


UNIVERSIDAD TECNICA FEDERICO SANTA MARIA

DEPARTAMENTO DE INGENIERIA COMERCIAL

VALPARAISO - CHILE



PREDICCIÓN DEL MERCADO DE VALORES Y MARCO ETICO-
LEGAL: COMPARACIÓN DE DESEMPEÑO ENTRE LAS TÉCNICAS
DE IA MÁS UTILIZADAS.

MATÍAS FELIPE ARÉVALO ÁLVAREZ

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO COMERCIAL

PROFESOR GUIA: JORGE ORTEGA

MARZO 2024

DEDICATORIA

Entrego mis logros a aquellos que los aprecian incluso más que yo. Mis hermanos quienes aún me recuerdan. Ángelo Soto Lobos quien ha sido un padre para mí y Rosa Álvarez Iturrieta, mi madre, a quien le debo mi libertad.

"Un día, me opuse a ustedes con velas tensas y voluntad firme. Anhelaba navegar hacia un único objetivo, mi propio destino. Pero ustedes me soplasteis y me empujasteis hacia atrás, lejos de mi meta, hacia alta mar. Fue entonces cuando aprendí a navegar con todos los vientos.

Desde aquel día en que un viento se me opuso, navego con todas las corrientes. Ya no persigo un solo objetivo, sino que me dejo llevar por donde me lleven los vientos. Ahora comprendo que siempre he navegado hacia mi propio destino, incluso cuando luchaba contra el viento."

Friedrich Nietzsche

RESUMEN EJECUTIVO

El presente documento es una investigación fundamental y cualitativa que tiene como objetivo identificar y promover la gestión de nuevos métodos de predicción de precios en los mercados financieros mediante el uso de inteligencia artificial (IA). La investigación se enfoca en comparar tres técnicas avanzadas de IA: Neural Networks, Support Vector Machines y Neuro Fuzzy Models, con métodos tradicionales como el random walking y los modelos autorregresivos de medias móviles (ARMA), con el fin de evaluar su eficacia en la predicción de índices bursátiles y más específicamente, el índice de precios compuesto JSE del mercado de valores de Johannesburgo.

La motivación principal de este estudio radica en la necesidad de mejorar la precisión y eficiencia en las predicciones del mercado financiero, buscando inversiones más sostenibles y eficientes. La transformación digital de las finanzas, impulsada por la IA, ofrece una oportunidad única para combinar la información financiera con capacidades tecnológicas avanzadas, reduciendo así los errores humanos y creando un entorno empresarial y económico más seguro.

Se llevó a cabo un análisis comparativo entre los métodos de IA seleccionados y los enfoques tradicionales. Para ello, se utilizaron datos históricos del índice JSE, aplicando cada método para predecir futuros movimientos del mercado. La precisión de las predicciones se evaluó utilizando métricas estadísticas como el error cuadrático medio (MSE) y la raíz del error cuadrático medio (RMSE), entre otras. Además, se consideraron factores como la robustez del modelo, la capacidad de generalización y la complejidad computacional.

Se encontró que ninguno de los modelos complejos utilizados en este ejercicio pudo superar al modelo de caminata aleatoria (Random Walking). Cabe destacar que este

modelo solo puede utilizarse para la predicción del precio del día siguiente. Basado en los resultados de este experimento, se puede concluir que usar un método común como la caminata aleatoria arrojaría mejores resultados. Sin embargo, los métodos complejos podrían considerarse cuando se aumenta el horizonte temporal de la predicción.

Los resultados obtenidos también muestran que las tres técnicas de IA tienen la capacidad de pronosticar el precio del índice, sin embargo prever el precio con un horizonte de tiempo más grande es mucho más desafiante. Si se predice dentro de un cierto nivel de precisión, puede proporcionar más información sobre el comportamiento futuro de las acciones del mercado. Esto envía un buen mensaje a los inversores de que las técnicas de inteligencia artificial si pueden usarse para la previsión del mercado.

Otro objetivo del estudio era demostrar que los precios pasados de las acciones tienen un poder predictivo. Los resultados han mostrado que las acciones contienen información que puede utilizarse para predecir los precios futuros.

La implementación de la IA en los mercados financieros presenta múltiples beneficios, incluyendo una mayor precisión en las predicciones a largo plazo, una reducción de los errores humanos y una aceleración de la transformación digital de las finanzas. Sin embargo, también existen desafíos importantes que deben ser abordados. Estos incluyen la complejidad inherente de los modelos de IA, el riesgo de sesgos en los datos y algoritmos, y las responsabilidades legales y éticas asociadas con el uso de estas tecnologías en decisiones financieras críticas.

El estudio subraya la necesidad de desarrollar un marco regulatorio adecuado que equilibre los beneficios y riesgos de la IA. Este marco debe garantizar la confianza en las tecnologías, proteger los derechos fundamentales de los participantes del mercado y evitar la creación de inseguridades jurídicas que puedan obstaculizar la adopción de IA en el sector financiero.

En conclusión, la investigación demuestra que la inteligencia artificial puede ofrecer mejoras significativas en la predicción de precios en los mercados financieros en casos donde el horizonte de tiempo sea más largo, proporcionando herramientas más precisas y eficientes para los inversores. No obstante, para aprovechar plenamente estas ventajas, es crucial abordar los desafíos asociados y desarrollar un entorno regulatorio que apoye la integración segura y efectiva de la IA en el sector financiero. Este enfoque contribuirá a crear un entorno empresarial más robusto, seguro y eficiente, impulsando la sostenibilidad y la innovación en los mercados financieros.

TABLA DE CONTENIDOS

1	INTRODUCCIÓN	14
	CAPÍTULO 1: PROBLEMA DE INVESTIGACIÓN	16
1.1	PROBLEMAS DERIVADOS	16
1.1.1	Responsabilidades Éticas y Legales.....	16
1.2	HIPÓTESIS	18
	CAPÍTULO 2: OBJETIVOS DEL ESTUDIO.....	19
2.1	OBJETIVO GENERAL	19
2.2	OBJETIVOS ESPECÍFICOS	19
	CAPÍTULO 3: ALCANCE	20
3.1	ASPECTOS GENERALES.....	20
3.2	CRITERIOS DE SELECCIÓN PARA LOS MODELOS DE PREDICCIÓN	20
3.2.1	Precisión.....	21
3.2.2	Efectos del Marco Temporal en la Proyección.....	21
3.2.3	Facilidad de Aplicación.....	22
3.2.4	Evaluación In-sample contra out-of-sample	22
3.2.5	Proyecciones y Costos de Transacción	23
3.3	BOLSA DE VALORES DE JOHANNESBURGO	23
3.4	MARCO REGULATORIO	24
	CAPÍTULO 4: MARCO TEÓRICO.....	25
4.1	QUINTA REVOLUCIÓN INDUSTRIAL	25
4.2	INTELIGENCIA ARTIFICIAL	28
4.2.1	Componentes Técnicos de una IA	29
4.3	ALGORITMOS MATEMATICOS	30
4.3.1	Algoritmo Básico.....	31
4.4	CODIFICACION Y REPRESENTACION NUMERICA.....	32

4.4.1	Sistemas de Numeración.....	33
4.5	MODELOS MATEMÁTICOS E INTELIGENCIA ARTIFICIAL.....	36
4.6	TÉCNICAS DE INTELIGENCIA ARTIFICIAL	37
4.6.1	Redes Neuronales.....	38
4.6.2	Redes Topológicas	39
4.6.3	Multi-Layer Perceptron (MLP).....	40
4.7	FUNCION DE ACTIVACION	42
4.8	SUPPORT VECTOR MACHINE	44
4.8.1	Clasificación Lineal	47
4.8.2	Clasificación No Lineal	48
4.8.3	Función de Base Radial (RBF)	50
4.9	MODELOS NEURO-FUZZY	51
4.9.1	Arquitectura del Modelo Neuro Fuzzy	52
4.10	MEDIA MOVIL AUTORREGRESIVA (ARMA).....	55
4.11	RANDOM WALKING	58
4.12	IMPACTO DE LA INTELIGENCIA ARTIFICIAL.....	59
4.13	MERCADOS FINANCIEROS.....	59
4.14	ÍNDICES DE MERCADO	60
4.15	HIPÓTESIS SOBRE EFICIENCIA DEL MERCADO.....	60
4.15.1	Estudios de Evaluación de la EMH.....	62
4.16	LA IA EN LOS MERCADOS FINANCIEROS	64
4.16.1	Gestión de Riesgo.....	66
4.16.2	Automatización de Procesos	67
4.17	FORECASTING.....	68
4.17.1	Predicción del Mercado.....	69
4.18	MODELIZACIÓN DE PRECIOS Y RETORNO	70

4.18.1	Smoothing	71
4.18.2	Ajuste de Curvas	71
4.18.3	Modelado Lineal	72
4.19	DESAFÍOS LEGALES Y ÉTICOS DE LA IA	73
4.19.1	Reflexiones sobre los Reglamentos Existentes	74
4.20	OBSTÁCULOS PARA UN MARCO REGULATORIO	75
4.20.1	Obstáculos Técnico-Jurídicos.....	76
4.20.2	Obstáculos Ético-Políticos	77
4.21	TRANSPARENCIA Y COMPLEJIDAD DE LA INFORMACIÓN	79
4.21.1	Protección de Datos Personales.....	79
4.21.2	Prohibición de la Discriminación	80
4.22	TRANSPARENCIA ALGORÍTMICA	81
4.22.1	Elección de los Consumidores.....	81
CAPÍTULO 5: METODOLOGÍA DE INVESTIGACIÓN		83
4.23	CONSTRUCCIÓN DE LOS MODELOS	84
4.23.1	Network Training	84
4.23.2	Número de Iteraciones.....	85
4.24	ESPACIO MUETRAL.....	86
4.25	MEDIDAS DE RENDIMIENTO	86
4.25.1	Matrix de Confusión.....	88
CAPÍTULO 6: RECOPIACIÓN Y ANÁLISIS DE DATOS		90
6.1	MULTILAYER PERCEPTRON	90
6.1.1	Resultados MLP.....	90
6.2	SUPPORT VECTOR MACHINES	94
6.2.1	Resultados SVM	94
6.3	NEURO-FUZZY	98

6.3.1	Experimento Neuro Fuzzy	100
6.3.2	Resultados Neuro Fuzzy	102
6.4	AUTO-REGRESSIVE MOVING AVERAGE MODELLING (ARMA)	106
6.5	RANDOM WALK	108
CAPÍTULO 7: CONCLUSIONES		109
7.1	INTERPRETACIÓN DE LOS RESULTADOS	109
7.2	COSTOS DE TRANSACCIÓN Y EMH.....	110
7.3	COMPARACIÓN DE LAS TÉCNICAS	110
7.4	RESPONSABILIDADES ETICO-LEGALES.....	112
7.5	BALANCE DE HIPOTESIS.....	114
CAPÍTULO 8: RECOMENDACIONES		116
9.1	RECOMENDACIONES DERIVADAS DEL ESTUDIO.....	116
9.2	RECOMENDACIONES APLICADAS AL ÁMBITO FINANCIERO	117
9.3	SUGERENCIAS	118
10	APÉNDICES.....	120
10.1	APÉNDICE A: MÉTODOS DE PRECISIÓN.....	120
10.1.1	Error Porcentual Absoluto Medio (MAPE).....	120
10.1.2	MSE.....	121
10.1.3	RMSE.....	121
10.1.4	MSRE.....	121
10.1.5	Anderson-Darlington	122
10.2	APÉNDICE B: NORMALIZACION DE DATOS	123
10.3	APÉNDICE C: CÓDIGO MATLAB	123
10.3.1	Código Matlab para Normalización de Datos	123
10.3.2	Código Matlab para Ordenamiento de Datos	124
10.3.3	Código Matlab de Entrenamiento y Prueba para SVM.....	127

10.3.4	Código Matlab de Entrenamiento y Prueba de Neuro-Fuzzy	130
9	REFERENCIAS.....	137

LISTA DE TABLAS

Tabla 1: Ejemplo de la Matriz de Confusión	88
Tabla 2: Diferentes Arquitecturas MLP	93
Tabla 3: Medidas de Precisión de Resultados para MLP	93
Tabla 4: Matriz de Confusión para los Resultados de MLP.....	93
Tabla 5: Medidas de Precisión de Resultados para SVM.	94
Tabla 6: Matriz de Confusión de Resultados para SVM.....	97
Tabla 7: Medidas de Precisión de Resultados para Neuro-Fuzzy	103
Tabla 8: Matriz de Confusión de Resultados para Neuro-Fuzzy	105
Tabla 9: Medidas de Precisión de Resultados para ARMA	107
Tabla 10: Matriz de Confusión de Resultados para ARMA.....	107
Tabla 11: Medidas de Precisión de Resultados para Random Walk	108
Tabla 12: Comparación de los Métodos de Predicción	112

LISTA DE FIGURAS

Figura 1 Etapas de la Revolución Industrial	26
Figura 2: Algoritmo Básico en Python.....	31
Figura 3: Diagrama de Flujo del Algoritmo.....	32
Figura 4: Esquema de Conversión de un Número Decimal a Binario	33
Figura 5: Esquema de Conversión de un Número Binario a Decimal	34
Figura 6: Ejemplo de Codificación ASCII.....	35
Figura 7: Multiplicación Hexadecimal.....	35
Figura 8: Elaboración de una Neurona	38
Figura 9: Diagrama de Topología de Avance.....	40
Figura 10: Diagrama de la Red Neuronal Recurrente.....	41
Figura 11: Diagrama Generalizado de un Modelo de Red Neuronal	42
Figura 12: Diagrama de la Función de Activación Sigmoidea	43
Figura 13: Diagrama de una Función de Activación Tanh	44
Figura 14: Clasificación: Caso Lineal Separable	45
Figura 15: Margen Hiperplano Máximo Entrenado con Ejemplos de Dos Clases	47
Figura 16: Clasificación de Dos Dimensiones	48
Figura 17: Clasificación Multi Dimensional.....	49
Figura 18: Mapeo de la Función Kernel	49
Figura 19: Mapeo en Varias Dimensiones	50
Figura 20: Clasificación Separada con EBF Kerne.....	51
Figura 21: Red Adaptativa de Avance Presentada por Capa.....	53
Figura 22: Red Adaptativa Recurrente.....	54
Figura 23: Red de Avance de Ordenamiento Topológico	54
Figura 24: Diagrama de Flujo sobre la Creación de los Modelos.....	84
Figura 25: Objetivo vs. Outputs del Modelo MLP para 3 inputs.....	91

Figura 26: Objetivo vs. Outputs del Modelo MLP para 5 inputs.....	91
Figura 27: Objetivo vs. Outputs del Modelo MLP para 7 inputs.....	92
Figura 28: Objetivo vs. Outputs del Modelo MLP para 10 inputs.....	92
Figura 29: Objetivo vs. Outputs del Modelo SVM para 3 inputs.	95
Figura 30: Objetivo vs. Outputs del Modelo SVM para 5 Inputs	95
Figura 31: Objetivo vs. Outputs del Modelo SVM para 7 Inputs.....	96
Figura 32: Objetivo vs. Outputs del Modelo SVM para 10 Inputs.....	96
Figura 33: Diagrama de Flujo del Poces de Aprendizaje Neuro-Fuzzy.....	99
Figura 34: Procedimiento de Inicialización de Agrupamiento Hiperelipsoidal	100
Figura 35: Error de Validación Cruzada vs. Diagrama de Complejidad	101
Figura 36: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 3 Inputs	103
Figura 37: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 5 Inputs	104
Figura 38: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 7 Inputs	104
Figura 39: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 10 Inputs	105
Figura 40: Fluctuaciones de Precio ALSI Año 2002 – 2005	106
Figura 41: Output Medido y Predicho por Modelo ARMA.....	107

1 INTRODUCCIÓN

La predicción de los rendimientos bursátiles es un tema de gran relevancia en el ámbito financiero, el cual ha atraído la atención de los investigadores durante décadas. Este campo implica la suposición de que la información pública disponible tiene una relación predictiva con los futuros rendimientos del mercado de valores. Sin embargo, esta aseveración está ligada a la asunción general de la eficiencia del mercado, la cual postula que todos los datos disponibles que afectan los valores bursátiles actuales son considerados por el mercado antes de que el público pueda operar basándose en ellos. A pesar de ello, existe un debate respecto a esta teoría, debido a la evidencia de que los mercados no son completamente eficientes, lo que sugiere que es posible predecir los precios futuros con resultados superiores al azar.

Los estudios sobre los cambios en el mercado de valores se centran en dos áreas principales: la prueba de la eficiencia del mercado y la modelización de los rendimientos bursátiles. La eficiencia del mercado de valores tiene implicaciones en la modelización de los precios de las acciones y se captura claramente mediante la hipótesis del mercado eficiente (EMH). Debido a esto, a lo largo de los años se han empleado diversas técnicas de modelización, incluyendo el análisis técnico y el análisis fundamental, para intentar comprender y predecir los movimientos del mercado.

El presente estudio se enfoca en la predicción del índice del mercado de valores utilizando técnicas de inteligencia artificial, clasificándose bajo el análisis técnico de los precios del mercado de valores. Se parte de la premisa de que las predicciones pueden basarse únicamente en los datos de los precios de las acciones, desafiando así la aleatoriedad en la que los cambios sucesivos carecen de correlación. En este contexto, se exploran y comparan técnicas como las Neural Networks, Support Vector Machines y

Neuro-Fuzzy Models con los métodos de predicción tradicionales Random Walking y ARMA.

Además, el uso de técnicas de inteligencia artificial en la predicción del mercado plantea una serie de implicaciones legales y éticas que también se recapitularán en este estudio, lo cual se ahonda en una recapitulación de declaraciones y noticias recopiladas con un enfoque en las regulaciones de la unión europea. El objetivo de esta segunda temática es poner en evidencia los grandes cambios que está causando la inteligencia artificial en sí mismo al desconocimiento de la tecnología.

CAPÍTULO 1: PROBLEMA DE INVESTIGACIÓN

Dentro de los avances tecnológicos producidos cada vez con más fuerza, nos encontramos con muchas problemáticas correspondientes a su utilización. En el caso de la IA, hace falta detenerse y preguntar: ¿Cómo nos afectará la implementación de una tecnología que alcanzará a todas las áreas de nuestras vidas? Siguiendo esta premisa, la problemática que planea dar respuesta esta investigación tiene que ver con los puntos más relevantes de la aplicación de la IA en relación a los mercados financieros.

La motivación fundamental para intentar predecir los precios del mercado de valores es la ganancia financiera. La capacidad de descubrir un modelo matemático que pueda predecir consistentemente la dirección de los precios futuros de las acciones crearía grandes beneficios al propietario. Por lo tanto, los investigadores, inversionistas y profesionales de la inversión siempre están tratando de encontrar un modelo que les brinde mayores rendimientos. Siguiendo esta idea, también busco responder a la pregunta sobre cuál es el modelo con más beneficios para los usuarios. Por otro lado, dentro de los mercados financieros podemos encontrar problemáticas en las áreas de adaptación de la IA como el sesgo de información y los aspectos legales-éticos.

1.1 PROBLEMAS DERIVADOS

1.1.1 Responsabilidades Éticas y Legales

La determinación de responsabilidades por daños causados por la IA es un tema complejo, ya que surge la pregunta sobre quién debe responder por los perjuicios ocasionados por sistemas automatizados. La falta de claridad en la asignación de responsabilidades legales ante incidentes relacionados con la IA. Es crucial establecer un marco regulatorio claro junto con mecanismos de rendición de cuentas para los desarrolladores y usuarios de IA.

Regulación y Supervisión:

- La complejidad de los sistemas de IA dificulta que los reguladores y supervisores financieros puedan comprender, monitorear y controlar adecuadamente su funcionamiento. Esto plantea desafíos para garantizar el cumplimiento normativo y la protección de los consumidores.

Protección de Datos:

- Los problemas legales asociados con la protección de datos son críticos, especialmente cuando se utilizan herramientas de IA sin regulación adecuada. La seguridad de la información es un aspecto crucial en la protección de datos, ya que garantiza la confidencialidad, integridad y disponibilidad de la información.

Discriminación de Clientes:

- Los sistemas de IA pueden excluir a ciertos grupos de consumidores basados en una mayor probabilidad de beneficio, reduciendo el potencial del mercado y limitando la inclusión. Esto puede tener implicaciones éticas y sociales al perpetuar desigualdades y discriminación.

Transparencia y Claridad de la Información:

- A medida que los modelos de IA se vuelven más sofisticados, puede ser cada vez más difícil para los usuarios y reguladores entender cómo toman las decisiones y qué razonamientos se usan para poder llegar a estas.
- La falta de transparencia y claridad de los algoritmos de IA puede generar preocupaciones sobre la fiabilidad, imparcialidad y responsabilidad de las decisiones financieras. En muchos casos estos algoritmos son propiedad intelectual de la empresa creadora.

1.2 HIPÓTESIS

Hipótesis 1: Los modelos vanguardistas de predicción de datos basados en la inteligencia artificial son superiores a los modelos tradicionales en términos de precisión y efectividad.

Hipótesis 2: Las Neural Networks, los sistemas Neuro-Fuzzy y las Support Vector Machines pueden ser efectivas para predecir los precios futuros del mercado de valores.

Hipótesis 3: Los precios pasados de las acciones contienen información que puede utilizarse para predecir los precios futuros.

Hipótesis 4: La complejidad de los modelos de inteligencia artificial puede tener implicaciones éticas y legales, ya que podría violar regulaciones relacionadas con la equidad y la transparencia en las transacciones financieras.

CAPÍTULO 2: OBJETIVOS DEL ESTUDIO

2.1 OBJETIVO GENERAL

Analizar los desafíos y cambios que ha producido la implementación de la IA en los mercados de valores por medio de la experimentación y comparación entre los modelos matemáticos tradicionales y los nuevos modelos desarrollados con IA.

2.2 OBJETIVOS ESPECÍFICOS

- Recapitular en las lecturas pertinentes con relación a los avances tecnológicos que dieron origen a la inteligencia artificial.
- Analizar cómo los avances de la inteligencia artificial han transformado los mercados financieros en términos de velocidad y eficiencia en la ejecución de transacciones.
- Examinar cómo la inteligencia artificial ha revolucionado la forma en que se realizan las predicciones del mercado.
- Demostrar la eficiencia y precisión de los modelos matemáticos en la predicción de los precios en el mercado de valores mediante la comparación de sus resultados, evaluando su capacidad para predecir tendencias y movimientos futuros con exactitud y consistencia.
- Indagar en los avances que se han efectuado en torno a la IA, exponiendo los desafíos ético-legales que esta implica.

CAPÍTULO 3: ALCANCE

3.1 ASPECTOS GENERALES

- **Contextualización:** Analizar la evolución de los mercados financieros desde una perspectiva cuantitativa y cualitativa, identificando cómo han evolucionado las tecnologías para dar origen a los modelos de IA.
- **Introducción de los nuevos modelos:** Explorar cómo la incorporación de los algoritmos complejos ha transformado la forma en que se operan los mercados financieros, haciendo énfasis en la predicción de precios.
- **Aplicaciones prácticas:** Analizar casos concretos donde el uso de algoritmos y modelos matemáticos tienen un impacto significativo en los mercados financieros, como en la predicción de precios de las acciones.
- **Desafíos y Consideraciones Éticas:** Discutir los desafíos éticos y regulatorios asociados con el uso creciente de algoritmos en los mercados financieros, incluyendo cuestiones de transparencia, equidad y responsabilidad bajo el marco regulatorio europeo.
- **Perspectivas Futuras:** Explorar las tendencias emergentes en el uso de inteligencia artificial, aprendizaje automático y modelos matemáticos avanzados en los mercados financieros, anticipando posibles escenarios futuros y sus implicaciones.

3.2 CRITERIOS DE SELECCIÓN PARA LOS MODELOS DE PREDICCIÓN

A lo largo de los años se han desarrollado diversas técnicas para realizar previsiones. El reto siempre ha consistido en encontrar un método capaz de ofrecer la mejor aproximación al sistema que se está modelizando. Existen varias formas de organizar los criterios de selección y comparación de los métodos de previsión, pero en general suelen organizarse por orden de importancia, dándose la máxima prioridad a la

precisión. Otros criterios utilizados son el patrón de los datos que hay que pronosticar, el tipo de serie, el horizonte temporal que hay que cubrir en la previsión y la facilidad de aplicación.

3.2.1 Precisión

La precisión es muy importante para determinar el modelo correcto para la predicción de precios. Los datos insuficientes o el uso de una técnica que no se ajusta al patrón de los datos, se refleja en predicciones menos precisas (S. Makridakis; H. Hibon, 1992, p. 98-123). Hay buenas razones para respaldar una predicción independientemente de la precisión si la predicción se realiza en una situación altamente incierta. En este experimento, la precisión se utiliza para medir la desviación de los resultados pronosticados de los valores reales.

3.2.2 Efectos del Marco Temporal en la Proyección

Una de las razones por las que el horizonte temporal es particularmente importante en la selección de un método de pronóstico, es que la importancia relativa de los diferentes sub-patrones cambia a medida que cambia el horizonte temporal de planificación. A corto plazo, la aleatoriedad suele ser el elemento más importante. Luego, a medio plazo, el elemento cíclico se vuelve importante y finalmente, a largo plazo, el elemento de tendencia es el que domina. Generalmente, hay una mayor incertidumbre a medida que el horizonte temporal se alarga. Makridakis y Hibon (S. Makridakis; H. Hibon, 1992 p. 98-123) encontraron que un factor importante que afecta la precisión del pronóstico es el tipo de serie temporal utilizada. Con datos micro, los métodos de suavizado exponencial parecían funcionar mucho mejor que las metodologías estadísticamente sofisticadas de ARMA, pronóstico bayesiano, método de Parzen y filtrado adaptativo. Armstrong y Green (J. Scott; C. Kesten, 2011, p. 1-19) concluyeron como parte de los

principios generales que, al hacer pronósticos en situaciones de alta incertidumbre, se debe ser conservador.

3.2.3 Facilidad de Aplicación

Incluidos bajo este título se encuentran aspectos como la complejidad de los métodos, la puntualidad de los pronósticos que proporciona, el nivel de conocimiento necesario para su aplicación, los conceptos básicos y la facilidad con la que se puede transmitir al usuario final del pronóstico (S. Makridakis; Wheelwright; McGEE, 1997, p. 147-160). Una de las desventajas al adoptar técnicas de pronóstico apropiadas es hacer que el usuario final se sienta cómodo con la técnica y su fundamentación, de modo que pueda juzgar efectivamente los resultados del método de pronóstico y su utilidad. Las técnicas de inteligencia artificial son cajas negras que son fáciles de usar; sin embargo, el usuario no puede determinar cómo se calcularon los resultados de estas técnicas.

