



**UNIVERSIDAD DE CONCEPCIÓN
FACULTAD DE INGENIERÍA
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA**



**PREDICCIÓN DE PRECIOS EN EL MERCADO FINANCIERO MEDIANTE
INDICADORES TÉCNICOS Y UN SISTEMA DE INFERENCIA NEURO-DIFUSO
ADAPTATIVO (ANFIS)**

POR

Pablo Ignacio Fajardo Bernal

Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de Concepción para
optar al título profesional de Ingeniero Civil Electrónico

Profesor Guía
Juan Pablo Segovia V.

Marzo 2025
Concepción (Chile)

©2025 Pablo Ignacio Fajardo Bernal

©2025 Pablo Ignacio Fajardo Bernal

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.

*A mis padres, cuya incansable paciencia y apoyo
han sido la base de cada uno de mis logros.*

Agradecimientos

Quiero expresar mi más sincero agradecimiento a todas las personas que han sido parte fundamental en este proceso universitario y en mi crecimiento, tanto personal como profesional.

Agradezco de corazón a mi padre Ricardo y mi madre María Angélica, quienes con su amor incondicional y su esfuerzo constante han hecho posible alcanzar cada uno de mis sueños. Su apoyo inquebrantable me ha impulsado a dar lo mejor de mí y espero, en el futuro, poder retribuirles todo lo que han hecho por mí.

A Rayen, cuyo amor y apoyo constante han sido un refugio y fuente de inspiración en cada paso de este camino. Su comprensión, paciencia y empatía han llenado mi vida de alegría y me ayuda cada día a ser mejor persona.

A quienes conocí en mi vida universitaria y que hoy llamo amigos. Cada jornada de estudio, trabajo en grupo y salidas, hicieron de esta etapa una experiencia inolvidable. Agradezco también a mis amigos fuera de la universidad, quienes, con su espontaneidad y apoyo, han llenado mi vida de momentos únicos. Su amistad ha sido un pilar fundamental en este camino.

A mi profesor guía Juan Pablo Segovia, por su dedicación, paciencia y confianza en mi trabajo. Su orientación y conocimientos han sido fundamentales en el desarrollo de este trabajo, y sus enseñanzas, que van más allá del ámbito académico, han enriquecido mi formación como futuro profesional.

Sumario

La presente memoria desarrolla un modelo de predicción de precios en el mercado financiero basado en un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS). Este sistema utiliza indicadores técnicos como entradas primarias, extendido con variables macroeconómicas para mejorar su capacidad predictiva en diferentes horizontes temporales. Las empresas analizadas fueron CMPC y Antofagasta Minerals, representando sectores clave de la economía chilena: forestal y minería, respectivamente.

El trabajo se estructura en tres fases principales: (1) desarrollo preliminar del modelo ANFIS con indicadores técnicos, (2) configuración y evaluación del modelo base para combinaciones de 4 y 5 variables, y (3) extensión del modelo mediante la integración de variables macroeconómicas relevantes como el tipo de cambio, precios de commodities e índices económicos. Se evaluaron métricas estándar como RMSE, MAPE y R^2 para determinar el desempeño de los modelos en validación y predicción, comparando el impacto de los horizontes temporales en la precisión de las estimaciones.

Los resultados muestran que el modelo ANFIS tiene un desempeño superior en horizontes de predicción cortos ($t + 1$ y $t + 5$), siendo más preciso con indicadores técnicos. Sin embargo, al incorporar variables macroeconómicas, el modelo demostró mayor estabilidad y precisión en horizontes medianos y largos ($t + 15$ y $t + 30$). Además, se identificaron diferencias significativas en el desempeño entre ambas empresas, destacando la influencia del tipo de cambio en CMPC y del precio de los metales en Antofagasta Minerals.

Este trabajo contribuye a la literatura existente al combinar indicadores técnicos y variables macroeconómicas en un enfoque híbrido, proporcionando una metodología robusta para el análisis y predicción de precios en mercados financieros.

Summary

This thesis develops a financial market price prediction model based on an Adaptive Neuro-Fuzzy Inference System (ANFIS). The model utilizes technical indicators as primary inputs, extended with macroeconomic variables to enhance predictive capability across different time horizons. The analyzed companies were CMPC and Antofagasta Minerals, representing key sectors of the Chilean economy: forestry and mining, respectively.

The study is divided into three main phases: (1) preliminary development of the ANFIS model with technical indicators, (2) configuration and evaluation of the base model using combinations of 4 and 5 variables, and (3) extension of the model by integrating relevant macroeconomic variables such as exchange rates, commodity prices, and economic indices. Standard metrics, including RMSE, MAPE, and R^2 , were used to assess model performance in validation and prediction, with a focus on the impact of time horizons on prediction accuracy.

The results indicate that the ANFIS model performs best in short prediction horizons ($t + 1$ y $t + 5$), showing higher precision with technical indicators. However, when macroeconomic variables were included, the model exhibited greater stability and accuracy in medium and long-term horizons ($t + 15$ y $t + 30$). Significant differences were identified between the companies, highlighting the impact of the exchange rate on CMPC and metal prices on Antofagasta Minerals.

This study contributes to existing literature by combining technical indicators and macroeconomic variables in a hybrid approach, providing a robust methodology for price analysis and prediction in financial markets.

Tabla de contenido

Capítulo 1. Introducción	1
1.1 Introducción general	1
1.2 Problemática	1
1.3 Objetivos	2
1.3.1 Objetivo general.....	2
1.3.2 Objetivos específicos	2
1.4 Alcances y limitaciones	3
1.5 Metodología	3
Capítulo 2. Revisión bibliográfica	4
2.1 Introducción	4
2.2 Principios y retos en la predicción de mercados financieros	4
2.3 ANFIS como metodología para el pronóstico financiero	4
2.4 Uso de indicadores técnicos y lógica difusa en el trading	5
2.5 Integración de variables macroeconómicas y selección de entradas	5
2.6 Enfoques híbridos y optimizaciones avanzadas.....	6
2.7 Consideraciones para la adopción práctica de ANFIS.....	6
2.8 Relevancia para la presente investigación	7
Capítulo 3. Marco Teórico	8
3.1 Introducción	8
3.2 Sistema de Inferencia Neuro-Difusa Adaptativo	8
3.2.1 Conceptos fundamentales	8
3.2.2 Arquitectura y funcionamiento	9
3.3 Indicadores Técnicos	12
3.3.1 Convergencia/Divergencia de Media Móvil (MACD)	12
3.3.2 Índice de Fuerza Relativa (RSI).....	13
3.3.3 Oscilador Estocástico.....	14
3.3.4 Bandas de Bollinger.....	15
3.4 Métricas de evaluación	15
3.4.1 Raíz del Error Cuadrático Medio (RMSE)	16
3.4.2 Coeficiente de Determinación (R^2).....	16
3.4.3 Error Porcentual Absoluto Media (MAPE)	16
Capítulo 4. Desarrollo y configuración preliminar del modelo ANFIS.....	17
4.1 Introducción	17

