuesto por Cheng y Yang (2018).....	55
Figura 23. Modelo propuesto en Duan et al. (2018).....	56
Figura 24. Modelo propuesto en Ebadati y Mortazavi (2018).....	57
Figura 25. Modelo propuesto en Hu et al. (2018).....	58
Figura 26. Modelo propuesto en Lei (2018)	59
Figura 27. Modelo propuesto en Malagrino et al. (2018).....	60
Figura 28. Modelo propuesto en Xiao et al. (2018).....	62
Figura 29. Modelo propuesto en Malqui y Fernandez (2018)	62
Figura 30. Modelo de predicción propuesto en Malqui y Fernandez (2018)....	64
Figura 31. Arquitectura propuesta por Kamalov (2020).....	65
Figura 32. Arquitectura propuesta por Staffini (2022)	66

Figura 33. Arquitectura propuesta por Jia et al. (2024)	67
Figura 34. Modelo de predicción propuesto (Elaboración propia)	73
Figura 35. Recopilación de datos (Elaboración propia).....	75
Figura 36. Cálculo de características (Elaboración propia)	76
Figura 37. Selección de atributos (Elaboración propia).....	77
Figura 38. Módulo de Predicción propuesto (Elaboración propia).....	78
Figura 39. Arquitectura del Sistema Propuesto (Elaboración propia)	80
Figura 40. Base de Datos del Sistema Propuesto (Elaboración propia).....	81
Figura 41. Diagrama de Componentes de la Interfaz de Usuario para el usuario normal (Elaboración propia).....	83
Figura 42. Diagrama de Componentes de la Interfaz de Usuario para el usuario administrador (Elaboración propia).....	84
Figura 43. Diagrama de Componentes del Módulo de Entrenamiento (Elaboración propia)	84
Figura 44. Diagrama de Componentes del Módulo de Predicción (Elaboración propia).....	85
Figura 45. Código del frontend (Elaboración propia).....	85
Figura 46. Código del entrenamiento y validación (Elaboración propia).....	86
Figura 47. Código de la API (Elaboración propia).....	86
Figura 48. Validación de avance progresivo (Elaboración propia)	91
Figura 49. Resultados del modelo híbrido de media ponderada con varianza para CSRN3 (precio mínimo).....	97
Figura 50. Resultados del modelo híbrido de media ponderada con varianza para CSRN3 (precio máximo)	97
Figura 51. Resultados del modelo híbrido de media ponderada con varianza para CPFE3 (precio mínimo).....	98
Figura 52. Resultados del modelo híbrido de media ponderada con varianza para CPFE3 (precio máximo)	98
Figura 53. Resultados del modelo híbrido de media ponderada con varianza para Dow Jones (precio mínimo)	99
Figura 54. Resultados del modelo híbrido de media ponderada con varianza para Dow Jones (precio máximo)	99
Figura 55. Ingreso al Sistema (Elaboración propia)	104
Figura 56. Creación de usuario – I (Elaboración propia).....	105
Figura 57. Creación de usuario – II (Elaboración propia)	105
Figura 58. Búsqueda de Acciones (Elaboración propia)	106

Figura 59. Análisis de la Acción y visualización de las predicciones (Elaboración propia).....	107
Figura 60. Consolidación de Predicciones (Elaboración propia).....	108

TABLA DE CONTENIDOS

RESUMEN.....	4
ABSTRACT	5
CAPÍTULO 1: INTRODUCCIÓN	13
1.1. ANTECEDENTES	13
1.2. DEFINICIÓN DEL PROBLEMA.....	14
1.2.1. <i>Problema general</i>	14
1.2.2. <i>Problemas específicos</i>	14
1.3. IMPORTANCIA	14
1.4. MOTIVACIÓN.....	16
1.5. OBJETIVOS.....	17
1.5.1. <i>Objetivo general</i>	17
1.5.2. <i>Objetivos específicos</i>	17
1.6. PROPUESTA	18
1.7. ORGANIZACIÓN	18
CAPÍTULO 2: MARCO TEÓRICO	20
2.1. SISTEMA PREDICTIVO	20
2.2. MODELO HIBRIDO	20
2.3. BOLSA DE VALORES.....	20
2.4. REGRESIÓN VS CLASIFICACIÓN	21
2.5. ALGORITMOS SUPERVISADOS.....	21
2.5.1. <i>Máquina de Soporte Vectorial</i>	21
2.5.2. <i>Regresión de Soporte Vectorial</i>	22
2.5.3. <i>Árbol de decisión</i>	23
2.5.4. <i>Bosques aleatorios</i>	23

2.6.	RED NEURONAL ARTIFICIAL.....	23
2.6.	COEFICIENTE DE CORRELACIÓN DE PEARSON	24
CAPÍTULO 3: ESTADO DEL ARTE		25
2.7.	METODOLOGÍA.....	25
2.8.	PLANIFICACIÓN.....	26
2.9.	DESARROLLO	27
2.10.	RESULTADOS	29
2.11.	ANÁLISIS.....	31
2.11.1.	<i>¿Qué modelos existen para predecir los precios en una bolsa de valores, en especial aquellos referentes a los precios máximos y mínimos del día siguiente?.....</i>	<i>31</i>
2.11.2.	<i>¿Qué factores afectan la variación de precios en una bolsa de valores?.....</i>	<i>70</i>
2.11.3.	<i>¿Qué herramientas existen para predecir los precios?</i>	<i>72</i>
CAPÍTULO 4: MODELO PROPUESTO		73
4.1.	MODELO PROPUESTO	73
4.2.	JUSTIFICACIÓN.....	74
4.3.	RECOPILACIÓN DE DATOS	75
4.4.	PREPROCESAMIENTO DE DATOS	76
4.5.	SELECCIÓN DE ATRIBUTOS	77
4.6.	MODELO DE PREDICCIÓN.....	78
CAPÍTULO 5: SISTEMA DE PREDICCIÓN DE PRECIOS MÁXIMOS Y MÍNIMOS DEL DÍA SIGUIENTE		79
5.1.	ARQUITECTURA	79
5.2.	REQUISITOS FUNCIONALES Y NO FUNCIONALES.....	81
5.2.1.	<i>Requisitos Funcionales.....</i>	<i>81</i>
5.2.2.	<i>Requisitos No Funcionales</i>	<i>81</i>
5.3.	BASE DE DATOS	81
5.4.	METODOLOGÍA.....	82

5.5.	DIAGRAMA DE COMPONENTES.....	83
5.5.1.	<i>Interfaz de usuario</i>	83
5.5.2.	<i>Módulo de entrenamiento</i>	84
5.5.3.	<i>Módulo de predicción</i>	85
5.6.	INTEGRACIÓN	85
5.7.	LIMITACIONES	87
CAPÍTULO 6:	VALIDACIÓN Y PRUEBAS	88
6.1.	CONJUNTO DE DATOS	88
6.2.	CARACTERÍSTICAS SELECCIONADAS	89
6.3.	DISEÑO DE ENTRENAMIENTO Y VALIDACIÓN	91
6.4.	CALIBRACIÓN DE HIPERPARÁMETROS.....	92
6.5.	RESULTADOS DE PRUEBAS	95
CAPÍTULO 7:	CONCLUSIONES Y TRABAJOS FUTUROS	101
7.1.	CONCLUSIONES	101
7.2.	TRABAJOS FUTUROS.....	102
ANEXO A:	MANUAL DE USUARIO	103
1.1.	ESTRUCTURA GENERAL DEL SISTEMA.....	104
1.1.1.	<i>Ingreso al sistema</i>	104
1.1.2.	<i>Creación de usuario</i>	105
1.1.3.	<i>Búsqueda de acciones</i>	106
1.1.4.	<i>Análisis de la acción y visualización de predicciones</i>	106
1.1.5.	<i>Consolidación de predicciones</i>	108
1.2.	ACCESOS.....	108
REFERENCIAS.....		109

CAPÍTULO 1: INTRODUCCIÓN

1.1. ANTECEDENTES

Las bolsas de valores son las entidades especializadas en el negocio de reunir a compradores y vendedores de acciones y valores. Por otro lado, el Mercado de Valores es un mercado donde se realiza la negociación de acciones de una organización, tanto valores cotizados como no cotizados. Es diferente de la bolsa de valores porque incluye todas las bolsas de valores nacionales del país. Los compradores y vendedores de acciones no son otros que los participantes del mercado de valores, que van desde pequeños inversores en acciones individuales hasta grandes comerciantes de fondos de cobertura, quienes pueden estar situados en cualquier parte del mundo. Se dice que su negocio se realiza cuando un profesional en una bolsa de valores ejecuta una orden para dicha transacción (Gagandeep, 2014).

Las bolsas de valores tienen múltiples roles en la economía, entre los principales se puede mencionar los siguientes: recaudación de capital para las empresas, formas comunes de aumento de capital, movilización de ahorros para inversión facilitando el crecimiento de la empresa, creación de oportunidades de inversión para pequeños inversores y barómetro de la economía. Entre las mayores bolsas de valores se tiene la Bolsa de Nueva York, NASDAQ y la Bolsa de Tokio (Gagandeep, 2014). Algunos autores han tratado de predecir el comportamiento de las Bolsas de Valores, donde destaca el precio de las acciones (Laboissiere et al., 2015), la dirección de los precios de las acciones (Lei, 2018), la dirección de índices de las acciones (Malagrino et al., 2018) y las estrategias de inversión (Zbikowski, 2015).

La predicción del mercado de valores es el acto de tratar de determinar el valor futuro de las acciones de una empresa u otro instrumento financiero negociado en una bolsa (Jain y Mark, 2018). El mercado de valores es uno de los componentes más vitales de la economía actual. Muchas personas siempre intentan predecir los precios de las acciones, incluidos los precios de apertura, los precios más alto, los precios de cierre y los volúmenes de negociación de sus acciones favoritas. Predecir con precisión los precios de las acciones puede brindar a los inversores más oportunidades de obtener ganancias en la bolsa de valores (Hu et al., 2018). Mientras diferentes opiniones difieren en la eficiencia de los mercados, muchos estudios han mostrado que los mercados y las bolsas de valores son predecibles.

1.2. DEFINICIÓN DEL PROBLEMA

1.2.1. Problema general

Predecir los precios máximos y mínimos de las acciones del día siguiente en una bolsa de valores con la mayor precisión posible.

1.2.2. Problemas específicos

- ¿Qué modelos de *machine learning* existen para la predicción de los precios de acciones mínimos y máximos?
- ¿Es posible diseñar un modelo híbrido de machine learning para predecir los precios de acciones mínimos y máximos, y presente mejores resultados que los modelos singulares que lo integran?
- ¿Es posible verificar el desempeño del modelo híbrido propuesto?

1.3. IMPORTANCIA

La bolsa de valores es el escenario en el que se realiza la compraventa de valores. La mayor bolsa de valores es la de Nueva York (BBC Mundo, 2011), cuya capitalización

bursátil (entendiéndose como el número de acciones multiplicado por la cotización del mercado bursátil de una acción), en octubre de 2017, ascendía a 25 billones de dólares (Capital, 2024).

Para comprender la gran importancia de la bolsa de valores, se debe recordar la caída del lunes 19 de octubre de 1987 (lunes negro). Según menciona (O' Connel, 2018), se produjo una caída del 22.6 % del índice bursátil Dow Jones (mide el desempeño de las 30 mayores empresas que cotizan en el mercado de EE. UU.), mucho mayor que la caída de 1929. Hay muchos factores que explican esta caída: el dólar en declive, la incertidumbre mediática, el comercio digital y el seguro de cartera. Para traducir esta caída en números, (Vegas et al., 2017) menciona que el lunes negro no discriminó entre profesionales y particulares. Warren Buffett perdió 347 millones de dólares; Bill Gates, 255 millones de dólares, y la familia de Sam Walton, fundador de los almacenes Wal-Mart, vio cómo su riqueza menguaba en 1.750 millones de dólares.

La inversión en acciones es una actividad monetaria emocionante y desafiante, y la previsión de la tendencia y el precio de las acciones juega un papel importante en el mercado de valores. Los inversionistas en acciones podrían tener la oportunidad de ganar mucho dinero en devoluciones de acciones con decisiones sabias. Sin embargo, la mayoría de los inversores mantienen una imagen pesimista con una gran pérdida de dinero en la inversión de valores, esto debido a que el comportamiento del mercado de valores es no lineal y no estacionario, así mismo, si no se cuenta con experiencia o conocimiento experto, la fluctuación del precio de las acciones es extremadamente difícil de predecir correctamente (Cheng y Yang, 2018).

Según la revista Forbes, a mediados del año 2024, el 20 % de las 200 personas más ricas del mundo obtuvieron su riqueza mediante el rubro de las finanzas y las inversiones (Forbes, 2024). Esto indica que la inversión en las Bolsas de Valores puede ser una

actividad lucrativa, pero para esto es necesario tener suerte, conocer de antemano la ocurrencia de eventos que harán fluctuar los precios de las acciones o poder predecir el valor que tendrá una acción en determinado momento para decidir vender o comprar determinada acción.

Los inversores quieren maximizar sus ganancias y minimizar sus pérdidas. Si se conocen los precios mínimos y máximos de las acciones del día siguiente, se sabe exactamente en qué momento se debe vender o comprar determinada acción (se vende la acción cuando el precio es máximo, y se compra cuando el precio es mínimo), de esta manera, se obtiene la mayor ganancia posible.

1.4. MOTIVACIÓN

Como se menciona en Laboissiere et al. (2015), la mayoría de los artículos existentes en la literatura proponen metodologías para determinar los precios de cierre y/o dirección de bolsas específicas. En Laboissiere et al. (2015), se propone usar redes neuronales para predecir los precios máximos y mínimos de las bolsas de valores.

La variación de las acciones es por la compraventa de los inversores. Es importante saber qué factores explican esta decisión. Según Túfecksi (2016), estos factores son los indicadores macroeconómicos, eventos políticos, especulación financiera, variación del tipo de cambio, políticas de las empresas, entre otros, donde los primeros son los más relevantes.

En Malagrino et al. (2018), se menciona que las bolsas de valores pueden ser influenciadas por otras bolsas de valores alrededor del mundo, hace un estudio sobre qué tanto influyen otros índices bursátiles alrededor del mundo sobre un índice bursátil particular.

En Duan et al. (2018), el estudio parte de la premisa del mercado incremental, el cual se refiere a que en un tiempo específico las acciones siempre tienden a incrementar. A partir de los modelos, se obtienen resultados favorables que sugieren que, a pesar de la volatilidad diaria de los precios, al final de una serie temporal, estos tienden a ser más altos.

En problemas relacionados con la predicción de los precios de cierre y apertura, la dirección de los precios y el mejor momento para vender o comprar acciones, se han usado métodos híbridos de *machine learning*, los cuales han demostrado tener una mayor tasa de acierto, como se muestra en los trabajos de Lei (2018) y Ahmadi et al. (2018).

1.5. OBJETIVOS

1.5.1. Objetivo general

Desarrollar un sistema predictivo de los precios máximos y mínimos de las acciones del día siguiente en la bolsa de valores para mejorar la tasa de acierto mediante el uso de un modelo híbrido de *machine learning*.

1.5.2. Objetivos específicos

Los objetivos específicos son los siguientes:

- Realizar una revisión de literatura para identificar los modelos usados para la predicción en una bolsa de valores, en particular, los precios de las acciones.
- Desarrollar un modelo híbrido de *machine learning* para predecir los precios máximos y mínimos de las acciones del día siguiente en una bolsa de valores.
- Probar el modelo propuesto con un caso de estudio, usando data histórica, en una bolsa de valores específica.

1.6. PROPUESTA

Se propone una herramienta de apoyo para predecir el precio máximo y mínimo del día siguiente de las acciones de la bolsa de valores con baja tasa de error, el cual se basa en un modelo híbrido de *machine learning*. El esquema de la herramienta planteada se presenta en la Figura 1, en donde a partir de los datos históricos de las acciones obtenidos de Yahoo! Finance, el modelo híbrido predice los precios máximos y mínimos.