3.2.4 Evaluación In-sample contra out-of-sample

Los investigadores generalmente han llegado a un consenso de que los métodos de pronóstico deben ser evaluados en términos de precisión utilizando pruebas fuera de la muestra, en lugar de la bondad de ajuste a datos pasados o pruebas en la muestra. El rendimiento de un modelo en datos fuera de los utilizados en su construcción sigue siendo el punto de referencia para su utilidad en todas las aplicaciones (R. Fieldes; Makridakis, 1995, p. 289-308). Los practicantes de la investigación en pronósticos han avanzado dos razones para llegar a esta conclusión. La primera razón es que, para un modelo de pronóstico dado, los errores en la muestra probablemente subestimen los errores de pronóstico. La selección y estimación del modelo están diseñadas para calibrar un procedimiento de pronóstico de datos históricos. Los datos pasados y los futuros probablemente tengan dinámicas diferentes y esto puede afectar al modelo

seleccionado. Además, los intervalos de predicción contruidos sobre errores estándar en la muestra probablemente sean demasiado estrechos (C. Chatfield, 1993, 121-135). La segunda razón es que un modelo seleccionado sobre la base del mejor ajuste en la muestra puede que no sea el mejor para predecir datos fuera de la muestra.

3.2.5 Proyecciones y Costos de Transacción

Los costos de transacción y las restricciones comerciales cambian las pruebas de eficiencia del mercado de forma importante. De manera más obvia, si los costos de transacción son muy altos, la previsibilidad ya no queda excluida por el arbitraje, ya que sería demasiado caro aprovechar incluso un componente predecible de gran tamaño en los rendimientos (A. Timmermann; C. Granger, 2004, p. 15-27). Un inversor puede prever que una acción en particular superará al mercado en un 4% al día siguiente, pero si el costo de transacción para comprar el activo es del 6%, entonces puede que no sea rentable explotar esta predicción.

3.3 BOLSA DE VALORES DE JOHANNESBURGO

La Bolsa de Valores de Johannesburgo (JSE) se destaca como el principal mercado financiero de Sudáfrica, desempeñando un papel fundamental en la economía del país. Fundada el 8 de noviembre de 1887, la JSE ha sido un punto de encuentro para empresas de diversos sectores industriales y comerciales que buscan financiamiento público para expandirse, generando así empleo, productos, servicios y oportunidades para el crecimiento económico.

Es en este contexto que la JSE se ha convertido en la fuente primaria de datos utilizada en diversos estudios financieros y análisis de mercado. Los datos sobre precios de acciones, índices bursátiles y otros indicadores financieros relevantes se obtienen de la

JSE, proporcionando a investigadores y analistas una valiosa información para comprender y predecir las tendencias del mercado financiero sudafricano.

Los datos de las acciones consisten en tres precios diferentes del índice: el máximo intra-día, el mínimo intra-día y el precio de cierre. El precio de cierre fue elegido para representar el precio del índice a modelar y predecir, ya que refleja todas las actividades del índice en un día. Los datos del mercado de valores fueron obtenidos de la Bolsa de Valores de Johannesburgo (JSE), abarcando todos los días de negociación desde 2002 hasta 2005, excluyendo días festivos y fines de semana. Los datos se dividieron en datos de entrenamiento y prueba. Se utilizaron 500 puntos de datos para el entrenamiento (de 2002 a 2004) y 200 puntos para las pruebas (de 2004 a 2005).

El comportamiento del precio del ALSI (All Share Index) revela fluctuaciones significativas dentro de cortos períodos, lo que puede dificultar la comprensión de las técnicas de inteligencia computacional. Para evitar este problema, todos los datos fueron normalizados a un valor entre cero y uno, facilitando que los algoritmos comprendan mejor los datos como se explica en el Apéndice B.

3.4 MARCO REGULATORIO

Esta investigación se centra en el análisis del marco regulatorio de la inteligencia artificial (IA) en la Unión Europea, con énfasis en Francia. Se examinan las leyes y políticas actuales relacionadas con la IA, abordando cuestiones como la transparencia algorítmica, la responsabilidad, la protección de datos y la equidad en su desarrollo y despliegue. El objetivo es contribuir al debate sobre cómo garantizar un desarrollo ético y sostenible de la IA en la UE, prestando especial atención al contexto francés.

CAPÍTULO 4: MARCO TEÓRICO

4.1 QUINTA REVOLUCIÓN INDUSTRIAL

En el período anterior a la Primera Revolución Industrial, más del 80% de la población mundial se dedicaba a la agricultura, (Muir, 2018, p. 1). La Primera Revolución Industrial comenzó en el Reino Unido y duró desde 1760 hasta 1870, marcando la transición a nuevos procesos de producción. Fuentes de energía como el vapor y el carbón hicieron que el uso de máquinas fuera más factible, y la idea de la fabricación con máquinas se expandió rápidamente. La industria transformó el transporte y la industria textil, que en ese momento eran las áreas dominantes en términos de empleo, valor y capital invertido. En palabras simples, el uso de máquinas permite producir una mayor variedad de bienes de manera más rápida y fácil, y así crear un mejor nivel de vida (Jenis, 2019; Muir, 2018, p. 1).

La Primera Revolución Industrial fue al mismo tiempo una causa directa de la creciente urbanización debido al aumento de personas que se trasladaban a las ciudades para trabajar en fábricas. Por ejemplo, para el año 1800, hasta un 10% de los británicos se habían trasladado a Londres para trabajar (Muir, 2018, p. 1).

La Segunda Revolución Industrial tuvo lugar principalmente en Gran Bretaña, América y Alemania y duró desde 1870 hasta 1914. Esta revolución industrial, a menudo referida por los historiadores como la "revolución tecnológica", provocó cambios en la situación socioeconómica mundial. El acero reemplazó al hierro y su producción masiva hizo posible construir ferrocarriles, lo que a su vez mejoró la conexión y las condiciones de transporte de las personas y los bienes. La electricidad y las bombillas reemplazaron a las velas, y los generadores eléctricos alimentaban las máquinas. Alexander Graham Bell inventó el teléfono en 1876, diez años después, Karl Benz patentó el primer

automóvil del mundo, y diez años más tarde, Henry Ford fabricó su primer automóvil con muchos esfuerzos invertidos. Para enfrentar este desafío, Ford rediseñó la planta creando estaciones de trabajo, en las que los automóviles se ensamblaban en etapas, es decir, de estación en estación. Las piezas para las estaciones eran entregadas por cintas transportadoras y al mismo tiempo eran las primeras líneas de ensamblaje. Junto con la creciente automatización en las fábricas, el mundo se enfrentó a un empleo masivo.




Figura 1 Etapas de la Revolución Industrial (Xiao Chen, 2021, p. 8).

La Tercera Revolución Industrial fue desencadenada por la invención de un microprocesador que fue desarrollado en 1969 por Intel. Además, llevó a la invención de la computadora personal. Estas primeras computadoras solían ser muy simples, aparatosas e increíblemente grandes en comparación con la potencia informática que podían proporcionar, pero sentaron las bases para el mundo actual que es difícil de imaginar sin tecnología informática. Las computadoras personales monitorearon y revolucionaron el lugar de trabajo, y a partir de ese momento, las tareas complejas y repetitivas fueron realizadas por programas que proporcionaban orientación de procesos y automatización tanto en la oficina como en la línea de producción (Muir, 2018, p. 1).

La industria 3.0 ha introducido múltiples sistemas automatizados en la línea de ensamblaje para realizar tareas humanas utilizando controladores lógicos programables (PLC). Aunque los sistemas automatizados existían, todavía dependían de la entrada e intervención humanas (Jenis 2019, p. 1). La planificación de requerimientos de materiales (MRP), gestión de relaciones con clientes (CRM), gestión de la cadena de suministro (SCM) e inteligencia empresarial (BI) son solo algunos de los términos que se han vuelto familiares y se han convertido en formas de recopilar y entender la información mientras permiten que las empresas sean más eficientes. Internet se utilizó como plataforma para transmitir esta información, lo que llevó al surgimiento de la computación en la nube y el comercio electrónico (Muir 2018, p. 1).

La ciber física o la conexión de la tecnología con los seres humanos se conoce como la cuarta revolución industrial, y la necesidad diaria de usar un teléfono móvil, una tableta o un dispositivo de gestión de la vida es su inicio. Esta revolución es la era de las máquinas inteligentes, los sistemas de almacenamiento y las instalaciones de fabricación que pueden intercambiar información de manera autónoma, iniciar acciones y controlarse entre sí sin intervención humana. El intercambio de información es posible gracias al internet industrial de las cosas (IIoT). Los elementos clave de la Industria 4.0 incluyen el sistema ciber físico, internet de las cosas (IoT), computación en la nube y computación cognitiva. Muir afirma que la cuarta revolución industrial no solo es una plataforma tecnológica, sino que también significa avances en la comunicación y la conectividad, como de 3G a 4G a 5G. También se afirma que los cambios en la producción, como la impresión en 3D, nos evitarán transportar productos terminados en todo el mundo, sino que en su lugar transportaremos materias primas para luego imprimir y ensamblar localmente. La industria 4.0 nos está llevando a la industria 5.0 cuando se comienza a permitir a los usuarios personalizar lo que desean, lo que ya ha

sucedido y nos está sucediendo (Figura 1), lo que significa que la quinta revolución industrial, la revolución de la IA, ya ha comenzado.

La quinta revolución industrial se enfoca en el regreso de las mentes y manos humanas dentro del marco industrial. Así, la industria 5.0 es una revolución en la que el hombre y la máquina se reconcilian y encuentran formas de trabajar juntos produciendo productos perfectos a una velocidad sin precedentes (Lewis, 2017, p. 1). Vivimos en un momento en el que los consumidores quieren más y producción en masa ya no es suficiente. Se busca la personalización en masa, que solo se puede obtener cuando el toque humano vuelve a la producción, y esta es la esencia de la industria 5.0 (Østergaard, 2019, p. 1-7). En su artículo, afirma que los productos de la industria 5.0 empoderan a las personas para realizar el impulso humano básico de expresarse. Hacer estos productos personalizados requiere lo que llamamos el toque humano. Por supuesto, una mayor personalización de productos no es inherente en algunas industrias, pero si lo es el papel humano en el caso empresarial de la digitalización y la automatización (Olsevskaja, 2019, p. 69-79). Al mismo tiempo, la industria 5.0 puede ser más respetuosa con el medio ambiente a medida que las empresas desarrollan sistemas que funcionan con energía renovable y eliminan los desechos (Jenis, 2019, p. 1).

4.2 INTELIGENCIA ARTIFICIAL

La IA se refiere al campo de estudio y desarrollo tecnológico enfocado en crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana. Estas tareas incluyen, pero no se limitan al reconocimiento de patrones, el aprendizaje, la planificación, el razonamiento lógico, la comprensión del lenguaje natural, la percepción y la interacción con el entorno.

La IA se puede clasificar en dos categorías principales, la IA débil y la IA fuerte. La IA débil se refiere a sistemas diseñados y entrenados para realizar una tarea específica sin la conciencia de su entorno, como los asistentes virtuales o los sistemas de recomendación. Por otro lado, la IA fuerte se refiere a los sistemas con capacidades cognitivas generales similares a las humanas, capaces de aplicar inteligencia a cualquier problema, aunque esta sigue siendo un área de investigación teórica (Nacho Palou, 2023, p. 1).

En una forma técnica, la inteligencia artificial se refiere a la simulación de los procesos de la inteligencia humana por parte de las máquinas, especialmente en los sistemas informáticos. En un sentido más específico, implica el desarrollo de algoritmos y modelos computacionales que pueden realizar tareas que normalmente requieren inteligencia humana. Estos sistemas de IA pueden ser diseñados para aprender de los datos, adaptarse a nuevas situaciones y realizar tareas complejas de manera autónoma (Microsoft, 2024, p.1).

4.2.1 Componentes Técnicos de una IA

La IA se encarga de desarrollar sistemas capaces de llevar a cabo tareas que requerirían de la inteligencia humana. Para lograr esto, se basa en diferentes componentes que permiten el funcionamiento de estos sistemas (ICCSI, 2024, p.1).

- Aprendizaje Automático (Machine Learning): Es un componente esencial de la IA que permite a los sistemas aprender patrones a partir de datos y mejorar su rendimiento con la experiencia.
- Procesamiento del Lenguaje Natural (Natural Language Processing - NLP): Este componente permite a las máquinas entender y comunicarse en lenguaje humano.

Facilita la interacción con los usuarios y la comprensión del significado del lenguaje escrito y hablado.

- **Visión por Computadora:** Capacita a las máquinas para interpretar y analizar imágenes y videos, permitiéndoles reconocer objetos, rostros, movimientos, entre otros aspectos visuales.
- **Razonamiento y Toma de Decisiones:** Estos componentes permiten a los sistemas de IA procesar información, evaluar diferentes opciones y tomar decisiones basadas en datos y reglas predefinidas.
- **Robótica:** La robótica en el contexto de la IA implica es el uso de algoritmos y sensores que permiten a los sistemas percibir su entorno físico, planificar acciones y ajustar su comportamiento en función de cambios en el entorno. Esto incluye tareas como el desplazamiento, la manipulación de objetos y la interacción con otros agentes.

4.3 ALGORITMOS MATEMÁTICOS

Los algoritmos matemáticos son procedimientos definidos paso a paso para realizar tareas específicas o resolver problemas. En el contexto de la inteligencia artificial, los algoritmos son fundamentales, ya que constituyen la base de los sistemas de IA (KEEPCODING, 2023, p.1). Un ejemplo de modelo simple es el algoritmo de búsqueda lineal. Este se utiliza para encontrar un elemento específico en una lista de elementos, recorriendo secuencialmente cada factor hasta que se encuentra el que se está buscando.

```

def busqueda_lineal(lista, objetivo):
    for i in range(len(lista)):
        if lista[i] == objetivo:
            return i # Devuelve la posición si encuentra el objetivo
    return -1 # Devuelve -1 si el objetivo no está en la lista

# Ejemplo de uso
lista = [3, 6, 8, 2, 9, 1]
objetivo = 8
resultado = busqueda_lineal(lista, objetivo)
print("El objetivo", objetivo, "se encuentra en la posición:", resultado)

```

Figura 2: Algoritmo Básico en Python (Elaboración Propia).

4.3.1 Algoritmo Básico

1. Búsqueda Lineal:

- Entrada (Input): Una lista de elementos y un valor a buscar.
- Salida (Output): La posición del valor buscado en la lista o un mensaje indicando que el valor no se encuentra en la lista.

2. Paso a Paso:

- Se recorre cada elemento de la lista secuencialmente, comenzando desde el primer elemento.
- Se compara cada elemento con el valor buscado.
- Si se encuentra el valor, se devuelve la posición en la que se encontró.
- Si se recorre toda la lista y no se encuentra el valor, se devuelve un mensaje indicando que el valor no está presente.

3. Ejemplo:

- Supongamos que buscamos el valor 8 en una lista de valores: [3, 6, 2, 8, 9, 1].
- Comenzamos desde el primer elemento (3) y lo comparamos con 8. No es igual.
- Pasamos al siguiente elemento (6) y lo comparamos con 8. Tampoco es igual.
- Continuamos con los siguientes elementos hasta llegar a 8 en la posición 4.

4. Resultado:

- El algoritmo de búsqueda lineal encontraría el número 8 en la posición 4 de la lista.




Figura 3: Diagrama de Flujo del Algoritmo (Elaboración Propia).

Teniendo esto en cuenta, cabe resaltar que hay diferencias gigantes entre una IA y un algoritmo simple. Principalmente, un algoritmo simple es un conjunto de instrucciones ordenadas diseñadas para resolver un problema específico. Se utiliza en diversas áreas, como matemáticas, informática, física e ingeniería. Por ejemplo, una receta de cocina es un algoritmo simple que describe los pasos para preparar un plato. Por otro lado, la inteligencia artificial es un término más amplio que se refiere a sistemas o máquinas capaces de realizar tareas que normalmente requieren inteligencia humana (BrainCode, 2023, p. 1). Sin embargo, pese a que estos dos modelos sean diferentes, Los algoritmos simples se pueden llegar a transformar en algoritmos avanzados.

4.4 CODIFICACIÓN Y REPRESENTACIÓN NUMÉRICA

La codificación y representación numérica son conceptos fundamentales en informática y sistemas digitales, que permiten almacenar y procesar información de manera eficiente. A continuación, se explican los aspectos clave:

4.4.1 Sistemas de Numeración

La codificación numérica es el proceso de asignar una representación numérica a datos o información para que puedan ser procesados por sistemas digitales. En otras palabras, es la conversión de información no numérica, como caracteres, imágenes o sonidos, en una secuencia de números que los dispositivos electrónicos puedan entender y manipular.

Sistema Binario: Desde la época romana, el ser humano viene utilizando 10 símbolos (desde el 0 hasta el 9) para representar los datos numéricos, esta forma de representación recibe el nombre de “Sistema Decimal”. Sin embargo, cuando se empezaron a diseñar los ordenadores se llegó a la conclusión de que era mucho más fácil construir máquinas capaces de representar la información con solo 2 símbolos (el 0 y el 1). Esta forma de representar la información se conoce como Sistema Binario (González Manuel, 2020, p.1).

Para averiguar cómo codificaría un ordenador un número que está expresado en el sistema decimal habrá que dividir dicho número consecutivamente entre 2, hasta que no sea posible la división, y quedarse con los restos de todas las divisiones empleadas en orden inverso, así por ejemplo el número 77 un ordenador lo representaría como 100101.




Figura 4: Esquema de Conversión de un Número Decimal a Binario (G. D. Manuel, 2020, p. 1)

El paso contrario puede hacerse mediante el método de los pesos, consistente en asociar al dígito binario situado más a la derecha, el peso 1, el que le sigue a su izquierda, el peso 2, el siguiente, peso 4 y así vamos doblando el peso de los restantes con respecto al que tienen a su derecha. Una vez asignados todos los pesos sumamos solamente aquellos en que corresponden a aquellos dígitos binarios de valor 1. Veámoslo con el siguiente ejemplo, imaginemos que queremos convertir el número binario 101001 a decimal (González Manuel, 2020, p. 1).

		x 2	x 2	x 2	x 2	
		←	←	←	←	
Peso	32	16	8	4	2	1
Dígitos binarios	1	0	1	0	0	1

Figura 5: Esquema de Conversión de un Número Binario a Decimal (G. D. Manuel, 2020, p. 1)

Los ordenadores almacenan texto asignando a cada carácter como una secuencia única de ceros y unos, conocida como código de caracteres. Uno de los primeros códigos utilizados fue el ASCII (American Standard Code for Information Interchange), que asigna una secuencia de 8 bits (o 1 byte) a cada carácter. La tabla ASCII completa consta de 256 caracteres diferentes, que van desde letras y números hasta símbolos especiales. Por ejemplo, la letra "A" se representa en ASCII como 01000001 en binario o 65 en decimal. Esta codificación permite que los ordenadores puedan procesar y almacenar texto de manera eficiente.




Figura 6: Ejemplo de Codificación ASCII (G. D. Manuel, 2002, p. 1)

Sistema Hexadecimal: El sistema hexadecimal es un sistema de numeración posicional que utiliza 16 dígitos diferentes: 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E y F. Es ampliamente utilizado en informática y electrónica debido a su estrecha relación con el sistema binario (Cornejo Eloy 2012, p. 2-8).

x	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F	10
1	1	2	3	4	5	6	7	8	9	A	B	C	D	E	F	10
2	2	4	6	8	A	C	E	10	12	14	16	18	1A	1C	1E	20
3	3	6	9	C	F	12	15	18	1B	1E	21	24	27	2A	2D	30
4	4	8	C	10	14	18	1C	20	24	28	2C	30	34	38	3C	40
5	5	A	F	14	19	1E	23	28	2D	32	37	3C	41	46	4B	50
6	6	C	12	18	1E	24	2A	30	36	3C	42	48	4E	54	5A	60
7	7	E	15	1C	23	2A	31	38	3F	46	4D	54	5B	62	69	70
8	8	10	18	20	28	30	38	40	48	50	58	60	68	70	78	80
9	9	12	1B	24	2D	36	3F	48	51	5A	63	6C	75	7E	87	90
A	A	14	1E	28	32	3C	46	50	5A	64	6E	78	82	8C	96	A0
B	B	16	21	2C	37	42	4D	58	63	6E	79	84	8F	9A	A5	B0
C	C	18	24	30	3C	48	54	60	6C	78	84	90	9C	A8	B4	C0
D	D	1A	27	34	41	4E	5B	68	75	82	8F	9C	A9	B6	C3	D0
E	E	1C	2A	38	46	54	62	70	7E	8C	9A	A8	B6	C4	D2	E0
F	F	1E	2D	3C	4B	5A	69	78	87	96	A5	B4	C3	D2	E1	F0
10	10	20	30	40	50	60	70	80	90	A0	B0	C0	D0	E0	F0	100

Figura 7: Multiplicación Hexadecimal (P. Aida, 2017, p. 6)

El sistema hexadecimal se utiliza principalmente en informática y tecnología por varias razones:

- **Representación compacta de datos binarios:** Dado que cada dígito hexadecimal representa 4 bits binarios, el sistema hexadecimal permite una representación más compacta y legible de grandes cantidades de datos binarios que son fundamentales para el funcionamiento de las computadoras.
- **Facilidad de conversión binario-hexadecimal:** La conversión entre los sistemas binario y hexadecimal es relativamente sencilla, ya que cada dígito hexadecimal corresponde directamente a un grupo de 4 bits binarios. Esto facilita el manejo y visualización de datos binarios.
- **Representación de colores:** En informática, los valores hexadecimales se utilizan para representar los colores en formato RGB (rojo, verde, azul).
- **Depuración y análisis de programas:** Los programadores utilizan el sistema hexadecimal para depurar y analizar el contenido de la memoria y los registros de las computadoras durante el desarrollo de software.

4.5 MODELOS MATEMÁTICOS E INTELIGENCIA ARTIFICIAL

Convertir un algoritmo simple en una inteligencia artificial implica una evolución significativa que abarca desde la identificación del problema hasta la implementación de algoritmos avanzados, el entrenamiento del modelo, la optimización continua y la integración de componentes especializados (Juan Gomila, 2023, p. 1). Sin embargo, hay algunos pasos que se mantienen en la mayoría de los modelos:

1. Identificar el problema y los objetivos que se desea resolver.
2. Recopilar datos relevantes que alimentarán a la IA para que pueda aprender y tomar decisiones basadas en la información disponible.
3. Seleccionar algoritmos especializados, como redes neuronales, aprendizaje profundo o sistemas expertos, que permitirán a la IA realizar tareas más complejas.

4. Entrenar al modelo de IA con los datos recopilados, ajustando los parámetros para mejorar su rendimiento y precisión en la resolución del problema.
5. La IA debe ser optimizada constantemente, mejorando su capacidad de aprendizaje, adaptación y toma de decisiones a medida que se enfrenta a nuevos escenarios.
6. Se pueden integrar componentes avanzados como procesamiento del lenguaje natural, visión por computadora o sistemas de recomendación para ampliar las capacidades de la IA.
7. Es crucial validar y evaluar el rendimiento de la IA en diferentes situaciones para garantizar su eficacia y precisión en la resolución de problemas.

Dados los pasos para pasar de un algoritmo simple a una IA. Estas tienen diferentes técnicas para procesar la información en base a modelos matemáticos que, en vez de limitarse en tratar de entender el pensamiento humano, tienen un funcionamiento con objetivos claros.

4.6 TÉCNICAS DE INTELIGENCIA ARTIFICIAL

La IA es la ciencia e ingeniería de crear máquinas inteligentes, especialmente programas informáticos inteligentes. Está relacionada con la tarea similar de utilizar computadoras para entender la inteligencia humana, pero la IA no tiene que confinarse a métodos que sean biológicamente observables. La inteligencia es la parte computacional de la capacidad para lograr objetivos. En esta investigación se analizarán las técnicas de redes neuronales de perceptrón multicapa (Multi-layer Perceptrón), máquinas de vectores de soporte (Support Vector Machine) y sistemas neuro difusos (Neuro-Fuzzy Methods) para la predicción del índice del mercado de valores y se compararán con el método de caminata aleatoria (Random Walk) y los modelos autorregresivos de medias móviles (ARMA) para determinar su relevancia real.

4.6.1 Redes Neuronales

La teoría de la computación de redes neuronales (NN) proporciona técnicas que imitan el cerebro humano y el sistema nervioso. Una red neuronal se caracteriza por el patrón de conexiones entre las diversas capas de la red, el número de neuronas en cada capa, el algoritmo de aprendizaje y las funciones de activación de las neuronas. En general, una red neuronal es un conjunto de unidades de entrada (Inputs) y salida (Outputs) conectadas, donde cada conexión tiene asociado un peso (Weight). Las redes neuronales pueden usarse para clasificación o regresión.

El interés por las NN surgió después de que McCulloch y Pitts introdujeran una versión simple de una neurona en 1943 (C. Bishop, 1999, p. 116-137). Este modelo de neurona se inspiró en la neurona biológica del cerebro humano y se presentó como un modelo matemático simple. Una red neuronal es un conjunto de neuronas y caminos que conectan las neuronas. Las NN también pueden definirse como generalizaciones de técnicas clásicas orientadas a patrones en áreas de estadísticas e ingeniería, como procesamiento de señales, identificación y control de sistemas.

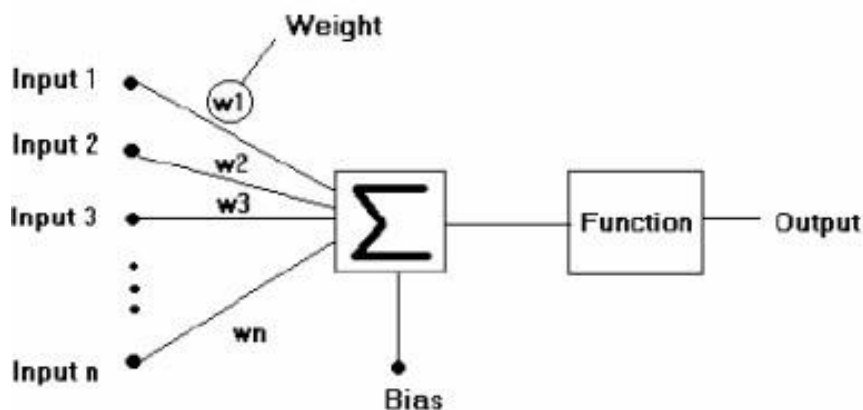


Figura 8: Elaboración de una Neurona (L. R. Marwala, 2010, p. 21).

Cada entrada se multiplica por algún factor w (Weight) a lo largo de su camino y las entradas ponderadas se suman y sesgan (Bias). Luego, esta entrada ponderada se sesga agregando un valor a la entrada ponderada. La salida de la suma se envía a una función que se llama “función de activación” (Activation Function), que el usuario especifica. La salida del bloque de la función alimenta a la neurona de salida.