4.2	Modelo ANFIS a trabajar.....	17
4.3	Recopilación y preparación de datos	19
4.4	Entradas del Modelo	22
4.5	Desarrollo del modelo ANFIS preliminar.....	24
4.5.1	Configuración del modelo preliminar	24
4.5.2	Entrenamiento y validación del modelo preliminar.....	26
Capítulo 5.	Desarrollo del modelo con indicadores técnicos.....	29
5.1	Introducción	29
5.2	Definición del modelo base	29
5.3	Desarrollo del modelo base.....	31
5.3.1	Proceso de entrenamiento	31
5.3.2	Proceso de validación y predicción.....	33
5.4	Resultados	34
5.4.1	Modelos de 4 entradas	34
5.4.2	Modelos de 5 entradas	35
5.5	Análisis general de resultados.....	36
5.5.1	Impacto del horizonte temporal	36
5.5.2	Influencia de los indicadores técnicos	37
5.5.3	Comparación entre empresas	37
5.5.4	Conclusiones	37
Capítulo 6.	Extensión del modelo con variables macroeconómicas	38
6.1	Introducción	38
6.2	Selección de variables macroeconómicas	38
6.2.1	Índices	38
6.2.2	Monedas.....	40
6.2.3	Commodities	43
6.3	Integración de las variables.....	45
6.4	Resultado del modelo extendido.....	46
6.4.1	Modelos de 4 entradas	47
6.4.2	Modelos de 5 entradas	49
6.5	Análisis general de resultados.....	51
Capítulo 7.	Resultados y análisis general.....	53
7.1	Introducción	53
7.2	Comparación entre empresas	53
7.3	Impacto de los horizontes de predicción.....	55

7.4	Relevancia de las variables seleccionadas	56
7.5	Contexto del mercado financiero chileno	57
7.5.1	Desempeño de los modelos en el contexto local	58
7.5.2	Impacto de los factores externos.....	58
Capítulo 8.	Conclusión	59
Referencias		61
Anexo A.	Resultados	A.1
A.1	Datos relevantes del modelo ANFIS preliminar	A.1
A.2	Resultados de los mejores modelos de 4 variables para CMPC	A.2
A.3	Resultados de los mejores modelos de 4 variables para ANTO	A.4
A.4	Resultados de los mejores modelos de 5 variables para CMPC	A.5
A.5	Resultados de los mejores modelos de 5 variables para ANTO	A.7
Anexo B.	Códigos relevantes	B.1
B.1	Código modelo ANFIS preliminar.....	B.1
B.2	Código iteración modelo ANFIS base	B.4
B.3	Código iteración modelo ANFIS extendido	B.6

Lista de tablas

Tabla 4.1: Componentes asociados a cada indicador técnico	22
Tabla 4.2: Entradas del modelo preliminar.	24
Tabla 4.3: Resultados del modelo ANFIS preliminar.	27
Tabla 5.1: Parámetros para la configuración de los modelos ANFIS.	31
Tabla 5.2: Abreviaciones para los indicadores técnicos.	34
Tabla 5.3: Mejores combinaciones de indicadores técnicos para modelos de 4 variables...35	
Tabla 5.4: Resultados de los mejores modelos de 4 variables.	35
Tabla 5.5: Mejores combinaciones de indicadores técnicos para modelos de 5 variables...35	
Tabla 5.6: Resultados de los mejores modelos de 5 variables	36
Tabla 6.1: Abreviación de las variables macroeconómicas.	47
Tabla 6.2: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 4 variables para CMPC.	47
Tabla 6.3: Modelos que presentaron mejores resultados de 4 variables para CMPC.	48
Tabla 6.4: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 4 variables para ANTO.	48
Tabla 6.5: Modelos que presentaron mejores resultados de 4 variables para ANTO.	49
Tabla 6.6: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 5 variables para CMPC.	49
Tabla 6.7: Modelos que presentaron mejores resultados de 5 variables para CMPC.	50
Tabla 6.8: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 5 variables para ANTO.	50
Tabla 6.9: Modelos que presentaron mejores resultados de 5 variables para ANTO.	51
Tabla A. 1: Reglas generadas mediante Grid Partition.	A.2
Tabla A. 2: Resultados de los mejores modelos de 4 variables (t+1) para CMPC.	A.3
Tabla A. 3: Resultados de los mejores modelos de 4 variables (t+5) para CMPC.	A.3
Tabla A. 4: Resultados de los mejores modelos de 4 variables (t+15) para CMPC.	A.3
Tabla A. 5: Resultados de los mejores modelos de 4 variables (t+30) para CMPC.	A.4
Tabla A. 6: Resultados de los mejores modelos de 4 variables (t+1) para ANTO.	A.4
Tabla A. 7: Resultados de los mejores modelos de 4 variables (t+5) para ANTO.	A.4
Tabla A. 8: Resultados de los mejores modelos de 4 variables (t+15) para ANTO.	A.5

Tabla A. 9: Resultados de los mejores modelos de 4 variables (t+30) para ANTO.	A.5
Tabla A. 10: Resultados de los mejores modelos de 5 variables (t+1) para CMPC.	A.5
Tabla A. 11: Resultados de los mejores modelos de 5 variables (t+5) para CMPC.	A.6
Tabla A. 12: Resultados de los mejores modelos de 5 variables (t+15) para CMPC.	A.6
Tabla A. 13: Resultados de los mejores modelos de 5 variables (t+30) para CMPC.	A.6
Tabla A. 14: Resultados de los mejores modelos de 5 variables (t+1) para ANTO.	A.7
Tabla A. 15: Resultados de los mejores modelos de 5 variables (t+5) para ANTO.	A.7
Tabla A. 16: Resultados de los mejores modelos de 5 variables (t+15) para ANTO.	A.8
Tabla A. 17: Resultados de los mejores modelos de 5 variables (t+30) para ANTO.	A.8

Lista de figuras

Figura 3.1: Sistema de Inferencia Difuso, adaptado de [21].	9
Figura 3.2: Arquitectura de una ANN, adaptado de [21].	9
Figura 3.3: Arquitectura de un ANFIS, adaptado de [21].	10
Figura 4.1: Metodología propuesta.	18
Figura 4.2: Arquitectura de un modelo ANFIS de 4 entradas y 16 reglas.	19
Figura 4.3: Datos históricos de CMPC en CLP	20
Figura 4.4: Datos históricos de ANTO en GBP	21
Figura 4.5: Precios de cierre para CMPC y ANTO	21
Figura 4.6: Gráficos de MACD para (a) CMPC y (b) ANTO	22
Figura 4.7: Gráficos de RSI para (a) CMPC y (b) ANTO	23
Figura 4.8: Gráficos del Oscilador Estocástico para (a) CMPC y (b) ANTO	23
Figura 4.9: Gráficos de las Bandas de Bollinger para (a) CMPC y (b) ANTO	24
Figura 4.10: Funciones de membresía para las 4 entradas del modelo preliminar.	25
Figura 4.11: Gráfico de error de entrenamiento a través de las épocas.	26
Figura 4.12: Superficie de reglas generado a partir de las entradas 1 y 2.	27
Figura 4.13: Resultados del modelo ANFIS preliminar.	28
Figura 5.1: Diagrama del número de modelos.	29
Figura 5.2: Diagrama del desplazamiento temporal.	30
Figura 5.3: Metodología para el modelo ANFIS base.	32
Figura 5.4: Nomenclatura para modelos de indicadores técnicos.	34
Figura 6.1: Gráfico del IPSA.	39
Figura 6.2: Gráfico del IMCE.	39
Figura 6.3: Gráfico del ICC.	40
Figura 6.4: Gráfico del IPEC.	40
Figura 6.5: Gráfico del tipo de cambio USD/CLP.	41
Figura 6.6: Gráfico del tipo de cambio EUR/CLP.	41
Figura 6.7: Gráfico del tipo de cambio CNY/CLP.	42
Figura 6.8: Gráfico de la variación mensual del IPC (%) 2018=100	42
Figura 6.9: Gráfico de Futuros de Cobre (HGZ4).	43
Figura 6.10: Gráfico de Futuros de Oro (GC1).	44