Figura 1. Esquema general de la propuesta

Fuente: Elaboración propia

1.7. ORGANIZACIÓN

La tesis está organizada en 7 capítulos que se describen a continuación:

En el capítulo 2, se indican los conceptos de la bolsa de valores, regresión, clasificación, algoritmos supervisados, redes neuronales y el coeficiente de correlación de Pearson para una mejor comprensión de la tesis.

En el capítulo 3, se realiza una revisión exhaustiva del estado del arte de los trabajos relacionados con la predicción del precio máximo y mínimo del día siguiente en una bolsa de valores.

En el capítulo 4, se propone un modelo para poder solucionar el problema definido en el punto 1.2.

En el capítulo 5, se describe el proceso de desarrollo del sistema de predicción.

En el capítulo 6, se ejecuta el entrenamiento y se realiza la validación del modelo propuesto para 3 conjunto de datos

En el capítulo 7, se describen las conclusiones de esta tesis, así como los futuros trabajos que abren esta investigación.

CAPÍTULO 2: MARCO TEÓRICO

Este capítulo presenta una breve explicación sobre la bolsa de valores, problemas de regresión, algoritmos supervisados, redes neuronales y coeficiente de correlación de Pearson.

2.1. SISTEMA PREDICTIVO

Los sistemas predictivos son sistemas que capturan relaciones entre variables en conjuntos de datos históricos y sus resultados. A partir de estas relaciones se desarrollan modelos que a su vez se utilizan para predecir nuevos resultados (Bryndin, E., 2019).

2.2. MODELO HIBRIDO

Los modelos híbridos son combinaciones de dos o más técnicas de aprendizaje automático. Estos modelos son más sólidos ya que a menudo complementan las ventajas de las técnicas individuales involucradas y mejoran la precisión del pronóstico (Deb et al., 2017).

2.3. BOLSA DE VALORES

Las Bolsas de Valores son organizaciones donde los miembros de la organización se reúnen para negociar acciones de empresas u otros valores. Los miembros podrán actuar como agentes de sus clientes, o como dueños de sus propias cuentas (Gagandeep, 2014). Las bolsas de valores también facilitan la emisión y rescate de valores y otros instrumentos financieros, instrumentos que incluyen el pago de ingresos y dividendos. el comercio en una bolsa es únicamente entre miembros y los corredores de bolsa tienen un asiento en la bolsa (Gagandeep, 2014).

2.4. REGRESIÓN VS CLASIFICACIÓN

Las variables se pueden caracterizar como cuantitativas o cualitativas (también conocido como categórico). Las variables cuantitativas toman valores numéricos. Los ejemplos incluyen la edad, la altura o los ingresos de una persona, el valor de una casa y el precio de una acción. Por el contrario, las variables cualitativas toman valores en una de K diferentes clases o categorías. Ejemplos de variables cualitativas incluir el estado civil de una persona (casada o no), la marca del producto comprado (marca A, B o C), si una persona incumple una deuda (sí o no), o un diagnóstico de cáncer (Leucemia Mielógena Aguda, Linfoma Agudo leucemia foblástica o sin leucemia). Solemos referirnos a problemas con una respuesta cuantitativa como problemas de regresión, mientras que aquellos que involucran una respuesta cualitativa a menudo se denomina problemas de clasificación (Gareth et al , 2013).

2.5. ALGORITMOS SUPERVISADOS

Los algoritmos de aprendizaje automático supervisados han sido un método dominante en el campo de la minería de datos (Uddin et al., 2019). Los algoritmos de aprendizaje automático emplean una variedad de métodos estadísticos, probabilísticos y de optimización para aprender de la experiencia pasada y detectar patrones útiles a partir de conjuntos de datos grandes, no estructurados y complejos (Van-Leeuwen, 2004).

Entre los algoritmos supervisados tenemos a la máquina de soporte vectorial y el bosque aleatorio.

2.5.1. Máquina de Soporte Vectorial

El algoritmo de máquina de soporte vectorial (SVM) puede clasificar datos lineales y no lineales. Primero, mapea cada elemento de datos en un espacio de características n-

dimensional, donde n es el número de características. Luego, identifica el hiperplano que separa los elementos de datos en dos clases, mientras maximiza la distancia marginal para ambas clases y minimiza los errores de clasificación. Para realizar la clasificación, se necesita encontrar el hiperplano que diferencia las dos clases por el margen máximo (Joachims, 1998).

Para el caso específico de clasificación no lineal, SVM hace uso del kernel trick, representando los datos solo a través de un conjunto de comparaciones de similitud por pares entre los puntos de datos originales utilizando una función *kernel*, que los transforma en coordenadas en un espacio de características de dimensiones superiores. Por lo tanto, las SVM utilizan el truco del *kernel* para mapear implícitamente sus entradas en espacios de características de alta dimensión, donde se puede realizar la clasificación lineal (Awad, 2015).

2.5.2. Regresión de Soporte Vectorial

La regresión de soporte vectorial (SVR) es una técnica basada en máquina de soporte vectorial pero que en lugar de ser de tipo clasificación binaria, es utilizada para la regresión. Ha tenido exitosos rendimientos en series de tiempo (Smola y Schölkopf, 2004).

El modelo SVR, a diferencia de los modelos de regresión típicos, emplea principios de máquinas de vectores de soporte (SVM) para transformar características de entrada en espacios de alta dimensión para ubicar el hiperplano ideal que represente con precisión los datos (Smola y Schölkopf, 2004).

2.5.3. Árbol de decisión

El árbol de decisiones (DT) es uno de los primeros y más destacados algoritmos de aprendizaje automático. Un árbol de decisión modela las lógicas de decisión, es decir, prueba y corresponde los resultados para clasificar elementos de datos en una estructura similar a un árbol. Los nodos de un árbol DT, normalmente, tienen varios niveles, donde el primer nodo o el más alto se llama nodo raíz. Todos los nodos internos (es decir, nodos que tienen al menos un hijo) representan pruebas sobre variables o atributos de entrada. Dependiendo del resultado de la prueba, el algoritmo de clasificación se ramifica hacia el nodo hijo apropiado, donde el proceso de prueba y ramificación se repite hasta que alcanza el nodo hoja (Quinlan, 1986).

2.5.4. Bosques aleatorios

Los bosques aleatorios o bosques de decisión aleatoria son un método de aprendizaje conjunto para clasificación, regresión y otras tareas que funciona creando una multitud de árboles de decisión durante el entrenamiento. Para las tareas de clasificación, la salida del bosque aleatorio es la clase seleccionada por la mayoría de los árboles. Para las tareas de regresión, el resultado es el promedio de las predicciones de los árboles (Tin Kam Ho, 1995) (Tin Kam Ho, 1998).

2.6. RED NEURONAL ARTIFICIAL

Las redes neuronales artificiales (RNA) son un conjunto de algoritmos de aprendizaje automático que se inspiran en el funcionamiento de las redes neuronales del cerebro humano. Primero, fueron propuestos por McCulloch y Pitts, y luego popularizados por los trabajos de Rumelhart et al. en la década de 1980. En el cerebro biológico, las neuronas están conectadas entre sí a través de múltiples uniones de axones que forman un gráfico

similar en un modelo. Estas interconexiones se pueden volver a cablear (por ejemplo, a través de la neuro plasticidad), lo cual ayuda a adaptar, procesar y almacenar información. Asimismo, los algoritmos RNA se pueden representar como un grupo de nodos interconectados. La salida de un nodo va como entrada a otro nodo para su posterior procesamiento de acuerdo con la interconexión. Los nodos, normalmente, se agrupan en una matriz llamada capa, según la transformación que realicen. Además de la capa de entrada y salida, puede haber una o más capas ocultas en un marco RNA. Los nodos y los bordes tienen pesos que permiten ajustar la intensidad de la señal de comunicación que puede amplificarse o debilitarse mediante el entrenamiento repetido. Según el entrenamiento y la adaptación posterior de las matrices, los pesos de los nodos y los bordes, las RNA pueden hacer una predicción para los datos de prueba (Uddin et al., 2019).

2.6. COEFICIENTE DE CORRELACIÓN DE PEARSON

El coeficiente de correlación de Pearson (r) es una medida de la asociación lineal de dos variables. El análisis de correlación suele comenzar con una representación gráfica de la relación de pares de datos mediante un diagrama de dispersión. Los valores del coeficiente de correlación varían de -1 a $+1$. Los valores positivos del coeficiente de correlación indican una tendencia de una variable a aumentar o disminuir junto con otra variable. Los valores negativos del coeficiente de correlación indican una tendencia a que el aumento de los valores de una variable se asocie con la disminución de los valores de la otra variable y viceversa. Los valores del coeficiente de correlación cercanos a cero indican una baja asociación entre variables, y aquellos cercanos a -1 o $+1$ indican una fuerte asociación lineal entre dos variables (Pearson, 2008).

CAPÍTULO 3: ESTADO DEL ARTE

Se realiza una búsqueda sobre artículos existentes en la literatura relacionados con el tema de investigación, así como una breve descripción de los artículos seleccionados. Además, se observa un aumento en la cantidad de artículos publicados durante el periodo 2001-2024, con un crecimiento notable a partir del año 2009, lo cual refleja un mayor interés en el tema (ver Figura 2).

2.7. METODOLOGÍA

Los artículos académicos fueron recopilados mediante el uso de las cadenas de búsqueda y otros criterios. Se hizo un análisis de los títulos, los resúmenes de los artículos y gracias al uso de criterios de exclusión se consiguieron 28 artículos (ver Figura 2).

Una revisión sistemática de la literatura fue conducida siguiendo las directrices usadas por Kitchenham y Charters (2007), determinando las siguientes fases:

- Revisión de la planificación: Las preguntas de investigación, cadenas de búsqueda, criterios de selección y palabras claves se definen aquí.
- Desarrollo: Se aplica el protocolo definido y los artículos primarios se obtienen de acuerdo con los criterios establecidos.
- Resultados: En esta fase se presenta los resultados de la búsqueda y el análisis de los estudios seleccionados.

2.8. PLANIFICACIÓN

Se plantearon preguntas de investigación que se responderá posteriormente.

Q1: ¿Qué modelos existen para predecir los precios en una bolsa de valores, en especial aquellos referentes a los precios máximos y mínimos del día siguiente?

Q2: ¿Qué factores afectan la variación de precios en una bolsa de valores?

Q3: ¿Qué herramientas existen para predecir los precios en una bolsa de valores?

Se realizó la búsqueda de los artículos en el metabuscador *WebOfKnowdlegde*. Los artículos se consiguieron haciendo uso de la siguiente cadena de búsqueda: *TS = (model AND (forecasting OR prediction)) AND WC=Computer Science, Artificial Intelligence AND TI = ("stock market" OR "stock price")*, con el intervalo de fechas 2016-2024, y mediante algunos filtros se llegó a 28 artículos. Lo anterior se detalla en el punto de desarrollo.

Palabras clave	• Mercado de valores (en inglés, <i>stock market, stock price</i>) • Modelo (en inglés, <i>model</i>) • Precios máximos (en inglés, <i>maximum prices</i>) • Precios mínimos (en inglés, <i>minimum prices</i>) • Predicción (en inglés, <i>forecasting, prediction</i>) • Día siguiente (en inglés, <i>next day, one day, next-day, one-day</i>) • Herramientas (en inglés, <i>tools</i>)
Periodo de búsqueda	2016-2024

Tabla 1. Palabras clave y el periodo de búsqueda. Fuente: Elaboración propia

Para reducir el universo de los artículos, se utilizará los siguientes criterios de inclusión y exclusión. Esto es mostrado en la tabla 2.

Criterio de inclusión	Criterio de exclusión
Tipo de publicación: Artículos en revistas con factor de impacto SJR	No tener factor de impacto
Área: Ciencias de la computación e Inteligencia Artificial	Posters, editoriales, cartas, <i>erratum</i> y libros
El título debe hacer referencia o estar relacionado a las bolsas de valores.	Relacionado con fluctuación de energía

Tabla 2. Criterios de inclusión y exclusión. Fuente: Elaboración propia

2.9. DESARROLLO

Se realizaron 4 iteraciones con 4 cadenas de búsqueda distintas (ver tabla 3). En la última de estas búsquedas se obtuvo 268 resultados. Luego se aplicó los criterios de exclusión, obteniéndose 259 resultados. Posteriormente, se leyó el resumen de los artículos que quedaban, obteniéndose 50 resultados. A continuación, se agregaron 2 artículos del 2015, 4 del 2016, 2 del 2017, 3 del 2018, debido a que 2 mencionaban el tema de la tesis y los otros trataban acerca de modelos interesantes (optimización de enjambre de partículas multiobjetivo, SVM y redes artificiales neuronales), obteniéndose 61 artículos. Finalmente, se volvió a leer los resúmenes para un último filtrado, obteniéndose 28 artículos. Lo anterior se gráfica en la tabla 3 y en la figura 2.

Cadena de búsqueda	Resultado
TS = (model AND (minimum price OR maximum price) AND (next day OR one day OR next-day OR one-day) AND (forecasting OR prediction) AND tools) AND WC=Computer Science, Artificial Intelligence AND TI = ("stock market" OR "stock price") Intervalo: 2016-2024	1
TS = (model AND (minimum price OR maximum price) AND (forecasting OR prediction) AND tools) AND WC=Computer Science, Artificial Intelligence AND TI = ("stock market" OR "stock price") Intervalo: 2016-2024	2
TS = (model AND (forecasting OR prediction) AND tools) AND WC=Computer Science, Artificial Intelligence AND TI = ("stock market" OR "stock price") Intervalo: 2016-2024	22
TS = (model AND (forecasting OR prediction)) AND WC=Computer Science, Artificial Intelligence AND TI = ("stock market" OR "stock price") Intervalo: 2016-2024	268

Tabla 3. Iteraciones de las cadenas de búsqueda. Fuente: Elaboración propia




Figura 2. Flujograma utilizado para la búsqueda. Fuente: Elaboración propia

2.10. RESULTADOS

Con base en la última cadena de búsqueda seleccionada, se nota una tendencia creciente en las investigaciones sobre predicción de los precios en las acciones en una bolsa de valores. En la Figura 3, se muestra la evolución de los artículos existentes en el metabuscador *WebOfKnowdlegde* desde el año 2001 hasta el 2024, así como los artículos seleccionados por año. Los años indican el año de publicación del artículo.



Figura 3. Evolución de artículos en los años (2001-2024).

Fuente: Elaboración propia

En la tabla 4, se muestra un listado de los artículos seleccionados.