Esta estructura se denomina “Arquitectura Feedforward” porque las conexiones de la red fluyen unidimensionalmente desde la capa de entrada hasta la capa de salida sin ciclos de retroalimentación. En términos generales, la arquitectura se compone por:

- **La capa de entrada:** Contiene los predictores.
- **La capa oculta:** Contiene nodos (Unidades no observables). El valor de cada unidad oculta es una función de los predictores. La forma exacta de la función depende, por un lado, del tipo de red y, por otro, de las especificaciones controlables por el usuario.
- **La capa de salida:** Contiene las respuestas. Cada unidad de salida es una función de las entradas ocultas. Nuevamente, la forma exacta de la función depende, por un lado, del tipo de red y, por otro lado, de especificaciones controlables por el usuario.

4.6.2 Redes Topológicas

Esta sección presenta el patrón de conexiones entre las unidades y la propagación de datos. El patrón se puede distinguir de la siguiente manera:

Topología de Avance (FeedForward Topology): Donde el flujo de datos desde las unidades de entrada hasta las unidades de salida es estrictamente de avance. Este tipo de conexión no tiene retroalimentación (K. Hornik; H. White; M. Stinchcombe, 1989, p. 359-366).

Redes Recurrentes (Recurrent Networks): Contienen conexiones de retroalimentación como se muestra en la Fig. 10. Contrariamente a las redes de avance, lo más importante dentro de esta red son sus propiedades dinámicas (K. Hornik; H. White; M. Stinchcombe, 1989, p. 359-366)

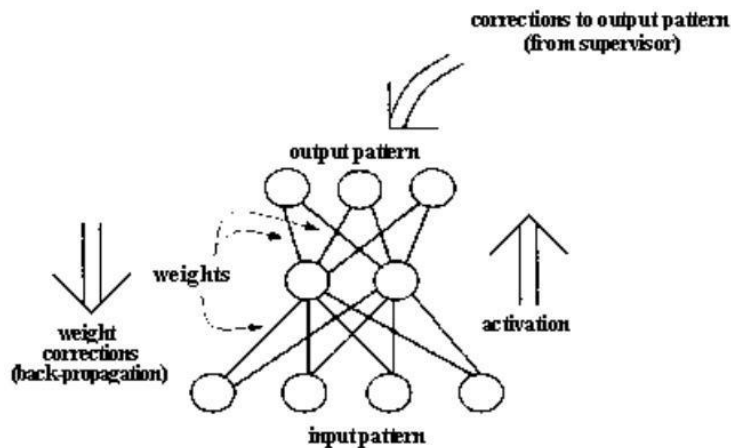


Figura 9: Diagrama de Topología de Avance (L. R. Marwala, 2010, p. 22).

4.6.3 Multi-Layer Perceptron (MLP)

Una red neuronal en su forma más simple tiene una sola capa con entradas dirigidas, y solo está limitada a clases linealmente separables como clasificador. Para que la red pueda lidiar con problemas no lineales más complejos, se agregan capas no lineales ocultas para formar un perceptrón multicapa. MLP está estructurado en una topología de avance donde cada unidad recibe su entrada de la anterior. Un diagrama de un modelo de red neuronal multicapa generalizado se muestra en la Figura 11.




Figura 10: Diagrama de la Red Neuronal Recurrente (L. R. Marwala, 2010, p. 23).

Las redes neuronales se utilizan más comúnmente como aproximadores de funciones que mapean las entradas de un proceso a las salidas. La razón de su amplio uso es que, suponiendo que no haya restricciones en la arquitectura, las redes neuronales pueden aproximar cualquier función continua de complejidad arbitraria (D. Tikk; L. T. Kóczy; T. D. Gedeon, 2001, p. 1-11).

El mapeo de las entradas a las salidas utilizando una red neuronal MLP puede expresarse de la siguiente manera:

$$Y_k = f \left(\sum_{j=1}^M w_{kj}^{(2)} \left(\sum_{i=1}^n w_{ji}^{(1)} x_i + w_{j0}^{(1)} \right) + w_{k0}^{(2)} \right) \quad (1)$$

En la ecuación, $w_{ji}^{(1)}$ y $w_{kj}^{(2)}$ indican los pesos (Weights) en la primera y segunda capa, respectivamente, yendo desde la entrada i a la unidad oculta j , donde M es el número de unidades ocultas (Capas intermedias), d es el número de unidades de salida, mientras que $w_{j0}^{(1)}$ indica el sesgo para la unidad oculta, $w_{k0}^{(2)}$ indica el sesgo para la unidad de salida k . Por simplicidad, los sesgos se han omitido del diagrama.




Figura 11: Diagrama Generalizado de un Modelo de Red Neuronal (L. R. Marwala, 2010, p. 24).

La capa de entrada consiste únicamente en las entradas a la red. Las neuronas de la capa de entrada no realizan ningún cálculo, simplemente distribuyen las entradas a los pesos de la capa oculta. A continuación, sigue una capa oculta, que consta de cualquier número de neuronas o unidades ocultas colocadas en paralelo. Cada neurona realiza una suma ponderada de las entradas, que luego pasa por una función de activación no lineal, también llamada “función de la neurona”.

4.7 FUNCIÓN DE ACTIVACIÓN

En el mundo de las redes neuronales, las funciones de activación juegan un papel fundamental. Son las encargadas de definir la relación matemática entre las señales que entran a una neurona y el valor final que sale de ella, impactando también en el resultado final de toda la red. Pero lo más importante es que introducen la no linealidad en el sistema.

Las funciones lineales solo pueden crear relaciones sencillas entre entradas y salidas, como líneas rectas. En cambio, el mundo real está lleno de relaciones mucho más complejas, y las redes neuronales necesitan esa capacidad no lineal para poder

funcionar. Las funciones de activación no lineales permiten a las redes neuronales modelar estas relaciones complejas, lo que las hace tan poderosas para tareas como el reconocimiento de patrones o la predicción (T. Chen; H. Chen, p. 1995, 911-917).

La función logística mostrada en la Figura 12 se elige para la capa oculta porque converge más rápido hacia una solución y, por lo tanto, reduce el costo de computación para la capa oculta con múltiples nodos. La serie temporal financiera bajo consideración es altamente no lineal y como resultado, requiere una función suficientemente no lineal para representar todas las propiedades de la serie.

$$g(x) = \frac{e^x}{1 + e^x} \quad (2)$$

Donde x es el resultado de la suma ponderada de cada neurona. Las neuronas de la capa de salida son lineales y solo calculan la suma ponderada de las entradas.




Figura 12: Diagrama de la Función de Activación Sigmoidea (L. R. Marwala, 2010, p. 25).

No está claro si diferentes funciones de activación tienen efectos significativos en el rendimiento de las redes. Una red puede tener diferentes funciones de activación para diferentes nodos en las mismas o diferentes capas. Las funciones como Tanh o Arctan, que producen tanto valores positivos como negativos, tienden a permitir un

entrenamiento más rápido que las funciones que producen solo valores positivos, como una función logística, debido a un mejor acondicionamiento numérico (X. Zhang; J. Mesirov; D. Waltz, 1992, p. 1049-1063).

La función de activación Tang se representa por la función:

$$g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

Y se representa por el siguiente diagrama:




Figura 13: Diagrama de una Función de Activación Tanh (L. R. Marwala, 2010, p. 25).

4.8 SUPPORT VECTOR MACHINE

Los enfoques tradicionales de redes neuronales tienen desafíos de generalización y ocasionalmente producen modelos que pueden sobre ajustarse a los datos. Esto es una consecuencia de los algoritmos de optimización utilizados para seleccionar los parámetros del modelo y las medidas estadísticas utilizadas para seleccionar el modelo que aproxima la relación entre la entrada y la salida. Las bases de las máquinas de vectores de soporte (SVM) fueron desarrolladas por Vapnik (C. Cortes; V. Vapnik, 1995,

273-297) y están ganando popularidad debido a múltiples características atractivas y un rendimiento empírico prometedor. Los modelos SVM están formulados utilizando el principio de Minimización del Riesgo Estructural (SRM), que se ha demostrado ser superior al principio de Minimización del Riesgo Empírico (ERM) empleado por las redes neuronales convencionales. SRM minimiza el límite superior del riesgo esperado, en oposición a ERM que minimiza el error empírico en los datos de entrenamiento. SRM dota a SVM de una mayor capacidad de generalización, que es el objetivo del aprendizaje estadístico (L. R. Marwala, 2010, p. 30-38).




Figura 14: Clasificación: Caso Lineal Separable (V. Rafael, 2019, p. 1.)

Las SVM mapean el vector de entrada a un espacio dimensional superior donde se construye un hiperplano separador maximal. Se construyen dos hiperplanos paralelos a cada lado del hiperplano que separa los datos. El hiperplano separador es el hiperplano que maximiza la distancia entre los dos hiperplanos paralelos. Se realiza la suposición de que cuanto mayor sea el margen o la distancia entre estos hiperplanos paralelos, mejor será el error de generalización del clasificador (V. Vapnik, 1995, p. 3-28).

Consideramos puntos de datos de la forma $\{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)\}$. Donde $y_n = \pm 1$, una constante que denota la clase a la que pertenece ese punto x_n con $n = \text{número de muestra}$. Cada x, n es un vector real p -dimensional. La escala es importante para protegerse contra variables (atributos) con una varianza mayor. Para visualizar estos datos de entrenamiento, utilizamos el hiperplano divisor, que toma la forma $wx + b = 0$ Donde b es un escalar y w es un vector p -dimensional. El vector w apunta perpendicularmente al hiperplano separador. Agregar el parámetro de compensación b nos permite aumentar el margen. En ausencia de b , el hiperplano se ve obligado a pasar por el origen, lo que restringe la solución. Al igual que con el interés en el margen máximo, estamos interesados en las SVM y los hiperplanos paralelos. Los hiperplanos paralelos se pueden describir mediante la ecuación:

$$f(x) = wx + b = 1 \wedge wx + b = -1 \quad (4)$$

Si los datos de entrenamiento son linealmente separables, podemos seleccionar estos hiperplanos para que no haya puntos entre ellos y luego intentar maximizar su distancia. Por geometría, encontramos que la distancia entre los hiperplanos es $\frac{2}{|w|}$. Por lo tanto, queremos minimizar $|w|$. Para excitar los puntos de datos, necesitamos asegurarnos de que para todos los i , ya sea:

$$f(x) = wx_i - b \geq 1 \vee wx_i - b \leq -1 \quad (5)$$

Esto se puede escribir como:

$$f(x) = y_i (wx_i - b) \geq 1, \quad \text{Donde } 1 \leq i \leq n \quad (6)$$




Figura 15: Margen Hiperplano Máximo Entrenado con Ejemplos de Dos Clases (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 186)

4.8.1 Clasificación Lineal

Antes de considerar hiperplanos de N dimensiones, echemos un vistazo a un ejemplo simple de 2 dimensiones. Supongamos que deseamos realizar una clasificación, y nuestros datos tienen una variable objetivo con dos categorías. También supongamos que hay dos variables predictoras que tienen valores continuos. Si representamos los puntos de datos utilizando el valor de una variable predictora en el eje X y la otra en el eje Y , podríamos obtener una imagen como la que se muestra en la Figura 16. Una categoría de la variable objetivo está representada por rectángulos mientras que la otra categoría está representada por óvalos. En este ejemplo idealizado, los casos con una categoría están en la esquina inferior izquierda y los casos con la otra categoría están en la esquina superior derecha, los casos están completamente separados. El análisis de SVM intenta encontrar un hiperplano de 1 dimensión que separe los casos según sus categorías objetivo. Hay un número infinito de líneas posibles; la pregunta es cuál es la mejor línea y cómo definimos la línea óptima. Las líneas punteadas dibujadas paralelas a la línea divisoria marcan la distancia entre la línea divisoria y los vectores más

cercanos a la línea. La distancia entre las líneas punteadas se llama margen. Los vectores (puntos) que limitan el ancho del margen son los vectores de soporte (H. Bhavsar; M. H. Panchal, 2012, p. 185-188).

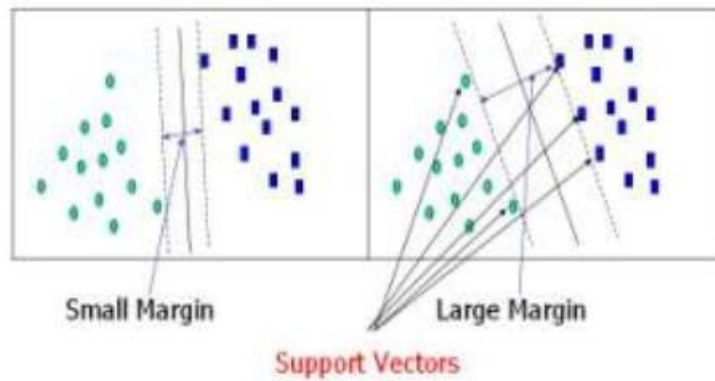


Figura 16: Clasificación de Dos Dimensiones (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 187)

Un análisis de SVM encuentra la línea que está orientada de manera que el margen entre los vectores de soporte se maximice. En la Fig. 16, la línea en el panel derecho es superior a la línea en el panel izquierdo. Desafortunadamente, SVM debe lidiar con:

- A. Más de dos variables predictoras.
- B. Separar los puntos con curvas no lineales.
- C. Casos en los que los grupos no pueden ser completamente separados.
- D. Manejar clasificaciones con más de dos categorías.

4.8.2 Clasificación No Lineal

La forma más sencilla de dividir dos grupos es con una línea recta, un plano o un hiperplano N -dimensional. Pero ¿qué pasa si los puntos están separados por una región no lineal como se muestra a continuación?




Figura 17: Clasificación Multi Dimensional (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 187)

En este caso, necesitamos una línea divisoria no lineal. En lugar de ajustar curvas no lineales a los datos, SVM maneja esto utilizando una función Kernel para mapear los datos en un espacio diferente donde se pueda utilizar un hiperplano para realizar la separación.

$$K(x, y) = (xy + 1)^d \quad (7)$$

Donde d es el grado polinomial de Kernel.




Figura 18: Mapeo de la Función Kernel (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 187)

La función Kernel se puede transformar dentro de un espacio multidimensional haciendo posible crear una separación mediante un hiperplano:

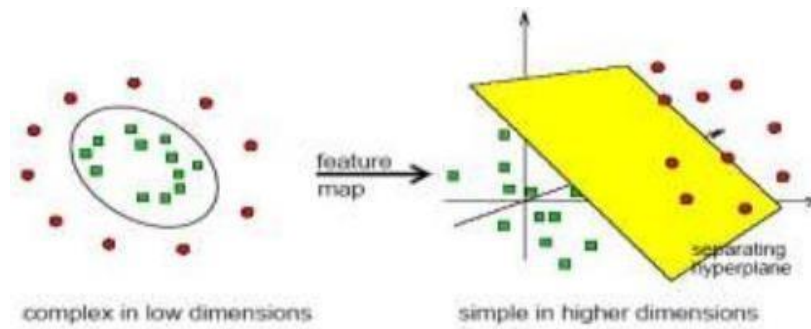


Figura 19: Mapeo en Varias Dimensiones (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 187)

El modelo Kernel polinomial es un Kernel no estacionario. Lo que lo hace funcionar bien en problemas que el entrenamiento del algoritmo se hace con datos normalizados.

$$K(x_i, x_j) = (y x_i^t x_j + r)^d, \quad y > 0 \quad (8)$$

4.8.3 Función de Base Radial (RBF)

La función de base radial (RBF) es una función Kernel comúnmente utilizada en máquinas de vectores de soporte (SVM) para realizar una transformación no lineal de los datos. Esta función calcula la similitud entre pares de puntos de datos en un espacio de características de dimensionalidad superior. La fórmula de la RBF se define como:

$$K(x_i, x_j) = \exp(-y \|x_i - x_j\|^2), \quad y > 0 \quad (9)$$

Donde x_i y x_j son puntos de datos, y es un parámetro que controla la forma de la función y $\|x_i - x_j\|^2$ es la distancia euclidiana al cuadrado entre los puntos en el espacio de entrada original. La función RBF mapea los datos a un espacio dimensionalmente superior donde las clases pueden ser separadas por un hiperplano. La flexibilidad de la RBF para capturar relaciones no lineales entre los datos la hace popular en aplicaciones de clasificación y regresión donde los datos no son linealmente separables en el espacio de entrada original.

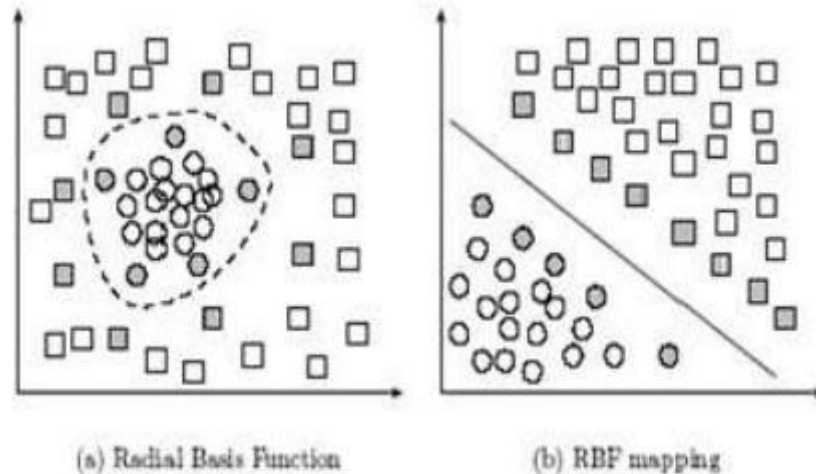


Figura 20: Clasificación Separada con EBF Kernel (Himani Bhavsar, Malhesh H. Panchal, 2012, p. 188)

RBF es la función de Kernel más popular debido a que mapea de forma no lineal a las muestras en un espacio de mayor dimensión, a diferencia del Kernel lineal. Además, también trabaja con menos hiperparámetros que el Kernel polinomial y tiene menos dificultades numéricas (V. Vapnik, 1995, p. 123-167).

4.9 MODELOS NEURO-FUZZY

Los conceptos de modelos difusos (Fuzzy Methods) y modelos de redes neuronales pueden combinarse de varias maneras. El modelo neuro difuso más popular es el modelo Takagi-Sugeno, que se utiliza ampliamente en la modelización basada en datos (R. Babuska; H. Verbruggen, 2003, 73-85).

El modelo basado en reglas Fuzzy de Takagi-Sugeno (TS) requiere solo un pequeño número de reglas para describir modelos complejos y altamente no lineales. El número de reglas puede ser significativamente menor que cuando se aplica el tipo de modelo Fuzzy de Mamdani. Una desventaja del modelo difuso de TS es su presentación menos comprensible en comparación con el tipo de modelo Fuzzy de Mamdani. La idea básica

del modelo TS es el hecho de que un sistema arbitrariamente complejo es una combinación de sub-sistemas mutuamente interconectados. Se determinan regiones correspondientes a sub-sistemas individuales en el espacio de estados bajo consideración. El comportamiento del sistema en estas regiones puede describirse con dependencias funcionales más simples. Si la dependencia es lineal y si se asigna una regla a cada sub-sistema, el modelo Fuzzy TS se puede representar con reglas de la como R_i : Si x_1 es A_{i1} y x_2 es A_{i2} y ... x_n es A_{in} .

Entonces:

$$y_i = a_i x + b_i \quad i = 1, 2, \dots, K. \quad (10)$$

Aquí R es la i -ésima regla y x_1, x_2, \dots, x_n , son las variables de entrada, $A_{i1}, A_{i2}, \dots, A_{in}$ son los conjuntos Fuzzy asignados a las variables de entrada correspondientes, representa el valor de salida de la regla y_i , a_i y b_i son parámetros de la función consecuente. La salida final del modelo Fuzzy TS para una muestra de entrada arbitraria se puede calcular utilizando la siguiente expresión:

$$Y_k = \frac{\sum_{i=1}^K \beta_i(x_k) y_i(x_k)}{\sum_{i=1}^K \beta_i(x_k)}, \quad K = 1, 2, 3, \dots, N \quad (11)$$

Donde β_i representa la fuerza de la regla i -ésima y $y_i(x_k)$ es la salida de la regla i -ésima para la entrada de muestra x_k k -ésima (D. Kukolj, 2004, 272).

4.9.1 Arquitectura del Modelo Neuro Fuzzy

En el caso más general, una red adaptativa es heterogénea y cada nodo puede tener una función de nodo diferente. También que cada enlace en una red adaptativa se utiliza simplemente para especificar la dirección de propagación de la salida de un nodo.

Generalmente no hay pesos (Weights) ni parámetros asociados con los enlaces. La Fig. 21 muestra una red adaptativa típica con dos entradas y dos salidas.

Los parámetros de una red adaptativa están distribuidos en los nodos de la red, por lo que cada nodo tiene un conjunto de parámetros locales. La unión de estos conjuntos de parámetros locales es el conjunto de parámetros general de la red. Si el conjunto de parámetros de un nodo no está vacío, entonces su función de nodo depende de los valores de los parámetros; usamos un cuadrado para representar este tipo de nodo adaptativo. Por otro lado, si un nodo tiene un conjunto de parámetros vacío, entonces su función está fija; usamos un círculo para denotar este tipo de nodo fijo. Las redes adaptativas generalmente se clasifican en dos categorías según el tipo de conexiones que tienen: tipos de alimentación directa y recurrente.




Figura 21: Red Adaptativa de Avance Presentada por Capas (JYH-Shing Roger Jang; Chuen-Tsai Sun, 1994, p. 388).

La red adaptativa mostrada en la Fig. 21 es una red de alimentación directa, ya que la salida de cada nodo se propaga desde el lado de entrada (izquierda) hacia el lado de salida (derecha). Si hay un enlace de retroalimentación que forma un camino circular en una red, entonces la red es una red recurrente. La Fig. 22 es un ejemplo (Desde el punto de vista de la teoría de grafos, una red de alimentación directa se representa mediante un

gráfico dirigido acíclico que no contiene ciclos dirigidos, mientras que una red recurrente siempre contiene al menos un ciclo dirigido).




Figura 22: Red Adaptativa Recurrente (JYH-Shing Roger Jang; Chuen-Tsai Sun, 1994, p. 388),

En la representación en capas de la red adaptativa de alimentación directa en la Fig. 21, no hay enlaces entre nodos en la misma capa y las salidas de los nodos en una capa específica siempre están conectadas a los nodos en capas sucesivas. Esta representación generalmente se prefiere debido a su modularidad, ya que los nodos en la misma capa tienen la misma funcionalidad o generan el mismo nivel de abstracción sobre los vectores de entrada (JYH-Shing Roger Jang; Chuen-Tsai Sun, 1994, p. 378-402)

Otra representación de una red de avance es la de ordenamiento topológico, que etiqueta los nodos en una secuencia ordenada 1, 2, 3, ..., de tal manera que no haya enlaces del nodo i al nodo j siempre que i sea menor que j .




Figura 23: Red de Avance de Ordenamiento Topológico (JYH-Shing Roger Jang; Chuen-Tsai Sun, 1994, p. 389),

La Figura 23 es la representación de ordenamiento topológico del diagrama en la Figura 21. Esta representación es menos modular que la representación en capas, pero facilita la formulación de la regla de aprendizaje, como se verá en la siguiente sección. Conceptualmente, una red adaptativa Feedforward es en realidad un mapeo estático entre sus espacios de entrada y salida. Este mapeo puede ser una relación lineal simple o altamente no lineal, dependiendo de la estructura (disposición de nodos y conexiones, etc.) de la red y la función para cada nodo. Aquí nuestro objetivo es construir una red para lograr un mapeo no lineal deseado que esté regulado por un conjunto de datos que consiste en un número de pares de entrada-salida deseados de un sistema objetivo. Este conjunto de datos suele llamarse conjunto de datos de entrenamiento y el procedimiento que seguimos para ajustar los parámetros para mejorar el rendimiento de la red se denomina regla de aprendizaje o algoritmo de aprendizaje. Por lo general, el rendimiento de una red adaptativa se mide como la discrepancia entre la salida deseada y la salida de la red bajo las mismas condiciones de entrada. Esta discrepancia se llama medida de error y puede asumir diferentes formas para diferentes aplicaciones.

4.10 MEDIA MÓVIL AUTORREGRESIVA (ARMA)

El modelo ARMA se representa mediante una serie de ecuaciones. Estas ecuaciones combinan la ecuación autorregresiva (AR) y la ecuación de media móvil (MA). Los modelos autorregresivos se basan en el concepto de que el valor actual de la serie temporal x_t , puede explicarse como una función de p valores pasados, x_{t-1} , x_{t-2} , x_{t-3} , ... , x_{t-p} , donde p determina el número de períodos en el pasado seleccionados para predecir el valor actual (Bogacka Barbara, 2008, p. 84-90). Las ecuaciones se simplifican primero al reducir la serie temporal a media cero, es decir, se resta la media muestral. La serie se ajusta a la media de la siguiente manera:

$$x_{ajustado} = x - x_{promedio} \quad (12)$$

Donde x es la serie temporal original, $x_{promedio}$ es su media muestral, y $x_{ajustado}$ es la serie ajustada a la media. Un modelo AR expresa una serie temporal como una función lineal de sus valores pasados. El orden del modelo AR es el número de valores pasados con rezago que deben incluirse en el modelo. El modelo AR más simple es el modelo con solo un valor pasado con rezago, que es el modelo autorregresivo de primer orden, o AR (1):

$$x_t + a_1 x_{t-1} = e_t \quad (13)$$

Donde x_t es la serie ajustada a la media en el día t , x_{t-1} es la serie en el día anterior, a_1 es el coeficiente autorregresivo de *rezago* -1 , y e_t es el parámetro de ruido. El ruido también puede denominarse error, choque aleatorio y residuo. Se asume que los residuos e_t ocurren de manera aleatoria en el tiempo o ruido blanco (no autocorrelacionado) y tienen una distribución gaussiana. Al reescribir la ecuación para el modelo AR (1) como:

$$x_t = e_t - a_1 x_{t-1} \quad (14)$$

se ilustra que el modelo AR (1) tiene la forma de un modelo de regresión en el que x_t se regresa a su valor anterior. En esta forma, a_1 es análogo al coeficiente de regresión y e_t a los residuos de regresión.

Los modelos autorregresivos de orden superior incluyen más términos con rezago de x_t , como predictores. Por ejemplo, el modelo autorregresivo de tercer orden, AR (3), se expresa como

$$x_t + a_1x_{t-1} + a_2x_{t-2} + a_3x_{t-3} = e_t \quad (15)$$

Donde a_1, a_2, a_3 son los coeficientes autorregresivos en los rezagos 1, 2 y 3. El orden p -ésimo modelo autorregresivo, AR(p), incluye términos rezagados de los años $t - 1$ a $t - p$.