Figura 6.11: Gráfico de Futuros de Plata (SI1)	44
Figura 6.12: Gráfico de Futuros de Petróleo WTI (CL1).....	45
Figura 6.13: Metodología para el modelo ANFIS extendido.	46
Figura 6.14: Nomenclatura para los modelos de variables macroeconómicas.....	47
Figura 7.1: Gráfico de error de validación para distintos modelos de 4 variables.	53
Figura 7.2: Gráfico de error de validación para distintos modelos de 5 variables.	54
Figura 7.3: Gráfico de R2 de modelos de (a) 4 entradas y (b) 5 entradas.	55
Figura 7.4: Error de predicción para distintos modelos de 4 variables.	56
Figura 7.5: Gráfico de conteo de indicadores técnicos en modelos de validación.....	57
Figura 7.6: Gráfico de conteo de indicadores técnicos en modelos de predicción.	57
Figura A. 1: Datos históricos de CMPC en CLP.....	A.1
Figura A. 2: Datos históricos de ANTO en GBP.	A.1

Abreviaciones

Mayúsculas

ANN	: Artificial Neural Network (red neuronal artificial).
ANFIS	: Adaptive Neuro-Fuzzy Inference System (sistema de inferencia neuro-difusa adaptativo).
ARIMA	: AutoRegressive Integrated Moving Average (modelo autorregresivo integrado de media móvil)
EMA	: Exponential Moving Average (media móvil exponencial).
EMH	: Efficient Market Hypothesis (hipótesis de mercado eficiente).
GA	: Genetic Algorithm (algoritmo genético).
LSTM	: Long Short-Term Memory (red de memoria a corto-largo plazo)
MACD	: Moving Average Convergence-Divergence (convergencia-divergencia de media móvil).
MAPE	: Mean Absolute Percentage Error (error medio porcentual absoluto).
MF	: Membership Function (función de membresía).
MSE	: Mean Square Error (error cuadrático medio).
QPSO	: Quantum-behaved Particle Swarm Optimization (optimización por enjambre de partículas con comportamiento cuántico).
RL	: Reinforced Learning (aprendizaje por refuerzo).
RMSE	: Root Mean Squared Error (raíz del error cuadrático medio).
R^2	: Coefficient of Determination (coeficiente de determinación).
RSI	: Relative Strength Index (índice de fuerza relativa).

Nomenclatura

P_t	: Precio de cierre de un activo en el instante t .
P_{t+1}	: Precio de cierre predicho en el instante t .
X_i	: Vector de i variables de entradas.
M_j	: Variable macroeconómica j incluida como factor externo.
μ	: Función de membresía.
y	: Variable de salida o valor objetivo para el modelo ANFIS.
e_t	: Error de predicción en el instante t .
a_i, b_i, c_i	: Parámetros de premisa.
p_i, q_i, r_i	: Parámetros consecuentes.
$RMSE$	: Métrica de raíz del error cuadrático medio.
$MAPE$	: Métrica del error medio porcentual absoluto.
R^2	: Métrica del coeficiente de determinación.

Capítulo 1. Introducción

1.1 Introducción general

Los mercados financieros se caracterizan por una alta complejidad y dinamismo, lo que se traduce en grandes desafíos para la predicción de precios de activos. Factores macroeconómicos, noticias globales y comportamientos especulativos conforman un entorno impredecible y en constante cambio. Con el paso de los años, se han propuesto diversas metodologías para tratar de anticipar los movimientos del mercado, desde análisis puramente estadísticos hasta enfoques de inteligencia artificial más avanzados [1]. Sin embargo, ninguno ha conseguido ofrecer resultados completamente fiables de manera consistente. Por un lado, los métodos tradicionales suelen apoyarse en supuestos lineales y simplistas que no reflejan las fluctuaciones reales de los precios; por otro, los métodos más complejos enfrentan dificultades en términos de interpretabilidad y, en ocasiones, en la integración de factores externos [4].

Además de esta complejidad intrínseca, la interacción entre indicadores técnicos y condiciones macroeconómicas introduce múltiples dimensiones de incertidumbre. Mientras que los indicadores técnicos se enfocan en patrones históricos de precios y volúmenes [13], los factores macroeconómicos pueden alterar significativamente la dirección del mercado a corto, mediano y largo plazo [11]. Esta combinación de señales heterogéneas hace que la predicción financiera requiera modelos capaces de manejar la no linealidad y de adaptarse a distintos horizontes de pronóstico.

En este contexto, resulta crítico identificar los principales retos que persisten en la predicción de precios y entender por qué, a pesar de los avances tecnológicos y metodológicos, sigue siendo una tarea abierta e inexacta [2]. La presente investigación parte de esta problemática y se enfoca en analizar las brechas que dificultan el desarrollo de modelos predictivos más fiables y robustos.

1.2 Problemática

La mayoría de los mercados de activos refleja comportamientos que difícilmente pueden encapsularse en modelos lineales [1]. Cambios abruptos o ajustes de precios pueden surgir por eventos externos (políticos, económicos, sociales) que escapan a los datos históricos, que son puramente técnico [5]. Este carácter no lineal incrementa la dificultad de generalizar conclusiones válidas sobre el futuro comportamiento del mercado.

Aunque los indicadores técnicos arrojan señales útiles, frecuentemente se deja de lado la influencia de variables macroeconómicas (tasas de interés, inflación, tipos de cambio, etc.) que afectan la formación de precios a diferentes escalas temporales. La falta de una aproximación integral limita la capacidad de los modelos para capturar movimientos que, a menudo, están más correlacionados con la coyuntura económica global que con patrones de precios aislados [2].

No todas las estrategias o metodologías funcionan de manera uniforme en distintos plazos. Es común que un modelo sea eficaz para predicciones de muy corto plazo, pero pierda exactitud en pronósticos semanales o mensuales, o viceversa [7]. Esta variación de desempeño según el horizonte plantea la necesidad de evaluar sistemáticamente cómo un mismo modelo se comporta en diferentes escalas de tiempo.

En definitiva, el problema central radica en la necesidad de formular modelos de predicción capaces de abordar de manera conjunta la no linealidad de los mercados, la incorporación de variables macroeconómicas pertinentes y la adaptación a diferentes horizontes de pronóstico. No se trata únicamente de idear un enfoque más avanzado, sino de identificar de forma objetiva qué indicadores técnicos y qué factores exógenos aportan valor, cómo articularlos coherentemente y hasta qué punto el horizonte temporal afecta la precisión de las estimaciones.

1.3 Objetivos

1.3.1 Objetivo general

Desarrollar un sistema de predicción de precios en el mercado financiero mediante un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS) e indicadores técnicos como entradas primarias, extendido con variables macroeconómicas relevantes, para evaluar la capacidad predictiva del modelo en diferentes horizontes de tiempo.