Título	Autor	Revista
New efficient hybrid candlestick technical analysis model for stock market timing on the basis of the Support Vector Machine and Heuristic Algorithms of Imperialist Competition and Genetic	Ahmadi et al. (2018)	Expert Systems with Applications (Q1)
Fuzzy time-series model based on rough set rule induction for forecasting stock price	Cheng y Yang (2018)	Neurocomputing (Q1)
An adaptive stock index trading decision support system. Expert Systems with Applications	Chiang et al. (2016)	Expert Systems with Applications (Q1)

Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies	Chong et al. (2017)	Expert Systems with Applications (Q1)
Elliott wave theory and the Fibonacci sequence-gray model and their application in Chinese stock market	Duan et al. (2018)	Journal of Intelligent & Fuzzy Systems (Q3)
An efficient hybrid machine learning method for time series stock market forecasting	Ebadati y Mortazavi (2018)	Neural Network World (Q4)
Stock price prediction using hybrid soft computing models incorporating parameter tuning and input variable selection	Göçken et al. (2017)	Neural computing & Applications (Q2)
Predicting the direction of stock markets using optimized neural networks with Google Trends	Hu et al. (2018)	Neurocomputing (Q1)
ResNLS: An improved model for stock price forecasting	Jia et al (2024)	Computational Intelligence (Q3)
Forecasting significant stock price changes using neural networks	Kamalov (2020)	Neural computing & Applications (Q2)
Maximum and minimum stock price forecasting of Brazilian power distribution companies based on artificial neural networks	Laboissiere et al. (2015)	Applied Soft Computing (Q1)
Wavelet Neural Network Prediction Method of Stock Price Trend Based on Rough Set Attribute Reduction	Lei (2018)	Applied Soft Computing (Q1)
Empirical analysis: stock market prediction via extreme learning machine	Li et al. (2016)	Neural computing & Applications (Q2)
Using mixture design and neural networks to build stock selection decision support systems	Liu y Yeh (2017)	Neural computing & Applications (Q2)
Multiobjective optimization based adaptive models with fuzzy decision making for stock market forecasting	Mahji y Anish (2015)	Neurocomputing (Q1)
Forecasting stock market index daily direction: A Bayesian Network approach	Malagrino et al. (2018)	Expert Systems with Applications (Q1)
Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques	Malqui y Fernandez (2018)	Applied Soft Computing (Q1)
Stock market forecasting by using a hybrid model of exponential fuzzy time series	Mirzaei et al. (2016)	International Journal of Approximate Reasoning (Q2)
A multiple support vector machine approach to stock index forecasting with mixed frequency sampling	Pan et al. (2017)	Knowledge-based systems (Q1)

Association rule mining using enhanced apriori with modified GA for stock prediction	Prasanna y Ezhilmaran (2016)	International Journal of Data Mining, Modelling and Management (Q4)
A Repairing Artificial Neural Network Model-Based Stock Price Prediction	Prabin y Thanabal (2021)	International Journal of Computational Intelligence Systems (Q3)
A hybrid model based on differential fuzzy logic relationships and imperialist competitive algorithm for stock market forecasting	Sadadei et al. (2016)	Applied Soft Computing (Q1)
Stock Price Forecasting by a Deep Convolutional Generative Adversarial Network	Staffini (2022)	Frontiers in Artificial Intelligence (Q2)
Classification-based prediction models for stock price index movement	Tüfekci (2016)	Intelligent data analysis (Q4)
A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting	Wei (2016)	Applied Soft Computing (Q1)
A new approach for stock price analysis and prediction based on SSA and SVM	Xiao et al. (2018)	International Journal of Information Technology & Decision making (Q3)
An Integrated Model Combined ARIMA, EMD with SVR for Stock Indices Forecasting	Yang y Lin (2016)	International Journal on Artificial tools (Q4)
Multidimensionalk-nearest neighbor model based on EEMD for financial time series forecasting	Zhang et al. (2018)	Physica A: Statistical Mechanics and its Applications (Q2)

Tabla 4. Artículos elegidos de WOS (Web of Knowledge)

2.11. ANÁLISIS

En esta sección se responde a las preguntas de investigación planteadas en la planificación.

2.11.1. ¿Qué modelos existen para predecir los precios en una bolsa de valores, en especial aquellos referentes a los precios máximos y mínimos del día siguiente?

Laboissiers et al. (2015) son motivados debido a que la mayoría de los artículos en la literatura proveen metodologías para determinar los precios de cierre, así como la

dirección de ciertas acciones. Además, las redes neuronales son técnicas ampliamente usadas para predecir precios en los mercados de valores, lo que permite asistir a los inversores en la toma de decisiones.

Motivado por lo anterior, los autores proponen un modelo basado en redes neuronales para predecir el precio máximo y mínimo de las acciones del día siguiente (ver Figura 4). Este modelo tiene 5 bloques: obtención de datos históricos, preprocesamiento de datos, análisis de correlación, uso del modelo (redes neuronales artificiales) y evaluación de los resultados.

El primero consiste en recopilar los valores históricos de algunas bolsas de valores (CSRN3, CEBR3 y CPFE3), dos índices bursátiles (Ibovespa y IEE) y la cotización del dólar americano.

El segundo consiste en una etapa de preprocesamiento para filtrar posibles fluctuaciones a través de una Media Móvil Ponderada de los días negociables de los últimos 30 días y luego evidenciar tendencias en los precios de las acciones.

El tercero consiste en disminuir la cantidad de posibles atributos de entrada, a través de una selección de atributos basados en un análisis de correlación entre un posible atributo de entrada y la salida deseada (precios máximos y mínimos del día), en donde los atributos con más alta correlación con la salida son considerados para predecir el precio máximo y mínimo para cada acción.

El cuarto consiste en el uso de una red neuronal multicapa con uno o dos capas ocultas, basado en un algoritmo llamado Levenderg-Marquardt en lugar del gradiente descendente y probando diversas topologías. Cada acción fue entrenada por una red neuronal.

El quinto consiste en evaluar el rendimiento de cada red neuronal en la tarea de predecir los precios máximos y mínimos diarios de las acciones.



Figura 4. Modelo propuesto en Laboissiers et al. (2015)

Como conclusión, los autores mencionan que seleccionando los atributos más relevantes en lugar de usar todos como entrada para una red neuronal se obtiene una mejora. Con el modelo propuesto se llega a un cálculo de MAPE de 0.9 % para el precio máximo y 2.1 % para el precio mínimo.

Mahji y Anish (2015) afirman que los modelos de optimización multiobjetivo tienen muy poco material informativo en la literatura, pero aun así se esperan buenos resultados de ellos, ya que los modelos de optimización de un solo objetivo no satisfacen las funciones de costo, lo cual motivó a los autores a entrar en el tema de los modelos de optimización multiobjetivo. Los resultados de la simulación revelan que, en términos de precisión direccional (DA) y tiempo de cálculo, el modelo basado en MOPSO es mejor, así mismo, en términos de varianza relativa promedio (ARV) e I-metric, el modelo NSGA-II es superior. Sin embargo, con respecto a la media del porcentaje de error (MAPE) y la U de

Theli, MOPSO está mejor por encima de la predicción de un mes. Sin embargo, para una predicción de menos de un mes, el modelo NSGA-II es preferible. Para facilitar la comparación, también se desarrollan dos modelos basados en la optimización objetiva única (basados en PSO y GA), donde el rendimiento se ha obtenido a través del estudio de simulación. Estos modelos usan la expansión del polinomio de Legendre para sus predicciones (ver Figura 5).




Figura 5. Modelo propuesto en Mahji y Anish (2015)

Como conclusiones, se demuestra que ambos modelos son competentes entre sí de alguna manera. Se ha empleado una estrategia de selección basada en lógica difusa para elegir las mejores soluciones posibles desde el frente de Pareto. De este modo, se observa que, en términos de MAPE y DA, los modelos de optimización multiobjetivo (MOPSO y NSGA-II) muestran un rendimiento de predicción mejorado en comparación con los modelos basados en un solo objetivo (PSO y GA). Además, estos a su vez difieren entre sí (ver tabla 5).

Performance criteria	MOPSO based model	NSGA-II based model
MAPE	Superior for one month and above	Superior for less than one month
DA	Superior	Inferior
Theli's U	Superior for more than one month	Superior for less than one month
ARV	Inferior	Superior
Computation time	Less	More
I-Metric	Better for one day	Better for more than one day

Tabla 5. Diferencias entre modelos. Mahji y Anish (2015)

En Chiang et al. (2016), la predicción y el movimiento de los precios del índice bursátil es importante porque el desconocimiento de estos se traduce en negociaciones excesivas, costos de transacción y oportunidades perdidas. La motivación de los autores empieza aquí, ya que existen métodos sistemáticos, pero solo enfocados en un aspecto en particular (por ejemplo, activos financieros). Las personas necesitan a menudo un método sistemático para detectar oportunidades comerciales y, en general, para tener un enfoque coherente.

El sistema propuesto se muestra en la Figura 6. Este consta de cuatro módulos básicos: el módulo de preprocesamiento de datos, el módulo de inicialización de redes neuronales, el módulo de capacitación de redes neuronales y el módulo de salida.

Las salidas son el porcentaje de predicciones de las acciones y la cantidad de beneficios que podría dar este sistema. Se considera que, si se tiene un porcentaje mayor a 50 %, se puede aprovechar este sistema.




Figura 6. Modelo propuesto en Chiang et al. (2016)

Como conclusión se tiene que el modelo adaptativo propuesto es único porque optimiza el rendimiento de la red para cada índice de stock individual. Este sistema también supera una gran debilidad de un enfoque de ANN tradicional, que a menudo es muy sensible a la selección de entradas y parámetros, al ajustar el modelo de forma adaptativa para ajustarse a diferentes índices bursátiles.

Li et al. (2016) menciona que las noticias del mercado y los precios de las acciones son dos de los más importantes recursos de información del mercado, esto es motivado debido a que los artículos existentes en la literatura toman estos recursos por separado para predecir los precios de las acciones.

Motivado por lo anterior, propone un modelo en donde se usa de manera conjunta las noticias financieras y data histórica (ver Figura 7). La salida del modelo es una señal de si los precios suben, se mantienen o bajan. Este modelo presenta 5 pasos: Preprocesamiento de precios y noticias, Alinear noticias y precios, Normalización, Entrenamiento del modelo y Evaluación.

El primer paso consiste en el preprocesamiento por separado de los precios históricos del mercado y los artículos de noticias financieras. Para los precios, estos se ordenan y posteriormente se interpolan los valores faltantes. Para los artículos de noticias

financieras, se hizo un análisis de texto que incluyó la segmentación de los términos en las noticias y la determinación de la ocurrencia de una palabra en los artículos.

El segundo paso es combinar las dos fuentes de información mediante la extracción del “contexto de precio” alrededor de cada evento noticioso, construir las características para el “contexto de precio” y luego combinar las características de las noticias y las características de los precios.

El tercer paso consiste en normalizar los indicadores de las noticias y los precios, después de la normalización el rango de estos valores es $[-1, 1]$.

En el cuarto paso, se compara el modelo de entrenamiento propuesto ELM con otros existentes en el estado del arte (Red neuronal y SVM).

En el último paso, se evalúa la precisión del modelo, así como su rapidez.




Figura 7. Modelo propuesto en Li et al. (2016)

Como conclusiones los autores presentan que el modelo basado en una ELM kernelizada es mejor que los otros modelos en comparación. Sin embargo, mencionan que el método hace demasiado consumo de CPU, por lo que proponen otros estudios para reducir los requerimientos computacionales del modelo propuesto.

En Mirzaei et al. (2016), el objetivo inicial de este estudio es proponer un método híbrido basado en series temporales difusas exponenciales y optimización basada en autómatas de aprendizaje para la previsión del mercado de valores. La motivación gira en que, si bien este modelo tiene muchos homólogos, la competencia gira en torno a la mayor precisión que tenga el modelo. Para ello, se introduce un enfoque de dos fases (ver Figura 8).

En la primera fase, las longitudes óptimas de los intervalos se obtienen aplicando una serie de tiempo difusa convencional junto con el algoritmo de inteligencia de enjambre de autómatas de aprendizaje para ajustar la longitud de los intervalos correctamente. Posteriormente, las longitudes óptimas obtenidas se aplican para generar una nueva serie temporal difusa, propuesta en este estudio, denominada serie temporal difusa exponencial. En esta fase final, debido a la naturaleza de las series de tiempo difusas exponenciales, se requiere otra ronda de optimización para estimar ciertos parámetros del método.




Figura 8. Modelo propuesto en Mirzaei et al. (2016)

Finalmente, este modelo se utiliza para previsiones futuras. Para validar el método híbrido propuesto, se emplean cuarenta y seis estudios de caso de cinco bases de datos de índices bursátiles y los hallazgos se comparan con modelos de series de tiempo difusos bien conocidos y métodos clásicos para series de tiempo. El modelo propuesto ha superado a sus homólogos en términos de precisión.

Las conclusiones son que el estudio del modelo híbrido puede escalar a otros estudios, es decir, haciendo uso de algoritmos evolutivos, como este caso, se puede mejorar el rendimiento de los modelos.

Prasanna y Ezhilmaran (2016) menciona que los precios de las acciones tienen un comportamiento no lineal y hasta ahora ningún modelo ha logrado una certeza en la

predicción de estos, lo que los motivó a proponer un modelo híbrido para mejorar la precisión de los modelos en el estado del arte.

Los autores proponen un modelo mediante el uso de un algoritmo a priori mejorado y de un algoritmo genético modificado (ver Figura 9).

El modelo cuenta los siguientes bloques: Datos históricos, Explicación de la base de datos, Algoritmo A priori mejorado, Algoritmo genético modificado y Selección de la mejor regla de mercado.

El modelo recopila una base de datos históricos de los precios de las acciones, posteriormente, los transforma en 4 indicadores (punto de pivote, media móvil exponencial, índice de fuerza relativa y tasa de cambio). Con base en estos indicadores, se obtienen reglas de asociación mediante un algoritmo a priori mejorado (tiene menos costo computacional) que refleja el comportamiento de estos datos históricos y, posteriormente, mediante el uso de algoritmos genéticos, se obtiene la regla que mejor modela los datos históricos.




Figura 9. Modelo propuesto en Prasanna y Ezhilmaran (2016)

Con este modelo se logró generar reglas de mercado que podría ser usadas para soportar toma de decisiones en oferta de acciones y en predicción.

En Sadadei et al. (2016), se presenta un nuevo tipo de conjunto difuso en el campo de las series de tiempo difuso. Se espera estimar las tendencias con las series de tiempo difusas. El proceso consiste en tomar dos puntos de la serie de tiempo difusa y calcular la relación difusa diferencial, para luego estimar la tendencia, si es en aumento o es en caída.

Esto se consigue tomando en cuenta algunos pasos.

En primer lugar, los datos históricos se confunden en conjuntos difusos diferenciales, y luego se calculan las relaciones difusas diferenciales.

En segundo lugar, los grupos lógicos difusos diferenciales se establecen agrupando relaciones difusas diferenciales.

Finalmente, en el paso de desborrosificación, se calculan las previsiones. Sin embargo, para aumentar la precisión de los modelos, se inyecta un algoritmo evolutivo (un algoritmo imperialista competitivo (ICA)) para entrenar el modelo.

La motivación del autor va por el interés que se tiene de los FTS (Series de tiempo difusas) debido al aumento de artículos sobre el tema y a la alta tasa de opciones que hay para mejorar el rendimiento de las precisiones de estas. El flujograma de este modelo es mostrado en la Figura 10.




Figura 10. Modelo propuesto en Sadadei et al. (2016)

Las conclusiones obtenidas muestran que optimizando los datos y agregando el factor de la tendencia de los datos se logra un pronóstico de alto rendimiento con las FTS.

En Túfecksi (2016), hay varios factores para predecir el índice de precios de las acciones: indicadores macroeconómicos, eventos políticos, especulación financiera, variación del tipo de cambio y políticas de las empresas. La motivación del autor aquí nace porque el conocimiento de los precios de las acciones supone tomar decisiones sobre prácticamente altas ganancias en el mercado bursátil.

También hay modelos predictivos: ANN, LR y BLR. De estos modelos, el ANN es el más usado y el que tiene mayor precisión. El procesamiento para estos modelos se hace

en WEKA, que es una colección de algoritmos de *machine learning*. Para seguir este procesamiento, se tiene una estructura a seguir (ver Figura 11).




Figura 11. Modelo propuesto por Tüfekçi (2016)

Los resultados experimentales mostraron que los rendimientos de predicción de los modelos, que son 64.13 %, 63.09 %, 81.54 % y 100 % para el período de sesiones, diario, semanal, y los conjuntos de datos mensuales, respectivamente, fueron encontrados por MLP.

Wei (2016) menciona que los modelos existentes en la literatura no se pueden aplicar a los conjuntos de datos que no los siguen, esto lo motivó a proponer un modelo basado en lógica difusa que no tiene el problema mencionado anteriormente.

El autor propone un modelo de 6 pasos: Coleccionar datos, Descomponer variables de entrada por EMD, Genera ANFIS, Entrenar sistema de inferencia difusa, Validar conjunto de prueba usando el sistema de predicción y Calcular el RMSE. El modelo es mostrado en la Figura 12.

El primer paso consiste en seleccionar los datos históricos.