El modelo de media móvil (MA) es otro subconjunto del modelo ARMA en el que la serie temporal se considera una media móvil (ponderada de manera desigual) de una serie de choques aleatorios e_t . El modelo de media móvil de primer orden, o MA (1), se expresa como:

$$x_t = e_t + c_1e_{t-1} \quad (16)$$

Donde e_t, e_{t-1} son los residuos en los tiempos t y $t - 1$, y c es el coeficiente de media móvil de primer orden. Al igual que con los modelos AR, los modelos de media móvil de orden superior incluyen términos con mayor rezago. Por ejemplo, el modelo de media móvil de segundo orden, MA (2), es:

$$x_t = e_t + c_1e_{t-1} + c_2e_{t-2} + c_3e_{t-3} \quad (17)$$

Se utiliza la letra q para el orden del modelo de media móvil. El modelo de media móvil de segundo orden es MA (q) con $q = 2$ (Rastogi Vaibhav, 2023, p. 1).

El modelo autorregresivo incluye términos rezagados en la propia serie temporal, y el modelo de media móvil incluye términos rezagados en el ruido o residuos. Al incluir ambos tipos de términos rezagados, llegamos a lo que se llama modelos autorregresivos de media móvil, o modelos ARMA, cuyo orden se incluye entre paréntesis como ARMA

(p, q) , donde p es el orden autorregresivo y q el orden de la media móvil. El modelo ARMA más simple y utilizado es el modelo ARMA (1,1):

$$x_t + a_1 x_{t-1} = e_t + c_1 e_{t-1} \quad (18)$$

4.11 RANDOM WALKING

La caminata aleatoria, abreviado en inglés como RW (Random Walks), es una formalización matemática de la trayectoria que resulta de hacer sucesivos pasos aleatorios. Este término fue introducido por Karl Pearson en 1905 (R. F. Victoria, 2018, p. 1).

Los resultados del estudio de las caminatas aleatorias han sido aplicados a muchos campos como la computación, la física, la química, la ecología, la biología, la psicología o la economía. Podemos decir que un proceso estocástico sigue una caminata aleatoria si se cumple que:

$$Y_t = e_t + Y_{t1} \quad (19)$$

Donde e_t es ruido blanco (Referencia a variables independientes e idénticamente distribuidas).

Si Y_t sigue una caminata aleatoria, el mejor pronóstico es el valor actual.

$$E[y_t | y_{t1}, y_{t2}, y_{t3}, \dots] = y_{t1} \quad (20)$$

En un principio, Random Walk se refiere a una serie temporal que no capta tendencia ni estacionalidad, es decir, lo único que encontramos es la serie temporal con el error e_t .

4.12 IMPACTO DE LA INTELIGENCIA ARTIFICIAL

La inteligencia artificial tiene un impacto significativo en diversos aspectos de la sociedad y los negocios, transformando la forma en que interactuamos con el mundo y conducimos nuestras actividades diarias (Nelly Flores, 2023, p. 1). Algunos de los impactos más destacados de la IA incluyen la automatización y eficiencia de las tareas repetitivas y procesos. Ofrecer experiencias personalizadas a los usuarios en diferentes sectores. La capacidad de la IA para analizar grandes conjuntos de datos en tiempo real proporciona información valiosa que guía la toma de decisiones informadas en diversos campos, como la medicina, la industria automotriz y el servicio al cliente e impulsar la creación de productos y servicios innovadores que antes eran difíciles de imaginar

Debido a los cambios globales y transversales que han provocado los avances digitales, actualmente se habla de una nueva revolución tecnológica que está afectando a todo el sector de la sociedad. Poco a poco estos cambios se han ido introduciendo a las diferentes áreas de nuestras vidas, yendo desde las tareas más simples como identificaciones de rostros en las cámaras fotográficas, a la introducción de algoritmos capaces de predecir comportamientos en los procesos de elecciones políticas.

4.13 MERCADOS FINANCIEROS

Los mercados financieros son un entorno donde se lleva a cabo el intercambio de activos financieros, como acciones, bonos, divisas, materias primas, entre otros. Estos mercados facilitan la interacción entre inversores, empresas, gobiernos y otras entidades que desean comprar o vender activos financieros. En los mercados financieros, los precios de los activos se determinan a través de la oferta y la demanda. Los inversores compran y venden activos en función de sus expectativas sobre el rendimiento futuro de esos activos y las condiciones del mercado (Raisin GmbH, 2024, p. 1).

Los mercados financieros desempeñan varios roles importantes en la economía, incluyendo la asignación eficiente de recursos, la facilitación del financiamiento para empresas y gobiernos, la mitigación de riesgos a través de instrumentos como los seguros y los derivados, y la determinación de precios de referencia para productos y servicios. También existen diferentes tipos de mercados financieros, como el mercado de valores, donde se negocian acciones, el mercado de bonos, donde se negocian bonos y otros instrumentos de deuda, el mercado de divisas, donde se negocian monedas extranjeras, y el mercado de materias primas, donde se negocian productos básicos como el petróleo, el oro y los productos agrícolas. Estos mercados pueden operar de manera física en lugares como bolsas de valores o de manera electrónica a través de plataformas en línea.

4.14 ÍNDICES DE MERCADO

Un índice de mercado se define como una medida estadística de los cambios en una cartera de acciones que representan una parte del mercado en general (una pendiente). Esencialmente, el índice del mercado es una muestra más pequeña del mercado que es representativa del conjunto. Con la creciente importancia del mercado de valores en diferentes sociedades, índices como el JSE All Share, el FTSE, DJIA, Nikkei y Nasdaq composite se han convertido en parte del vocabulario cotidiano. El índice se utiliza como medida del rendimiento del mercado y el cambio en el precio representa el cambio proporcional de las acciones incluidas en el índice (Standard Bank, 2007, p. 1).

4.15 HIPÓTESIS SOBRE EFICIENCIA DEL MERCADO

La prueba de la Hipótesis del Mercado Eficiente (EMH) ha sido investigada por muchos años. El término "mercado eficiente" afirma que, en promedio, la competencia causará que los efectos completos de la nueva información sobre los valores intrínsecos se

reflejen instantáneamente en los precios reales. Se creía que cuando surge información, las noticias se difunden muy rápidamente y se incorporan en los precios de los valores sin demora. La implicación de esta hipótesis es que el análisis técnico de valores y el análisis fundamental de las empresas no generarían retornos más extraordinarios para los inversores que una estrategia de "comprar o mantener" (E. Fama, 1970, p. 382-417).

La EMH se basa en:

- La afirmación de que los precios de las acciones reflejan el verdadero valor de las acciones.
- La ausencia de oportunidades de arbitraje en la economía dominada por agentes racionales que maximizan sus beneficios.
- La hipótesis de que toda la información disponible llega al mercado de manera aleatoria y se refleja completamente en los precios de mercado.

La EMH está relacionada con el concepto de aleatoriedad, que afirma que los precios futuros de las acciones se alejan aleatoriamente de los precios pasados (E. Fama, 1965, p. 34-105). La razón es que la nueva información se refleja inmediatamente en el precio de las acciones y el precio futuro también reflejará información que llega de manera aleatoria. La ausencia de predictibilidad de los precios hace que la estrategia de "comprar o mantener" sea la más apropiada.

Hay tres tipos de EMH:

Eficiencia en la Forma Débil: Esta forma de eficiencia establece que la información del precio pasado está completamente incorporada en el precio actual y no tiene ningún poder predictivo. Esto significa que predecir los retornos futuros de un activo basado en análisis técnico es imposible.

Eficiencia en la Forma Semi-fuerte: esta forma de eficiencia establece que cualquier información pública está completamente incorporada en el precio actual de un activo. La información pública incluye los precios pasados y también los datos reportados en los estados financieros de una empresa, anuncios de ganancias y dividendos, la situación financiera de los competidores de la empresa, expectativas sobre factores macroeconómicos, etc.

Eficiencia en la Forma Fuerte: esta forma de eficiencia establece que el precio actual incorpora toda la información, tanto pública como privada. Esto significa que ningún actor del mercado puede obtener consistentemente beneficios incluso si opera con información que no es de conocimiento público.

Esto es explicado por Cuthberston como:

$$E(p_{j,t+1}|\partial_t) = [1 + E(r_{j,t+1}|\partial_t)]p_{jt} \quad (21)$$

Donde E es el operador de valor esperado, $p_{j,t+1}$ es el precio del valor j en el tiempo $t + 1$, $r_{j,t+1}$ es el rendimiento del valor j durante el período $t + 1$, y ∂_t es el conjunto de información disponible para los inversores en el tiempo t . El lado izquierdo de la fórmula $E(p_{j,t+1}|\partial_t)$ denota el precio esperado al final del período en el valor j , dado la información disponible al principio del período ∂_t . En el lado derecho, $1 + E(r_{j,t+1}|\partial_t)$ denota el rendimiento esperado durante el próximo período de valores que tienen la misma cantidad de riesgo que el valor j (K. Cuthbertson, 1996, p. 91-116).

4.15.1 Estudios de Evaluación de la EMH

Los estudios empíricos previos sobre la prueba de la EMH han utilizado principalmente modelos econométricos como la prueba de corrida, la prueba de correlación serial y la

prueba de razón de varianza. La prueba de correlación serial y las pruebas de corrida se utilizan para probar la dependencia de los precios hacia las acciones. Encontrar alguna forma de dependencia en los precios permite a los pronosticadores utilizar estas relaciones para predecir precios o rendimientos futuros, refutando así la EMH (A. Thomspson; M. Ward, 1995, p. 33-63). Este tipo de prueba se enfoca en la eficiencia de la forma débil. La validez de la hipótesis se confirma al encontrar una correlación cero.

E. Fama hizo un estudio sobre una muestra de 30 acciones industriales de Dow Jones y encontró que la correlación serial que existía era demasiado pequeña para cubrir los costos de transacción del comercio. También encontraron que las reglas simples de negociación técnica habrían podido predecir los cambios en el promedio industrial de Dow Jones. La investigación posterior ha encontrado que las ganancias de las estrategias no son suficientes para cubrir los costos de transacción. De hecho, estos estudios son consistentes con la eficiencia de la forma débil. Otra forma de probar este tipo de eficiencia es encontrar relaciones estadísticas entre precios pasados y precios futuros. Estas relaciones permiten a los pronosticadores hacer predicciones sobre los rendimientos futuros del mercado de valores. Se han utilizado diversos métodos estadísticos para probar la EMH, como la heteroscedasticidad condicional autorregresiva (ARCH), la heteroscedasticidad condicional autorregresiva generalizada (GARCH) y el autorregresivo móvil (ARMA) (R. Balvers; T. Cosimano; M. McDonald, 1990, p. 1109-1128), (D. Keim; R. Stambaugh, 1986, p. 357-390) (D. Bao; Z. Yang, 2006, p. 620-627). Se puede argumentar que el enfoque econométrico tradicional basado en modelos con especificaciones simples y parámetros constantes, como los modelos ARMA de Box-Jenkins, no pueden responder a la dinámica inherente en series económicas y financieras (A. Timmermann; C. Cranger, 2004, p. 15-27). Sin embargo, el debate sobre las ganancias provenientes del uso de modelos no lineales aún no ha

llegado a un consenso (M. Clements; P. Franses; N. Swanson, 2004, p. 169-183) lo cual ha estimulado a la investigación en áreas como la selección de modelos no lineales, la estimación y los enfoques de evaluación.

La eficiencia semi-fuerte se refiere a la información disponible públicamente. La prueba para esta forma de eficiencia se centra en la evaluación de la velocidad y precisión del ajuste de los precios de las acciones debido a la disponibilidad de la información. La información que crea ajustes significativos en los precios de las acciones incluye anuncios de ganancias, cambios en la política de dividendos, capitalizaciones, anuncios de planes de fusión, la situación financiera de la competencia, expectativas sobre factores macroeconómicos, etc. Probar esta forma de eficiencia es bastante complejo. La forma en que generalmente se hace es tratar de predecir un precio futuro utilizando diferentes metodologías de fijación de precios de activos y luego comparar el precio con el ajustado. La diferencia entre los dos precios se analiza entonces para determinar la velocidad y la precisión de los ajustes (A. Thompsom; M. Ward, 1995, p. 33-63).

La eficiencia de la forma fuerte se prueba evaluando si hay individuos que tienen acceso a información privada que les ayuda a obtener rendimientos por encima del promedio en el mercado. Si hay un inversor que constantemente supera al mercado, entonces hay evidencia de la falta de eficiencia de la forma fuerte.

4.16 LA IA EN LOS MERCADOS FINANCIEROS

La revolución tecnológica también ha introducido la inteligencia artificial en los mercados financieros, transformando la forma en que se toman decisiones, se gestionan activos y se detecta el fraude.

La IA, como símbolo del presente y futuro del sector financiero, afecta todas las áreas que abarca, en las cuales la velocidad y precisión de la computación digital están en aumento (Njegovanović, 2018, p. 58-66). Las operaciones financieras modernas serían imposibles sin la tecnología digital y los algoritmos capaces de procesar y analizar la vasta cantidad de datos que provienen de la existencia y operaciones cotidianas de las instituciones financieras y los mercados. Por esta razón, y por muchas otras, el sector financiero es uno de los primeros en adoptar la IA (Bughin, Hazan, Ramaswamy, Chui, Allas, Dahlstöm, Henke, Trench, 2017, p. 6-19). Además, el Informe de Microsoft, basado en encuestas y entrevistas a líderes de IA en 277 empresas, en 7 sectores, incluido el sector de servicios financieros, en 15 países europeos, realizado por Ernst & Young (EY), dice que las empresas actualmente líderes en términos de madurez de IA, entre otros, son los servicios financieros (Microsoft; EY; Kieboj, 2018, p. 1). De todos los sectores encuestados en este estudio, el sector de servicios financieros ha mostrado que espera el mayor porcentaje de beneficios empresariales del uso de la IA en el futuro. Más específicamente, en la parte del Informe que examina los beneficios de usar IA en el sector de servicios financieros, las respuestas a la pregunta sobre qué beneficios empresariales esperan generar las empresas en este sector a través de la IA, fueron que se esperan los siguientes porcentajes de beneficios en estas áreas:

- Atracción de clientes 78%.
- Optimización empresarial 84%.
- Empoderamiento de empleados 67%.
- Transformación de productos y servicios 73%.

Actualmente estamos experimentando el comienzo de una nueva revolución industrial, en la que la IA y el aprendizaje automático están en la vanguardia, transformando

seriamente la sociedad y la economía. Por lo tanto, surge una pregunta lógica, que también coincide con nuestra pregunta de investigación, es decir: ¿cómo está transformando la IA al mercado de valores?

La IA se puede utilizar para mejorar la eficiencia en los mercados financieros a través de diversas aplicaciones clave. Por ejemplo, en la gestión de riesgos y detección de fraudes, los algoritmos de IA analizan grandes volúmenes de datos en tiempo real para identificar patrones sospechosos y minimizar riesgos crediticios. Además, la IA permite la predicción del mercado al analizar datos financieros, que es el tema principal de esta investigación. La automatización impulsada por la IA agiliza procesos financieros como la contabilidad y la generación de informes, reduciendo errores humanos y permitiendo un enfoque en actividades estratégicas. Estas aplicaciones demuestran cómo ha mejorado significativamente la eficiencia en los mercados financieros (Barcelona Business School, 2023, p. 1).

4.16.1 Gestión de Riesgo

La IA ha revolucionado a la gestión de riesgo al ofrecer herramientas avanzadas que permiten identificar, predecir y mitigar riesgos de manera más eficiente y precisa. A través de algoritmos sofisticados. La IA analiza grandes volúmenes de datos en tiempo real para detectar patrones sospechosos, prevenir fraudes y evaluar riesgos crediticios con mayor precisión. Esta capacidad predictiva y analítica permite a las instituciones financieras anticiparse a posibles amenazas, tomar decisiones informadas y adoptar medidas preventivas para proteger sus activos y garantizar la estabilidad financiera en un entorno cada vez más complejo y dinámico (Mónica Jiménez, 2023, p. 1). Dentro de las optimizaciones en el análisis de riesgo se encuentra la detección de fraudes, pues mediante las mejoras que hay en la cantidad y calidad de la gestión de datos, es más

fácil poder determinar un fraude de forma rápida y eficiente. Pese a esto, también existen otras formas de utilizar la IA. Como por ejemplo en la predicción y prevención de Riesgos. La IA puede predecir posibles situaciones de alto riesgo que podrían ocurrir en el futuro, permitiendo a las organizaciones tomar medidas preventivas para mitigar los impactos negativos.

4.16.2 Automatización de Procesos

La automatización de procesos financieros mediante inteligencia artificial es fundamental para mejorar la eficiencia y precisión en la gestión financiera de las empresas. Esta automatización permite generar informes financieros en tiempo real, optimizar tareas repetitivas, y facilitar la toma de decisiones estratégicas. Al integrar la IA en los procesos financieros, se logra una visión completa y en tiempo real de los datos financieros, reduciendo errores, agilizando operaciones y mejorando la seguridad al limitar el acceso no autorizado. La colaboración entre equipos financieros y otros departamentos es clave para impulsar la eficiencia global de la organización, y la automatización financiera debe ser un proceso en constante evolución, con monitoreo continuo para identificar áreas de mejora y realizar ajustes necesarios.

A través de sistemas especializados en finanzas, es posible analizar datos financieros, identificar patrones y predecir tendencias, automatizando tareas como la generación de informes y la reconciliación de transacciones (Grupo Sistemas, 2023, p. 1). Esta automatización inteligente, que combina IA y Machine Learning, segmenta transacciones, agiliza procesos contables y financieros, y mejora la eficiencia en la gestión financiera. Además, tecnologías como el reconocimiento óptico de caracteres (OCR) permiten digitalizar documentos financieros, mientras que el Procesamiento del

Lenguaje Natural (PLN) facilita la identificación de proveedores y la detección de fraudes mediante el análisis de textos financieros y comunicaciones (YooZ, 2023, p. 1).

Asimismo, los asistentes virtuales impulsados por IA brindan asesoramiento financiero personalizado a los clientes, mientras que los algoritmos de trading ejecutan operaciones en tiempo real con mayor rapidez y precisión que los operadores humanos. Esto ha resultado en un aumento significativo en la inversión en activos financieros y una mayor adopción de estrategias basadas en modelos matemáticos y algoritmos para optimizar procesos como el balanceo de carteras (Steven Dunne, 2020, p. 1).

4.17 FORECASTING

La predicción es un intento de predecir cómo ocurrirá un evento futuro. El objetivo principal de predecir la ocurrencia de este evento es tomar mejores decisiones. Hay dos enfoques principales para la predicción, explicativo (causal) y de series temporales (S. Makridakis; Wheelwright; McGEE, 1997, p. 345-346). La predicción explicativa asume una relación de causa y efecto entre las entradas y salidas. Según la predicción explicativa, cambiar las entradas afectará la salida del sistema de manera predecible, asumiendo que la relación de causa y efecto es constante. A diferencia de la predicción explicativa, la predicción de series temporales trata al sistema como una caja negra y se esfuerza por descubrir los factores que afectan su comportamiento. Hay dos razones para querer tratar un sistema como una caja negra. Primero, es posible que el sistema no se comprenda y, aunque se comprenda, puede ser extremadamente difícil medir las relaciones que se supone que gobiernan su comportamiento. En segundo lugar, la principal preocupación puede ser solo predecir qué sucederá y no por qué sucede. Las series temporales financieras es una de las áreas menos comprendidas que ha estado

bajo escrutinio durante algún tiempo por razones que son bien conocidas, mejorar los rendimientos de inversión (S. Makridakis; Wheelwright; McGEE, 1997, p. 345-346).

4.17.1 Predicción del Mercado

La predicción del mercado es un proceso fundamental en el ámbito financiero que se apoya en herramientas y técnicas avanzadas, como la IA, para anticipar los movimientos futuros de los mercados. Al igual que en la gestión de riesgos, la IA desempeña un papel crucial al analizar grandes volúmenes de datos en tiempo real, identificar patrones y tendencias, y proporcionar predicciones precisas que ayudan a los inversores a tomar decisiones informadas y a identificar oportunidades de inversión (Wendi Acevedo, 2023). Para predecir los movimientos del mercado financiero con inteligencia artificial, se utilizan diversos tipos de algoritmos que incluyen:

- Algoritmos de aprendizaje Automático: Estos algoritmos son fundamentales para analizar grandes volúmenes de datos financieros, noticias y tendencias económicas, identificar patrones y relaciones en los datos, y generar predicciones sobre los movimientos del mercado.
- Redes Neuronales: Las redes neuronales son un tipo de algoritmo de aprendizaje profundo que imita el funcionamiento del cerebro humano para procesar información y reconocer patrones complejos en los datos financieros, lo que ayuda a predecir tendencias del mercado con mayor precisión.
- Algoritmos de Procesamiento del Lenguaje Natural (PLN): Estos algoritmos permiten analizar y comprender el lenguaje humano en noticias financieras, informes económicos y redes sociales para extraer información relevante que influya en los movimientos del mercado

- **Algoritmos de Análisis Técnico:** Estos algoritmos se basan en el estudio de gráficos de precios históricos y patrones técnicos para predecir futuros movimientos del mercado, lo que ayuda a los inversores a tomar decisiones informadas sobre sus inversiones.

Para entrenar los algoritmos de inteligencia artificial en la predicción del mercado financiero, se utilizan diversos tipos de datos, como datos financieros históricos que incluyen precios de activos y volúmenes de transacciones, noticias y eventos económicos relevantes que puedan influir en los mercados, datos de sentimiento del mercado para capturar la psicología colectiva de los inversores, y datos macroeconómicos como tasas de interés e indicadores económicos clave. Estos datos son fundamentales para el entrenamiento de los algoritmos, permitiendo analizar patrones pasados, evaluar el impacto de eventos y factores económicos en los precios de los activos, y generar predicciones precisas sobre los movimientos futuros del mercado financiero (Eduardo Rodríguez, 2023, p. 1). Dentro de las aplicaciones posibles en los mercados financieros, se puede ver cómo es que los algoritmos simples hechos para tareas lineales han tomado uso de todos los procesos de desarrollo necesarios para especializarse en las tareas demandadas por el mercado financiero.

4.18 MODELIZACIÓN DE PRECIOS Y RETORNO

Los modelos de pronóstico han evolucionado con el tiempo y la complejidad de estos modelos también ha aumentado para poder hacer frente a la creciente complejidad de los mercados. Esta sección presenta los diferentes modelos que se han utilizado anteriormente, los que se están utilizando actualmente y los que todavía están en investigación.

4.18.1 Smoothing

Los métodos de suavizado (Smoothing) se utilizan para determinar el valor promedio alrededor del cual fluctúan los datos. Dos ejemplos de este tipo de enfoque son el promedio móvil y el suavizado exponencial.

Promedios Móviles: Se construyen sumando una serie de datos y dividiendo por el total de observaciones. El número total de observaciones se determina arbitrariamente para comprometer entre la estabilidad y la capacidad de respuesta del pronosticador. El promedio móvil es probablemente el método más ampliamente utilizado para identificar tendencias, ya que hacen un buen trabajo al suavizar estas fluctuaciones aleatorias (G. Box; G. Jenkins, 1970, p. 7-42).

Suavizado Exponencial: Se construye de tal manera que el valor pronosticado es un promedio ponderado de las observaciones anteriores, donde las ponderaciones (Weights) disminuyen con la antigüedad de las observaciones pasadas. El suavizado exponencial tiene uno o más parámetros que determinan la tasa de disminución de los pesos. Estos parámetros pueden determinarse arbitrariamente o por otros métodos intuitivos como el método de mínimos cuadrados.

4.18.2 Ajuste de Curvas

Un gráfico de la historia de diferentes procesos de series temporales exhibe patrones característicos que se repiten con el tiempo. La tendencia a extrapolar tales patrones a menudo es difícil de resistir. Varios métodos de pronóstico se han basado en la premisa de que tal extrapolación es algo razonable. El ajuste de curvas o la minería de datos es el "arte" de sacar conclusiones basadas en información pasada. Cuando se aplica a un esquema de inversión o estrategia comercial, la historia muestra que a menudo tales conclusiones no son válidas una vez que se implementan.

4.18.3 Modelado Lineal

Los modelos de pronóstico de regresión lineal han demostrado su utilidad para predecir rendimientos tanto en mercados desarrollados como en mercados en desarrollo (H. R. Campbell, 1995, p. 773-816). Los modelos de regresión lineal que se han probado pueden predecir correctamente la dirección del mercado más del 60% del tiempo. Se estableció que la hipótesis de la caminata aleatoria (RW), podría predecir la dirección de los precios del mercado el 50%. Puede ser razonable afirmar en este punto que las no linealidades en el comportamiento de los precios de mercado de valores podrían ser la causa de esta incapacidad de los métodos lineales para exhibir una superioridad significativa sobre la hipótesis de la caminata aleatoria. Por esta razón, los métodos de regresión lineal no han podido dar resultados satisfactorios para los inversores (G. Box; G. Kenkins, 1970, p. 339-385). El modelo ARIMA (autorregresivo integrado de media móvil) es uno de los métodos lineales que se ha utilizado extensamente para intentar predecir la dirección de los precios del mercado. El modelo ARIMA es capaz de transformar series temporales no estacionarias en series temporales estacionarias mediante un proceso llamado diferenciación (J. Hamilton; G. Lin, 1996, p. 573-593). En otras investigaciones, se encontró que las técnicas estadísticas de orden superior eran superiores a los modelos ARIMA. Los modelos lineales son simples y como resultado, tienden a querer simplificar un sistema tan complicado como el comportamiento del mercado financiero. Sin embargo, la ventaja de los modelos lineales radica en su simplicidad. Un modelo solo es útil siempre y cuando sus predicciones no se desvíen demasiado del resultado del proceso subyacente. Con los modelos lineales, hay un compromiso entre la simplicidad y la precisión de las predicciones.

4.19 DESAFÍOS LEGALES Y ÉTICOS DE LA IA

El parlamento europeo, en una propuesta de resolución de 2016, hacía referencia a las famosas leyes de Asimov para llamar la atención de la comisión europea sobre la necesidad de adoptar un marco regulatorio para el desarrollo de la robótica y la inteligencia artificial. Sin embargo, estas leyes ficticias no pueden ser una fuente de inspiración relevante para la elaboración de un marco legal que promueva la adopción de la inteligencia artificial y al mismo tiempo considere los riesgos asociados con el uso de estas nuevas tecnologías. Si bien el derecho ha sido influenciado por la ciencia ficción, como lo demuestra la connotación jurídica de las leyes de Asimov, ¿Puede la inteligencia artificial ser regulada por el derecho, y especialmente por las leyes de la Unión Europea?