1.3.2 Objetivos específicos

1. Desarrollar e implementar el modelo ANFIS con indicadores técnicos seleccionados como entradas principales, para evaluar su capacidad de predicción a corto, mediano y largo plazo.
2. Extender el modelo ANFIS incorporando variables macroeconómicas para evaluar su impacto en la precisión de las predicciones.
3. Evaluar y comparar el desempeño del modelo utilizando métricas estándar de error

predictivo como el RMSE, MAPE y el R2, en función de las diferentes configuraciones de entradas y horizontes de predicción.

1.4 Alcances y limitaciones

- Se hace uso de datos históricos disponibles online de las empresas seleccionadas.
- La implementación se lleva a cabo mediante el software de MATLAB.
- El modelo se limita a las empresas CMPC y Antofagasta Minerals, por lo que los resultados no pueden ser generalizados a otros sectores o mercados.
- La selección de indicadores técnicos se basa en su aplicabilidad y popularidad en el análisis financiero.
- Aunque el modelo incorpora variables macroeconómicas, no se contempla el uso de todas las posibles variables globales que podrían influir en el precio de las acciones.
- La precisión de las predicciones puede verse afectada por la calidad y cantidad de datos históricos disponibles.

1.5 Metodología

La metodología adoptada para este trabajo se estructura en varias etapas clave. Se parte el estudio recopilando datos históricos de precios de acciones de CMPC y Antofagasta Minerals, de donde se obtienen los indicadores técnicos correspondientes. Se recopilarán también datos históricos de las variables macroeconómicas relevantes. Estos datos se procesarán para asegurar que estén listos para su uso en el modelo ANFIS.

Luego se implementará el modelo ANFIS utilizando indicadores técnicos seleccionados como entradas, y se evaluará su desempeño a través de las métricas RMSE, MAPE y R2. Una vez se tiene el modelo base, se extenderá el modelo mediante la incorporación de variables macroeconómicas, y se evaluará su impacto en el desempeño del modelo.

Se analizarán los resultados para diferentes configuraciones de entradas y horizontes de predicción, comparando los resultados para las dos empresas y evaluando la capacidad predictiva del modelo. Se discutirá el impacto de los horizontes de predicción y las variables macroeconómicas en la precisión de las predicciones, y se identificarán configuraciones óptimas que maximicen el desempeño del modelo.

Capítulo 2. Revisión bibliográfica

2.1 Introducción

En este capítulo se expone un análisis detallado de estudios previos relacionados con los retos de la predicción financiera, la utilidad de las metodologías basadas en ANFIS y la lógica difusa, la influencia de factores macroeconómicos, así como la importancia de la correcta configuración de modelos y la exploración de técnicas híbridas.

2.2 Principios y retos en la predicción de mercados financieros

Uno de los principales desafíos en el pronóstico de precios en los mercados financieros radica en la complejidad y alta volatilidad inherentes a estos entornos. Según [1], la Hipótesis del Mercado Eficiente (EMH, por sus siglas en inglés) sostiene que los precios reflejan toda la información disponible, dificultando así la generación de beneficios por encima de la media. Sin embargo, se argumenta que los mercados muestran comportamientos caóticos más que puramente aleatorios, lo que abre la posibilidad de predecir movimientos de precios a través de modelos no lineales. Trabajos como [2] y [3] confirman que los métodos tradicionales basados en análisis técnico y modelos de regresión presentan limitaciones al enfrentar la complejidad de las series de precios, instando a explorar enfoques más avanzados.

En este contexto, la incertidumbre y la dinámica no estacionaria de los datos financieros se convierte en uno de los factores críticos que deben abordar los modelos predictivos [4]. Además, la existencia de ruido y la influencia de fenómenos macroeconómicos y políticos elevan aún más la dificultad de capturar tendencias y cambios de régimen en los mercados [5].

2.3 ANFIS como metodología para el pronóstico financiero

El Sistema Adaptativo de Inferencia Neuro-Difusa (ANFIS) ha demostrado ser una alternativa efectiva para modelar relaciones no lineales y capturar la complejidad de los mercados bursátiles [6]. Por ejemplo, [7] destaca la capacidad de ANFIS para predecir valores de cierre a varios días, logrando un error relativo promedio inferior al 1.5% en el mercado de Zagreb, y [8] confirma su eficiencia en entornos de trading de alta frecuencia. De igual modo, [9] reporta que ANFIS puede superar a redes neuronales tradicionales (ANN) en la predicción de precios de acciones, gracias a su

combinación de lógica difusa y aprendizaje automático.

La literatura sugiere que la combinación de reglas difusas y un ajuste de las funciones de membresía habilita al ANFIS para aproximar funciones complejas en mercados complejos [10]. Asimismo, [11] evidencia que ANFIS puede desempeñarse mejor que modelos estadísticos clásicos, como ARIMA, tanto en el ámbito financiero como en aplicaciones de otro tipo, por ejemplo, en la predicción de ingresos por exportaciones agrícolas.

2.4 Uso de indicadores técnicos y lógica difusa en el trading

Parte de la investigación se centra en la aplicación de la lógica difusa para la toma de decisiones de inversión, integrando indicadores técnicos populares. Por ejemplo, [12] propone un sistema de trading basado en reglas difusas que se apoyan en indicadores como MACD, CCI, RSI y Bandas de Bollinger. Del mismo modo, [13] y [4] enfatizan la relevancia de la lógica difusa para tratar la incertidumbre inherente al momento de ingresar o salir de una operación, así como para ajustar el tamaño de la posición. Desde la perspectiva del análisis técnico, la flexibilidad de la lógica difusa facilita la adaptación de señales tradicionales, que usualmente son binarias, a un rango continuo de recomendaciones de compra o venta, lo cual puede resultar en estrategias más robustas durante periodos de alta volatilidad [4]. Además, en la detección de patrones técnicos, se ha explorado cómo la lógica difusa puede identificar formaciones de hombro-cabeza-hombro u otros patrones en los que interviene la interpretación subjetiva del analista [14].

2.5 Integración de variables macroeconómicas y selección de entradas

Varios estudios señalan la importancia de incluir factores macroeconómicos y otros indicadores externos para mejorar la calidad de las predicciones. Según [5], la incorporación de variables como tipos de cambio o índices globales puede elevar la precisión de los retornos pronosticados. De manera similar, [11] exhibe resultados positivos al combinar datos históricos de exportaciones con métodos de inferencia difusa, demostrando que los modelos ANFIS pueden ajustarse a distintos dominios cuando las variables adecuadas están bien seleccionadas.

La selección de entradas y el dimensionamiento de horizontes de predicción resultan determinantes para el desempeño de ANFIS. Trabajos como [15] destacan cómo el diseño experimental y la identificación de los mejores parámetros -por ejemplo, el número y tipo de

funciones de membresía- influyen de forma significativa en la exactitud del modelo. Esto también coincide con los hallazgos de [16], en los que se observa que incrementar el número de funciones de membresía tiende a mejorar la correlación y reducir el error en ámbitos tan diversos como la predicción de la distribución de temperatura en nano fluidos.