El segundo paso consiste en descomponer las variables de entrada en un conjunto finito de IMF's mediante *Empirical Mode Decomposition*, exhibiendo una estable y regular variación.

El tercer paso consiste en generar un sistema ANFIS usando agrupamiento sustractivo a la partición del universo de discurso de las variables de entrada y generando el sistema de inferencia difusa.

El cuarto paso consiste en entrenar los parámetros del sistema de lógica difusa usando el método de mínimo cuadrados y gradiente descendiente.

El quinto paso consiste en validar el modelo mediante los datos de prueba.

Finalmente, el sexto paso consiste en la calculación del criterio de evaluación del modelo, en este caso el RMSE.




Figura 12. Modelo propuesto por Wei (2016)

El autor prueba el modelo en índices bursátiles. El modelo propuesto se muestra superior a otros modelos en término de RMSE. También es evidente que EMD puede revelar los patrones ocultos y tendencias de series de tiempo, lo cual puede efectivamente asistir en la predicción de series de tiempo financieras.

Yang y Lin (2016) menciona un modelo ARIMA (Modelos Autorregresivos Integrados de Medias Móviles) integrado que abarca las series financieras lineales y no lineales. El modelo ARIMA es de los más populares, de ahí su uso, pero con ayuda de las redes neuronales artificiales se logra una mayor exactitud de la predicción. La motivación del autor es que las personas que tranzan con acciones ganan y pierden mucho dinero por culpa del desconocimiento de las acciones de una empresa grande (por ejemplo, Straton).

El enfoque contiene cuatro pasos: (1) usar ARIMA para analizar la parte lineal de la serie de tiempo original; (2) EMD (Modo de descomposición empírica) se utiliza para descomponer la dinámica de la parte no lineal en varios componentes de función de modo intrínseco (IMF) y un componente residual; (3) desarrollar un modelo de SVR (Support Vector Regression) utilizando los FMI anteriores y los componentes residuales como insumos para modelar la parte no lineal, y (4) combinando los resultados de pronóstico del modelo lineal y el modelo no lineal. El modelo propuesto es mostrado en la Figura 13.




Figura 13. Modelo propuesto por Yang y Lin (2016)

Los resultados obtenidos son de 3 tipos, los que se usaron solo el modelo ARIMA, que mostró buenos resultados; los híbridos de ARIMA con SVR, que lograron mejores resultados; y los modelos de pronóstico híbridos que también incluyen EMD (*Empirical mode decomposition*), los cuales obtuvieron los mejores resultados.

El examen de las diferentes proporciones de datos de entrenamiento (60 %, 70 %, 80 % y 90 %) también demostró la solidez del modelo.

Chong et al. (2017) menciona que la habilidad de extraer características de datos e identificar relaciones no lineales ocultas, sin confiar en asunciones econométricas ni del conocimiento experto humano, hace a los modelos de *deep learning* atractivos como una alternativa a los modelos existentes.

Propone un *framework* (ver Figura 14) para trabajar con *deep learning*, donde f es una función predictora, u_t es la representación de las características extraídas de la información disponible en el tiempo t , r_{t+1} retorno de la acción en el tiempo $t+1$ y puede ser descompuesta en 2 partes: la salida predictiva y la parte impredecible, la cual tiene una distribución normal con media cero y varianza beta. La representación u_t puede ser una transformación lineal o no lineal de la información en bruto (R_t). Se define la información al nivel crudo como los pasados retornos de acciones. Donde $r_{i,t}$ denota el retorno de la acción i en el tiempo t .

$$\begin{aligned}
 u_t &= \phi(R_t), \\
 \text{and} \\
 \hat{r}_{t+1} &= f \circ \phi(R_t), \\
 r_{t+1} &= \hat{r}_{t+1} + \gamma, \quad \gamma \sim \mathcal{N}(0, \beta), \\
 R_t &= [r_{1,t}, \dots, r_{1,t-g+1}, \dots, r_{M,t}, \dots, r_{M,t-g+1}]^T \in \mathbb{R}^{Mg}.
 \end{aligned}$$

Figura 14. Framework propuesto por Chong et al. (2017)

Cuando los autores usaron el *framework* en casos de estudios, este no consiguió gran precisión. Una de las razones que dan es que las técnicas de *deep learning* son incipientes, pero que este *framework* podría servir como base para nuevas técnicas de Deep Learning con mayor precisión.

En Göçken et al. (2017), se hace mención de que una de las principales ideas para estudios en acciones de mercado es proveer el mejor resultado de la predicción usando los mínimos relevantes datos de entrada.

Este artículo propone un modelo híbrido basado en una búsqueda armónica para seleccionar las variables de entrada (ver Figura 15).




Figura 15. Modelo propuesto en Göçken et al. (2017)

Lo novedoso del modelo propuesto en este estudio es el hecho del uso de la búsqueda armónica, tanto para la selección de variables como para el ajuste de los parámetros.

Liu y Yeh (2017) habla del comportamiento del mercado de valores (hipótesis del mercado eficiente) y se busca enseñar a una red neuronal este comportamiento para poder modelarlo. Tiene como entradas el valor de mercado y el índice S&P. La motivación del autor es aprovechar las ventajas de mercado eficiente mediante un diseño mixto, ya que él tiene interés sobre la variación del mercado de valores.

El procedimiento para construir el sistema de soporte de decisión de selección de valores se muestra en la figura 16.

Paso 1: Generar combinaciones de ponderación de conceptos de selección de valores con un diseño de mezcla

Paso 2: Simular combinaciones de ponderación de conceptos de selección de valores mediante *backtesting*

Paso 3: Crear y analizar el modelo de predicción de rendimiento con redes neuronales

Paso 4: Buscar la combinación de ponderación óptima de los conceptos de selección de valores a través de la optimización

Paso 5: Validar las combinaciones de ponderación óptima de los conceptos de selección de valores mediante el *backtesting* Los rendimientos empíricos de las combinaciones de ponderación óptima se obtienen realizando un *backtest* a través de los datos históricos del mercado de valores. Estos resultados se pueden utilizar para validar si las combinaciones de ponderación óptimas pueden satisfacer las preferencias de varios inversores, (ver Figura 16). Se obtienen varias salidas considerando los errores (ver Figura 17).




Figura 16. Modelo propuesto por Liu y Yeh (2017)




Figura 17. Salidas del modelo propuesto por Liu y Yeh (2017)

Las conclusiones son las siguientes:

Maximización de las tasas de retorno anualizadas. La tasa de retorno anualizada (12.6 %) obtenida por el modelo de optimización es mayor que la de Standard and Poor's 500 (7.0 %) durante el mismo período.

Maximización de las tasas de retorno en exceso. La tasa de retorno en exceso trimestral (1.5 %) es significativamente (al usar los rendimientos trimestrales de S&P 500 como referencia).

Pan et al. (2017) hace uso del muestreo mixto de datos sin restricciones (MVSM por sus siglas en inglés), debido a que los datos variables independientes de frecuencia mixta usados para las predicciones tienen muchas frecuencias (en días, semanas, meses con un rango de datos mayor al necesario) y esto reduce la precisión de la predicción. La motivación del autor es que al utilizar el muestreo de datos mixto (MIDAS) los datos en la práctica son más realistas, lo cual genera mejores resultados en la previsión.

Las entradas son datos de los precios de la bolsa de junio de 2008 hasta abril de 2015. El proceso para aplicar el MVSM-MIDAS se realiza mediante un proceso y con ayuda de algoritmos genéticos se optimizan estos datos para posteriormente aplicar MVSM (ver Figura 18).




Figura 18. Modelo propuesto en Pan et al. (2017)

Los resultados obtenidos son favorables, ya que, de los 3 casos (t-1, t-2, t-3) tomados para la prueba, varios se asemejan al precio real.

El uso de variables independientes de frecuencia mixta ofrece la oportunidad de utilizar diferentes tipos de información útil relacionada con el índice de precios de las acciones.

Zhang et al. (2017) propone un modelo basado en Ensemble Empirical Mode Decomposition (EEMD) y multidimensional K-Nearest Neighbor Model (MKNN) para predecir simultáneamente los precios de cierre y máximo de las acciones.

El modelo tiene una mayor precisión para predicción de corto tiempo. Este fue usado en el caso de predicción de dos dimensiones del precio de cierre y máximo para cuatro acciones (NAS, S&P500, DJI y STI índice) al mismo tiempo. El resultado indica que el modelo propuesto por los autores tiene una mayor predicción que los métodos de EMD-KNN, KNN y ARIMA.

Se usaron las variables de precio máximo y de cierre como datos de entrada al modelo.

Ahmadi et al. (2018) menciona que los mercados de valores tienen un comportamiento no lineal, donde las redes neuronales artificiales son el método más común en cuanto a la predicción de los precios de las acciones. Sin embargo, las Máquinas de Soporte Vectorial (SVM por sus siglas en inglés) han mostrado mayor precisión. Esto motivó a los autores a proponer un modelo basado en SVM.

El problema que buscan resolver es determinar el momento para comprar o vender acciones. Para resolver este problema, ellos proponen un modelo (ver Figura 19) en el cual se usarán como entrada 2 conjuntos de datos que incluyen los precios mínimos, máximos, de cierre y apertura, los cuales son transformados en indicadores técnicos y, posteriormente, divididos en datos para entrenamiento y prueba, además, como salida el rendimiento del mercado es dado en forma de una señal de compra, venta o no-acción. En este modelo se busca mejorar la precisión de una SVM (a través de encontrar los mejores valores para los parámetros función de costo y desviación estándar), mediante el uso de las metaheurísticas de Algoritmos Genéticos (GA) y Algoritmos Imperialistas Competitivos (ICA). Los algoritmos empleados son mostrados en las Figuras 20 y 21, respectivamente.

Para evaluar el modelo propuesto, se usó como estudio base una red neuronal *feed-forward*, obteniéndose una precisión de 74.2 % del estudio base, así como 76 % y 60 % del modelo propuesto basado en ICA y GA, respectivamente.




Figura 19. Modelo propuesto por Ahmadi et al. (2018)




Figura 20. Optimización de SVM con ICA propuesto en Ahmadi et al. (2018)




Figura 21. Optimización de SVM con ICA propuesto en Ahmadi et al. (2018)

Cheng y Yang (2018) menciona que los modelos existentes en la literatura no se pueden aplicar a los conjuntos de datos que no los siguen. Motivado por esto, propone un modelo basado en sistemas de lógica difusa que no posee el problema anteriormente descrito.

De esta manera, plantea un modelo de 4 fases: Preprocesamiento, Modelamiento, Predicción inicial, Predicción final y Evaluación. El modelo es mostrado en la Figura 22.




Figura 22. Modelo propuesto por Cheng y Yang (2018)

Como conclusión, los autores muestran que el modelo presentado obtiene una mayor precisión que los otros modelos en comparación. Además, plantean que los resultados pudrían proporcionar a los inversores la utilización de toda la información disponible para optimizar sus beneficios.

Duan et al. (2018) menciona que la teoría de ondas de Elliott representa con precisión la forma en que funciona el mercado de valores. Propone demostrar esto aplicándolo al mercado de valores chino, teniendo como entradas índices compuestos de la bolsa desde 3 de diciembre de 2012 hasta el 25 de enero de 2016. Los pasos por seguir para procesar la data empiezan con preparar la data hasta seleccionar el modelo con mayor precisión (ver Figura 23).




Figura 23. Modelo propuesto en Duan et al. (2018)

Ebadati y Mortazavi (2018) menciona que cuando la cantidad de datos de entrada en un modelo basado en redes neuronales aumenta, el tiempo consumido para su entrenamiento aumenta de manera precipitada.

Lo anterior motiva a los autores a proponer un modelo (ver Figura 24) mediante el cual se busca mejorar la precisión de una red neuronal con *back-propagation* (BP-ANN) a través del uso de Algoritmos genéticos para optimizar sus pesos. El modelo propuesto usó como entrada los precios de apertura y como salida los precios de cierre en un día de negocios. Estos precios son normalizados a valores entre [0,1].




Figura 24. Modelo propuesto en Ebadati y Mortazavi (2018)

Como resultado se muestra que el modelo que es propuesto obtiene una mejora de 99.42 % en la precisión y 88.75 % en el consumo de tiempo.

Hu et al. (2018) menciona que los datos de los mercados bursátiles contienen información muy útil, y que para una buena precisión del pronóstico se debe considerar una gran cantidad de información. Los autores son motivados por la gran cantidad de información disponible sobre la bolsa, no solo limitándose a sus datos históricos.

Basado en esto, los autores proponen un modelo (ver Figura 25) donde los datos de entrada son los datos históricos y los datos correspondiente en Google Trend y la salida es el precio de apertura. En este modelo, se usa un Algoritmo seno-coseno (SCA por sus siglas en inglés) mejorado mediante la adición de un cuarto parámetro para optimizar los parámetros de una red neuronal.




Figura 25. Modelo propuesto en Hu et al. (2018)

Como conclusión, los autores muestran que el modelo propuesto mejora entre un 10 y 20 % con respecto a los otros modelos en comparación, así mismo, muestran que usando data de Google Trend se obtiene una mejora de casi 0.2 %.

Lei (2018) menciona que la predicción de los precios de las acciones es una tarea difícil. Para resolver este obstáculo se han usado redes neuronales, sin embargo, estas tienen problemas como la baja precisión, lenta convergencia y la fácil inclinación al mínimo local. Con base en ello, los autores han propuesto el uso de redes neuronales Wavelet, sin embargo, estas también presentan dificultades. Respecto al problema de predicción de los precios de las acciones, menciona que las tendencias de los precios de las acciones tienen

mutabilidad y variabilidad, así mismo, hay una considerable cantidad de información en los datos de tendencia de los precios de las acciones. Lo anteriormente descrito son los problemas que se presentan al usar redes neuronales, lo que motivó al autor a proponer su modelo.

En el modelo propuesto, las entradas son los precios máximos, mínimos, de cierre y apertura, y la salida la tendencia del precio de las acciones (Caída, Estabilidad y Alza). El modelo es mostrado en la Figura 26. Este usa redes artificiales neurales Wavelet y las optimiza mediante el uso de *Rough Set*. RS juega dos roles: reduce la dimensión de entrada de WNN, mediante la eliminación de variables redundantes, y optimiza la estructura de red de WNN, mediante la determinación del número correcto de nodos en la capa oculta y la determinación de los pesos.




Figura 26. Modelo propuesto en Lei (2018)

Como conclusión se tiene que, al comparar el modelo en 5 de los mayores índices bursátiles con otros modelos, el modelo propuesto muestra una mejora con respecto a los

otros y reduce el tiempo de entrenamiento. Además, disminuye el tamaño de la red neuronal, simplifica la estructura de la red y mejora la precisión de la predicción y el tiempo de entrenamiento.

En Malagrino et al. (2018), los autores se sienten motivados por la preferencia de aquellos que confían en los métodos de aprendizaje automático por utilizar únicamente los datos de capacitación del mercado de valores sobre el cual se realizarán predicciones, ignorando las influencias de fuentes externas y basándose en solo unos pocos ejemplos de estudios realizados en diferentes mercados.

Los autores proponen una red bayesiana para predecir la dirección del cierre de índices. En esta red se trata de modelar algunas intuitivas dependencias entre mercados intercontinentales. Se probó con dos modelos: uno con una ventana de 24 horas entre la apertura y cierre de mercados intercontinentales, y otra ventana de 48 horas. Además, en cada modelo se probó con 1,2 y 3 índices por mercado. En la Figura 27, se muestra las redes bayesianas usadas en los modelos descritos por los autores.




Figura 27. Modelo propuesto en Malagrino et al. (2018)

Como conclusión se tiene que el mejor modelo es el que considera una ventana de 24 horas y 1 índice por mercado.

En Xiao et al. (2018), se hace mención que las acciones exhiben características distintas durante diferentes escalas de tiempo debido a los efectos de factores complejos. El análisis de estas características puede ayudar a delinear los mecanismos que determinan el precio de las acciones y mejoran la precisión de la predicción del precio de las acciones. También se indica que los modelos basados en SVM han demostrado ser mejores que otros métodos, de esta manera, integra un modelo de predicción con un método de descomposición.