Es cierto que, en el ámbito mediático, la inteligencia artificial suele recibir un tratamiento más folclórico y fantasioso que científico. Esto se aplica tanto a las promesas, que a menudo son excesivas, como a los riesgos, que a veces son fantasmagóricos. La pregunta sobre si la Unión Europea logrará adoptar una regulación convincente sobre la IA ha estado en la agenda desde que la comisión publicó, el 21 de abril de 2021, una primera versión del AI Act. La propuesta responde a los llamamientos del parlamento y el consejo europeos para la adopción de medidas armonizadas que aseguren el buen funcionamiento del mercado de sistemas de IA, equilibrando sus riesgos y beneficios. Ambiciosamente, el futuro reglamento tiene como objetivo convertir a la Unión en un actor mundial en el desarrollo de una IA segura, confiable y ética (EU Artificial Intelligence ACT, 2024, p. 1).

En su propuesta, la Comisión afirma que las normas sobre IA deberían estar centradas en el factor humano, de manera que las personas puedan confiar en que la tecnología se

utiliza de manera segura y legalmente conforme, especialmente en lo que respecta al respeto de los derechos fundamentales. Este proyecto legislativo, que promueve un enfoque coordinado de las implicaciones humanas de la IA, se basa en preocupaciones sobre la imprevisibilidad, opacidad y autonomía de algunos sistemas de IA, así como en los riesgos de errores y sesgos. Una intervención a nivel de la Unión es necesaria para evitar que enfoques nacionales heterogéneos creen inseguridad jurídica y frenen la penetración de la IA en el mercado europeo. Además, solo un marco regulatorio común de la IA puede garantizar condiciones de competencia justas para las empresas, fortalecer la competitividad de los Estados miembros y proteger la soberanía digital de Europa. El AI Act también tiene como objetivo evitar que una disparidad de normas nacionales debilite los valores de la Unión.

4.19.1 Reflexiones sobre los Reglamentos Existentes

Hasta la fecha, no existe un marco legal o regulatorio dedicado a la inteligencia artificial, ya sea a nivel nacional, europeo o internacional. Sin embargo, se han tomado numerosas iniciativas en Francia, Europa y en el extranjero para determinar si el derecho existente es aplicable a la inteligencia artificial o si es necesario establecer un régimen legal dedicado (Brunessen Bertrand, 2023, p. 122-131).

En Francia, a modo de ejemplo, ha publicado un Libro Blanco sobre inteligencia artificial con el objetivo de proporcionar una visión general de los problemas planteados, dado que la investigación en IA ha logrado avances significativos en la última década. Los avances más conocidos son aquellos realizados en el aprendizaje automático, gracias en particular al desarrollo de arquitecturas de aprendizaje profundo y de redes neuronales multicapa, cuyo aprendizaje se realiza a partir de grandes volúmenes de datos en arquitecturas de cálculo intensivo.

La oficina parlamentaria de evaluación de elecciones científicas y tecnológicas publicó su informe el 15 de marzo de 2017, que también presenta los desafíos éticos, jurídicos, económicos, sociales y científicos de estas tecnologías.

El gobierno lanzó, el 20 de enero de 2017, la iniciativa France IA, compuesta por varios grupos de trabajo, incluido uno dedicado a cuestiones jurídicas, que concluye la necesidad de combinar los mecanismos y regímenes legales actuales, con la flexibilidad contractual para afrontar las evoluciones tecnológicas proporcionando, salvo casos particulares, un nivel de seguridad jurídica satisfactorio.

4.20 OBSTÁCULOS PARA UN MARCO REGULATORIO

La adopción final de un reglamento para establecer normas armonizadas sobre la IA con el fin de preservar los derechos fundamentales y los valores de la UE no se logrará sin intensas controversias, dada la extrema sensibilidad del tema. Miles de enmiendas han sido presentadas por los actores institucionales de la UE. Si bien la Comisión se ha inspirado en las resoluciones del Parlamento Europeo en su propuesta legislativa, será necesario tener en cuenta las posiciones de los Estados miembros y sus estrategias nacionales respectivas para esperar dotar a la IA de un marco legal a nivel europeo. Es cierto que el objetivo perseguido por la UE es ambicioso, ya que se trata de brindar a los ciudadanos europeos confianza en los sistemas de IA, ofreciéndoles garantías sólidas en términos de derechos y libertades, al mismo tiempo que se anima a los operadores a desarrollar la IA para convertir a la UE en un líder mundial en este sector altamente estratégico (Brunessen Bertrand, 2023, p. 122-131).

4.20.1 Obstáculos Técnico-Jurídicos

Aunque no constituye propiamente un obstáculo para la adopción de un futuro reglamento, es importante destacar la abundancia de textos producidos en materia de IA en los últimos años. Las múltiples cartas sobre IA, carentes de carácter vinculante, tienden a difuminar las fronteras entre el derecho y la ética, especialmente cuando se mencionan los derechos fundamentales. Sin mencionar la doctrina cuyo papel es precisamente producir literatura, las instituciones de la UE, especialmente la Comisión y el Parlamento, también se han dedicado a multiplicar las comunicaciones, otras veces para compartir preocupaciones sobre los riesgos asociados con el uso de algoritmos, y también para resaltar los beneficios de recurrir a ciertos sistemas de IA. La inflación de esta literatura gris sobre, acentuada por las recomendaciones de los grupos de expertos, no solo concierne a la UE, ya que se encuentra dentro de instancias nacionales e internacionales, públicas y privadas. Si bien la voluntad de controlar o regular la IA es loable, la producción normativa, que tiende a favorecer la flexibilidad de la “Soft Law” en detrimento de la rigidez de un marco reglamentario clásico, contribuye a socavar la calidad, la autoridad y la legitimidad de un derecho percibido cada vez más como ambiguo. Quizás este sea un primer indicio de la incapacidad de lo jurídico para comprender la IA en toda su complejidad técnica. Y esto es lo que la Comisión parece admitir implícitamente cuando destaca la importancia de los códigos de conducta. Estos códigos, que pueden incluir compromisos voluntarios relacionados con la sostenibilidad ambiental, la accesibilidad para personas con discapacidad y la diversidad de equipos, son, en ciertas condiciones, creados e implementados por los propios proveedores. El principal obstáculo "tecno-jurídico" para la adopción de un reglamento europeo sobre IA radica sin duda en la elección de las definiciones adoptadas por la Comisión, comenzando por la de IA (Anaëlle Martin 2022, p. 1-11).

La primera versión del AI Act opta por la expresión "sistema de IA" en lugar de "IA", esta última refiriéndose más a una disciplina teórica. Los sistemas de IA se definen, en el artículo 3, como software desarrollado utilizando técnicas enumeradas en el anexo I que pueden, para un conjunto dado de objetivos definidos por el ser humano, generar resultados como contenido, predicciones, recomendaciones o decisiones que influyen en los entornos con los que interactúa. Es legítimo cuestionar la oportunidad de agregar la precisión de que los objetivos deben ser definidos por el ser humano. Esta precaución parece hacer eco de las ficticias leyes de la robótica de Asimov a las que el Parlamento Europeo se mostró particularmente sensible en una de sus resoluciones. Esta definición provisional podría ser aligerada o precisada, especialmente en sus aspectos más superficiales como el hecho de que el resultado influye en el entorno. Lo mismo ocurre con la lista indicativa de resultado, que parece traicionar un titubeo conceptual por parte de los redactores. Definir la IA es fundamental para la UE, ya que las definiciones determinan el ámbito de aplicación del texto y buscan permitir que ciertos productos y servicios circulen libremente en el mercado europeo, siempre que cumplan con los requisitos contenidos en el futuro reglamento. El desafío es aún mayor, ya que una definición amplia podría generar inseguridad jurídica y posibles conflictos de interpretación. Un enfoque así sería perjudicial para la innovación y el comercio de productos basados en la IA. Por otro lado, una definición flexible permitiría tener en cuenta los avances técnicos y la dinámica inherente a la materia tecnológica, pero se requiere un mínimo de precisión si se desea garantizar la seguridad jurídica.

4.20.2 Obstáculos Ético-Políticos

Durante las últimas dos presidencias rotativas del consejo, Eslovenia y Francia compartieron textos de compromiso en los que los estados miembros reafirmaron su competencia exclusiva en materia de seguridad nacional, insistiendo en que los sistemas

desarrollados para la investigación científica quedaran excluidos del ámbito de aplicación del AI Act. al igual que aquellos desarrollados para fines militares. La sensibilidad política de un campo como la IA también se manifiesta en el enfoque equilibrado de la Comisión que busca un compromiso entre los requisitos mínimos para regular los riesgos asociados con la IA (en seguridad, salud y derechos fundamentales) y el establecimiento de un marco lo suficientemente flexible para no obstaculizar su desarrollo. La búsqueda de objetivos tan diametralmente opuestos se asemeja a la búsqueda de la cuadratura del círculo, como lo demuestran las reacciones contradictorias suscitadas en la sociedad por la publicación del proyecto de reglamento. Si las asociaciones defensoras de las libertades consideran que el texto es laxo en la garantía de los derechos humanos, los empresarios e inversores digitales están preocupados por el impacto negativo en las Start-ups. Ambos sectores también critican la falta de claridad del texto de la comisión. La UE, siendo ante todo un mercado, no puede ignorar las críticas de los operadores económicos, ya que una regulación demasiado estricta podría desalentar a las empresas de invertir en IA. Esta tensión entre la protección de los principios éticos y legales, por un lado, y la innovación por otro, atraviesa las posiciones y oposiciones de los estados miembros. Las diferencias de estrategias sobre la IA pueden complicar las discusiones y retrasar la adopción del AI Act. Como tecnología altamente política, la IA plantea un problema de soberanía nacional e internacional. Sin embargo, en la esfera pública y mediática, la creación de condiciones favorables para su desarrollo está eclipsada por las preocupaciones sobre las libertades individuales y colectivas. Los expertos advierten sobre los efectos negativos de la tecnología digital en las personas y la sociedad. La utilización de esta tecnología con fines represivos divide a los estados, y las opiniones difieren sobre cómo abordar el asunto. Mientras que algunos países desean tratar este tema por separado,

otros presionan para flexibilizar su uso por parte de las fuerzas del orden. Además, se han producido profundas divergencias entre algunos países y la UE en lo que respecta al equilibrio entre la protección de la privacidad y la seguridad pública. Estas cuestiones son también, sobre todo, éticas. Si el desarrollo de la IA no se controla adecuadamente, algunos sistemas podrían causar daños irreparables a nuestras sociedades, reconfigurando el modelo de democracia y estado de derecho. Estas preocupaciones han sido la base de algunas críticas al proyecto de reglamento. Algunos observadores han señalado que, más allá de la consideración de los derechos humanos, el AI Act. no tiene suficientemente en cuenta los daños sociales. Otras preocupaciones, menos fundamentadas, pero ampliamente difundidas, apuntan a una supuesta laguna en el proyecto de reglamento (Anaëlle Martin 2022, p. 1-11).

4.21 TRANSPARENCIA Y COMPLEJIDAD DE LA INFORMACIÓN

4.21.1 Protección de Datos Personales

La protección de los datos personales, al igual que el RGPD (Règlement Général sur la Protection des Données), el proyecto de regulación sobre IA tiene como objetivo fortalecerla. Sin embargo, debido a problemas de opacidad, complejidad y dependencia de los datos, el uso de ciertos sistemas de IA puede infringir principios como el derecho al respeto de la vida privada y como resultado, la protección de datos personales. Según el RGPD, la protección de datos personales es obligatoria para cualquier información sobre una persona física identificada o identificable. Sin embargo, los avances tecnológicos han modificado las condiciones bajo las cuales una persona física puede ser identificable. El estado anónimo resulta ilusorio cuando una combinación de datos anónimos permite identificar o volver identificable a una persona. Además, la

recopilación de datos con fines de influencia en el comportamiento también tiene un impacto significativo en las personas.

En vista de estos nuevos desafíos, el concepto jurídico de datos personales está siendo cuestionado. Algunos autores han abogado por modificar el marco legal para tener en cuenta las inferencias realizadas a partir de los datos personales (S. Wachter; B. Mittelstadt, 2019, p. 18-78) en lugar de centrarse en los datos y su acceso, como lo hace el derecho de la UE.

4.21.2 Prohibición de la Discriminación

El proyecto de regulación sobre IA pretende complementar el derecho existente en materia de no discriminación al prever requisitos específicos para reducir el riesgo de discriminación algorítmica, especialmente en lo que respecta al diseño y calidad de los conjuntos de datos. Se propone clasificar como de alto riesgo los sistemas utilizados para cuestiones relacionadas con el empleo, ya que pueden afectar las perspectivas laborales y los medios de vida de las personas. Algunos sistemas de IA pueden perpetuar patrones históricos de discriminación, por ejemplo, hacia las mujeres, ciertos grupos de edad, personas con discapacidad, o personas de ciertas etnias u orientaciones sexuales.

La definición jurídica de la discriminación y su prohibición, en el centro del derecho derivado de la UE, presentan limitaciones conceptuales cuando los datos en cuestión son simplemente rastros conductuales. Las limitaciones del derecho y los regímenes jurídicos clásicos para abordar estas formas novedosas de discriminación se hacen evidentes. Las violaciones del derecho al respeto de la vida privada o las prácticas discriminatorias deberían dar lugar a la responsabilidad de los autores. Sin embargo, en

el ámbito de la IA, es extremadamente complejo identificar las causalidades y, por lo tanto, buscar la responsabilidad de los actores involucrados en la toma de decisiones.

4.22 TRANSPARENCIA ALGORÍTMICA

Dado que los motores de inteligencia artificial son diseñados y desarrollados por humanos, se parte del principio de que sus instrucciones deben permanecer explicables. Aquí se apunta a la noción misma de transparencia algorítmica. Sin embargo, la verdadera propiedad intelectual de una inteligencia artificial reside en sus algoritmos. Por lo tanto, en un entorno altamente competitivo, esta transparencia puede parecer utópica. Además, los sistemas de aprendizaje automático más sofisticados a veces pueden resultar ser cajas negras, al punto de que incluso los editores de las soluciones a veces tienen dificultades para explicar adecuadamente la razón detrás de una decisión de IA. Como señala Nozha Boujemaa, directora de investigación en Inria, encargada del lanzamiento de la plataforma TransAlgo.

"Los algoritmos están en todas partes en nuestra vida diaria digital (...). Es crucial entender los mecanismos en juego y asegurarse de que respeten los intereses de los consumidores y los derechos de los ciudadanos" (Nozha Boujemaa, 2018, p. 1).

Es esta capacidad para explicar claramente las razones detrás de una decisión tomada por una IA lo que garantizará esta transparencia algorítmica y sentará las bases para una relación de confianza.

4.22.1 Elección de los Consumidores

Finalmente, los consumidores, con los que las marcas dialogan para generar compromiso, deben ser considerados como socios de estas marcas. La información sobre las técnicas de IA utilizadas para la promoción de las marcas y la posibilidad de

oponerse a cualquier forma de decisión automática de segmentación reforzarán esta confianza, necesaria para la sostenibilidad del mercado. Es importante recordar que, en cuanto a la publicidad conductual, los profesionales han demostrado una gran responsabilidad, ya que han surgido excelentes iniciativas internacionales, como la plataforma paneuropea “Your online choices”, que ofrece a los consumidores la posibilidad de oponerse a este tipo de publicidad (Your Online Choices, 2009, p. 1).

CAPÍTULO 5: METODOLOGÍA DE INVESTIGACIÓN

El presente trabajo se trata de una investigación fundamental y cualitativa que tiene como objetivo identificar y fomentar la gestión de nuevos métodos de predicción de precios en los mercados financieros a través de la inteligencia artificial. También se busca presentar cómo trabaja la inteligencia artificial, aumentando las opciones de inversión para los actores de los mercados financieros. Esta investigación se centró en la construcción de tres modelos de inteligencia computacional, explicando cómo se realizó la construcción de los tres modelos y posteriormente comparándolos con los modelos tradicionales ARMA y RW. Luego se enfoca en la prueba de los modelos, comenzando con el Multilayer Perceptron, seguido por los Support Vector Machines y por último con los sistemas Neuro-Fuzzy.

Para abordar los objetivos planteados en mi investigación, he diseñado una metodología que combina enfoques cualitativos y cuantitativos, permitiéndome explorar a fondo el impacto de los avances tecnológicos en los mercados financieros y la gestión empresarial. En primer lugar, realice una revisión exhaustiva de la literatura existente y un análisis documental para comprender el contexto y los desafíos relacionados con los temas de interés, incluyendo la inteligencia artificial, la eficiencia en los medios de comunicación, la eficiencia del mercado y los desafíos legales de la IA.

Posteriormente, llevaré a cabo un análisis cuantitativo de datos utilizando información financiera histórica proveniente de la bolsa de valores de Johannesburgo (uno de los mercados más importantes de África), para evaluar el impacto de los avances tecnológicos en los mercados de capitales. Emplearé técnicas estadísticas y modelos econométricos como el modelo ARMA y el Random Walking, para analizar tendencias

en los datos recopilados y de esta forma poder compararlos con los modelos no lineales de IA (Multi-Layer Perceptron, Neuro-Fuzzy y Support Vector Regression).

4.23 CONSTRUCCIÓN DE LOS MODELOS

Después de que los datos fueron procesados, el siguiente paso fue la creación de los modelos. Se utilizaron tamaños de ventana de 3, 5, 7 y 10 para la extracción de las características que se ocuparon para entrenar y probar los modelos.

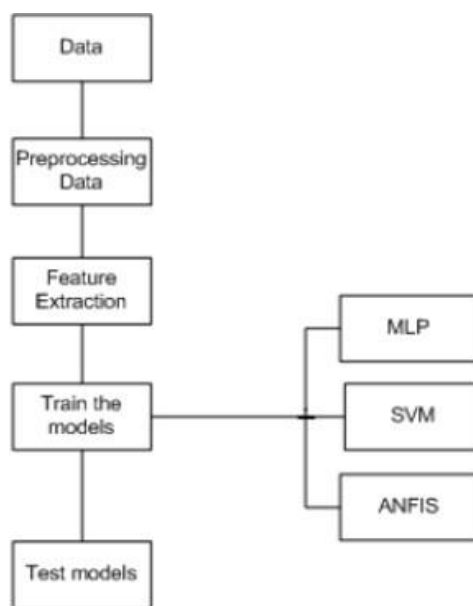


Figura 24: Diagrama de Flujo sobre la Creación de los Modelos

4.23.1 Network Training

El entrenamiento de una red neuronal implica presentarle diferentes patrones de entrada (Inputs) contenidos en los datos para que la red pueda reducir su error empírico y mejorar su rendimiento. El algoritmo utilizado para entrenar la red puede variar dependiendo de la arquitectura de la red, pero el algoritmo de entrenamiento más común al diseñar redes neuronales financieras es el de retro propagación, que es el proceso de propagar los errores a través de la red desde la capa de salida hacia la capa de entrada

durante el entrenamiento. La retro propagación es necesaria porque las unidades ocultas no tienen un valor objetivo de entrenamiento que se pueda utilizar, por lo que deben entrenarse en función de errores de capas anteriores (L. R. Marwala, 2010, p. 20-30)

4.23.2 Número de Iteraciones

El número de iteraciones es importante para encontrar el error mínimo que se puede lograr mediante el entrenamiento. Siempre existe el peligro de quedar atrapado en un mínimo local y luego no poder encontrar el mínimo global. El problema de los mínimos locales se puede mitigar utilizando métodos de optimización como algoritmos genéticos. La primera aproximación al entrenamiento es ejecutar las iteraciones hasta que no haya mejoras en el error. El punto en el que el error de la red ya no mejora se llama convergencia. La segunda aproximación son las interrupciones de entrenamiento-prueba (G. Deboeck; M. Cader, 1994, p. 27-131). El entrenamiento se detiene después de un número predeterminado de iteraciones y se evalúa la capacidad de generalización de la red en el conjunto de prueba, y luego se reanuda el entrenamiento.

La capacidad de generalización de la red es fundamental para predecir los precios futuros de las acciones, y el no saber cuándo detener el entrenamiento puede llevar al sobre entrenamiento, lo que es un problema serio. Ocurre cuando la red neuronal memoriza los patrones de entrada y, por lo tanto, pierde su capacidad de generalizar o hacer predicciones. Es un factor importante en estos sistemas de predicción, ya que su uso principal es predecir sobre datos de entrada que nunca ha visto. El sobre entrenamiento puede ocurrir al tener demasiadas unidades ocultas en la capa oculta o entrenar durante demasiados períodos de tiempo. Los resultados pobres en los documentos a menudo se atribuyen al sobre entrenamiento (K. Kim, 2006, p. 356-366).

Sin embargo, se puede prevenir realizando procedimientos de prueba y entrenamiento o validación cruzada.

4.24 ESPACIO MUESTRAL

La muestra de entrenamiento se utiliza para desarrollar un modelo de redes neuronales. Para la predicción y la muestra de prueba se utilizan para probar la capacidad de generalización del modelo. A veces se introduce una tercera muestra para evitar el problema del sobreajuste o para determinar un punto de detención del proceso de entrenamiento, y esta muestra se llama muestra de validación (X. Zhang; J. Mesrov; D. Waltz, 1992, p. 1049-1063). Granger sugiere que, para modelos de pronóstico no lineales, al menos el 20% de cualquier muestra debe reservarse para una evaluación de pronóstico fuera de la muestra (C. W. J. Granger, 1993, p. 233-238). Para este trabajo se utilizó un enfoque del 70% frente al 30% para crear suficientes datos para la muestra de prueba. El conjunto de datos que se utilizó contenía un total de 750 puntos de datos. Los datos se dividieron en diferentes filas de diferentes tamaños de ventana y sus respectivos precios de salida objetivo. Estas filas de datos luego se dividieron en dos conjuntos de datos, 500 filas para entrenamiento y 200 filas para probar la red entrenada. Las filas de entrenamiento se reorganizaron aleatoriamente para desestacionalizar el conjunto de entrenamiento.

4.25 MEDIDAS DE RENDIMIENTO

Se utilizaron diferentes arquitecturas para este experimento. Los resultados se presentan de forma gráfica y también en una tabla que compara la precisión de las predicciones de las diferentes arquitecturas. El número de nodos ocultos para los diferentes modelos se determinó empíricamente probando diferentes redes con nodos de 2 a 30.

Una parte importante de la predicción financiera es la evaluación del algoritmo de predicción. Se utilizan varias medidas de rendimiento amplio, pero una medida de rendimiento por sí sola no es suficiente para una evaluación satisfactoria. También se necesitan puntos de referencia relevantes. Básicamente, un punto de referencia es un algoritmo de predicción diferente utilizado para comparación. Esta sección brinda una visión general de las herramientas de medición del rendimiento utilizadas para este experimento.

La investigación de Tashman enseña tres lecciones sobre el promedio de una serie:

- Se debe evitar el uso de medidas de error dependientes de la escala. Esto incluye medidas de error como el error cuadrático medio (RMSE) o la desviación media absoluta (MAD). Cambiar la escala de la medición también altera la medida de error. Las desviaciones más grandes pueden dominar las medidas de error (L. J. Tashman 2000, p. 437-450).
- Se deben utilizar medidas de error porcentual como el error porcentual absoluto porque son independientes de la escala. Sin embargo, las medidas porcentuales también tienen sus propias limitaciones, la distribución de los errores porcentuales puede estar muy sesgada, especialmente si la serie contiene valores cercanos a cero.
- Se pueden utilizar medidas de error relativo si es necesario promediar sobre series temporales que difieren en volatilidad.

Se utilizaron diversos métodos de medición y de precisión para evitar algunas de las dificultades que ya se han destacado sobre algunos de los métodos y se seleccionaron debido a su diversidad. Estos métodos incluyen el error porcentual absoluto medio (MAPE), el error porcentual absoluto simétrico (sMAPE), el error cuadrático medio (MSE), el error cuadrático medio raíz (RMSE) y el error relativo cuadrático medio (MSRE). Para más detalles sobre los métodos, consultar el apéndice A.

La implementación del experimento se llevó a cabo en un entorno MAT LABTM. El conjunto de herramientas utilizado para entrenar las redes neuronales es el conjunto de herramientas NETLAB utilizado con MAT LABTM. El conjunto de herramientas NETLAB para MAT LABTM es bien conocido para la enseñanza e investigación en los campos de reconocimiento de patrones y análisis de datos. Los detalles están en el Apéndice C.

4.25.1 Matrix de Confusión

Una matriz de confusión (R. Kohavi; F. Provost, 1998, p. 271-274) contiene información sobre las clasificaciones reales y predichas realizadas por un sistema de clasificación. El rendimiento de dichos sistemas se evalúa comúnmente utilizando los datos de la matriz. La siguiente tabla muestra la matriz de confusión para un clasificador de dos clases.

Las entradas en la Tabla 1 tienen el siguiente significado en el contexto de nuestro estudio:

- A es el número de predicciones correctas de que una instancia está en alza.
- B es el número de predicciones incorrectas de que una instancia está a la baja.
- C es el número de predicciones incorrectas de que una instancia está al alza.
- D es el número de predicciones correctas de que una instancia está a la baja.

Tabla 1: Ejemplo de la Matriz de Confusión

	Predicted Up	Predicted Down
True Up	A	B
True Down	C	D

La precisión (AC) es la proporción del número total de predicciones que fueron correctas. Es determinado usando la ecuación:

$$AC = \frac{A + D}{A + B + C + D} \quad (22)$$

La precisión determinada mediante la ecuación puede no ser una medida de rendimiento adecuada cuando el número de casos negativos es mucho mayor que el número de casos positivos.

En el pronóstico financiero, la clasificación se puede realizar prediciendo si el precio del índice del próximo día será más alto o bajo que el precio del día anterior. Esto se hace mediante una comparación directa entre los dos precios. Esto ayuda a medir el rendimiento de un algoritmo en su capacidad para predecir entre los dos estados (más alto o bajo) en comparación con el objetivo. Los resultados se presentan en una matriz de confusión.

Por último, analizaré las regulaciones existentes y las normativas éticas y legales relacionadas con el uso de la inteligencia artificial y otros avances tecnológicos. Evaluaré el impacto de la adopción de los algoritmos y modelos matemáticos complejos en la gestión empresarial, incluida la equidad, la privacidad de los datos y la seguridad. A través de esta metodología integral, espero obtener una comprensión completa y profunda de los temas investigados, lo que me permitirá abordar mis objetivos y validar mis hipótesis desde diferentes perspectivas.