2.6 Enfoques híbridos y optimizaciones avanzadas

La combinación de ANFIS con otras técnicas de aprendizaje o heurísticas de optimización ha demostrado un rendimiento superior en ciertos escenarios. Investigaciones muestran que el uso de Algoritmos Genéticos (GA) o la Optimización por Enjambre de Partículas con Comportamiento Cuántico (QPSO) puede aumentar la precisión predictiva de ANFIS, a costa de una mayor complejidad computacional [17], [18]. De igual modo, [19] plantea la posibilidad de integrar Aprendizaje por Refuerzo (RL) para optimizar las decisiones de entrada y salida al mercado, superando en muchos casos a modelos puramente basados en redes neuronales o lógica difusa estándar.

En el ámbito de la predicción multi-step, se destaca la utilidad de estructuras recurrentes y modelos evolutivos para capturar dinámicas más largas y no estacionarias, extendiendo el horizonte de pronóstico más allá de la predicción a un paso [20], [3]. Aunque estos enfoques presentan mejoras en métricas como RMSE o Nash-Sutcliffe, deben balancearse cuidadosamente con el costo computacional [17].

2.7 Consideraciones para la adopción práctica de ANFIS

A pesar de su eficacia comprobada en múltiples estudios, la implementación de ANFIS en entornos de trading en tiempo real implica diversos retos operativos. Trabajos como [8] resaltan la necesidad de contar con datos de alta frecuencia de calidad y de ajustar continuamente los parámetros del modelo a medida que las condiciones de mercado cambian. Además, [2] y [6] apuntan que, si bien el corto plazo se presta mejor para capturar tendencias inmediatas, los horizontes de predicción más largos suelen estar sujetos a mayor incertidumbre, lo que exige incorporar técnicas de validación y actualización de modelos más robustas. El equilibrio entre precisión y complejidad computacional es otro aspecto central. De acuerdo con [17], los enfoques híbridos y las configuraciones con algoritmos evolutivos ofrecen ventajas importantes en términos

de exactitud, pero pueden presentar tiempos de procesamiento considerables. En el contexto de esta investigación, se buscará un balance entre la robustez del modelo y su viabilidad operativa, considerando los costos de implementación y la escalabilidad de la solución.

2.8 Relevancia para la presente investigación

La revisión evidencia que ANFIS y los modelos difusos pueden manejar la naturaleza no lineal y volátil de las series financieras, superando en muchos casos a métodos tradicionales [5], [7] y [9]. Asimismo, se pone de manifiesto la importancia de seleccionar las variables adecuadas, tanto indicadores técnicos como factores macroeconómicos [11], [5]. En línea con esto, la presente investigación integra dichos hallazgos para desarrollar un modelo ANFIS que incorpore, como entradas primarias, indicadores técnicos y variables macroeconómicas, con el fin de evaluar su capacidad predictiva en diferentes horizontes temporales. De esta manera, se pretende reforzar la utilidad práctica de ANFIS como herramienta para la toma de decisiones en el mercado bursátil.

Por otra parte, aunque la literatura sugiere que la inclusión de enfoques híbridos o algoritmos de optimización puede mejorar el rendimiento [18], [17], la propuesta de esta memoria se centra en diseñar y validar un sistema predictivo con un enfoque más directo, donde la combinación de múltiples indicadores y variables exógenas cumple el rol clave de incrementar la precisión del modelo. Con ello, se busca aportar una metodología sólida y viable para el pronóstico de precios de acciones en distintos marcos de tiempo, sin recurrir necesariamente a esquemas de optimización complejos.

Capítulo 3. Marco Teórico

3.1 Introducción

Este capítulo introduce los conceptos fundamentales necesarios para comprender y desarrollar el modelo propuesto. En particular, se describen los principios de los sistemas ANFIS, la lógica difusa y los indicadores técnicos seleccionados, junto con las métricas de evaluación utilizadas para medir el desempeño del modelo.

3.2 Sistema de Inferencia Neuro-Difusa Adaptativo

El Sistema de Inferencia Neuro-Difusa Adaptativo (ANFIS, por sus siglas en inglés) es una técnica híbrida que combina las capacidades de aprendizaje de las redes neuronales artificiales (ANN) con la interpretabilidad y flexibilidad de los sistemas de inferencia difusa (FIS). Esta metodología fue introducida por Jang [21] en 1993 y se ha consolidado como una herramienta eficaz para modelar relaciones no lineales en sistemas complejos, donde las técnicas tradicionales suelen fallar debido a las limitaciones en la capacidad de captura de patrones y la dependencia de linealidades.

3.2.1 Conceptos fundamentales

El ANFIS opera integrando dos paradigmas principales, la lógica difusa y las redes neuronales artificiales.

La lógica difusa, desarrollada por Lotfi A. Zadeh [22] en 1965, es un marco matemático que expande los límites de la lógica clásica al permitir grados de verdad intermedios entre 0 y 1. A diferencia de la lógica booleana convencional, que opera con valores binarios (verdadero o falso), la lógica difusa es capaz de manejar incertidumbre y ambigüedad, lo que la hace particularmente útil en sistemas donde las fronteras entre categorías no son claras. Consta de tres principios fundamentales:

1. Conjuntos difusos: a los elementos pertenecientes a la lógica difusa, se le atribuyen un grado de pertenencia entre 0 y 1 a un conjunto.
2. Funciones de membresía: estas funciones asignan un grado de pertenencia a cada elemento en un dominio, representando la relación entre el elemento y el conjunto difuso.
3. Reglas if-then: se utilizan reglas lingüísticas para modelar relaciones complejas.




Figura 3.1: Sistema de Inferencia Difuso, adaptado de [21].

Las ANN, inspiradas en el funcionamiento del cerebro humano, fueron conceptualizadas inicialmente por Warren McCulloh y Walter Pitts [23] en 1943, quienes desarrollaron un modelo matemático para describir el comportamiento de las neuronas. Posteriormente, Frank Rosenblatt introdujo en 1958 [24] el perceptrón, considerado la base de las ANN modernas.

Las ANN consisten de nodos o “neuronas” conectados entre sí. Cada nodo recibe entradas ponderadas, las procesa mediante una función de activación y produce una salida. Las redes suelen estar organizadas en capas (entrada, ocultas y salida), donde cada capa está compuesta por nodos y realiza una transformación de los datos. Esta estructura pasa por un proceso de aprendizaje, el cual se realiza ajustando los pesos de las conexiones entre nodos mediante algoritmos como el descenso de gradiente, con la finalidad de minimizar el error entre la salida predicha y la real.




Figura 3.2: Arquitectura de una ANN, adaptado de [21].

3.2.2 Arquitectura y funcionamiento

Como se mencionó previamente, un sistema ANFIS se basa en un modelo de inferencia difusa de tipo Takagi y Sugeno [25], en el cual las reglas tienen salidas lineales o constantes. Considerando un sistema con dos entradas (x y y) y una salida (f), la arquitectura puede ser descrita con las

siguientes reglas de ejemplo:

- Regla 1: Si x es A_1 y y es B_1 , entonces $f_1 = p_1x + q_1y + r_1$
- Regla 2: Si x es A_2 y y es B_2 , entonces $f_2 = p_2x + q_2y + r_2$

Cada regla se implementa a través de las cinco capas por las cuales está compuesta la arquitectura de un ANFIS típico, como se ilustra en la Figura 3.3.