Los autores proponen un modelo basado en la descomposición de la serie de tiempo de los precios de las acciones usando SSA (Singular Spectrum Analysis) en 3 componentes: tendencia a largo plazo de las acciones (que está determinada por el desarrollo económico de un país), el componente de fluctuación del mercado (que se utiliza principalmente para describir los impactos de importantes eventos económicos o no económicos en el precio de las acciones a medio plazo), y el componente de ruido (que representa principalmente el efecto del ruido en el mercado de valores). Sobre cada uno de los componentes se aplica un modelo de SVM con distintos tipos de núcleos, posteriormente, con los valores predichos obtenidos en cada componente se usa otro modelo basado en SVM para predecir el precio final de la acción. El modelo propuesto por los autores es mostrado en la Figura 28.




Figura 28. Modelo propuesto en Xiao et al. (2018)

Malqui y Fernandez (2018) propone un modelo para predecir el comportamiento de la tasa de cambio de la criptomoneda llamada Bitcoin con respecto al dólar americano.

El modelo propuesto es mostrado en la Figura 29.




Figura 29. Modelo propuesto en Malqui y Fernandez (2018)

Los autores proponen los siguientes pasos:

- Recopilar datos

Se recopila las siguientes variables internas: tipo de cambio de apertura, máximo, mínimo y cierre de Bitcoin, el volumen de operaciones, los costos totales de

transacción, el número de transacciones, el costo por transacción y la tasa de hash promedio.

Además de las siguientes variables externas: los precios del crudo del petróleo, los precios del oro, los índices S&P 500, NASDAQ y DAX.

- Preprocesamiento:

Después de esta etapa, se obtiene un conjunto de dato compuesto de los atributos mostrados en la tabla 6.

Day D	Day ($D = i$)	30-day WMA
Opening price	Price direction	Opening price
Timestamp	Opening price	Maximum price
	Maximum price	Minimum price
	Minimum price	Closing price
	Closing price	Volume of trades
	Volume of trades	Number of txn
	Number of txn	Transaction fees
	Transaction fees	Cost per txn
	Cost per txn	Hash rate avg
	Hash rate avg	Closing crude price
		Closing gold price
		Closing S&P500 price
		Closing Nasdaq price
		Closing DAX price

Tabla 6. Características usadas en Malqui y Fernandez (2018)

- Particionamiento de datos:

Se definieron dos intervalos:

Intervalo 1: 80 % para entrenamiento / 20 % para prueba

Intervalo 2: 75 % para entrenamiento / 25 % para prueba

- Selección de atributos:

Se utilizan las siguientes 5 técnicas de selección de atributos:

- Análisis de correlación
- Técnica de relieve (Relief technique, en inglés)

- Método de ganancia de información
- PCA
- Selección de subconjuntos de características basadas en correlación

Para los cinco selectores, los 20 mejores atributos fueron seleccionados.

- Modelos

Propone 3 ensamblados, tal como se muestra en la Figura 30.




Figura 30. Modelo de predicción propuesto en Malqui y Fernandez (2018)

- Evaluación de modelos
 - Para los modelos de regresión, se usaron las siguientes métricas: MAE, MAPE, RMSE.
 - Para los modelos de clasificación (predicción de la dirección del precio): Área bajo la curva ROC (AUC) y una fórmula de precisión exployada en el artículo.

En cuanto a los experimentos de regresión, el algoritmo SVM obtuvo los mejores resultados para todas las predicciones (máximo, mínimo y precios de cierre) y para ambos intervalos.

Los autores lograron obtener Errores de porcentaje medio absoluto (MAPE)

Kamalov (2020) menciona que en la literatura no existen modelos que predigan cambios significativos en el precio de una acción basado en cambios previos. Motivado por esto, utiliza tres arquitecturas de redes neuronales: Perceptrón Multicapa (MLP), Redes Neuronales Convolucionales (CNN) y Memoria de Corto-Largo plazo (LSTM), tal como se muestra en la Figura 31.

Network	Hidden layer 1	Hidden layer 2
MLP	Dense 64	Dense 32
CNN	Conv1D 64, length 7, dropout rate = 0.2	Dense 32, dropout rate = 0.2
LSTM	LSTM 64 with return sequence, dropout rate = 0.2	LSTM 32, dropout rate = 0.2

Figura 31. Arquitectura propuesta por Kamalov (2020)

Para mostrar la eficacia del modelo propuesto, el autor utiliza como *benchmark* Bosques Aleatorios (Random Forest) e Índice de Fuerza Relativa (RFI), mostrando que los modelos basados en redes neuronales obtienen un mejor AUC que los otros modelos y, en particular, resalta el modelo de LSTM, el cual obtiene AUC de 0.8.

Prabin y Thanabal (2021) mencionan que los modelos presentes en el estado del arte dependen de la calidad de los datos usados y los parámetros óptimos de los modelos. Debido a esto, proponen un modelo dinámico auto reparador llamado RANN que permite evitar la total reconstrucción del modelo para cada predicción, así como ahorrar tiempo.

Como conclusión, los autores mencionan que el modelo propuesto supera a otras arquitecturas basadas en redes neuronales al mostrar menor ratios de error y mayor precisión de la predicción mientras adopta cambios dinámicos.

Staffini (2022) propone un modelo basado en aprendizaje profundo llamado Red Generativa Adversarial Convolutiva Profunda (DCGAN) para predecir el precio de cierre de una acción. La arquitectura del modelo se muestra en la Figura 32. Como variables de entrada de su modelo, el autor propone usar varios indicadores técnicos, así como los precios de cierre, apertura, máximo, mínimo y el volumen de la acción.




Figura 32. Arquitectura propuesta por Staffini (2022)

El autor muestra que, al realizar predicciones de un solo paso (*single-step forecasting*) y de varios pasos (*multi-step forecasting*), su modelo propuesto rinde mejor que los modelos normalmente usados (ARIMA y LSTM).

En Jia et al. (2024), se menciona que pocos artículos toman en consideración variar los grados de dependencia entre los precios adyacentes de una acción cuando se pretende predecir sus valores futuros. Motivados por esto, los autores proponen un nuevo modelo

hibrido (ResNLS), que está compuesta principalmente por dos arquitecturas neuronales: ResNet y LSTM, tal como se muestra en la Figura 33.




Figura 33. Arquitectura propuesta por Jia et al. (2024)

Como conclusión, los autores mencionan que el modelo propuesto supera a los modelos basados en CNN, RNN, LSTM y BiLSTM en términos de precisión de la predicción. También demuestran un mejoramiento sobre el estado del arte de al menos el 20 %.

Lo anterior se resumen en la tabla 7.

Referencia	Descripción
Laboissiers et al. (2015)	Red neuronal y análisis de correlación para predecir el precio máximo y mínimo del día siguiente
Mahji (2015)	Red neuronal de Legendre con algoritmos genéticos (NGSA – II) y optimización de partículas multiobjetivo (MOPSO) para predecir los precios de las acciones
Chiang et al. (2016)	Uso de reglas difusas optimizadas por PSO y el uso de redes neuronales para predecir la tendencia en precio de las acciones y predecir también el precio de las acciones
Li et al. (2016)	Máquina de soporte vectorial (SVM) y Muestreo de datos mixtos (MIDAS) con data histórica para conocer la tendencia en el precio de las acciones para predecir el precio de las acciones
Mirzaei et al. (2016)	MLP (ANN's), LR, BLR, apoyados con algoritmos de machine learning para predecir los precios de las acciones
Prasanna y Ezhilmaran (2016)	Algoritmo a priori mejorado y algoritmo genético modificado para predecir los precios de las acciones
Sadadei et al. (2016)	Lógica difusa (FL) para las series temporales y algoritmo imperialista competitivo (ICA) para la predicción de los precios de las acciones
Túfecki (2016)	Series temporales difusas apoyado con algoritmos evolutivos para predecir los precios de las acciones
Wei (2016)	ANFIS con <i>Empirical Mode Descomposicion</i> y <i>Subtractive Clustering</i> para predecir los índices bursátiles
Yang y Lin (2016)	Modelo autorregresivo integrado de media móvil (ARIMA) combinado, Modo de descomposición empírica (DM) con SVM para predecir los índices bursátiles
Chong et al. (2017)	Framework para el uso de técnicas de Deep learning para la predicción de los precios de las acciones
Göçken et al. (2017)	Modelo híbrido basado en búsqueda armónica para reducción de variables de entrada y optimización de parámetros para predecir los precios de las acciones
Liu y Yeh (2017)	Diseño de mezcla y redes neuronales para su uso en modelos en modelos de toma de decisiones
Pan et al. (2017)	Máquina de soporte vectorial (SVM) y Muestreo de datos mixtos (MIDAS) para predecir los precios de las acciones
Zhang et al. (2017)	Modelo basado en <i>Ensemble Empirical Mode Decomposition</i> (EEMD) y <i>Multidimensional K-Nearest Neighbor Model</i> (MKNN) para predecir los precios máximos y de cierre de las acciones

Ahmadi et al. (2018)	SVM con algoritmos genéticos (GA) y con algoritmo imperial competitivo (ICA) para calcular el tiempo en el cual compro o vendo acciones
Cheng y Yang (2018)	Series de tiempo difusa basadas en <i>Rough Set</i> para predecir los precios de las acciones
Duan et al. (2018)	Teoría de ondas de Elliot y la secuencia gris de Fibonacci para modelar el comportamiento del mercado de valores
Ebadati y Mortazavi (2018)	Red Neuronal con algoritmos genéticos para predecir los precios de las acciones
Hu et al. (2018)	Google Trend como fuente de datos adicional y Red neuronal con SCA mejorado predecir los precios de las acciones
Lei (2018)	Red Neuronal Wavelet con 2 <i>Rough Set</i> para conocer la tendencia en los precios de las acciones
Malagrino et al. (2018)	Redes bayesianas para predecir la tendencia de los índices bursátiles
Malqui y Fernandez (2018)	Modelo de Regresión: Se hace uso de ANN, SVM y RNN, y modelo de Clasificación (Predicción de la dirección del precio): Algoritmos simples (ANN y SVM) y Ensamblados (k-Means, RNN y Árboles de decisión) para predecir el comportamiento de la tasa de cambio de la criptomoneda llamada Bitcoin con respecto al dólar americano.
Xiao et al. (2018)	Modelo híbrido basado en Singular Spectral Analysis y SVM para predecir los precios de las acciones
Kamalov (2020)	Redes neuronales para predecir el retorno diario de acciones
Prabin y Thanabal (2021)	Redes neuronales auto reparables para predecir el precio de cierre de las acciones
Staffini (2022)	Red Generativa Adversarial Convolutiva Profunda para predecir el precio de cierre de las acciones
Jia et al. (2024)	Modelo híbrido basado en ResNet y en LSTM para predecir el precio de las acciones

Tabla 7. Modelos existentes para predecir precios en la Bolsa de Valores

2.11.2. ¿Qué factores afectan la variación de precios en una bolsa de valores?

Con base en los artículos leídos, se elaboró la tabla 8, en donde se muestra las variables que los autores consideraron que son necesarias como variables de entrada para hacer una buena predicción.

Variables	Descripción	Artículos
Cotización del dólar americano	Cantidad en dólares que se necesita para comprar una unidad de moneda extranjera	Laboissiere et al. (2015)
Instrumentos financieros	Datos de los últimos precios de instrumentos financieros como acciones, índices en una Bolsa de Valores	Mahji, B y Anish, C (2015), Li et al. (2016), Túfecksi (2016), Wei (2016), Cheng y Yang (2018), Hu et al. (2018), Duan et al. (2018), Sadadei et al. (2016), Mirzaei et al. (2016), Liu, Y. y Yeh, I (2017), Malqui y Fernandez (2018)
Datos de Google Trend	Google trend es una herramienta de Google que muestra los términos de búsqueda más populares del pasado reciente.	Hu et al. (2018)
Índices bursátiles	Indicador que muestra la variación del precio de un conjunto de activos cotizados que reúnen unas determinadas características	Laboissiere et al. (2015), Yang y Lin (2016), Pan et al. (2017), Chiang et al. (2016)
Indicadores técnicos	Cálculos matemáticos basados en datos históricos de precios, volúmenes, intereses, entre otros	Prabin y Thanabal (2021), Staffini (2022)
Noticias financieras	Artículos noticieros respecto a acciones, empresas, Bolsas o Mercado de Vales	Li et al. (2016)

Precio de apertura	Precio al inicio de una sesión de operaciones en la Bolsa	Laboissiere et al. (2015), Ebadati y Mortazavi (2018), Staffini (2022)
Precio de cierre	Precio al final de una sesión de operaciones en la Bolsa	Laboissiere et al. (2015), Ebadati y Mortazavi (2018), Jia et al. (2024), Prabin y Thanabal (2021), Staffini (2022), Zhang et al. (2017)
Precio máximo diario	Precio más alto que tuvo una acción en una sesión diaria de operaciones en la Bolsa	Laboissiere et al. (2015), Prasanna y Ezhilmaran (2016), Ahmadi et al. (2018), Lei (2018), Staffini (2022), Zhang et al. (2017)
Precio mínimo diario	Precio más bajo que tuvo una acción en una sesión diaria de operaciones en la Bolsa	Ahmadi et al. (2018), Laboissiere et al. (2015), Lei (2018), Prasanna y Ezhilmaran (2016), Staffini (2022),
Precio de oferta	Precio más alto que un comprador está dispuesto a pagar por una acción	Laboissiere et al. (2015)
Precio de demanda	Precio más bajo que un vendedor está dispuesto a pagar por una acción	Laboissiere et al. (2015)
Retorno diario	Cambio porcentual en el precio de una acción	Kamalov (2020)
Volumen diario	Número de acciones totales intercambiadas durante el día	Staffini (2022)

Tabla 8. Variables usadas para predecir precios en la Bolsa de Valores

2.11.3. ¿Qué herramientas existen para predecir los precios?

Con base en los artículos leídos, se elaboró la tabla 9, en donde se muestra las herramientas que los autores usaron para desarrollar sus modelos.

Herramientas	Descripción	Artículos
LIBDVM	Herramienta para desarrollar SVM en Matlab	Li et al. (2016)
Matlab	Herramienta de software matemático	Li et al (2016), Prasanna y Ezhilmaran (2016), Zhang et al. (2017)
Neural Network Toolbox.	Herramienta para desarrollar redes neuronales en Matlab	Laboissiere et al. (2015)
Scikit-learn	Biblioteca de Python de código abierto para el desarrollo de aplicaciones de aprendizaje automático y redes neuronales profundas	Kamalov (2020)
Python	Lenguaje de programación interpretado, de alto nivel y de propósito general que se destaca por su simplicidad y legibilidad	Staffini (2022)
Tensorflow	Biblioteca de código abierto para el desarrollo de aplicaciones de aprendizaje	Kamalov (2020)
WEKA	Plataforma de software para el desarrollo de aplicaciones de aprendizaje automático y la minería de datos (Universidad de Waikato)	Túfecksi (2016)

Tabla 9. Herramientas usadas para predecir precios en la Bolsa de Valores

CAPÍTULO 4: MODELO PROPUESTO

En el presente capítulo, se propone un modelo para la predicción de precios máximos y mínimos del día siguiente de una acción en la Bolsa de Valores. Asimismo, se justifica el modelo y se describen las partes que componen el modelo propuesto.

4.1. MODELO PROPUESTO

El aporte consiste en la implementación de un Modelo de Predicción de Precios Máximos y Mínimos del día siguiente de una acción en la Bolsa de Valores, con el objetivo de poder conocer los Precios Máximos y Mínimos de una acción al día siguiente con el mínimo error posible.

A continuación, se presenta el modelo propuesto (ver Figura 34).