CAPÍTULO 6: RECOPIACIÓN Y ANÁLISIS DE DATOS

El precio objetivo (Target) es el precio real de la acción al que se debería llegar mediante el modelo matemático y el Output es el valor entregado por el modelo. Los nodos ocultos en los modelos, también conocidos como neuronas ocultas, son unidades de procesamiento artificial que se encuentran entre las capas de entrada y salida de una red neuronal. A diferencia de los nodos de entrada (Input) y salida (Output), que tienen una función simple de recibir y transmitir información, los nodos ocultos realizan cálculos más complejos y no tienen una correspondencia directa con las variables de entrada o salida del modelo. En todos los casos, la variable de predicción son los precios de las acciones en la bolsa de Johannesburgo con relación al tiempo.

6.1 MULTILAYER PERCEPTRON

La arquitectura básica de la red comprendía una capa de entrada con los nodos iguales al número de entradas, una capa oculta con nodos que se determinaron empíricamente y luego una capa de salida con un nodo de salida. Las arquitecturas de red construidas se entrenaron durante 5000 a 10000 iteraciones. La red de entrenada se probó y validó.

6.1.1 Resultados MLP

La precisión del modelo construido con 5 entradas es mayor que la de los otros tres modelos. El modelo construido con 10 entradas es mucho menos preciso que todos los otros modelos y su desviación es alta. La razón de la pobre actuación de este modelo podría ser resultado de la incapacidad para capturar la dinámica de los datos. En general, los resultados muestran que el MLP tiene la capacidad de aprender las relaciones no lineales que existen entre la entrada y la salida. Las Figuras. 25–28 muestran que el MLP es capaz de seguir la tendencia de los precios objetivo.

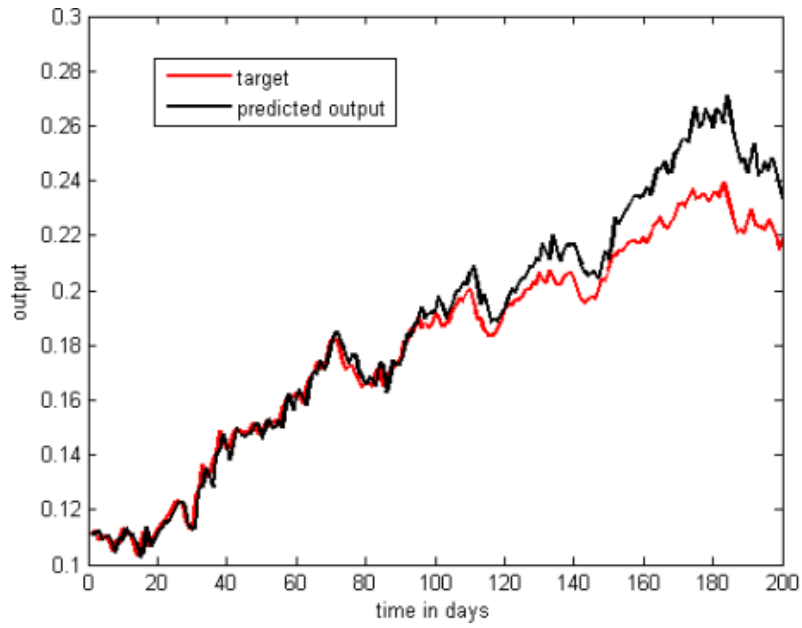


Figura 25: Objetivo vs. Outputs del Modelo MLP para 3 inputs.

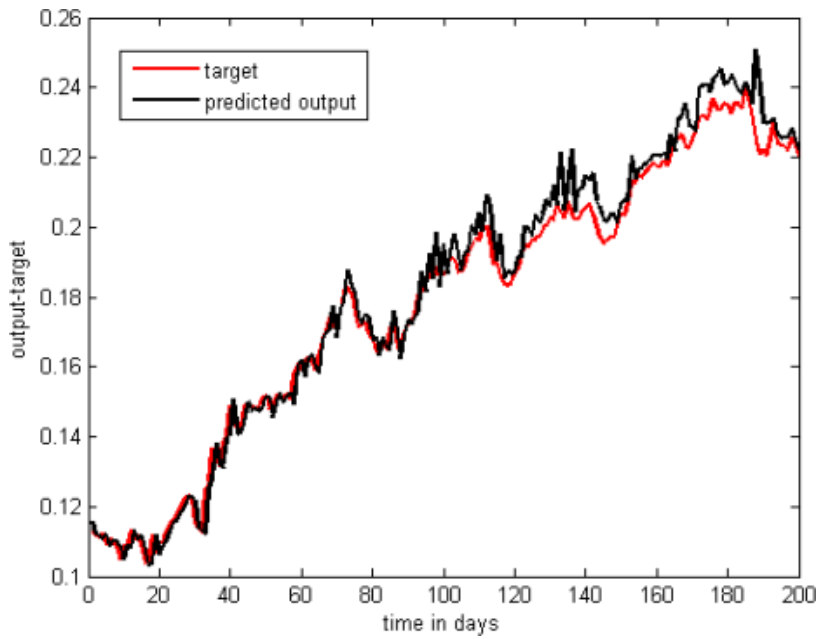


Figura 26: Objetivo vs. Outputs del Modelo MLP para 5 inputs.




Figura 27: Objetivo vs. Outputs del Modelo MLP para 7 inputs.




Figura 28: Objetivo vs. Outputs del Modelo MLP para 10 inputs.

Los modelos también fueron evaluados en términos de su capacidad para predecir si el precio del índice subirá o bajará al día siguiente.

Tabla 2: Diferentes Arquitecturas MLP.

N. de Inputs	N. de Nodos Ocultos	Arquitectura
3 Inputs	5 Nodos	3-5-1
5 Inputs	8 Nodos	5-8-1
7 Inputs	10 Nodos	7-10-1
10 Inputs	12 Nodos	10-12-1

Tabla 3: Medidas de Precisión de Resultados para MLP.

N. de Inputs	sMAPE	MAPE	MSE	MSRE	RMSE
3 Inputs	4,2%	4,3%	1,5E-04	3,3E-03	1,2E-02
5 Inputs	2,3%	2,3%	3,2E-05	9,2E-04	5,7E-03
7 Inputs	3,7%	3,7%	6,6E-05	1,7E-03	8,0E-03
10 Inputs	6,9%	7,3%	4,2E-04	9,0E-03	2,0E-02

Tabla 4: Matriz de Confusión para los Resultados de MLP.

	Predicted Up	Predicted Down
True Up	84	32
True Down	22	62

Accuracy 73%
a) Confusion Matrix of Price Prediction
(3 Inputs)

	Predicted Up	Predicted Down
True Up	92	22
True Down	6	80

Accuracy 86%
b) Confusion Matrix of Price Prediction
(5 Inputs)

	Predicted Up	Predicted Down
True Up	114	26
True Down	18	40

Accuracy 77%
c) Confusion Matrix of Price Prediction
(7 Inputs)

	Predicted Up	Predicted Down
True Up	100	22
True Down	26	52

Accuracy 76%
d) Confusion Matrix of Price Prediction
(10 Inputs)

6.2 SUPPORT VECTOR MACHINES

6.2.1 Resultados SVM

Hay tres métodos para controlar el modelo de regresión: La función de pérdida, el método Kernel y el control adicional de capacidad. Los experimentos para el modelo de regresión utilizado para la predicción del índice del mercado de valores se realizaron con diferentes funciones de pérdida, con diferentes Kernels y diferentes grados de control de capacidad. Se probaron varias combinaciones, y finalmente se eligió una función de base radial como el Kernel con $\varepsilon = 0.01$ y $C = 100$. El modelo se entrena con el conjunto de datos de entrenamiento con 500 instancias, y luego se prueba con el conjunto de datos de prueba con otras 200 instancias.

Los resultados indican que la regresión SVM es una herramienta adecuada de aprendizaje automático para la predicción del precio futuro del índice del mercado de valores. El error de predicción de SVM aumenta a medida que aumenta el número de entradas. La predicción es más precisa cuando solo hay tres inputs.

Tabla 5: Medidas de Precisión de Resultados para SVM.

N. de Inputs	sMAPE	MAPE	MSE	MSRE	RMSE
3 Inputs	1,8%	1,8%	1,7E-05	5,8E-04	4,1E-03
5 Inputs	3,7%	3,6%	7,6E-05	2,1E-03	8,7E-03
7 Inputs	4,3%	4,4%	1,3E-04	3,3E-03	1,2E-02
10 Inputs	5,7%	8,0%	3,2E-04	1,6E-02	1,8E-02

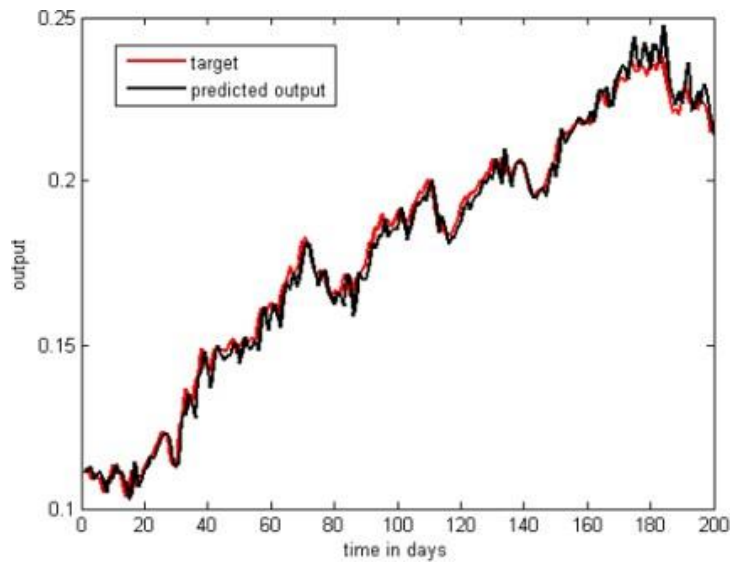


Figura 29: Objetivo vs. Outputs del Modelo SVM para 3 inputs.




Figura 30: Objetivo vs. Outputs del Modelo SVM para 5 Inputs.




Figura 31: Objetivo vs. Outputs del Modelo SVM para 7 Inputs.




Figura 32: Objetivo vs. Outputs del Modelo SVM para 10 Inputs.

La ventana de tres entradas se utiliza para el entrenamiento y es mucho menos precisa cuando se utiliza la ventana de diez entradas, como se muestra en la Tabla 6. La razón de esto podría ser que los precios más recientes del índice antes del precio de predicción contienen información relevante sobre la dirección futura de los precios del índice y forman parte de los vectores de soporte. La ventana de diez entradas tiene una predicción menos precisa para todos los intervalos de tiempo considerados y por lo tanto, contiene información irrelevante que no tiene poder predictivo para el día undécimo o el precio futuro. Los resultados también se ilustran gráficamente con las Figuras 29-32.

La Tabla 6 muestra las matrices de confusión que ilustran qué tan precisos fueron los modelos de SVM al predecir si el precio del índice del día siguiente subirá o bajará. El modelo con tres entradas pudo predecirlo con una precisión de hasta el 96%.

Tabla 6: Matriz de Confusión de Resultados para SVM.

	Predicted Up	Predicted Down
True Up	112	4
True Down	4	80

Accuracy 96%
a) Confusion Matrix of Price Prediction
(3 Inputs)

	Predicted Up	Predicted Down
True Up	100	11
True Down	8	80

Accuracy 90%
b) Confusion Matrix of Price Prediction
(5 Inputs)

	Predicted Up	Predicted Down
True Up	100	14
True Down	20	66

Accuracy 83%
c) Confusion Matrix of Price Prediction
(7 Inputs)

	Predicted Up	Predicted Down
True Up	56	36
True Down	34	74

Accuracy 65%
d) Confusion Matrix of Price Prediction
(10 Inputs)

Esta sección examinó la aplicación de la regresión de vectores de soporte para predecir el precio del índice de todas las acciones. Como se demostró por los resultados, SVM es una herramienta prometedora que se puede utilizar para este propósito. La selección de entradas se diseñó utilizando el enfoque de ventana móvil. El uso de diferentes ventanas de entrada muestra cómo el rendimiento de pronóstico puede mejorar o empeorar.

6.3 NEURO-FUZZY

Un sistema Neuro-Fuzzy tiene dos tipos de ajustes, conocidos como ajuste estructural y ajuste paramétrico, que son necesarios para construir un modelo. El ajuste estructural tiene como objetivo encontrar un número adecuado de reglas y una partición adecuada del espacio de entrada. Una vez que se alcanza una estructura satisfactoria, el ajuste paramétrico busca las funciones de pertenencia óptimas junto con los parámetros óptimos de los modelos consecuentes. En algunos casos, puede haber múltiples combinaciones de estructura y parámetros que hagan que el modelo difuso funcione de manera satisfactoria. El problema es encontrar la complejidad estructural que pueda brindar el mejor rendimiento de generalización. En este proceso se elige el número de reglas como medida de la complejidad que debe ajustarse adecuadamente en función de los datos disponibles. Un enfoque incremental donde se evalúan primero diferentes arquitecturas con diferentes complejidades (Número de nodos) en validación cruzada y luego se comparan para seleccionar la mejor. Todo el procedimiento de aprendizaje está representado en el diagrama de flujo en la Fig. 33.

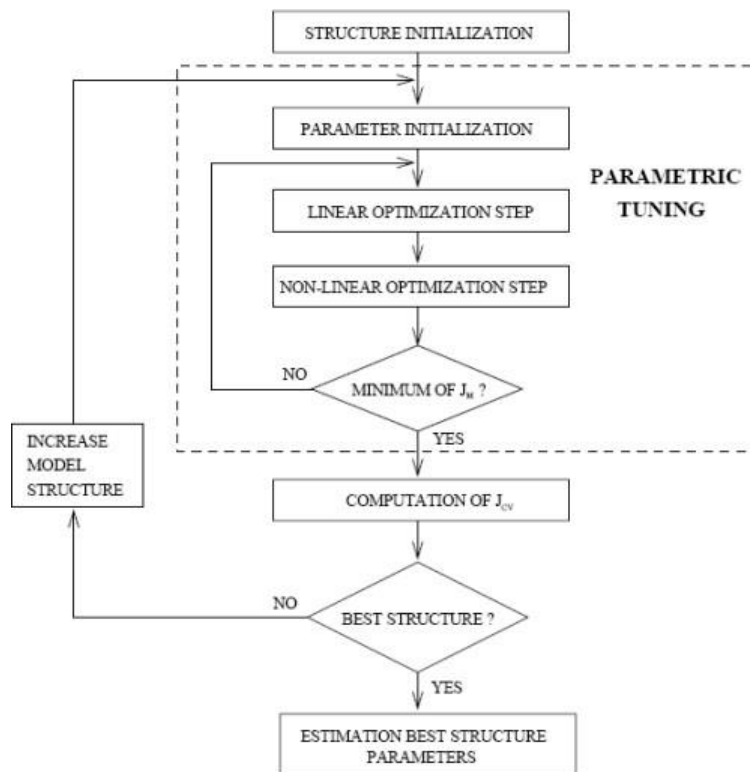


Figura 33: Diagrama de Flujo del Pceso de Aprendizaje Neuro-Fuzzy (L. R. Marwala, 2010, p. 77)

La inicialización de la arquitectura se realiza mediante un procedimiento de agrupamiento difuso hiperelipsoidal inspirado en Babuska y Verbruggen (R. Babuska; H. Verbruggen, 1997, p. 75-100). Este procedimiento agrupa los datos en el dominio de entrada-salida obteniendo un conjunto de hiperelipsoides que son una representación preliminar aproximada del mapeo entrada-salida (R. Bakuska, 1991, p. 17-23). Los ejes de los elipsoides (vectores propios de la matriz de dispersión) inicializan los parámetros de las funciones consecuentes f^i , luego los centros de los grupos se proyectan en el dominio de entrada para inicializar los centros de los antecedentes y se adopta la matriz de dispersión para calcular el ancho de las funciones de membresía. Un ejemplo de agrupamiento difuso en el caso de una función de entrada-salida única modelada por un sistema de inferencia difuso con antecedentes gaussianos se representa en la Fig. 34.




Figura 34: Procedimiento de Inicialización de Agrupamiento Hiperelipsoidal (L. R. Marwala, 2010, p. 78)

Una vez completado el proceso de inicialización, comienza el procedimiento de aprendizaje. Se anidan dos bucles de optimización: el paramétrico y el estructural. El bucle paramétrico (el interno) busca el mejor conjunto de parámetros minimizando una función de costo de suma de cuadrados JM que depende exclusivamente del conjunto de entrenamiento. Este paso aprovecha las técnicas de aprendizaje de redes neuronales para obtener la solución óptima. En el caso de los modelos TS lineales, este procedimiento de minimización puede descomponerse en un problema de mínimos cuadrados para estimar los parámetros lineales de los modelos consecuentes f^i (J. S. R. Jang; C. T. Sun; E. Mizutani, 1997, p. 1482-1482) y una minimización no lineal (Levenberg-Marquardt) para encontrar los parámetros de las funciones de membresía A_j^i .

6.3.1 Experimento Neuro Fuzzy

El experimento incluye dos características:

Entrenamiento de un modelo con complejidad fija: El usuario elige la arquitectura del sistema de inferencia difusa y fija el número de reglas. Elige el método de inicialización y proporciona al programa un conjunto de datos de muestras de entrada-

salida. El programa devuelve el modelo entrenado en forma de parámetros de funciones de membresía y parámetros consecuentes.

Selección del modelo: Esto implica buscar la complejidad adecuada de la arquitectura mediante la adopción de un procedimiento de validación cruzada en el conjunto de datos disponible. Comienza con un número mínimo de reglas y en cada paso aumenta el número de reglas reiniciando el procedimiento global, hasta alcanzar un número máximo de reglas. El usuario es libre de establecer el rango de complejidad deseado. El programa trazará, como se muestra en la Fig. 35, el error de validación cruzada frente al número de reglas para ayudar al diseñador a elegir la mejor estructura.




Figura 35: Error de Validación Cruzada vs. Diagrama de Complejidad (L. R. Marwala, 2010, p. 79)

El conjunto de datos se dividió en tres conjuntos, el conjunto de entrenamiento, el conjunto de datos de validación y el conjunto de datos de prueba. Se utilizaron 500 puntos de datos dentro de la muestra para entrenar los modelos y 200 puntos de datos se utilizaron para probar el modelo. Las funciones de membresía antecedentes se construyeron utilizando una función gaussiana. La función consecuente es una función lineal. El algoritmo de agrupamiento utilizado para este experimento es una extensión del método de c-medias difuso que es el algoritmo de Gustafson-Kessel (GK). El algoritmo GK es una extensión del algoritmo estándar de c-medias difuso al emplear una norma de distancia adaptativa para detectar grupos de diferentes formas geométricas en un conjunto de datos. El algoritmo GK básicamente consta de cuatro pasos:

1. Calcular de prototipos o medias de grupo.
2. Calcular las matrices de covarianza del grupo.
3. Calcular las distancias del grupo.
4. Actualizar la matriz de partición.

El algoritmo luego itera a través de estos pasos hasta que el cambio en los grados de membresía sea menor que la tolerancia dada.

6.3.2 Resultados Neuro Fuzzy

Los resultados de este experimento varían con los diferentes tamaños de ventana de los datos de entrada. La precisión de los resultados de prueba se presenta en la Tabla 7, la cual muestra que con cinco entradas hay una mejor capacidad predictiva. Los modelos Neuro-Fuzzy deben ser capaces de capturar la dinámica de los datos del índice con cinco Inputs de mejor forma que con las otras. En general, el rendimiento de pronóstico

de los sistemas Neuro-Fuzzy es bueno. Las Figuras 36-39 muestran una comparación entre los valores objetivo y los valores predichos.

Tabla 7: Medidas de Precisión de Resultados para Neuro-Fuzzy.

N. de Inputs	sMAPE	MAPE	MSE	MSRE	RMSE
3 Inputs	3,6%	3,5%	6,3E-05	1,6E-03	7,9E-03
5 Inputs	1,9%	1,8%	1,6E-05	5,7E-04	4,1E-03
7 Inputs	2,6%	2,5%	3,1E-04	8,8E-04	5,6E-03
10 Inputs	2,9%	2,8%	4,1E-04	1,1E-03	6,4E-03

Se ha mencionado anteriormente que los modelos Neuro-Fuzzy son semitransparentes, lo que los convierte en una "caja gris". Esto significa que el modelo es legible hasta cierto punto.




Figura 36: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 3 Inputs.




Figura 37: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 5 Inputs.




Figura 38: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 7 Inputs.




Figura 39: Objetivo vs. Outputs del Modelo Neuro-Fuzzy para 10 Inputs.

La Tabla 8 muestra matrices de confusión que ilustran qué tan precisos fueron los modelos de SVM. El modelo con tres entradas pudo predecir los resultados con una precisión de hasta el 98%.

Tabla 8: Matriz de Confusión de Resultados para Neuro-Fuzzy.:

	Predicted Up	Predicted Down
True Up	100	8
True Down	12	80

Accuracy 90%
a) Matrix of Prediction Price (3 Inputs)

	Predicted Up	Predicted Down
True Up	120	2
True Down	2	76

Accuracy 98%
b) Matrix of Prediction Price (5 Inputs)

	Predicted Up	Predicted Down
True Up	118	7
True Down	6	68

Accuracy 93%
c) Matrix of Prediction Price (7 Inputs)

	Predicted Up	Predicted Down
True Up	110	16
True Down	10	64

Accuracy 87%
d) Matrix of Prediction Price (10 Inputs)

6.4 AUTO-REGRESSIVE MOVING AVERAGE MODELLING (ARMA)

Los datos del mercado de valores consisten en tres precios: El máximo intradía, el mínimo intradía y el precio de cierre. El máximo intradía representa el precio máximo del índice durante la negociación intradía; el mínimo intradía representa el precio mínimo del índice durante la negociación intradía; y el precio de cierre indica el precio del índice cuando el mercado cierra. Para esta investigación, se eligió el precio de cierre para representar el precio del índice a modelar y predecir. La razón de esta elección es que el precio de cierre refleja todas las actividades del índice en un día. Es una serie temporal que refleja todos los días de negociación desde 2002 hasta 2005, excluyendo festivos y fines de semana. El comportamiento del precio del ALSI (All Shares Index) se muestra gráficamente en la Figura 40.

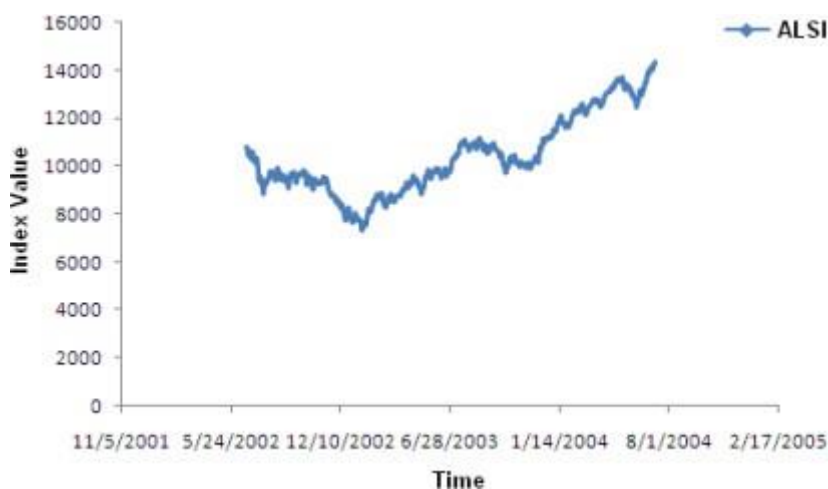


Figura 40: Fluctuaciones de Precio ALSI Año 2002 – 2005 (L. R. Marwala, 2010, p. 51)

El precio del índice fluctúa entre grandes altibajos en un corto período de tiempo, dependiendo de la volatilidad del mercado o del desempeño del mercado en su conjunto. Estas fluctuaciones pueden causar grandes dificultades para que las técnicas de inteligencia computacional comprendan y pueden perder la esencia de la serie. Además,

las funciones de activación que se utilizan en los algoritmos solo operan dentro de ciertos rangos que los datos del mercado de valores pueden exceder.




Figura 41: Output Medido y Predicho por Modelo ARMA (L. R. Marwala, 2010, p. 60)

El último paso es la etapa de pronóstico utilizando el modelo construido. El modelo representado por las ecuaciones anteriores se probó utilizando datos fuera de la muestra. Los resultados se presentan en la Fig. 41 y en la Tabla 10.

Tabla 9: Medidas de Precisión de Resultados para ARMA

sMAPE	MAPE	MSE	MSRE	RMSE
3,9%	4,0%	6,4E-05	0,0026	8,0E-03

Tabla 10: Matriz de Confusión de Resultados para ARMA

	Predicted Up	Predicted Down
True Up	100	8
True Down	10	82

Accuracy 91%
a) Confusion Matrix of Price Prediction

6.5 RANDOM WALK

El punto de referencia convencional que se utiliza para evaluar la confianza de las técnicas de predicción es el método de caminata aleatoria (RW). Establece que la mejor predicción para el precio de mañana es el precio de hoy, $P_{T+1} = P_t$. Cabe señalar que, por su propia naturaleza, el método de caminata aleatoria está limitado a una predicción de un paso adelante. La Tabla 11 presenta los resultados obtenidos al usar esta técnica. El ejercicio se realizó utilizando valores normalizados.

Tabla 11: Medidas de Precisión de Resultados para Random Walk

sMAPE	MAPE	MSE	MSRE	RMSE
1,5%	1,5%	9,9E-06	5,8E-05	3,1E-03

CAPÍTULO 7: CONCLUSIONES

Se aplicaron tres técnicas de inteligencia artificial para predecir el precio futuro del índice de precios del mercado de valores. Las redes neuronales artificiales, las máquinas de vectores de soporte y los sistemas neuro-difusos se utilizaron para predecir el índice de precios compuesto JSE. El enfoque adoptado para este proyecto fue predecir el precio futuro del índice de todos los compartimentos. La gran cantidad de trabajo realizado en esta área con las tres técnicas se ha centrado más en predecir la dirección del precio futuro. Esto significa que la mayoría de los investigadores simplemente querían saber si el precio de las acciones subirá o bajará en el futuro. Determinar la dirección no revela el margen de aumento o disminución del precio.

Los resultados obtenidos muestran que las tres técnicas tienen la capacidad de predecir el precio del índice. Predecir el precio es mucho más desafiante que simplemente la dirección. Si se predice dentro de un cierto nivel de precisión, puede proporcionar más información sobre el comportamiento futuro del precio de las acciones en el mercado. Esto envía un buen mensaje a los inversores de que las técnicas de inteligencia computacional pueden ser utilizadas para la predicción en el mercado.