Figura 3.3: Arquitectura de un ANFIS, adaptado de [21].

Partiendo por la primera capa, cada nodo corresponde a una función de membresía asociada a una variable de entrada. Por ejemplo, si se utiliza una función de membresía gaussiana o tipo bell, su salida es:

$$\mu_{A_i}(x) = \frac{1}{1 + \left(\frac{x - c_i}{a_i}\right)^{2b}} \quad (1)$$

Donde c_i es el centro, a_i el ancho y b la forma de la curva. Los parámetros en esta capa son llamados parámetros de premisa.

En la capa 2 se calcula el grado de activación (*firing strength*) de la regla i . Este grado se calcula como el producto de las funciones de membresía para cada entrada:

$$\omega_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad (2)$$

Aquí ω_i es el peso de la regla i , que representa su grado de cumplimiento.

Para la capa 3, los pesos de las reglas se normalizan para que la suma total de los pesos sea 1. Esto se realiza dividiendo el peso ω_i de cada regla por la suma de todos los pesos:

$$\hat{\omega}_i = \frac{\omega_i}{\sum_{i=1}^n \omega_i} \quad (3)$$

Luego, cada nodo en la capa 4 calcula la función lineal correspondiente a la regla i . La salida f_i

de la regla i es una combinación lineal de las entradas ponderada por el peso normalizado de la regla $\hat{\omega}_i$:

$$f_i = \hat{\omega}_i \cdot (p_i x + q_i y + r_i) \quad (4)$$

Los parámetros p_i , q_i y r_i son ajustados durante el entrenamiento, y son los llamados parámetros consecuentes.

Finalmente, en la capa 5 se obtiene la salida final del modelo, la cual es la combinación ponderada de las salidas f_i de todas las reglas. La salida total z es calculada como:

$$f = \frac{\sum_{i=1}^n \hat{\omega}_i \cdot f_i}{\sum_{i=1}^n \hat{\omega}_i} \quad (5)$$

Dentro del proceso de aprendizaje de las redes neuronales, ANFIS utiliza un algoritmo híbrido para ajustar los parámetros del sistema. Este proceso es iterativo, comenzando con la fase de avance (*forward pass*), en donde se calculan las salidas de las capas y se ajustan los parámetros consecuentes (p_i, q_i, r_i) mediante el algoritmo de mínimos cuadrados (*Least Squares*), para luego pasar a la fase de retropropagación (*backward pass*), el cual minimiza el error entre la salida predicha y la observada ajustando los parámetros de premisa (a_i, b_i, c_i).

La fórmula general para el error cuadrático medio, la base para el algoritmo de mínimos cuadrados, se presenta como sigue:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

Donde:

- y_i es el valor real.
- $\hat{y}_i$ es el valor predicho por el modelo.
- N es el número total de muestras.

El algoritmo de gradiente descendente se ocupa en la fase de retropropagación para ajustar los parámetros de las funciones de membresía, el gradiente es calculado respecto a los parámetros μ_i , y la fórmula para el gradiente es:

$$\frac{\delta E}{\delta \mu_i} = -2 \sum_{j=1}^N \left[(y_j - \hat{y}_j) \cdot \frac{\delta \hat{y}_j}{\delta \mu_i} \right] \quad (7)$$

Donde:

- E es el error total del modelo.
- μ_i es el parámetro de la función de membresía i .
- y_j es el valor real de salida en la iteración j .
- $\hat{y}_i$ es la salida predicha por el modelo en la iteración j .

Las reglas difusas se generan automáticamente mediante un enfoque basado en particiones del espacio de entrada (*grid partitioning*). Su funcionamiento se basa en dividir el espacio de entrada en una grilla regular utilizando las funciones de membresía asociadas a cada variable de entrada. De acuerdo con el número de funciones de membresía se define cuántas divisiones tendrá cada dimensión. Luego, el método crea reglas difusas considerando todas las combinaciones posibles de las funciones de membresía de las variables de entrada, es decir, con n variables de entrada y m funciones de membresía se generarán un total de m^n reglas.

3.3 Indicadores Técnicos

El análisis técnico es una metodología ampliamente utilizada en los mercados financieros para predecir el comportamiento futuro de los precios de los activos, basada en la observación de patrones históricos y estadísticas de mercado. De este análisis se desprenden los indicadores técnicos, los cuales son herramientas matemáticas que permiten analizar estas tendencias de precios, facilitando la identificación de puntos de entrada y salida del mercado. Estos indicadores transforman datos crudos en señales visuales o numéricas que permiten al usuario:

- Evaluar la fuerza y dirección de las tendencias de mercado.
- Identificar condiciones de sobrecompra o sobreventa de un activo.
- Determinar niveles clave de soporte y resistencia.
- Medir la volatilidad y el *momentum* del mercado.

Para este estudio, se seleccionaron cuatro indicadores técnicos clave: MACD, RSI, Oscilador Estocástico y Bandas de Bollinger, escogidos por su capacidad de capturar aspectos complementarios del comportamiento del mercado.

3.3.1 Convergencia/Divergencia de Media Móvil (MACD)

Es un indicador técnico de tendencia que mide la relación entre dos medias móviles exponenciales (EMA) de diferentes periodos, específicamente ayuda a identificar cambios en la

dirección, fuerza y duración de una tendencia. Este indicador fue desarrollado por Gerald Appel y es una de las herramientas más utilizadas para el análisis técnico en el mercado financiero [26]. Se compone de dos líneas, la línea MACD y la línea de señal. La línea MACD se calcula restando la media móvil exponencial de 26 periodos (típicamente llamada EMA rápida) de la media móvil exponencial de 12 periodos (típicamente llamada EMA lento), se formula como:

$$MACD = EMA_{12 \text{ periodos}} - EMA_{26 \text{ periodos}} \quad (8)$$

La línea de señal es una EMA de 9 periodos del MACD:

$$Linea \ de \ Señal = EMA(MACD)_{9 \text{ periodos}} \quad (9)$$

La EMA es una técnica de suavizado utilizada para filtrar el ruido de los precios y destacar la tendencia subyacente de un activo. A diferencia de la media móvil simple (SMA), la EMA otorga más peso a los datos recientes, haciéndola de esta forma más reactiva a los cambios de precio. Su fórmula es:

$$EMA_t = \alpha \cdot P_t + (1 - \alpha) \cdot EMA_{t-1} \quad (10)$$

Donde:

- P_t es el precio del activo en tiempo t .
- α es el factor de suavizado, calculado como $\alpha = \frac{2}{n+1}$, con n el número de periodos para el cálculo de la EMA.

Fue elegido por su capacidad de adaptarse tanto a mercados alcistas como bajistas, proporcionando señales de compra o venta cuando las líneas se cruzan, entregando así señales claras y confiables sobre cambios en las tendencias de mercado.