Figura 34. Modelo de predicción propuesto (Elaboración propia)

El modelo se inicia con un componente de **Recopilación de datos**, el cual recopilará datos históricos de las acciones. Subsiguientemente, se calculará algunas características en el

subcomponente de **Cálculo de Características**. Subsiguientemente, en el subcomponente de **Normalización**, se normalizarán los datos obtenidos desde los datos históricos. Dado que no todas las características obtenidas en los pasos anteriores resultarán útiles, estas se reducen a aquellas que se correlacionan más con las variables de salida (precio máximo y mínimo del día siguiente) en el componente de **Selección de Atributos**.

Las características seleccionadas en el paso anterior entran a un modelo **conformado por tres técnicas de *machine learning* (redes neuronales artificiales, bosques aleatorios y regresión de soporte vectorial) y ponderadas mediante una red neuronal**. Este modelo, una vez que haya aprendido de los datos, permitirá conocer el precio máximo y mínimo del día siguiente de una acción dada.

4.2. JUSTIFICACIÓN

El presente modelo se sustenta fundamentalmente en los siguientes puntos:

- De la bibliografía consultada, solo una pequeña cantidad de artículos hablan sobre precios máximos y/o mínimos:
 - Laboissiers (2015) predice los precios máximos y mínimos del día siguiente.
 - Malqui y Fernandez (2018) predice el comportamiento de la tasa de cambio de la criptomoneda llamada Bitcoin con respecto al dólar americano (entre los comportamientos estudiados se encuentran el precio máximo y mínimo).
 - Zhang et al. (2017) predice el precio de cierre y máximo de las acciones.
- Los modelos híbridos han demostrado tener una mayor precisión en la predicción de precios que aquellos que no, según Ahmadi et al. (2018), Ebadati y Mortazavi (2018), Jia et al. (2024), entre otros.

- Los modelos de predicción de precios se componen mayoritariamente de los siguientes componentes: Recopilación de datos, Preprocesamiento de datos, Modelo de Predicción per se, y la Comparación de Resultados. Algunos autores proponen otros componentes: Laboissiers (2015) usa un componente de Selección de Atributos entre el Preprocesamiento de Datos y el Modelo de Predicción per se.
- Malqui y Fernandez (2018) propone un modelo basado en redes neuronales, máquina de soporte vectorial y redes neuronales recurrente, donde la salida del modelo es el que obtiene mejor resultado. En el modelo presentado en este trabajo, en vez de que la salida sea aquella que obtenga mejor resultado, se utiliza otra red neuronal como forma de ponderación entre la salida de las otras técnicas.

4.3. RECOPIACIÓN DE DATOS

En este componente, se seleccionan los datos a utilizar para el modelo de predicción de una o varias fuentes de información. Con base en Laboissiers et al. (2015) y Li et al. (2016), se seleccionan como fuentes de información la acción a predecir, y de esta se obtiene los precios máximos, mínimos, de cierre y apertura de la acción (ver Figura 35).



Figura 35. Recopilación de datos (Elaboración propia)

4.4. PREPROCESAMIENTO DE DATOS

Este componente está basado en Laboissiers et al. (2015), con algunos subcomponentes adicionales. Consta de los siguientes subcomponentes:

- Cálculo de características

No siempre se trabaja con los datos extraídos directamente de las fuentes de información, muchas veces se calculan características mediante estos datos (ver Figura 36). Se calculará las siguientes características.

- Día D: Precio de apertura
- Día D-1: Precio de apertura, precio máximo, precio mínimo, precio de cierre, precio de demanda, precio de oferta
- Media ponderada móvil (WMA) con una ventana de 30 días calendario, de los precios: máximo, mínimo, de apertura y de cierre

La Media Ponderada Móvil es calculada usando la siguiente fórmula:

$$WMA_M = \frac{\sum_{n=1}^M \frac{n \cdot P_n}{M}}{\sum_{n=1}^M \frac{n}{M}}, \text{ donde } P \text{ es una determinada serie de tiempo y } M \text{ es}$$

la ventana de tiempo. En el modelo propuesto, se usará una ventana de 30 días calendario hábiles.




Figura 36. Cálculo de características (Elaboración propia)

- Normalización

Muchos de los datos tendrán rangos diferentes, por lo que se deben normalizar para una mayor precisión del modelo. Se usará la siguiente fórmula para normalizar los valores en un rango de [0,1]:

$$normalización = \frac{P - \min(P)}{\max(P) - \min(P)}, \text{ donde } P \text{ es una determinada serie de tiempo.}$$

4.5. SELECCIÓN DE ATRIBUTOS

Con base en Laboissiers et al. (2015), no todas las características extraídas serán útiles para predecir el precio máximo y mínimo, por lo que se utilizará un análisis de correlación de cada característica con el precio máximo y mínimo para determinar aquellas que son útiles (ver Figura 37).



Figura 37. Selección de atributos (Elaboración propia)

El análisis de correlación se basa en el coeficiente de Pearson, donde aquellos atributos que tienen una mayor correlación con el valor a predecir (coeficiente cercano a 1) son seleccionados.

4.6. MODELO DE PREDICCIÓN

Con base en Malqui y Fernandez (2018), las características seleccionadas entrarán en un modelo compuesto por una red neuronal, una regresión de soporte vectorial (SVR) y un modelo de bosques aleatorios (*Random Forest*), ponderada mediante otra red neuronal (ver Figura 38). El modelo híbrido propuesto usa otra red neuronal para combinar la predicción de los modelos base anteriormente mencionados. En el caso de las redes neuronales, se usará una arquitectura de 3 capas, donde la capa oculta tendrá función de activación tangente hiperbólica y la capa de salida una función de activación lineal.




Figura 38. Módulo de Predicción propuesto (Elaboración propia)

CAPÍTULO 5: SISTEMA DE PREDICCIÓN DE PRECIOS

MÁXIMOS Y MÍNIMOS DEL DÍA SIGUIENTE

En el presente capítulo, se describe lo relacionado con el Sistema desarrollado, incluyendo, pero no limitándose a: Arquitectura, Requisito, Diseño de Base de Datos, etc.

5.1. ARQUITECTURA

La arquitectura planteada se describe a continuación.

Cuenta de los siguientes elementos:

- Interfaz de Usuario: Elemento que interactúa directamente con el usuario. Está desarrollada usando la tecnología Vue.js. Cuenta con las siguientes interfaces:
- Ingreso al sistema
 - Registro de Usuario
 - Búsqueda de acciones
 - Análisis de acción
 - Visualización de predicciones
- Fuentes de Información: Para el desarrollo del modelo de *machine learning* que alimentará con las predicciones a la Interfaz de Usuario, se usaron data de la siguiente fuente de información: *Yahoo Finance*, de esta fuente se extrajeron los siguientes datos: precio máximo, precio mínimo, precio de cierre y precio de apertura. Se usó una biblioteca en Python que actúo como un api de *Yahoo Finance* hacia el modelo propuesto, la biblioteca es *pandas-reader*.

- Base de Datos

Para el desarrollo de la base de datos, se consideró el uso de Base de Datos NoSql, además, se usó la base de datos *MongoDB*.

- Servidor

El modelo de *machine learning* está compuesto de 3 subelementos, el módulo de entrenamiento, el repositorio de archivos y el módulo de predicción. Estos están almacenados en una máquina servidor que ejecuta los módulos de acuerdo con fechas programadas.

- El módulo de entrenamiento consume las fuentes de información y obtiene los valores óptimos para el modelo que son almacenados en el repositorio de archivos.
- El modelo de predicción consume las fuentes de información y el Repositorio de archivos para predecir los precios máximos y mínimos del día siguiente.

En la Figura 39, se plasma la arquitectura propuesta.




Figura 39. Arquitectura del Sistema Propuesto (Elaboración propia)

5.2. REQUISITOS FUNCIONALES Y NO FUNCIONALES

5.2.1. Requisitos Funcionales

- Debe ser una aplicación web.
- Se debe tener un usuario para ingresar al sistema.
- Se debe poder buscar una acción, además, el sistema debe poder listar las acciones relacionadas.
- Se debe poder elegir una de las acciones listada por el sistema.
- Al elegir una acción, se debe mostrar algunos datos:
 - Precios históricos
 - Último precio de cierre
- Mostrar el histórico de las predicciones hechas

5.2.2. Requisitos No Funcionales

- Tiempo de respuesta: Tiempo real
- Error estimado: 1 %

5.3. BASE DE DATOS

Se usó una base de datos no relacional. A continuación, se muestra el diagrama:




Figura 40. Base de Datos del Sistema Propuesto (Elaboración propia)

5.4. METODOLOGÍA

Se usó la metodología Scrum, debido a que esta permite varios desarrollos y correcciones, lo que agiliza el desarrollo de los proyectos.

Inicialmente, se definieron los requisitos que el aplicativo debería cumplir.

Posteriormente, en conjunto con el Product Owner, se definió el Backlog que contenía todas las actividades a realizarse para el desarrollo del aplicativo desde la recopilación de los requisitos hasta las pruebas del aplicativo.

Los roles definidos son mostrados a continuación:

- Scrum Master: Dr. David Mauricio
- Product Owner: Dr. David Mauricio
- Equipo: Sebastián Gabriel Tuesta Gonzales

A continuación, se muestra el Backlog usado:

Actividad	Inicio	Fin	Duración (días)
Planificación de Actividades	14 de julio del 2024	31 de julio del 2024	18
Recopilación de Requisitos del Cliente	01 de agosto del 2024	14 de agosto del 2024	15
Desarrollo de las Interfaces	15 de agosto del 2024	31 de agosto del 2024	15
Recopilación de datos	01 de setiembre del 2024	04 de setiembre del 2024	5
Preprocesamiento	05 de setiembre del 2024	15 de setiembre del 2024	11
Selección de atributos	16 de setiembre del 2024	21 de setiembre del 2024	6
Modelo ML	22 de setiembre del 2024	15 de octubre del 2024	24
Integración	16 de octubre del 2024	31 de octubre del 2024	16
Testeo	1 de noviembre del 2024	20 de noviembre del 2024	21

Tabla 10. Backlog

5.5. DIAGRAMA DE COMPONENTES

Se mostrará el diagrama de componentes de los elementos del sistema desarrollado.

5.5.1. Interfaz de usuario

La interfaz de usuario cuenta con los siguientes componentes:

- Ingreso al Sistema
- Registro de Usuario
- Búsqueda de Acciones
- Análisis de acción y visualización de predicciones
- Consolidación de predicciones

De los anteriores componentes, solo los componentes “Registro de Usuario” y “Consolidación de Predicciones” son visibles para el usuario administrador.

Para acceder a cualquiera de los componentes, el usuario debe acceder primero al componente “Ingreso al Sistema”, asimismo para acceder al componente “Análisis de acción y Visualización de predicciones” se debe acceder primero al componente “Búsqueda de acciones”.

El diagrama de componentes de este elemento del sistema se muestra en la Figura 41 para el Usuario normal y en la Figura 42 para el Usuario administrador.




Figura 41. Diagrama de Componentes de la Interfaz de Usuario para el usuario normal

(Elaboración propia)




Figura 42. Diagrama de Componentes de la Interfaz de Usuario para el usuario administrador (Elaboración propia)

5.5.2. Módulo de entrenamiento

En el módulo de entrenamiento, se plasma casi la totalidad del modelo propuesto en el capítulo anterior. Consta de los siguientes componentes:

- Recopilación de datos
- Preprocesamiento
- Selección de atributos
- Modelo de ML
- Exportación a Repositorio

Una vez que el modelo obtenga los parámetros óptimos para sí, estos se guardan en un repositorio para su posterior lectura, esto se hace con el componente de “Exportación a Repositorio”.

El diagrama de componentes se muestra en la Figura 43.



Figura 43. Diagrama de Componentes del Módulo de Entrenamiento (Elaboración propia)

5.5.3. Módulo de predicción

Una vez obtenido los parámetros óptimos en el módulo de entrenamiento, el módulo de predicción usa estos parámetros óptimos y, con base en la data nueva, realiza la predicción. El diagrama de componentes se muestra en la Figura 44.



Figura 44. Diagrama de Componentes del Módulo de Predicción (Elaboración propia)

5.6. INTEGRACIÓN

- Para el desarrollo de la interfaz de usuario, se usó Vue.js. En la Figura 45, se muestra el código asociado.




Figura 45. Código del frontend (Elaboración propia)

- Para la base de datos, se alojó la base de datos MongoDB en un servidor Linux instalado en una máquina local.
- Los módulos de entrenamiento y validación se ejecutan en un servidor Linux alojado en una máquina local. En la figura 46, se muestra el código asociado.




Figura 46. Código del entrenamiento y validación (Elaboración propia)

- La comunicación entre estos componentes se realiza mediante APIs desarrolladas en Python y Flask.




Figura 47. Código de la API (Elaboración propia)

5.7. LIMITACIONES

- Se debe poseer una conexión a internet.
- Para poder visualizar las interfaces, se debe tener un usuario registrado.
- Tiempo de entrenamiento del modelo propuesto

CAPÍTULO 6: VALIDACIÓN Y PRUEBAS

En este capítulo se desarrolla la validación y pruebas del sistema de predicción de precios máximos y mínimos del día siguiente, descrito en el capítulo previo. Para ellos se definirá los conjuntos de datos, las características seleccionadas, el diseño del entrenamiento y validación de los modelos, la calibración de hiperparámetros y los resultados.

El lenguaje de programación utilizado para la validación es Python.

Para los modelos de machine learning en específico se usaron las siguientes librerías:

- Tensorflow: Para las redes neuronales
- Sklearn: Para las máquinas de vector de soporte y los árboles de decisión

6.1. CONJUNTO DE DATOS

Se ha considerado 3 conjunto de datos: 2 de empresas del sector eléctricos usadas en Laboissiere et al. (2015) y un conjunto de datos sobre el índice de Dow Jones, con el objetivo de probar el modelo propuesto. Para la obtención de estos conjuntos de datos, se usó la plataforma finance.yahoo.com. La tabla 11, describe estos conjuntos de datos con el nombre de la compañía, el identificador en el mercado bursátil (ticker), el periodo usado para obtener los datos, la cantidad de registros y las características iniciales (precio mínimo, máximo, cierre y apertura).

Compañía	Ticker	Periodo	Cantidad de Registros	Características
Compañía Energética de Río Grande Norte – COSERN	CSRN3.SA	1/Ene/2008 – 30/Set/2013	1261	4
Compañía Energética CPFL ENERGIAON	CPFE3.SA	1/Ene/2008 – 30/Set/2013	1410	4
Índice Dow Jones	^DJI	3/Dic/2018 - 31/Ago/2024	1440	4

Tabla 11. Descripción de los conjuntos de datos (Elaboración propia)

6.2. CARACTERÍSTICAS SELECCIONADAS

Para cada conjunto de datos se generan las características adicionales (ver sección 4.4) y luego se normalizan los datos. A continuación, se determina el coeficiente de correlación de Pearson por cada características y conjunto de datos usando la librería sklearn de Python. El valor de este coeficiente se muestra en la Tabla 12.