7.1 INTERPRETACIÓN DE LOS RESULTADOS

Para llevar a cabo el experimento de pronóstico utilizando técnicas de inteligencia artificial. Se construyeron modelos con tres, cinco, siete y diez entradas para cada técnica. Los resultados experimentales indican que cada técnica tiene un modelo que supera a los demás de la misma técnica. Específicamente, para MLP, el modelo de cinco entradas supera a todos los demás. Para SVM, es el modelo de tres entradas, y para Neuro-Fuzzy, es el modelo de cinco entradas. El enfoque de la discusión se centra en estos modelos de mejor rendimiento para cada técnica.

Las distribuciones fueron confirmadas mediante la prueba de Anderson-Darling. Los gráficos de autocorrelación de los residuos indican que no hay correlación entre los errores, lo que significa su independencia. Además, los gráficos de ACF demuestran que los modelos de IA construidos se ajustan satisfactoriamente a los datos. Los residuos muestran picos dentro de los límites del intervalo de confianza del 95%, lo que sugiere una falta de picos residuales de ACF significativos como evidencia empírica de falta de ajuste. Para más detalles sobre estos procedimientos, dirigirse al Apéndice C.

7.2 COSTOS DE TRANSACCIÓN Y EMH

La pregunta que se puede hacer sobre los resultados presentados en esta investigación es ¿Los resultados refutan la hipótesis del mercado eficiente? EMH se refuta cuando un inversor logra consistentemente rendimientos por encima del promedio en el mercado. Esto requeriría que los rendimientos obtenidos sean más altos que los costos de transacción. Los rendimientos dependen de la magnitud del aumento del precio (a ser predicho), la precisión de la predicción y el número de acciones a ser negociadas. Usando las mediciones de predicción de las tres técnicas, hay instancias donde los rendimientos obtenidos serían buenos y donde no lo serían. La respuesta a esta pregunta no es fácil, pero los resultados han mostrado hasta cierto punto que el mercado no es tan eficiente como EMH afirma.

7.3 COMPARACIÓN DE LAS TÉCNICAS

Se utilizó el modelo ARMA y la técnica de caminata aleatoria en este trabajo como puntos de referencia. MAPE, sMAPE, MSE, RMSE y MSRE se utilizaron como medidas de error y en cada medida, las técnicas de IA se clasificaron más alto que el modelo ARMA. SVM utiliza técnicas que tienen una mejor capacidad de aprendizaje

que las redes neuronales, SRM para SVM y conjuntos difusos para sistemas Neuro-Fuzzy. MLP y los métodos Neuro-Fuzzy tienen su mejor rendimiento con cinco entradas. SVM tuvo su mejor rendimiento con tres entradas. La clasificación de estas técnicas depende de la medida de precisión utilizada. Esto está en línea con las conclusiones alcanzadas por los investigadores en el campo de la predicción, que cuando se miden las precisiones de diferentes métodos de predicción, la clasificación de las precisiones de las predicciones depende del método de medición de precisión utilizado. En este trabajo se utilizaron varios métodos de medición de precisión. Los resultados muestran que en los casos en que las precisiones de los tres algoritmos tienen una pequeña desviación, la clasificación de los dos algoritmos tenía una fuerte dependencia del método de medición de precisión utilizado. Sin embargo, cuando la desviación es grande, la clasificación alta o baja del algoritmo es consistente en todos los métodos de medición de precisión. Sin embargo, se encontró que todos los modelos complejos utilizados para este ejercicio no pudieron superar al Modelo de Caminata Aleatoria (RW). Se debe tener en cuenta que el modelo de caminata aleatoria solo se puede usar para la predicción del día siguiente. Basado en los resultados de este experimento, se puede concluir que el uso de un método como la caminata aleatoria daría mejores resultados en predicciones a corto plazo. Por otro lado, los métodos complejos pueden considerarse para cuando el horizonte temporal de la predicción aumenta.

Luego, se compararon los resultados de los mejores modelos de las técnicas de inteligencia artificial con los resultados del modelo ARMA. La Tabla 12 muestra la comparación de los resultados de los modelos de IA y el modelo ARMA. Los modelos de IA superan al modelo ARMA con respecto a los errores de predicción. La razón

puede ser porque los datos contienen comportamientos no lineales o caóticos, que no pueden ser capturados completamente por el modelo lineal ARMA.

Tabla 12: Comparación de los Métodos de Predicción

Técnica	sMAPE	MAPE	MSE	MSRE	RMSE
MLP (5 Inputs)	2,3%	2,3%	3,2E-05	9,2E-04	5,7E-03
SVM (3 Inputs)	1,8%	1,8%	1,7E-05	5,8E-04	4,1E-03
Neuro-Fuzzy (5 Inputs)	1,9%	1,8%	1,6E-05	5,7E-04	4,1E-03
ARMA	3,9%	4,0%	6,4E-05	2,6E-03	8,0E-03
RW	1,5%	1,5%	0,000099	0,000058	0,0031

7.4 RESPONSABILIDADES ETICO-LEGALES

La determinación de responsabilidades por daños causados por la IA es un tema complejo. Surge la pregunta sobre quién debe responder por los perjuicios ocasionados por sistemas automatizados, y actualmente, existe una falta de claridad en la asignación de responsabilidades legales ante incidentes relacionados con la IA. La abundancia de textos y la inflación de la literatura gris en materia de IA han diluido las fronteras entre el derecho y la ética, complicando esta asignación clara de responsabilidades. Por ello, es crucial establecer un marco regulatorio claro y mecanismos de rendición de cuentas para asegurar que tanto desarrolladores como usuarios de IA asuman sus responsabilidades de manera efectiva.

Regulación y Supervisión: La complejidad inherente a los sistemas de IA dificulta que los reguladores y supervisores financieros comprendan, monitoreen y controlen adecuadamente su funcionamiento. La preferencia por la "Soft Law" en lugar de un marco reglamentario clásico ha exacerbado la falta de claridad y la ambigüedad en la normativa actual, lo que plantea desafíos significativos para garantizar el cumplimiento normativo y la protección de los consumidores. Por lo tanto, es esencial desarrollar una

normativa que sea lo suficientemente precisa para garantizar la seguridad jurídica sin obstaculizar la innovación tecnológica.

Protección de datos: Los problemas legales asociados con la protección de datos son críticos, especialmente cuando se utilizan herramientas de IA sin regulación adecuada. La opacidad, la complejidad y la dependencia de los datos en la IA pueden infringir principios fundamentales como el derecho al respeto de la vida privada. La normativa debe adaptarse para incluir las inferencias realizadas a partir de los datos personales, asegurando que la recopilación y el uso de datos con fines de influencia se realicen de manera responsable y segura. Esto es vital para garantizar la confidencialidad, integridad y disponibilidad de la información.

Discriminación de clientes: Los sistemas de IA pueden excluir a ciertos grupos de consumidores basándose en una mayor probabilidad de beneficio, lo que reduce el potencial del mercado y limita la inclusión. La regulación propuesta busca complementar el derecho existente en materia de no discriminación mediante requisitos específicos para reducir el riesgo de discriminación algorítmica, especialmente en el diseño y calidad de los conjuntos de datos. Sin embargo, la identificación de causalidades en las decisiones de IA sigue siendo un desafío, lo que complica la búsqueda de responsabilidades y la protección de grupos vulnerables.

Transparencia y claridad de la información: A medida que los modelos de IA se vuelven más sofisticados, puede ser cada vez más difícil para los usuarios y reguladores entender cómo toman decisiones y qué razonamientos se utilizan. La transparencia algorítmica es crucial pero difícil de alcanzar debido a la propiedad intelectual y la complejidad técnica de los algoritmos de IA. Es necesario desarrollar mecanismos que permitan explicar claramente las decisiones de IA para garantizar la confianza y la

responsabilidad. Iniciativas como la plataforma TransAlgo y la necesidad de informar adecuadamente a los consumidores sobre el uso de técnicas de IA son pasos importantes en esta dirección.

7.5 BALANCE DE HIPÓTESIS

Hipótesis 1: Los modelos vanguardistas de predicción de datos basados en la inteligencia artificial son superiores a los modelos tradicionales en términos de precisión y efectividad.

R: Con relación al modelo Random Walk, se podría decir que estos modelos son superiores cuando se toma un horizonte de tiempo a largo plazo. De otra forma, cuando se quiere predecir la tendencia del día siguiente, RW es superior.

Por otro lado, en comparación al modelo ARMA, los modelos de IA son superiores en términos de errores porcentuales, probablemente por su adaptación a sistemas caóticos como el de los mercados financieros.

Hipótesis 2: Las Neural Networks, los sistemas Neuro-Fuzzy y las Support Vector Machines pueden ser efectivas para predecir los precios futuros del mercado de valores.

R: Los modelos son confiables al predecir una tendencia de los precios futuros. Dado que los modelos se entrenan para procesar los datos de formas diversas, se podría decir que cada uno tiene condiciones que lo podrían favorecer, como es el caso de la cantidad de inputs disponible para hacer la predicción. En conclusión, los 3 modelos son efectivos para la predicción del mercado de valores.

Hipótesis 3: Los precios pasados de las acciones contienen información que puede utilizarse para predecir los precios futuros.

R: Dados los resultados del experimento, podemos concluir que esta aceleración es correcta debido al éxito de RW. Este modelo funciona principalmente tomando en cuenta los precios del mercado del pasado para poder predecir la tendencia el día siguiente.

Hipótesis 4: La complejidad de los modelos de inteligencia artificial puede tener implicaciones éticas y legales, ya que podría violar regulaciones relacionadas con la equidad y la transparencia en las transacciones financieras.

R: Dado el contexto actual, no hay regulaciones por las cuales la inteligencia artificial se vea afectada, pues el marco regulatorio legal queda descartado por el momento, hasta que se defina correctamente que es una inteligencia artificial, sus alcances y las responsabilidades pertinentes. Sin embargo, si hay implicancias Éticas, pues la IA no distingue claramente las ideas de discriminación o privacidad como lo haría un humano. Siguiendo esta línea, se debe crear rápidamente un marco de contención para el desarrollo de la IA y debe haber un mutuo acuerdo entre los creadores de esta tecnología para autorregularse en el funcionamiento y alcance de sus algoritmos.

CAPÍTULO 8: RECOMENDACIONES

9.1 RECOMENDACIONES DERIVADAS DEL ESTUDIO

- Investigaciones futuras: pueden centrarse en el uso de variables macroeconómicas, como la tasa de interés, el PIB, etc., como entrada a los diferentes modelos para determinar si tienen algún poder predictivo. Se puede realizar un estudio para probar el efecto tanto de la tasa de interés como de la tasa de inflación en el índice de todas las acciones. El estudio puede ayudar a los tomadores de decisiones o inversores a comprender cómo se comportaría el mercado si la tasa de interés aumenta o disminuye.
- Desarrollo de Marcos Regulatorios Claros: Es fundamental establecer un marco regulatorio claro y preciso para la inteligencia artificial que abarque tanto responsabilidades éticas como legales. Los legisladores deben trabajar para definir quién es responsable de los daños causados por sistemas de IA y crear mecanismos efectivos de rendición de cuentas para desarrolladores y usuarios.
- Fortalecimiento de la protección de datos: Dada la importancia de la protección de datos personales, se recomienda implementar medidas estrictas de seguridad de la información. Esto incluye la adopción de políticas de privacidad robustas y el uso de tecnologías avanzadas para garantizar la confidencialidad, integridad y disponibilidad de los datos.
- Promoción de la transparencia algorítmica: Fomentar la transparencia y la explicabilidad en los sistemas de IA es esencial para construir confianza con los usuarios. Los desarrolladores deben asegurarse de que los algoritmos y los procesos de toma de decisiones sean comprensibles y accesibles tanto para los reguladores como para los consumidores.

- **Prevención de la discriminación algorítmica:** Es crucial diseñar e implementar sistemas de IA que sean justos y equitativos. Los desarrolladores deben realizar evaluaciones de impacto ético y social para identificar y mitigar posibles sesgos que puedan conducir a la discriminación de ciertos grupos de personas.
- **Monitoreo y evaluación continua de sistemas de IA:** Los sistemas deben ser monitoreados y evaluados de manera continua para garantizar su desempeño y conformidad con las regulaciones vigentes. Esto incluye la creación de comités de ética y la realización de auditorías regulares.

9.2 RECOMENDACIONES APLICADAS AL ÁMBITO FINANCIERO

- **Adopción de modelos:** Basado en los hallazgos del estudio, es recomendable que las instituciones financieras adopten modelos predictivos más sofisticados, como los modelos híbridos que combinan técnicas de ARMA con redes neuronales. Esto puede mejorar significativamente la precisión de las predicciones financieras.
- **Desarrollo de infraestructura de datos robusta:** Es crucial invertir en una infraestructura de datos sólida que permita la recopilación, almacenamiento y procesamiento eficiente de grandes volúmenes de datos. La calidad y disponibilidad de los datos son fundamentales para el éxito de los modelos predictivos.
- **Formación:** Se sugiere que los profesionales en finanzas reciban formación continua en las áreas de inteligencia artificial y Machine Learning para estar al tanto de las últimas tecnologías y metodologías. Esto permitirá una mejor integración y uso de estos modelos avanzados en sus análisis diarios.
- **Implementación de IA en la evaluación de riesgos:** Las instituciones financieras deben utilizar modelos de IA para mejorar la evaluación y gestión de riesgos. La IA

puede proporcionar análisis más precisos y detallados, ayudando a identificar posibles riesgos y oportunidades de manera más eficiente.

- Optimización de servicios al cliente mediante IA: Integrar chatbots y asistentes virtuales impulsados por IA para mejorar la atención al cliente. Estos sistemas pueden manejar consultas frecuentes, proporcionar asistencia 24/7 y mejorar la experiencia general del cliente.
- Personalización de productos financieros: Utilizar IA para personalizar productos y servicios financieros según las necesidades y comportamientos de los clientes. Los sistemas de IA pueden analizar datos de clientes para ofrecer recomendaciones personalizadas, mejorando la satisfacción y fidelización del cliente.

9.3 SUGERENCIAS

Se puede realizar un trabajo adicional en la predicción del índice de Todas las Acciones aumentando el número de parámetros en el espacio de características. La inclusión de otros indicadores técnicos como el promedio móvil junto con los precios del mercado para entrenar y probar los diferentes modelos puede ser una forma de abordar el estudio. Esto revelaría si la precisión de predicción de los tres modelos puede mejorarse.

La investigación futura también puede centrarse en el uso de variables macroeconómicas, como la tasa de interés, el PIB, etc., como entrada a los diferentes modelos para determinar si tienen algún poder predictivo. Se puede realizar un estudio para probar el efecto tanto de la tasa de interés como de la tasa de inflación en el Índice de Todas las Acciones. El estudio puede ayudar a los tomadores de decisiones o inversores a comprender cómo se comportaría el mercado si la tasa de interés aumenta o disminuye.

Otra área de interés sería examinar técnicas de inteligencia artificial que puedan ser adaptables y aprender los datos en línea. Esto examinaría métodos que sean capaces de aprender nuevos patrones del mercado a medida que ocurren en tiempo real y aún conserven un buen poder predictivo.

10 APÉNDICES

10.1 APÉNDICE A: MÉTODOS DE PRECISIÓN

10.1.1 Error Porcentual Absoluto Medio (MAPE)

El error porcentual absoluto medio (también conocido como MAPE) es una medida de precisión en un valor de serie temporal ajustado en estadística, específicamente en tendencias. La precisión se expresa como un porcentaje. Se representa con la ecuación:

$$Error = \frac{1}{n} \sum_{i=1}^n \left| \frac{X_i - F_i}{X_i} \right| \times 100 \quad (23)$$

La diferencia entre el valor real X y el valor pronosticado F , se divide nuevamente por el valor real X . El valor absoluto de este cálculo se suma para cada punto ajustado o pronosticado en el tiempo y se divide nuevamente por el número de puntos ajustados n . Esto lo convierte en un error porcentual, lo que permite comparar el error de series temporales ajustadas que difieren en nivel.

Aunque el concepto de MAPE parece muy simple y convincente, tiene dos desventajas importantes en la aplicación práctica:

1. Si hay valores cero, se produce una división por cero.
2. Cuando se tiene un ajuste perfecto, el MAPE es cero. El MAPE no tiene restricción en cuanto a su nivel superior.

Al calcular el MAPE promedio para una serie de series temporales, podría surgir un problema: un pequeño número de series con un MAPE muy alto podría distorsionar una comparación entre el MAPE promedio de series temporales ajustadas con un método comparado con el MAPE promedio usando otro método.

Para evitar este problema, se han definido otras medidas, por ejemplo, el MAPE simétrico (sMAPE) o una medida relativa de precisión. El MAPE simétrico se representa con una ecuación:

$$Error = \sum \frac{2x|X - F|}{X + F} \times 100 \quad (24)$$

Donde X es el valor real y F es el pronóstico. Al usar el sMAPE, se evita el problema de grandes errores cuando los valores reales X están cerca de cero y la gran diferencia entre los errores porcentuales absolutos cuando X es mayor que F y viceversa. Además, el sMAPE fluctúa entre 200% y -200%, mientras que la medida no simétrica no tiene límites.

10.1.2 MSE

$$Error = \frac{1}{N} \sum_i^n (x_i - y_i)^2 \quad (25)$$

Donde x_i y y_i son los valores de las muestras i en x (valor predicho) y y (valor objetivo), respectivamente, y N es el número de instancias.

10.1.3 RMSE

$$Error = \frac{\sqrt{\sum_{i=1}^n (x_i - y_i)^2}}{N} \quad (26)$$

Donde x_i y y_i son los valores de las muestras i en x (valor predicho) y y (valor objetivo), respectivamente, y N es el número de instancias.

10.1.4 MSRE

$$Error = \frac{1}{N} \sum_i^n \left(\frac{x_i - y_i}{x_i} \right)^2 \quad (27)$$

Donde x_i son los valores de las muestras i en x (valor predicho) y y_i (valor objetivo), respectivamente, y N es el número de instancias.

10.1.5 Anderson-Darlington

AD es representado en la función que muestra la ecuación:

$$AD = \sum_{i=1}^n \frac{1 - 2i}{n} \ln(F_o[Z_{(i)}]) + \ln(1 - F_o[Z_{n+1-i}]) \quad (28)$$

Donde F_o es la distribución asumida con parámetros asumidos o estimados de la muestra (μ, σ) ; $Z_{(i)}$ es el i -ésimo valor de la muestra ordenada y estandarizada; n es el tamaño de la muestra; \ln es el logaritmo natural (base e) y el subíndice i va desde 1 hasta n .

La hipótesis nula, que la verdadera distribución es F_o con los parámetros asumidos, es rechazada (a un nivel de significancia $\alpha = 0.05$, para un tamaño de muestra n) si el estadístico de prueba AD es mayor que el valor crítico (CV).

Resumen paso a paso de la prueba AD GoF para normalidad:

1. Ordenar la muestra original y estandarizar: $Z = \frac{x - \mu}{\sigma}$.
2. Establecer una hipótesis nula: asumir una distribución normal (μ, σ) .
3. Obtener los parámetros de la distribución.
4. Obtener la distribución acumulativa $F(Z)$.
5. Obtener el logaritmo de $F(Z)$: $\ln(F(Z))$.
6. Ordenar la probabilidad acumulativa $F(Z)$ en orden descendente $(n - i + 1)$.
7. Encontrar los valores de $1 - F(Z)$.
8. Encontrar el logaritmo de lo anterior: $\ln(1 - F(Z))$.
9. Evaluar los estadísticos de prueba AD y CV.
10. Si CV es mayor que AD, se asume que la distribución es normal.

10.2 APÉNDICE B: NORMALIZACIÓN DE DATOS

La normalización *min – max* se realizó utilizando la fórmula:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (29)$$

Donde x_{norm} es el valor normalizado, x es un valor de muestra de los datos, x_{min} es el valor mínimo del conjunto de datos y x_{max} es el valor máximo del conjunto de datos. Para este trabajo, se eligieron valores mínimos y máximos de 7000 y 3500, respectivamente, para permitir que el modelo acomode y haga predicciones sobre conjuntos de datos futuros.

Los datos se dividieron en ventanas de tamaño n de la serie temporal, evaluadas desde el día $t - (n - 1)$ hasta el día t . Esta técnica supone que el precio del índice en cualquier día es una función desconocida de los precios de los últimos n días. El ejemplo de entrenamiento consistió en una secuencia de precios de tamaño de ventana $n + 1$, donde los primeros n precios constituyen los atributos y el último precio es el objetivo realizado.

10.3 APÉNDICE C: CÓDIGO MATLAB

10.3.1 Código Matlab para Normalización de Datos

```
function [b] = normal(x)
% x is the vector with time series data
maxim = max(x); % Get the maximum value from the vector
minim = min(x); % get the minimum value from the vector
L = size(x) % get the length of the vector
for i = 1 : L
Normdata(i, 1) = (inputs(i) - minim)/(maxim - minim);
end
save Normdata;
```

10.3.2 Código Matlab para Ordenamiento de Datos

```
function [b] = sort(Normdata, x)
% x is the preferred number of inputs c = length(inputs); % get the length of the vector
a = 1;
s = 1;

for i = 1 : c
if x <= c
z = 1;
for j = s : x

datan(a, z) = inputs(j);
z = z + 1;
end
a = a + 1;
s = s + 1;
x = x + 1;
else
end
end
save datan
```

10.3.2.1 Funcion de Entrenamiento MLP

```
function[net, err, corr] = trainMLP2(traindata, targetdata, validatedata, valid)

% initialize the network parameters

nin = 10; % specify the number of inputs
nout = 1; % Specify the number of the network outputs
nhidden = 6; % Specify the number of hidden layers the network should have
options = zeros(1, 18);
options(1) = 1;
options(2) = 1e - 6;
options(14) = 1000; % Specify the number of epochs for the Neural Networks to be trained
alpha = 0.0001;
% initialize the network
actfunc = 'logistic'; % specify the output activation function
net = mlp(nin, nhidden, nout, actfunc, alpha); % Initialize the neural network
% load train data ;
% load target data ;
% load validate data ;
% load validate target data;
% optimization the network
alg = 'scg'; % Specify the optimisation technique, scg(Scaled Conjugate gradient descent)
[net, options] = netopt(net, options, traindata, targetdata, alg); % netopt is a function trains the net-work with the parameters
specied during initialization.
savetrainMLP netnet; % save the trained model
error = options(8); % get the training error
saveerror
```

```

vten = mlpfwd(net, validatedata); % mlpfwd is a function that is used for validating and testing
the trained network
savevten; % save the validation results
[errorv, corr] = errorMLP(v, valid); % errorMLP calculates the RMSE of the validation results
Saveerrorv

```

10.3.2.2 Función Netop Usada en el Entrenamiento de la Red

```

function[net, options, varargout] = netopt(net, options, x, t, alg);
% NETOPT Optimize the weights in a network model.
%
%
% [NET, OPTIONS] = NETOPT(NET, OPTIONS, X, T, ALG) takes a network
% data structure NET, together with a vector OPTIONS of parameters
% governing the behaviour of the optimization algorithm, a matrix X of
% input vectors and a matrix T of target vectors, and returns the
% trained network as well as an updated OPTIONS vector. The string ALG
% determines which optimization algorithm (CONJGRAD, QUASINEW, SCG,
% etc.) or Monte Carlo algorithm (such as HMC) will be used.
%
% [NET, OPTIONS, VARARGOUT] = NETOPT(NET, OPTIONS, X, T, ALG) also
% returns any additional return values from the optimisation algorithm.
%

optstring = [alg, ('neterr", w, options, "netgrad", net, x, t)'];
% Extract weights from network as single vector
w = netpak(net);
% Carry out optimisation
[s1 : nargout] = eval(optstring);
w = s1;
if nargout > 1
options = s2;

% If there are additional arguments, extract them
nextra = nargout - 2;
if nextra > 0
for i = 1 : nextra
varargout{i} = s{i + 2};
end
end
end

% Pack the weights back into the network
net = netunpak(net, w);

subsectionmlpfwd function for validating and testing the network

function[y, z, a] = mlpfwd(net, x)

```

```

%MLPFWD Forward propagation through 2-layer network.
% % Description
% Y = MLPFWD(NET, X) takes a network data structure NET together with a
% matrix X of input vectors, and forward propagates the inputs through
% the network to generate a matrix Y of output vectors. Each row of X
% corresponds to one input vector and each row of Y corresponds to one
% output vector.
% [Y, Z] = MLPFWD(NET, X) also generates a matrix Z of the hidden unit
% activations where each row corresponds to one pattern.
% [Y, Z, A] = MLPFWD(NET, X) also returns a matrix A giving the summed
% inputs to each output unit, where each row corresponds to one
% pattern.

% Check arguments for consistency
errstring = consist(net, 'mlp', x);
if isempty(errstring);
error(errstring);
end

ndata = size(x, 1);

z = tanh(x * net.w1 + ones(ndata, 1) * net.b1);
a = z * net.w2 + ones(ndata, 1) * net.b2;

switch net.outfn

    case 'linear' % Linear outputs

        y = a;

    case 'logistic' % Logistic outputs
% Prevent overflow and underflow: use same bounds as mlperr
% Ensure that log(1-y) is computable: need exp(a) > eps
maxcut = -log(eps);
% Ensure that log(y) is computable
mincut = -log(1/realmin - 1);
y = 1./(1 + exp(-a));

    case 'softmax' % Softmax outputs

% Prevent overflow and underflow: use same bounds as glmerr
% Ensure that sum(exp(a), 2) does not overflow
maxcut = log(realmax) - log(net.nout);
% Ensure that exp(a) > 0
mincut = log(realmin);
a = min(a, maxcut);
a = max(a, mincut);
temp = exp(a);
y = temp./(sum(temp, 2) * ones(1, net.nout));

    otherwise

```

```
error(['Unknownactivationfunction', net.outfn]);
```

```
end
```

10.3.2.3 Función de Prueba de Red

```
function[netmlp, err, c, rat] = testMLP(network, tstX, tstY)
```

```
testr = mlpfwd(network, tstX);
```

```
savetestr;
```

```
[errt, corr] = errorMLP(testr, tstY);
```

```
Saveerrt
```

10.3.3 Código Matlab de Entrenamiento y Prueba para SVM

10.3.3.1 Función para Empezar el Entrenamiento del SVM

```
function[x, y, z] = svr(T, S)
```

```
% T is the training data
```

```
% S is the target for the supervised training
```

```
C = 100 % choose the value of C e = 0.001% choose the value of e ker = 'poly' choose the type of kernel to be used  
loss = 'einsensitive' % choose the loss function [x, y, z] = svr(S, T, ker, C, loss, e)
```