3.3.2 Índice de Fuerza Relativa (RSI)

Este indicador, presentado por J. W. Wilder [27], es notorio por su capacidad para proporcionar señales tempranas de reversiones del mercado. El RSI incorpora un análisis relativo de ganancias y pérdidas, lo que lo hace más robusto para evaluar condiciones extremas en los mercados. De acuerdo a su fórmula (11), el indicador oscila entre 0 y 100, y se considera que un valor por encima de 70 generalmente indica que un activo está sobrecomprado y puede estar sujeto a una corrección o reversión a la baja, mientras que si está por debajo de 30 sugiere que un activo está sobrevendido y puede experimentar un rebote o reversión al alza.

$$RSI = 100 - \frac{100}{1 + RS} \quad (11)$$

Donde RS es la Fuerza Relativa, calculada como la media de las ganancias (*Average Gain*) dividida por la media de las pérdidas (*Average Loss*) en un periodo determinado. El período estándar utilizado para el cálculo del RSI es de 14.

$$Average\ Gain = \frac{\sum Total\ ganancias_{14\ periodos}}{14} \quad (12)$$

$$Average\ Loss = \frac{\sum Total\ perdidas_{14\ periodos}}{14} \quad (13)$$

$$RS = \frac{Average\ Gain}{Average\ Loss} \quad (14)$$

El RSI también puede ser utilizado para identificar divergencias. Una divergencia alcista ocurre cuando el precio del activo hace nuevos mínimos mientras el RSI hace mínimos más altos, sugiriendo una posible reversión al alza. En el caso contrario, una divergencia bajista ocurre cuando el precio del activo hace nuevos máximos mientras el RSI hace máximos más bajos, indicando una posible reversión a la baja.

3.3.3 Oscilador Estocástico

El Oscilador Estocástico, desarrollado por George Lane en la década de 1950 [28], es otro indicador clave de impulso utilizado en el análisis técnico. Este indicador compara el precio de cierre de un activo con su rango de precios durante un período de tiempo determinado, identificando posibles puntos de reversión en los mercados. El oscilador está limitado por un rango de 0 a 100, convirtiéndolo así en un indicador útil para identificar condiciones de sobrecompra y sobreventa. Normalmente, los valores por encima de 80 se consideran en el rango de sobrecompra, mientras que los valores por debajo de 20 se consideran en el rango de sobreventa. No obstante, esto no siempre es indicativo de un cambio de tendencia inminente; las tendencias muy fuertes pueden mantener las condiciones de sobrecompra o sobreventa durante un periodo prolongado de tiempo.

El indicador cuenta con dos líneas: $\%K$, la cual es la línea principal y mide el nivel actual del precio de cierre en relación con el rango alto-bajo durante un periodo específico, y $\%D$, la segunda línea la cual es una SMA de $\%K$ y actúa como una línea de señal suavizada. Su fórmula se expresa como:

$$\%K = \frac{C - L_n}{H_n - L_n} \cdot 100 \quad (15)$$

$$\%D = SMA(\%K, m) \quad (16)$$

Donde:

- C es el precio de cierre más reciente.
- L_n es el precio más bajo en los últimos n periodos.
- H_n es el precio más alto en los últimos n periodos.
- n es el número de periodos, generalmente 14.
- m es el número de periodos, generalmente 3.

3.3.4 Bandas de Bollinger

El último indicador son las Bandas de Bollinger, desarrolladas por John Bollinger en 1980 [29], las cuales son clave para medir la volatilidad del mercado. Este indicador consiste en una media móvil y dos desviaciones estándar trazadas por encima y por debajo de la media. Las Bandas de Bollinger se utilizan principalmente para identificar condiciones de sobrecompra o sobreventa y para anticipar posibles cambios en la volatilidad. El cálculo de esta herramienta es simple, cada componente se formula como sigue:

$$Upper\ Band = SMA(n) + (k \cdot DS) \quad (17)$$

$$Middle\ Band = SMA(n) \quad (18)$$

$$Lower\ Band = SMA(n) - (k \cdot DS) \quad (19)$$

Donde:

- n es el número de periodos, generalmente 20.
- k es el número de veces a multiplicar la desviación estándar, generalmente 2.
- SD es la desviación estándar del precio durante los n periodos.

3.4 Métricas de evaluación

La evaluación del desempeño de un modelo predictivo es un paso crucial para garantizar que los resultados obtenidos sean confiables y útiles. En el contexto de este estudio, se seleccionaron métricas ampliamente utilizadas en el análisis de modelos predictivos en el ámbito del mercado financiero, siendo estos la Raíz del Error Cuadrático Medio (RMSE), el Coeficiente de Determinación (R^2) y el Error Porcentual Absoluto Medio (MAPE). Cada una de estas métricas proporciona una perspectiva diferente sobre la precisión y robustez del modelo, permitiendo una evaluación más completa de su desempeño.

3.4.1 Raíz del Error Cuadrático Medio (RMSE)

Como su nombre lo indica, esta métrica es la raíz cuadrada del Error Cuadrático Medio (MSE). Su fórmula está dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^{pred})^2} \quad (20)$$

Donde:

- y_i es la salida real.
- y_i^{pred} es la salida predicha por el modelo.
- n es el número de datos.

3.4.2 Coeficiente de Determinación (R^2)

El R^2 mide la proporción de la variabilidad en los datos que es explicada por la fórmula:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i^{pred})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (21)$$

Donde $\bar{y}$ es el valor promedio de los datos reales. Un valor de R^2 cercano a 1 indica que el modelo explica la mayor parte de la variabilidad de los datos, mientras que valores cercanos a 0 indican un bajo poder explicativo.

3.4.3 Error Porcentual Absoluto Medio (MAPE)

El MAPE mide el error promedio en términos porcentuales, a diferencia del Error Absoluto Medio (MAE). Su fórmula es:

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^{pred}}{y_i} \right| \quad (22)$$

Capítulo 4. Desarrollo y configuración preliminar del modelo ANFIS

4.1 Introducción

En este capítulo se detalla el proceso de construcción y configuración del modelo ANFIS, comenzando por la selección y preparación de los datos históricos con los que se trabajará. Se describen las entradas del modelo, las funciones de membresía utilizadas, las reglas difusas generadas y el proceso de entrenamiento en MATLAB. Este desarrollo preliminar establece las bases para las etapas posteriores de análisis y extensión del modelo.

4.2 Modelo ANFIS a trabajar

Este modelo utiliza indicadores técnicos como entradas primarias para capturar la dinámica de corto y mediano plazo de los mercados financieros, empleando datos históricos diarios de dos grandes empresas chilenas: Compañía Manufacturera de Papeles y Cartones y Antofagasta Minerals. De ahora en adelante se abreviarán CMPC y ANTO respectivamente.

El enfoque metodológico a seguir durante el desarrollo de este estudio se divide en tres etapas clave, las cuales se detallan a continuación:

1. **Desarrollo y configuración preliminar del ANFIS:** se parte esta etapa en el presente capítulo, en donde se recopilan y preparan los datos a trabajar, se configura el modelo y se realiza una ejecución preliminar del modelo.
2. **Desarrollo del modelo base con indicadores técnicos:** en esta segunda etapa, se construyen y entrenan modelos ANFIS utilizando exclusivamente indicadores técnicos como entradas. Se busca implementar un diseño experimental factorial completo para evaluar todas las combinaciones posibles de 4 y 5 entradas, con el objetivo de identificar la configuración que maximiza el desempeño del modelo ANFIS.
3. **Extensión del modelo con variables macroeconómicas:** finalmente en esta tercera etapa se integran variables macroeconómicas relevantes, como índices del mercado, *commodities* y monedas, para evaluar su impacto en la capacidad predictiva del sistema y analizar como afectó al modelo. Esta inclusión de una variable macroeconómica reemplazará a una variable de indicadores técnicos.