Ticker	Valor por predecir	Características	Coeficiente de Pearson
CSRN3.SA	Mínimo	Precio de Apertura	0.9992
		Precio máximo del día anterior	0.9913
		Precio mínimo del día anterior	0.9921
		Precio de cierre del día anterior	0.9911
		Precio de apertura del día anterior	0.9921
		WMA30-Low	0.5111
		WMA30-High	0.5077
		WMA30-Open	0.5099
		WMA30-Close	0.5072
	Máximo	Precio de Apertura	0.9982
		Precio máximo del día anterior	0.9934
		Precio mínimo del día anterior	0.9907
		Precio de cierre del día anterior	0.9928
		Precio de apertura del día anterior	0.9913
		WMA30-Low	0.5076
		WMA30-High	0.5042
		WMA30-Open	0.5064
		WMA30-Close	0.5035
CPFE3.SA	Mínimo	Precio de Apertura	0.9989
		Precio máximo del día anterior	0.9976
		Precio mínimo del día anterior	0.9981
		Precio de cierre del día anterior	0.9986
		Precio de apertura del día anterior	0.9968
		WMA30-Low	0.8343
		WMA30-High	0.8229
		WMA30-Open	0.8291
		WMA30-Close	0.8301
	Máximo	Precio de Apertura	0.9990
		Precio máximo del día anterior	0.9983
		Precio mínimo del día anterior	0.9977
		Precio de cierre del día anterior	0.9988
		Precio de apertura del día anterior	0.9969
		WMA30-Low	0.8406

		WMA30-High	0.8295
		WMA30-Open	0.8355
		WMA30-Close	0.8364
^DJI	Máximo	Precio de Apertura	0.9990
		Precio máximo del día anterior	0.9968
		Precio mínimo del día anterior	0.9978
		Precio de cierre del día anterior	0.9980
		Precio de apertura del día anterior	0.9963
		WMA30-Low	0.5278
		WMA30-High	0.5429
		WMA30-Open	0.5352
		WMA30-Close	0.5352
	Mínimo	Precio de Apertura	0.9993
		Precio máximo del día anterior	0.9981
		Precio mínimo del día anterior	0.9976
		Precio de cierre del día anterior	0.9985
		Precio de apertura del día anterior	0.9971
		WMA30-Low	0.5376
		WMA30-High	0.5526
		WMA30-Open	0.5449
		WMA30-Close	0.5449

Tabla 12. Coeficiente de Pearson de las características de cada conjunto de datos (Elaboración propia)

A partir de los resultados de la Tabla 12, se han seleccionado las características que presentan una correlación de Pearson muy fuerte (0.9-1.0). Estas características coinciden para los 3 conjuntos de datos, tanto para la predicción del precio mínimo y máximo, y son mostradas en la Tabla 13.

Características Seleccionadas
Precio de Apertura
Precio máximo del día anterior
Precio mínimo del día anterior
Precio de cierre del día anterior
Precio de apertura del día anterior

Tabla 13. Características Seleccionadas (Elaboración propia)

6.3. DISEÑO DE ENTRENAMIENTO Y VALIDACIÓN

Los conjuntos de datos son divididos en 3 conjuntos: conjunto de entrenamiento, validación y de pruebas. Para el primero se seleccionaron el 80%, para el segundo 10% y para el tercero el 10%.

La calibración de los hiperparámetros se realizó usando en consideración la técnica llamada "validación de avance progresivo" tal como se describe en Wang et al., (2024). Esta técnica consiste en mantener el tamaño del conjunto de entrenamiento fijo, desplazándose un ejemplo en cada iteración. La división del conjunto de datos ejecutado con esta técnica se muestra en la Figura 48.




Figura 48. Validación de avance progresivo (Elaboración propia)

Además, para la comparación de la eficiencia de los modelos, se usará el Error Porcentual Absoluto Medio (MAPE), cuya fórmula es mostrada a continuación:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{Real_i - Pronóstico_i}{Real_i}$$

Al momento de usar el MAPE, se desnormalizan los valores reales y pronosticados, lo que permite evitar problemas cuando el valor real normalizado es igual a 0, esto último debido a que el valor real puede ser el valor mínimo del conjunto de datos normalizado.

6.4. CALIBRACIÓN DE HIPERPARÁMETROS

Para obtener mejores resultados se han calibrado los modelos singulares y el modelo híbrido RNA, considerando los hiperparámetros que se muestran en la tabla 14 y los conjuntos de datos de entrenamiento y validación.

Modelo	Hiperparámetros	Valor
Regresión de Soporte Vectorial (SVR)	Gamma	0.1,0.2,0.3,0.4,0.5
	Épsilon	0.1, 0.2, 0.3, 0.4, 0.5
	C	1, 2, 3, 4, 5, 6, 7, 8, 9, 10
	Núcleo	Polinomial grado 1, Polinomial grado 2, Polinomial grado 3, Lineal, Sigmoide, Rbf.
Redes Neuronales Artificiales (RNA)	Épocas	250
	Número de capas ocultas	1
	Neuronas en la(s) capa(s) oculta(s)	5,10,15,20
	Regularización	Early Stopping (paciencia = 10)
Bosques aleatorios (RF)	Número de árboles	10,20,30,40,50,100
Modelo híbrido RNA	Épocas	250
	Número de capas ocultas	1,2,3
	Neuronas en la(s) capa(s) oculta(s)	3
	Regularización	Early Stopping (paciencia = 10)

Tabla 14. Hiperparámetros usados para la calibración de los modelos

(Elaboración propia)

Luego del proceso de calibración, se obtuvieron los mejores valores de los hiperparámetros los cuales se presentan para cada conjunto de datos y para cada modelo en la Tabla 15.

Conjunto de datos	Modelo	Hiperparámetros
CSRN3 – Precio Mínimo	SVR	Núcleo= Polinomial grado 1. C= 9. Épsilon = 0.1. Gamma = 0.3.
	RNA	Épocas= 250. Neuronas en la capa oculta= 5.
	RF	Árboles= 30
	Híbrido RNA	Épocas = 250. Capas ocultas = 2. Neuronas en la capa oculta = 3
CSRN3 – Precio Máximo	SVR	Núcleo= Sigmoide. C = 5. Épsilon = 0.1. Gamma = 0.1
	RNA	Épocas = 250. Neuronas en la capa oculta = 5
	RF	Árboles =100
	Híbrido RNA	Épocas = 250. Capas ocultas = 2. Neuronas en la capa oculta = 3
CPFE3 – Precio Mínimo	SVR	Núcleo= Sigmoide. C = 5. Épsilon = 0.1. Gamma = 0.1
	RNA	Épocas = 250. Neuronas en la capa oculta = 5
	RF	Árboles =100
	Híbrido RNA	Épocas = 250. Capas ocultas = 1. Neuronas en la capa oculta = 3
CPFE3 – Precio Máximo	SVR	Núcleo = Rbf. C = 2 Épsilon = 0.1. Gamma = 0.1
	RNA	Épocas = 250, Neuronas en la capa oculta = 5
	RF	Árboles = 100
	Híbrido RNA	Épocas = 250. Capas ocultas = 1. Neuronas en la capa oculta = 3
Índice Dow Jones – Precio Mínimo	SVR	Núcleo = Polinomial grado 2. C = 8 Épsilon = 0.1. Gamma = 0.1
	RNA	Épocas = 250, Neuronas en la capa oculta = 15
	RF	Árboles = 80
	Híbrido RNA	Épocas = 250. Capas ocultas = 1. Neuronas en la capa oculta = 3
	SVR	Núcleo = Polinomial grado 2. C = 2 Épsilon = 0.1. Gamma = 0.1

Índice Dow Jones – Precio Máximo	RNA	Épocas = 250. Neuronas en la capa oculta = 20
	RF	Árboles = 80
	Híbrido RNA	Épocas = 250. Capas ocultas = 1. Neuronas en la capa oculta = 3

Tabla 15. Hiperparámetros calibrados para cada conjunto de datos y cada modelo (Elaboración propia)

Además de los modelos híbridos RNA se han considerado los modelos híbridos dados por la media ponderada de los precios estimados obtenidos por los modelos singulares y, la media ponderada con varianza de los precios estimados obtenido por los modelos singulares. Estos modelos se definen como sigue:

Modelo híbrido de media ponderada:

$$P_{min} = w_A * P_A + w_B * P_B + w_C * P_C \quad (1)$$

Donde:

P_A es el precio predicho por el modelo A,

P_B es el precio predicho por el modelo B,

P_C es el precio predicho por el modelo C,

x, y, z son la precisión de los modelos A, B y C.

$$w_A = \frac{x}{x+y+z}, w_B = \frac{y}{x+y+z}, w_C = \frac{z}{x+y+z}$$

Modelo híbrido de media ponderada con varianza:

$$P_{min} = w_A * P_A + w_B * P_B + w_C * P_C \quad (2)$$

Donde:

P_A es el precio predicho por el modelo A,

P_B es el precio predicho por el modelo B,

P_C es el precio predicho por el modelo C,

x, y, z son las precisiones de los modelos A, B y C.

v_A, v_B, v_C son las varianzas de los modelos A, B y C.

$$w_A = \frac{\frac{x}{v_A}}{\frac{x}{v_A} + \frac{y}{v_B} + \frac{z}{v_C}}, w_B = \frac{\frac{y}{v_B}}{\frac{x}{v_A} + \frac{y}{v_B} + \frac{z}{v_C}}, w_C = \frac{\frac{z}{v_C}}{\frac{x}{v_A} + \frac{y}{v_B} + \frac{z}{v_C}}$$

6.5. RESULTADOS DE PRUEBAS

A continuación, se muestran los resultados de los modelos singulares e híbridos propuestos para la predicción del precio mínimo y máximo con los datos de prueba para los 3 conjunto de datos.

La Tabla 16 muestra los resultados del MAPE para la predicción del precio mínimo y máximo de los datos de prueba de los conjuntos de datos CSRN3, CPFE3 e Índice Dow Jones, para los 3 modelos singulares.

Conjunto de datos	Precio	MAPE		
		SVR	RNA	RF
CSRN3	Mínimo	0.971	0.248	0.041
	Máximo	0.675	0.181	0.0495
CPFE3	Mínimo	1.422	0.746	0.864
	Máximo	1.011	0.747	0.754
Índice Dow Jones	Mínimo	4.332	0.3695	0.437
	Máximo	2.738	0.328	0.4001

Tabla 16. MAPE de la predicción de los modelos singulares para el precio mínimo y máximo de CSRN3, CPFE3 e Índice Dow Jones
(Elaboración propia)

De la Tabla 16 se observa lo siguiente:

- Para el conjunto de datos CSRN3 el mejor modelo es RF, el cual obtiene un MAPE para el precio mínimo de 0.041 y para el precio máximo de 0.0495.

- Para el conjunto de datos CPFE3 el mejor modelo es RNA, el cual obtiene un MAPE para el precio mínimo de 0.746 y para el precio máximo de 0.747.
- Para el conjunto de datos Índice Dow Jones el mejor modelo es RNA, el cual obtiene un MAPE para el precio mínimo de 0.3695 y para el precio máximo de 0.328.

La Tabla 17 presenta los resultados del MAPE de la predicción de los 5 modelos híbridos propuestos para el precio mínimo y máximo, para los tres conjuntos de datos de prueba.

Modelos híbridos	CSR3		CPFE3		Dow Jones	
	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo
RNA de 1 capa con 3 nodos	0.224	0.197	0.937	0.834	0.474	0.439
RNA de 2 capas con 3 nodos	0.178	0.177	0.943	0.858	0.513	0.494
RNA de 3 capas con 3 nodos	0.237	0.267	0.979	0.881	0.559	0.524
Media ponderada	0.342	0.252	0.860	0.706	24.662	23.843
Media ponderada con varianza	0.125	0.174	0.791	0.693	0.351	0.339

Tabla 17. MAPE de la predicción de los modelos híbridos para el precio mínimo y máximo de CSR3, CPFE3 e Índice Dow Jones
(Elaboración propia)

De la Tabla 17 se observa lo siguiente:

- El modelo híbrido de media ponderada con varianza presenta mejores resultados del MAPE que los otros modelos híbridos para los datos de prueba de los 3 conjuntos de datos analizados.
- El modelo híbrido de media ponderada con varianza presenta mejores resultados del MAPE para el precio máximo de los datos de prueba del conjunto de datos CPFE3 y el precio mínimo del índice Dow Jones comparado con los 3 modelos singulares. Sin embargo, es superado ligeramente (no mayor al 5.7%) por el modelo RNA para el precio máximo del índice Dow Jones y el precio mínimo del CPFE3.
- El modelo híbrido RNA presentó sus mejores resultados del MAPE para una arquitectura de 1 capa y fue empeorando gradualmente cuando se llegó a 3 capas.
- Los resultados del modelo híbrido de medias ponderadas presentan peores valores que el modelo híbrido de medias ponderadas con varianza, ello se explica por la

dispersión de los resultados de los modelos singulares, que es corregido por los pesos que incluyen esta dispersión en el modelo híbrido de medias ponderadas con varianza.

En las Figuras 49, 50, 51, 52, 53 y 54, se muestran gráficamente los resultados obtenidos por el modelo híbrido de media ponderada con varianza.




Figura 49. Resultados del modelo híbrido de media ponderada con varianza para CSRN3 (precio mínimo)




Figura 50. Resultados del modelo híbrido de media ponderada con varianza para CSRN3 (precio máximo)



Figura 51. Resultados del modelo híbrido de media ponderada con varianza para CPFE3 (precio mínimo)




Figura 52. Resultados del modelo híbrido de media ponderada con varianza para CPFE3 (precio máximo)




Figura 53. Resultados del modelo híbrido de media ponderada con varianza para Dow Jones (precio mínimo)




Figura 54. Resultados del modelo híbrido de media ponderada con varianza para Dow Jones (precio máximo)

Los resultados obtenidos demuestran que el modelo híbrido de media ponderada con varianza obtiene mejores resultados que los mostrados en el estado del arte (ver Capítulo

3) para los 2 conjunto de datos CSRN3 y CPFE3. En el experimento adicional usando el índice Dow Jones, el resultado obtenido por el modelo híbrido muestra resultados favorables al mostrar un MAPE de 0.351 para el precio mínimo y 0.339 para el precio máximo.

CAPÍTULO 7: CONCLUSIONES Y TRABAJOS FUTUROS

7.1. CONCLUSIONES

- Se implementó una herramienta utilizando técnicas un modelo híbrido de inteligencia artificial basado en las siguientes técnicas: redes neuronales artificiales, regresión de soporte vectorial y bosques aleatorios, que mediante un proceso de entrenamiento y validación permite predecir el precio máximo y mínimo diario de una acción con un MAPE de 0.125 para el precio mínimo y 0.174 para el precio máximo de para el conjunto de datos CSRN3, un MAPE de 0.791 para el precio mínimo y 0.693 para el precio máximo de para el conjunto de datos CPFE3, y un MAPE de 0.351 para el precio mínimo y 0.339 para el precio máximo para el conjunto de datos ^DJI.
- No se han encontrado amplios estudios del precio máximo y mínimo, apenas unos cuantos. Esto ha motivado la realización de esta investigación. Se identificaron todas las técnicas de inteligencia artificial que fueron usadas en la revisión de la literatura, las cuales se enfocaban en el problema de predicción del precio y se observó que la mayoría de los trabajos realizaban comparaciones de una técnica con otra técnica, mas no generaban modelos híbridos que en algunos casos daban mejores resultados.
- En este trabajo se desarrolló un Sistema Inteligente basado en un modelo híbrido que se puede aplicar en diferentes escenarios, además, muestra un error (MAPE) menor a 1 en todos los experimentos realizados.
- El modelo propuesto fue comparado con 2 acciones del estado del arte, obteniendo en ambos mejor resultados.

7.2. TRABAJOS FUTUROS

- Complementar el trabajo realizado desarrollando un sistema inteligente que determine, con base en el precio predicho del sistema propuesto, cuántas acciones comprar o vender en un momento dado.
- Incluir otras variables, por ejemplo, las noticias u otros indicadores técnicos.

ANEXO A: MANUAL DE USUARIO

1.1. ESTRUCTURA GENERAL DEL SISTEMA

La aplicación cuenta con las siguientes interfaces:

Para el aplicativo, se consideraron dos roles: Administrador y Usuario. Para el rol Administrador, se consideró que solo puede haber uno, mientras que para el rol Usuario el número es indistinto. Se consideraron las siguientes interfaces:

- Ingreso al Sistema
- Creación Usuario
- Búsqueda de Acciones
- Análisis de la Acción
- Visualización de Predicciones Totales

1.1.1. Ingreso al sistema

Esta es la interfaz que se muestra al usuario, al momento de ingresar a la página web.

Para poder ingresar, el usuario debe ingresar un usuario y contraseña válida. Dependiendo del usuario ingresado, la persona podrá tener uno de los dos perfiles.

En la figura 55, se muestra la interfaz.



Figura 55. Ingreso al Sistema (Elaboración propia)

1.1.2. Creación de usuario

A esta interfaz se accede ingresando como usuario Administrador. En el encabezado de la interfaz, se mostrará la opción “Crear usuario”, tal como se muestra en la figura 56.