10.3.3.2 Función Usada en el Entrenamiento del Support Vector Regression

```
function[nsv, beta, bias] = svr(X, Y, ker, C, loss, e)
```

```
% SVR Support Vector Regression
```

```
% Usage: [nsv beta bias] = svr(X,Y,ker,C,loss,e)
```

```
% Parameters: X - Training inputs
```

```
% Y - Training targets
```

```
% ker - kernel function
```

```
% C - upper bound (non-separable case)
```

```
% loss - loss function
```

```
% e - insensitivity
```

```
% nsv - number of support vectors
```

```
% beta - Difference of Lagrange Multipliers
```

```
% bias - bias term
```

```
if(nargin < 3|nargin > 6) % check correct number of arguments
```

```
helpsvr
```

```
else
```

```
fprintf('Support Vector Regressing ....')
```

```
fprintf('
```

```
n = size(X,1);
```

```
if(nargin;6) e=0.0; end
```

```
if(nargin;5) loss='eInsensitive'; end
```

```
if(nargin;4) C=Inf; end
```

```

if(nargin>3) ker='linear'; end
% tolerance for Support Vector Detection
epsilon = svtol(C);

% Construct the Kernel matrix

fprintf('Constructing...');
H = zeros(n, n);
fori = 1 : n
forj = 1 : n
H(i, j) = svkernel(ker, X(i, :), X(j, :));
end
end

% Set up the parameters for the Optimisation problem
switchlower(loss)
case 'einsensitive',
Hb = [H - H; -HH];
c = [(e * ones(n, 1) - Y); (e * ones(n, 1) + Y)];
vlb = zeros(2 * n, 1); % Set the bounds: alphas  $\zeta = 0$ 
vub = C * ones(2 * n, 1); % alphas  $j = C$ 
x0 = zeros(2 * n, 1); % The starting point is [0 0 0 0]
neqcstr = nobias(ker); % Set the number of equality constraints (1 or 0)
ifneqcstr A = [ones(1, n) - ones(1, n)]; , b = 0; % Set the constraint Ax = b
else
A = []; , b = [];
end
case 'quadratic',
Hb = H + eye(n)/(2 * C);
c = -Y;
vlb = -1e30 * ones(n, 1);
vub = 1e30 * ones(n, 1);
x0 = zeros(n, 1); % The starting point is [0 0 0 0]
neqcstr = nobias(ker); % Set the number of equality constraints (1 or 0)
if neqcstr
A = ones(1, n); , b = 0; % Set the constraint Ax = b
else
A = []; , b = [];
end
otherwise, disp('Error : Unknown Loss F unction');
end

% Add small amount of zero order regularisation to
% avoid problems when Hessian is badly conditioned.
% Rank is always less than or equal to n.
% Note that adding too much reg will perturb solution

Hb = Hb + 1e - 10 * eye(size(Hb));

% Solve the Optimisation Problem

```

```

fprintf('Optimising...');
st = cputime;

[alpha lambda how] = qp(Hb, c, A, b, vlb, vub, x0, neqcstr);
fprintf('Execution time : 4.1fseconds', cputime - st);
fprintf('Status : s', how);

switch lower(loss)
case 'einsensitive',
beta = alpha(1 : n) - alpha(n + 1 : 2 * n);
case 'quadratic',
beta = alpha;
end
fprintf('|w0|^2 : f', beta' * H * beta);
fprintf('Sum beta : f', sum(beta));

% Compute the number of Support Vectors
svi = find(abs(beta) > epsilon);
nsv = length(svi);
fprintf('Support Vectors : d(3.1f)', nsv, 100 * nsv);

% Implicit bias, b0
bias = 0;

% Explicit bias, b0
If nobias(ker) = 0
switch lower(loss)
case 'einsensitive',
% find bias from average of support vectors with interpolation error e
% SVs with interpolation error e have alphas: 0 ; alpha ; C
svii = find(abs(beta) > epsilon & abs(beta) < (C - epsilon));
if length(svii) > 0
bias = (1/length(svii)) * sum(Y(svii) - e * sign(beta(svii)) - H(svii, svi) * beta(svi));
else
fprintf('No support vectors with interpolation error e - cannot compute bias. ');
bias = (max(Y) + min(Y))/2;
end
case 'quadratic',
bias = mean(Y - H * beta);
end
end
end
end

```

10.3.3.3 Función de Validación y Prueba del Modelo SVR Construido

```

function [r] = test(X, Y, beta, bias)
ker = 'poly'; r = svroutput(X, Y, ker, beta, bias); saver

```

10.3.4 Código Matlab de Entrenamiento y Prueba de Neuro-Fuzzy

10.3.4.1 Función para el Entrenamiento para Neuro-Fuzzy

```
function = trainNF(x)
y = fuzzy b %fuzzy-b is the function on the toolbox that used to train the network
```

10.3.4.2 Función Fuzz-b Usada para el entrenamiento de Neuro Fuzzy

```
global model
global memb fun
global model bias
global arch
global format out
global init
global no sets

global mod id
global mod path
global mhist id
global mhist path
global err id
global err path
global ehist id
global ehist path
global pred id
global pred path
global memo id
global memo path

current_dir = pwd;
c = computer;

if isunix
current_dir = [current_dir, '''];
else
if strcmp(c(1 : 2), 'P C')
current_dir = [current_dir, '''];
end

if strcmp(c(1 : 2), 'MA')
current_dir = [current_dir, ':''];
end
end

% The 'data' (the training set) matrix is stored in the file:
Data_id = 'data.mat';
data_path = current_dir;
% Save the memoranda in the file:
```

```

memo_id = 'memo_d';
memo_path = current_dir;

% Train one model of given complexity or find the best complexity?
pr = 'evaluate';

%%for model training only
% complexity
comp = 5;
% Save the trained model in the file:
mod_id = 'model.mat';
mod_path = current_dir;
% Save the computation diary in the file:
mhist_id = 'mhist.txt';
mhist_path = current_dir;

% for model evaluating only % The trained model is stored in the file: tmod_id = 'model.mat';
tmod_path = current_dir;
% The 'in' (test set) matrix is stored in the file: in_id = 'in_mat'; in_path = current_dir; % Save the predicted output in the file: pred
id = 'out_hat_mat'; pred_path = current_dir;

% for complexity-error exploration only
% range of complexity
comp min = 10;
comp max = 20;
% validation
valid = 'xvalid';
% no sets x valid
no sets = 10;
% Save the error Vs complexity matrix in the file:
err_id = 'errors.mat';
err_path = current_dir;
% Save the computation diary in the file:
ehist id = 'ehist.txt';
ehist path = current dir;

% model type
model = 0fuz0;

% for complexity-error exploration and model training only:
% form of membership functions
memb fun = 'gaussian';

% for complexity-error exploration and model training only:
% Bias model bias = 'no bias';

% for complexity-error exploration and model training only:
% architecture
arch = 'comb';

```

```

% for complexity-error exploration and model training only:
% format,out
formatout = 'linear'

% cluster: initialization of the centers and bases
init = 'HFC';

if strcmp(pr, 'one_mod')
eval(['load', data_path, data_id]); fuz_aux(pr, comp, data);
elseif strcmp(pr, 'evaluate')
eval(['load', tmod_path, tmod_id]);
eval(['load', in_path, in_id]);
fuz_aux(pr, centers, bases, par, bias, in);
elseif strcmp(pr, 'com_err')
eval(['load', datapath, dataid]);
fuz_aux(pr, comp_min, comp_max, data);
end

clear model valid memb_fun model_bias
clear arch format out init no_sets
clear mod_id mod_path mhist_id mhist_path
clear err_id err_path ehist_id ehist_path
clear pred_id pred_path in_id in_path
clear tmod_id tmod_path
clear memo,d memo_path
clear pr
clear centers bases par bias in
clear comp comp_min comp_max
clear data data_id data_path
clear c current_dir

```

10.3.4.3 Función para Identificar los Parametros del Modeo Fuzzy

```
function[centers, bases, par, bias] = fuz - id(comp, training - set)
```

```

%FUZ-ID Identification of the parameters of a Fuzzy Model
% [centers,bases,par,bias]=fuz-id(comp,training-set)
% centers[no-rules,no-var]
% bases[no-rules,no-var]
% par[no-rules,no-par] where no-par=1 if model='constant'
% and no-par=no-var+1 if model='linear'
% bias[1,1]
% comp[1,1] is the complexity of the model being identified
% training-set[no-data,no-var+1] the first no-var columns are the
% inputs, the last one is the output
% The following global variable are required:
% memb-fun: 'gaussian'/'triangular'
% arch: 'weigthed'/'comb'
% format-out: 'linear'/'constant'
% init: 'k-mean'/'hfc'

```

```

%fid-h

global memb_fun
global arch
global format out
global init

global fid_h

%Initialization:

[centers, bases] = eval([init'(comp, training set)']);
%Optimization:
termination = 0;
oldSSE = 1e + 10;
k = 0.005;
[nodata, c] = size(training_set);
intrn = training_set(:, 1 : c - 1);
outtrn = training_set(:, c);

while(termination < 2)

% INVERSION to determine the parameters of the CONSEQUENTS

if strcmp(formatout, 'constant') [SSE, newpar, bias] = invco(intrn, centers, bases, outtrn);
end
if strcmp(formatout, 'linear')
[SSE, newpar, bias] = invli(intrn, centers, bases, outtrn);
End

if (SSE/old SSE > 1 - k)
termination = termination + 1;
end
if isnan(SSE)
break;
end
par = newpar;
fprintf(fid_h, 'Consequents optimization.SSE =%g', SSE);

oldSSE = SSE;

% LEVENBERG-MARQUARDT to determine the CENTERS and the BASES

[centers, bases] = levemao(intrn, centers, bases, par, bias, outtrn);
End

function [centers, bases] = levemao(inputs, centers, bases, par, bias, output)

% LEVEMAO LEVENBERG-MARQUARDT
% [centers, bases]=levemao(inputs,centers,bases,par,output)

```

```

% centers[norules, novar] centers of the membership functions
% bases[norules, novar] bases of the membership functions
% inputs[nodata, novar] % centers[norules, novar] centers (initial value)
% bases[norules, novar] bases (initial value)
% par[norules, npar] parameters of the consequent of each rule
% bias[1,1]
% output[nodata,1]
% The following global variable is required: fidh
% LEVENBERG-MARQUARDT is used to determine the CENTERS and the BASES

global fidh
me = 3;
gradmin = .25;
munit = 0.001;
muinc = 10;
mudec = 0.1;
mumax = 1e10;
nodata = size(inputs, 1);
[norules, novar] = size(centers);
mu = munit;
[errors, Jacobian] = errfuz(inputs, centers, bases, par, bias, output);
premise = [centers(:); bases(:)];
SSE = sumsq(errors);
message = sprintf('Premise optimization: f printf(fidh, message, 0, munit, SSE);

fori = 1 : me

% CHECK MAGNITUDE OF GRADIENT

if(norm(Jacobian0 * errors)/nodata < gradmin), break, end

% INNER LOOP, INCREASE MU UNTIL THE ERRORS ARE REDUCED

while(mu <= mumax)
H = Jacobian' * Jacobian;
g = Jacobian' * errors;
A = H + mu * no data * eye(2 * norules * novar);
tol = 1e - 9;
newpremise = premise - pinv(A, tol) * g;

centers = reshape(newpremise(1 : novar * norules), [norules novar]);
bases = reshape(newpremise(novar * norules + 1 : 2 * novar * norules), [norules novar]);
bases = bases + (bases < 0.1) * 0.1;

% EVALUATE NEW NETWORK

[newerrors, newJacobian] = errfuz(inputs, centers, bases, par, bias, output);
newSSE = sumsq(new errors);
if(newSSE < SSE), break, end
mu = mu * muinc;

```

```

end
if(mu > mumax), break, end
mu = mu * mudec;

% UPDATE NETWORK

premise = newpremise;
SSE = newSSE;
Jacobian = newJacobian;
fprintf(fidh, message, i, mu, SSE);

end

```

10.3.4.4 Función para Calcular los Outputs del Modelo Neuro Fuzzy

```

function out = fuz_mod(inputs, centers, bases, par, bias)

% FUZ-MOD
% out=fuz_mod(inputs,centers,bases,par,bias)
% out[n data,1]
% inputs[no data,no var]
% centers[no rules,no var] centers of the membership functions
% bases[no-rules,no var] bases of the membership functions
% par[no rules,no par] parameters of the consequent of each rule
% bias[1,1]
% Given an input matrix and the matrices centers, bases, par and bias,
% fuz-mod returns the corresponding output of the fuzzy system
% The following global variable are required:
% memb-fun: 'gaussian'/'triangular'% arch: 'weigthed'/'comb'% format-out: 'linear'/'constant'

global memb fun;
global arch;
global format out;

[no data, no var] = size(inputs);
[no rules, no var] = size(centers);
[no rules, no par] = size(par);

if strcmp(format out, 'linear')
y = [inputs, ones(no_data, 1)] * par';
end

if strcmp(format out, 'constant')
y = ones(no_data, 1) * par';
end

Sum_w = zeros(no_data, 1);
Sum_wy = zeros(no_data, 1);

```

```

for i = 1 : no_rules

w = ones(no_data, 1); %initialization of the degree of match
%of the inputs to the premise of the i-th rule

for j = 1 : no_var
%match[no_data, 1] is the degree of match of each
%datum to the premise of the i-th rule for what
%concerns the j-th direction of the input space

if strcmp(memb_fun, 'gaussian')
match = exp(-((inputs(:, j) - centers(i, j)).^2)/bases(i, j)));
end

if strcmp(memb_fun, 'triangular')
match = max(0, ones(no_data, 1) - 2 * abs(inputs(:, j) - centers(i, j))/bases(i, j));
end

w = w .* match;
end

Sum_wy = Sum_wy + w .* y(:, i);
Sum_w = Sum_w + w;
End

Sum_w = Sum_w + (Sum_w == 0); % if Sum_w = 0 then Sum_w = 1
% n.b. in this case Sum_wy = 0
if strcmp(arch, 'weighed')
out = Sum_wy./Sum_w;
end

if strcmp(arch, 'comb')
out = Sum_wy;
end

out = out + bias * ones(size(out))

```

9 REFERENCIAS

- Acevedo, Wendi (2023), “La IA en los mercados financieros”, <https://www.eleconomista.com.mx/opinion/La-Inteligencia-Artificial-en-los-mercados-financieros-20230519-0048.html>
- Anaëlle Martin (2022), “L’intelligence artificielle peut-elle être saisie par le droit de l’Union européenne ?”, l’Université de Strasbourg, CEIE.
- A. Thompson y M. Ward (1995), “The Johannesburg stock exchange as an efficient market: review”, Journal of Economics and Econometrics.
- A. Timmermann y C. Granger (2004), “Efficient market hypothesis and forecasting” International Journal of Forecasting, no. 20.
- AEPD (2020), “Protección de datos y seguridad”, <https://www.aepd.es/prensa-y-comunicacion/blog/proteccion-datos-seguridad>
- Barcelona Business School, “Cinco usos de la inteligencia artificial en Finanzas”, <https://barcelonafinanceschool.com/5-usos-de-la-inteligencia-artificial-en-finanzas/>
- Bogacka, Barbara (2008), “MTH6139 Time Series”, Queen Mary University of London, <https://webpace.maths.qmul.ac.uk/b.bogacka/TimeSeries/MAS328.html>
- BrainCode (2023), “¿Algoritmos e inteligencia artificial, Cual es la diferencia?”, <https://brainandcode.tech/algoritmos-e-inteligencia-artificial-cual-es-la-diferencia/>
- Bughin Jacques, Eric Hazan, Sree Ramaswamy, Michael Chui, Tera Alla, Peter Dahlström, Nicolaus Henke y Monica Trench (2017), “Artificial Intelligence The Next Digital Frontier?”, Mckinsey & Company.
- C. Bishop (1996), “Neural Networks for Pattern Recognition”, New York: Oxford University Press.
- C. C. Lee (1990), “Fuzzy logic in control systems: Fuzzy logic controller—Part I and II”, IEEE.

- C. Chatfield (1993), “*Calculating interval forecasts*”, Journal of Business and Economic Statistics, no. 11..
- C. Cortes y V. Vapnik (1995), “*Support vector networks*”, Machine Learning, vol. 20.
- Cornejo Eloy (2012), “*Sistema Hexadecimal*”, <https://fr.slideshare.net/campeon23479/sistema-hexadecimal-14032146>
- C. W. J. Granger (1993), “*Strategies for Modelling non-linear Time Series relationships*”, Economic Record, no. 60.
- D. Bao and Z. Yang (2006), “*Intelligent stock trading system by turning point confirming and probabilistic reasoning*”, Expert Systems with Applications.
- D. Keim and R. Stambaugh (1986), “*Predicting returns in the stock and bond markets*”, Journal of Financial Economics, vol. 17..
- D. Kujolj (2004), “*Identification of Complex Systems Based on Neural and Takagi–Sugeno Fuzzy Model*”, <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1262501>
- Dunne, Steven (2020), “*Como la automatización inteligente transformara la función de finanzas*”, <https://blog.workday.com/es-es/2020/how-intelligent-automation-transform-finance-function.html>
- D. Tikk, L. T. K’oczy, y T. D. Gedeon (2001), “*A survey of universal approximation and its applications in soft computing*”, Research Working Paper RWP-IT-2001. School of Information Technology, Murdoch University, Perth.
- E. Fama 1965, “*The behavior of stock market prices*”.
- E. Fama 1970, “*Efficient capital markets: a review of theory and empirical work*”, Journal of Finance, vol. 25.

- EU Artificial Intelligence Act (2014), “*La loi européenne sur l’intelligence artificielle*”, <https://artificialintelligenceact.eu/fr/>
- Flores, Nelly (2023), “*El impacto de la inteligencia artificial en la actualidad*”, <https://blog.maestriasydiplomados.tec.mx/el-impacto-de-la-inteligencia-artificial-en-la-actualidad>
- G. Box y G. Jenkins (1970), “*Time series analysis: Forecasting and control*”.
- G. Deboeck (1994), “*Trading on the edge. Neural, Genetic, and Fuzzy systems for chaotic financial markets*”, John Wiley & Sons.
- G. Deboeck y M. Cader (1994), “*Trading U.S. treasury notes with a portfolio of neural net models*”, Trading on the Edge: Neural, Genetic, and Fuzzy Systems for Chaotic Financial Market. John Wiley & Sons.
- Gomila Juan (2023), “*Algoritmos en Inteligencia Artificial y Aplicaciones Practicas: El Futuro ya esta Aqui*”, <https://cursos.frogamesformacion.com/pages/blog/algoritmo-en-inteligencia-artificial>
- G. D. Manuel (2020), “*El sistema binario y el lenguaje en los ordenadores*”, https://iesalandalus.es/tyc/t1/4el_sistema_binarioel_lenguaje_de_los_ordenadores.html
- Grupo Sistemas (2023), “*Integración de la IA en las finanzas empresariales*”, <https://sistemascc.com.mx/blog/integracion-inteligencia-artificial-finanzas-empresariales/>
- Himani Bhavsar y Mahesh H. Panchal (2012), “*A Review on Support Vector Machine for Data Classification*”, <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=d683a971524a0d76382ce335321b4b8189bc8299>

- H. R. Campbell (1995), “*Predictable risk and returns in emerging markets,*” Review of Economic Studies, vol. 8.
- ICCSI (2024), “*Principales componentes de la IA*”, <https://iccsi.com.ar/componentes-de-la-inteligencia-artificial/>
- J. Hamilton y G. Lin (1996), “*Stock market volatility and the business cycle*”, Journal of Applied Econometrics, vol. 11.
- Jenis, Sheth. (2019), “*The Industrial Revolution –From Industry 1.0 to Industry 5.0*”, <https://supplychaingamechanger.com/the-industrial-revolution-from-industry-1-0-to-industry-5-0/>
- Jimenez, Monica (2023), “*Inteligencia artificial aplicada a la gestión de riesgo*” <https://www.piranirisk.com/es/blog/inteligencia-artificial-ai-en-gestion-de-riesgos>
- J. Scott Armstrong y C. Kesten Green (2011), “*Demand forecasting: Evidence-based Method*”.
- JYH-Shing Roger Jang y Chuen-Tsai Sun (1994), “*Neuro Fuzzy Modeling and Control*”, by NASA Grant NCC 2-275, MICRO Grant 92-180, EPRI Agreement RP 8010-34, and in part by the BISC program.
- KeepCoding (2023), “*Relación entre la inteligencia artificial y los algoritmos*”, <https://keepcoding.io/blog/inteligencia-artificial-y-los-algoritmos/>
- K. Hornik, M. Stinchcombe y H. White (1989), “*Multilayer feedforward networks are universal approximators*” Neural Networks, vol. 2.
- K. Kim (2006), “*Artificial neural networks with evolutionary instance selection for financial forecasting*”, Expert Systems with Applications, vol. 20.
- Kiebdój, Aleksandra (2018), “*Artificial Intelligence in Europe, Outlook for 2019 and beyond. Summary of the Report*”, <https://www.linkedin.com/pulse/artificial-intelligence-europe-outlook-2019-beyond-summary-kiebdoj>.

- Larez, Francisco (2023), “*Los riesgos del sesgo en los proyectos de IA*”, <https://esemanal.mx/2023/09/los-riesgos-del-sesgo-en-los-proyectos-de-ia/>
- Lewis, Anna. (2017), “*Guide to Industry 4.0 & 5.0*”, <https://gesrepair.com/industry-4-and-5/>
- L.J. Tashman (2000), “*Out-of-sample tests of forecasting accuracy: an analysis and review*” International Journal of Forecasting, vol. 7, no. 4.
- L. R. Marwala (2010), “*Forecasting the stock market index using artificial intelligence techniques*”.
- Njegovanović, Ana (2017), “*Artificial Intelligence: Financial Trading and Neurology of Decision*”, Financial Markets, Institutions and Risks.
- M. Clements, P. Franses, y N.Swanson (2004), “*Forecasting economic and financial time series with non-linear models*”, International Journal of Forecasting, vol. 20.
- Microsoft (2024), “*¿Qué es el aprendizaje automático?*”, <https://azure.microsoft.com/es-es/resources/cloud-computing-dictionary/what-is-machine-learning-platform>
- Microsoft, EY y K. Aleksandra (2018), “*Artificial Intelligence in Europe, Outlook for 2019 and Beyond*”, <https://www.linkedin.com/pulse/artificial-intelligence-europe-outlook-2019-beyond-summary-kiebdof/>
- Muir, George (2018), “*AI -The Fifth Industrial Revolution*”, <https://aibusiness.com/livetiles-fifth-industrial-revolution/>
- Olsevskaja, Valerija (2019), “*Industry 5.0 –a step back from the "lights-out" factory or the return of the man*”.
- Ostergaard, Esben. (2019). “*Welcome to Industry 5.0: The Human Touch. Revolution Is Now under Way*”.

- P. Aida (2017), “Codi Binari”, <https://fr.slideshare.net/slideshow/codi-binari-71049737/71049737>
- Palou, Nacho (2023), “El matemático del Siglo IX que sentó las bases de la Inteligencia Artificial”, <https://telefonicatech.com/blog/breve-historia-algoritmos-matematico-siglo-ix-que-sento-bases-inteligencia-artificial>
- Parra, Blanca (2022), “Música y algoritmos matemáticos”, Paskin Matemático.
- Raisin (2024), “¿Que son los mercados financieros? Tipos, características y funciones”, <https://www.raisin.es/educacion-financiera/mercados-financieros-definicion-caracteristicas-y-volatilidad/>
- Rastogi, Vaibhav (2023), “ARMA (Autoregressive Moving Average) model” <https://medium.com/@vaibhav1403/the-arma-autoregressive-moving-average-model-is-a-popular-statistical-model-used-in-time-series-24ce43049366>
- R. Babuska y H. Verbruggen (2003), “Neuro-fuzzy methods for nonlinear system identification,” Annual Reviews in Control, vol. 27.
- R. Babuska y H. Verbruggen (1997), “Fuzzy set methods for local modelling and identification,” In R. Murray Smith and T.A. Johansen, editors, Multiple Model Approaches to Modeling and Control.
- R. Fieldes and S. Makridakis, (1995), “The impact of empirical accuracy studies on time series analysis forecasting”, International Statistical Review, no. 63.
- Rodriguez, Eduardo (2023), “La IA en la economía: Modelos financieros y predicciones de mercado”, <https://canalinnova.com/la-inteligencia-artificial-en-la-economia-modelos-financieros-y-predicciones-de-mercado/>
- R. F. Victoria (2018), “Camino aleatorio, paseo aleatorio o random walking” <https://rpubs.com/vicferu/394453>
- R. Kohavi y F. Provost (1998), “Glossary of terms.” Machine Learning, vol. 30.

- S. Makridakis y H. Hibon (1978), “*Accuracy of forecasting: An Emperical Investigation*”, J. Roy Statist. Soc.
- S. Makridakis, Wheelwright. y McGEE (1997), “*FORECASTING: Methods and Applications. John Wiley and Sons, Inc,second ed*”.
- Standard bank (2007), “*Basic investment course*”, www.securities.co.za
- S. Wachter y B. Mittelstadt (2019), “*A right to reasonable inferences: re-thinking data protection law in the age of big data and AI*”, Colum. Bus. L. Rev.
- Tapia, Gustavo (2023), “*La IA y los servicios financieros*”, <https://www.thomsonreuters.com.ar/es/soluciones-fiscales-contables-gestion/blog-empresas/la-inteligencia-artificial-y-los-servicios-financieros.html>
- T. Chen y H. Chen (1995), “*Universal approximations to nonlinear operators by neural networks with arbitrary activation functions and its application in dynamical systems*”, IEEE trans. Neural Networks, vol. 6(4).
- T. Takagi y M. Sugeno (1985), “*Fuzzy identification of systems and its application to modeling and control*”, IEEE Trans. Syst., Man, Cybern., vol. SMC-15.
- Bertrand Brunessen (2018), “*La Souveraineté numérique dix ans de débats, et après ?*”.
- V. Rafael (2019), “*¿Cual e sla diferencia entre las maquinas de soporte vectorial lineales y la regrecion logistica ?*”, <https://es.quora.com/Cu%C3%A1l-es-la-diferencia-entre-las-m%C3%A1quinas-de-soporte-vectorial-lineales-y-la-regresi%C3%B3n-log%C3%ADstica>
- V. Vapnik (1995). “*The Nature of Statistical Learning Theory*”, NY: Springer Verlag.

- Xiao Chen, Martin A. Eder, Asm Shihavuddin y Dan Zsheng (2021), “*A Human-Cyber-Physical System toward Intelligent Wind Turbine Operation and Maintenance*”.
- X. Zhang, J. Mesirov y D. Waltz (1992), “*Hybrid system for protein secondary structure prediction*” *Journal of Molecular Biology*, no. 225.
- YooZ (2023), “*Como usar la IA en las finanzas*”, <https://www.getyooz.com/es/blog/inteligencia-artificial-en-finanzas>
- *Your Online Choices* (2009), “*A guide to online behavioural advertising*”, <https://www.youronlinechoices.com/fr/foire-aux-questions/>