Figura 56. Creación de usuario – I (Elaboración propia)

Una vez que se hace *click* en la opción “CREA USUARIO”, se mostrará una interfaz, tal como se muestra en la figura 57. Esta opción solo permite la creación de usuario con rol de Usuario.



Figura 57. Creación de usuario – II (Elaboración propia)

En caso de querer volver a la interfaz de “Ingreso al Sistema”, se debe hacer *click* en el enlace “SALIR”.

1.1.3. Búsqueda de acciones

Esta interfaz es accesible por ambos roles.

Esta es la interfaz que se muestra al ingresar cualquier usuario con cualquier rol.

Aquí se busca el nombre de una acción (debido a que una acción es identificada con un código, conocido como *Ticker*), una vez identificada, se da *click* sobre el botón “Ir” y se irá a la interfaz de Análisis de la Acción.

En la figura 58, se muestra la interfaz.




Figura 58. Búsqueda de Acciones (Elaboración propia)

1.1.4. Análisis de la acción y visualización de predicciones

Esta interfaz es accesible por ambos roles.

Cada acción tiene su propia versión de esta interfaz.

- Los precios mínimo, máximo, de apertura y de cierre para último día bursátil cerrado
- Una gráfica de los precios máximos, mínimos, de cierre y de apertura de los últimos 30 días

- Un botón para añadir la acción analizada al proceso que predice las acciones, solo si esa acción no está dentro del proceso para el usuario en cuestión.
- Los precios mínimo y máximo predichos para el día bursátil actual, solo si esa acción está dentro del proceso para el usuario en cuestión.
- Un histórico de los precios máximos y mínimos predichos de los últimos 4 días, solo si esa acción está dentro del proceso para el usuario en cuestión.

En la Figura 59, se muestra la interfaz.





Figura 59. Análisis de la Acción y visualización de las predicciones (Elaboración propia)

1.1.5. Consolidación de predicciones

Esta interfaz es accesible solo por el rol *Administrador*.

En esta interfaz, se visualizan todas las acciones predichas, así como las predicciones de los últimos 4 días.

En la figura 60, se muestra la interfaz.



The screenshot shows a web application titled "FINANCIAL FORECASTING APP" with a header bar containing "ADMINISTRADOR" and "SALIR" buttons. Below the header, a table displays stock price data for "Alphabet Inc. (GOOG)". The table has five columns: "Fecha", "Precio Máximo Real", "Precio Máximo Predicho", "Precio Mínimo Real", and "Precio Mínimo Predicho". The data rows show dates from 2019-06-25 to 2019-07-01, with corresponding real and predicted price ranges.

Fecha	Precio Máximo Real	Precio Máximo Predicho	Precio Mínimo Real	Precio Mínimo Predicho
2019-06-25	1114.35	1130.669	1083.8	1103.4318
2019-06-26	1092.97	1099.3389	1072.24	1059.4529
2019-06-27	1087.1	1094.3115	1073.29	1059.4536
2019-06-28	1081	1095.61	1073.37	1059.4507
2019-07-01	1107.55	1100.0957	1093.7	1094.2834

Figura 60. Consolidación de Predicciones (Elaboración propia)

1.2. ACCESOS

- Para acceder a la herramienta, se debe utilizar el siguiente enlace:
<http://localhost:8080/ForecastingFrontend/#/login>
- El usuario administrador es el siguiente:
 - Usuario: admin
 - Contraseña: pwd

REFERENCIAS

- Ahmadi et al. (2018).** Ahmadi, E., Jasemi, M., Monplaisir, L., Nabavi, M. A., Mahmoodi, A., & Amini Jam, P. (2018). New efficient hybrid candlestick technical analysis model for stock market timing on the basis of the Support Vector Machine and Heuristic Algorithms of Imperialist Competition and Genetic. *Expert Systems with Applications*, 94, 21–31. doi: 10.1016/j.eswa.2017.10.023
- Awad (2015).** Awad, M., Khanna, R. (2015). Support Vector Machines for Classification. In: *Efficient Learning Machines*. Apress, Berkeley, CA. doi: 10.1007/978-1-4302-5990-9_3.
- BBC Mundo (2011).** BBC Mundo (2011). ¿Cómo funcionan las bolsas? https://www.bbc.com/mundo/noticias/2011/08/110805_como_funcionan_las_bolsas. Accedido el 9 de setiembre del 2024.
- Bryndin, E. (2019).** Collaboration robots with artificial intelligence (AI) as digital doubles of person for communication in public life and space. *Budapest International Research in Exact Sciences (BirEx-Journal)*, 1(4), 1–11. <https://doi.org/10.33258/birex.v1i4.473>
- Capital (2024).** Capital (2024). The largest stock exchanges in the world. <https://capital.com/markets/shares/largest-stock-exchanges>. Accedido el 9 de setiembre del 2024.

- Cheng y Yang (2018).** Cheng, C.-H., & Yang, J.-H. (2018). Fuzzy time-series model based on rough set rule induction for forecasting stock price. *Neurocomputing*, 302, 33–45. doi: 10.1016/j.neucom.2018.04.014
- Chiang et al. (2016).** Chiang, W.-C., Enke, D., Wu, T., & Wang, R. (2016). An adaptive stock index trading decision support system. *Expert Systems with Applications*, 59, 195–207. doi: 10.1016/j.eswa.2016.04.025
- Chong et al. (2017).** Chong, E., Han, C., & Park, F. C. (2017). Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83, 187–205. doi: 10.1016/j.eswa.2017.04.030
- Deb et al. (2017). Deb C., Zhang F., Yang J., Lee S.E., Shah K.W. A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74 (2017), pp. 902-924. Doi: <https://doi.org/10.1016/j.rser.2017.02.085>
- Duan et al. (2018).** Duan, H., Xiao, X., Yang, J., & Zeng, B (2018). Elliott wave theory and the Fibonacci sequence-gray model and their application in Chinese stock market. doi: 10.3233/JIFS-17108
- Ebadati y Mortazavi (2018).** Ebadati, EOM; Mortazavi, TM (2018). An efficient hybrid machine learning method for time series stock market forecasting.

Forbes (2024). Forbes.com (2024). The World's Billionaires.

<https://www.forbes.com/billionaires/list/>. Accedido el 9 de setiembre del 2024.

Gagandeep (2014). Gagandeep Kaur, CFA (2014). Evolution of stock markets and role of stock exchange. International Journal of Commerce, Business and Management, Vol. 3, No 4. ISSN: 2319-2828.

Gareth et al (2013). Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani. (2013). An introduction to statistical learning: with applications in R. New York: Springer

Göçken et al. (2017). Göçken, M., Özçalıcı, M., Boru, A., & Dosdoğru, A. T. (2017). Stock price prediction using hybrid soft computing models incorporating parameter tuning and input variable selection. Neural Computing and Applications. Doi:10.1007/s00521-017-3089-2

Hu et al. (2018). 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. doi: 10.1016/j.neucom.2018.01.038

- Jain y Mark (2018).** Jain, Shubham; Mark, Kain (2018). Prediction for Stock Marketing using Machine Learning. International Journal on Recent and Innovation Trends in Computing and Communication, Vol. 6, Issue 4. ISSN: 2321-8169 131-135
- Jia et al. (2024).** Jia, Y., Anaissi, A., & Suleiman, B. (2024). ResNLS: An improved model for stock price forecasting. Computational Intelligence, 40(1), e12608. <https://doi.org/10.1111/coin.12608>
- Joachims, T. (1998).** Joachims, T. (1998). Making large-scale SVM learning practical. Technical Reports, SFB 475, 28, 41–57. https://www.cs.cornell.edu/people/tj/publications/joachims_99a.pdf
- Kamalov (2020).** Kamalov, F. Forecasting significant stock price changes using neural networks. Neural Comput & Applic 32, 17655–17667 (2020). <https://doi.org/10.1007/s00521-020-04942-3>
- Kitchenham y Chartes (2007).** Kitchenham, B.A.; Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering version 2.3. http://www.elsevier.com/_data/promis_misc/525444systematicreviewsguide.pdf. Consultado el 1 de diciembre del 2018.
- Laboissiere et al. (2015).** Laboissiere, L. A., Fernandes, R. A. S., & Lage, G. G. (2015). Maximum and minimum stock price forecasting of Brazilian power

distribution companies based on artificial neural networks. *Applied Soft Computing*, 35, 66–74. doi: 10.1016/j.asoc.2015.06.005

Lei (2018). Lei, L. (2018). Wavelet Neural Network Prediction Method of Stock Price Trend Based on Rough Set Attribute Reduction. *Applied Soft Computing*, 62, 923–932. doi: 10.1016/j.asoc.2017.09.029

Li et al. (2016). Li, X., Xie, H., Wang, R., Cai, Y., Cao, J., Wang, F., Min H., Deng, X. (2016). Empirical analysis: stock market prediction via extreme learning machine. *Neural Computing and Applications*, 27(1), 67–78. doi: 10.1007/s00521-014-1550-z

Liu y Yeh (2017). Liu, Y.-C & Yeh, I.-C. (2017). Using mixture design and neural networks to build stock selection decision support systems. *Neural Computing and Applications*, 28(3), 521–535. doi: 10.1007/s00521-015-2090-x

Mahji y Anish (2015). Majhi, B., & Anish, C. M. (2015). Multiobjective optimization based adaptive models with fuzzy decision making for stock market forecasting. *Neurocomputing*, 167, 502–511. doi: 10.1016/j.neucom.2015.04.044

Malagrino et al. (2018). Malagrino, L. S., Roman, N. T., & Monteiro, A. M. (2018). Forecasting stock market index daily direction: A Bayesian Network approach. *Expert Systems with Applications*, 105, 11–22. doi: 10.1016/j.eswa.2018.03.039

Malqui y Fernandez (2018). Mallqui, D. C. A., & Fernandes, R. A. S. (2018).

Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing*. doi: 10.1016/j.asoc.2018.11.038

Mirzaei et al. (2016). Mirzaei Talarposhti, F., Javedani Sadaei, H., Enayatifar, R.,

Gadelha Guimarães, F., Mahmud, M., & Eslami, T. (2016). Stock market forecasting by using a hybrid model of exponential fuzzy time series. *International Journal of Approximate Reasoning*, 70, 79–98. doi: 10.1016/j.ijar.2015.12.011

O' Connell (2018, 9 octubre). O'Connell, Brian (2018). What Was Black Monday and

What Has Changed Since Then? <https://www.thestreet.com/politics/black-monday-1987-14738772>. Accedido el 9 de setiembre del 2024.

Pan et al. (2017). Pan, Y., Xiao, Z., Wang, X., & Yang, D. (2017). A multiple support

vector machine approach to stock index forecasting with mixed frequency sampling. *Knowledge-Based Systems*, 122, 90–102. doi: 10.1016/j.knosys.2017.01.033

Pearson (2008). (2008). Pearson's Correlation Coefficient. In: Kirch, W. (eds)

Encyclopedia of Public Health. Springer, Dordrecht.
https://doi.org/10.1007/978-1-4020-5614-7_2569

Prabin y Thanabal (2021). Prabin, S. & Thanabal, M. (2021). A Repairing Artificial Neural Network Model-Based Stock Price Prediction. *International Journal of Computational Intelligence Systems*. 14. 10.2991/ijcis.d.210409.002.

Prasanna y Ezhilmaran (2016). Prasanna, S., & Ezhilmaran, D. (2016). Association rule mining using enhanced apriori with modified GA for stock prediction. *International Journal of Data Mining, Modelling and Management*, 8(2), 195. doi: 10.1504/ijdm.2016.077162

Quinlan, J. R. (1986). Quinlan, J. R. (1986). Induction of decision trees. *Machine Learning*, 1(1), 81–106. <https://doi.org/10.1007/BF00116251>

Sadadei et al. (2016). Sadaei, H. J., Enayatifar, R., Lee, M. H., & Mahmud, M. (2016). A hybrid model based on differential fuzzy logic relationships and imperialist competitive algorithm for stock market forecasting. *Applied Soft Computing*, 40, 132–149. doi: 10.1016/j.asoc.2015.11.026

Smola y Schölkopf (2004). Smola, A.J., Schölkopf, B. A tutorial on support vector regression. *Statistics and Computing* 14, 199–222 (2004). <https://doi.org/10.1023/B:STCO.0000035301.49549.88>

Staffini (2022). Staffini, A. (2022). Stock Price Forecasting by a Deep Convolutional Generative Adversarial Network. *Frontiers in Artificial Intelligence*, 5, 837596. <https://doi.org/10.3389/frai.2022.837596>

Tin Kam Ho (1995). Tin Kam Ho (1995). Random decision forests. Proceedings of 3rd International Conference on Document Analysis and Recognition, Montreal, QC, Canada, 1995, pp. 278-282 vol.1, doi: 10.1109/ICDAR.1995.598994.

Tin Kam Ho (1998). Tin Kam Ho (1998). The Random Subspace Method for Constructing Decision Forests. IEEE Trans. Pattern Anal. Mach. Intell., 20, 832-844.

Túfekcsi (2016). Pinar Túfekci (2016). Classification-based prediction models for stock price index movement. Intelligent Data Analysis, 20(2), 357–376. doi: 10.3233/ida-160809

Uddin et al (2019). Uddin, S., Khan, A., Hossain, M. E., & Moni, M. A. (2019). Comparing different supervised machine learning algorithms for disease prediction. BMC Medical Informatics and Decision Making, 19(1), 281. <https://doi.org/10.1186/s12911-019-1004-8>

Van Leeuwen (2004). Van Leeuwen, J. (2004). Approaches in Machine Learning. In: Verhaegh, W.F.J., Aarts, E., Korst, J. (eds) Algorithms in Ambient Intelligence. Philips Research, vol 2. Springer, Dordrecht. https://doi.org/10.1007/978-94-017-0703-9_8

Vegas et al. (2017). P. Vegas, P. Calvo, V. Varó (2017). Lunes negro de 1987: El parque de Wall Street hizo “Crash”. <https://www.eleconomistaamerica.com/mercados->

cotizaciones/noticias/296737/10/07/Lunes-negro-de-1987-el-parque-de-Wall-Street-hizo-crash.html. Accedido el 9 de setiembre del 2024.

Wang et al. (2024). Wang S., Li K., Liu Y., Chen Y., and Tang X., “VIX constant maturity futures trading strategy: A walk-forward machine learning study,” *PLoS One*, vol. 19, no. 4, p. e0302289, Apr. 2024, doi: 10.1371/journal.pone.0302289.

Xiao et al. (2018). Xiao, J., Zhu, X., Huang, C., Yang, X., Wen, F., & Zhong, M. (2018). A New Approach for Stock Price Analysis and Prediction Based on SSA and SVM. *International Journal of Information Technology & Decision Making*. doi:10.1142/s021962201841002x

Yang y Lin (2016). Yang, H.-L., & Lin, H.-C. (2016). An Integrated Model Combined ARIMA, EMD with SVR for Stock Indices Forecasting. *International Journal on Artificial Intelligence Tools*, 25(02), 1650005. doi:10.1142/s0218213016500056

Wei (2016). Wei, L.-Y. (2016). A hybrid ANFIS model based on empirical mode decomposition for stock time series forecasting. *Applied Soft Computing*, 42, 368–376. doi: 10.1016/j.asoc.2016.01.027

Zhang et al. (2017). Zhang, N., Lin, A., & Shang, P. (2017). Multidimensional k-nearest neighbor model based on EEMD for financial time series forecasting. *Physica A: Statistical Mechanics and Its Applications*, 477, 161–173. doi: 10.1016/j.physa.2017.02.072

Zbikowski, K (2015). Żbikowski, K. (2015). Using Volume Weighted Support Vector Machines with walk forward testing and feature selection for the purpose of creating stock trading strategy. *Expert Systems With Applications*, 42(4), 1797-1805. <https://doi.org/10.1016/j.eswa.2014.10.001>