Los modelos ANFIS a trabajar se evaluarán mediante las métricas de RMSE, R^2 y MAPE, las cuales son métricas estándar y entregan información relevante del modelo. Estas métricas van a ser aplicadas al conjunto de validación tanto como a la predicción del modelo en datos fuera de

muestra. A continuación, en la Figura 4.1 se presenta de manera gráfica la metodología:




Figura 4.1: Metodología propuesta.

La implementación del modelo a lo largo de este estudio será utilizando el entorno MATLAB, en donde se empleará la herramienta Fuzzy Logic Toolbox para facilitar la configuración, entrenamiento y validación del modelo.

Para el diseño del modelo ANFIS con cuatro entradas, se presenta en la Figura 4.2 la arquitectura a seguir. Esta figura muestra la conexión de las cuatro entradas con las funciones de pertenencia asociadas, las cuales son procesadas a través de un conjunto de reglas difusas. La salida del modelo corresponde a la predicción del precio de cierre en el horizonte temporal definido. Para el caso específico de 4 entradas, con 2 funciones de membresía por entrada, se tienen un total de 16 reglas. La arquitectura del modelo se puede extender a 5 entradas con 2 funciones de membresía para un total de 32 reglas.




Figura 4.2: Arquitectura de un modelo ANFIS de 4 entradas y 16 reglas.

4.3 Recopilación y preparación de datos

La elección de CMPC y ANTO como empresas de estudio responde a su relevancia en el mercado chileno e internacional, así como a las características particulares de sus operaciones y activos financieros. Estas empresas representan dos sectores económicos clave del país: forestal y minería, cada una con dinámicas propias que ofrecen un contexto ideal para evaluar el desempeño del modelo ANFIS bajo diferentes condiciones de mercado.

Comenzando con CMPC, se considera que es una de las principales empresas del sector forestal y paplero en América Latina, con operaciones en distintos países de la región. Su modelo de negocio incluye la producción de celulosa, papel, productos de embalajes y otros, atendiendo así tanto a mercados locales como internacionales. Su acción principal se comercializa en la Bolsa de Comercio de Santiago (BCS), lo que significa que sus transacciones están denominadas en pesos chilenos (CLP). Sin embargo, al ser una empresa con operaciones internacionales significativas, el valor de sus acciones puede estar indirectamente influenciado por el dólar estadounidense (USD).

Antofagasta Minerals es uno de los mayores productores de cobre el mundo, y su actividad se

centra en la extracción y comercialización de cobre y subproductos como oro y molibdeno. Todas sus operaciones mineras se encuentran en Chile, pero la compañía tiene fuerte participación en los mercados internacionales, dado que el cobre se comercializa globalmente como un *commodity* crítico para la industria. Esta empresa a diferencia de la anterior, comercializa principalmente en la Bolsa de Valores de Londres (London Stock Exchange, LSE) bajo el símbolo ANTO.L, significando así que sus acciones están denominadas en libras esterlinas (GBP).

Los datos recopilados son los precios de apertura, cierre, máximo y mínimo de las empresas mencionadas anteriormente. Estos datos son diarios de lunes a viernes, ya que los sábados y domingos el mercado está cerrado. Se recolectaron datos diarios desde inicios del 2020 hasta mediados del 2024, no obstante, el rango temporal de los datos a trabajar abarca desde el lunes 04 de enero del 2021 hasta el viernes 29 de diciembre del 2023 para tener así un periodo cercano a tres años. Este periodo se considera más representativo del comportamiento financiero típico, eliminando las distorsiones iniciales asociadas a eventos extraordinarios, como lo fue en este caso el impacto inicial de la pandemia. Con este rango temporal, se tiene un total de 751 datos.




Figura 4.3: Datos históricos de CMPC en CLP

En la Figura 4.3 se pueden observar el gráfico del precio de cierre de CMPC, el cual es la serie temporal de interés. De la misma manera, en la Figura 4.4 se presenta el gráfico para ANTO (para visualizar los precios de apertura, cierre, máximo y mínimo de ambas empresas, ver Figura A.1 y A.2, en Anexo A).




Figura 4.4: Datos históricos de ANTO en GBP

Como lo que se busca es predecir los precios de cierre, se considerarán estos como la salida real del ANFIS. Se separará esta serie temporal en dos, un conjunto de entrenamiento y un conjunto de validación de acuerdo con la proporción de 70% y 30% respectivamente. En la Figura 4.5 se observan los precios de cierre para ambas empresas.




Figura 4.5: Precios de cierre para CMPC y ANTO

4.4 Entradas del Modelo

La selección de los indicadores técnicos a utilizar como entradas se debió principalmente a la capacidad de cada uno a cubrir un aspecto del mercado. Dentro de los cuatro indicadores técnicos con los que se va a trabajar, se tienen un total de 8 variables. Esto principalmente se debe a que, como se observa en la Tabla 4.1, hay indicadores con más de un componente.

Tabla 4.1: Componentes asociados a cada indicador técnico

Indicador Técnico	Variables asociadas
MACD	Línea MACD
	Línea de Señal
RSI	RSI
Oscilador Estocástico	% K
	% D
Bandas de Bollinger	Banda Superior
	Banda Media
	Banda Inferior

La MACD mide fuerza y dirección de las tendencias, y se calcula mediante la formula (8) y (9). En la Figura 4.6 se muestran ambas líneas para las empresas. Como se utilizaron 26 periodos para la línea MACD y 9 periodos para la línea de señal, se realiza el cálculo del MACD con 35 periodos previos al conjunto de datos para tener la misma cantidad de datos de entrada MACD que los datos históricos.




Figura 4.6: Gráficos de MACD para (a) CMPC y (b) ANTO

El RSI evalúa la magnitud de los cambios recientes en los precios para identificar condiciones de sobrecompra o sobreventa. En la Figura 4.7 se muestran los índices para cada empresa, de acuerdo con su fórmula (11). Debido al uso de 14 periodos en el cálculo, se realiza el cálculo usando 14 periodos previos al inicio del conjunto de datos a trabajar.




Figura 4.7: Gráficos de RSI para (a) CMPC y (b) ANTO

El Oscilador Estocástico es útil para identificar puntos de reversión a corto plazo. Para su cálculo (15) y (16), se utilizaron los periodos de $K = 14$ y $D = 3$, esto en conjunto con un promedio exponencial, dado que prioriza los datos más recientes. Dado a esta elección de periodos, al igual que para los casos previos, se realiza el cálculo con los datos previos al inicio del conjunto de datos a trabajar. Se ilustra para ambas empresas en la Figura 4.8.




Figura 4.8: Gráficos del Oscilador Estocástico para (a) CMPC y (b) ANTO

Las Bandas de Bollinger, son otro indicador técnico clave utilizado para medir la volatilidad del mercado. Posee una capacidad para adaptarse a las fluctuaciones de precios, proporcionando señales en periodos de alta o baja volatilidad. La Figura 4.9 presenta las bandas para ambas empresas.




Figura 4.9: Gráficos de las Bandas de Bollinger para (a) CMPC y (b) ANTO

La selección de los parámetros utilizados previamente en el cálculo de los indicadores técnicos se basa en valores estándar ampliamente reconocidos en la literatura del análisis técnico.

4.5 Desarrollo del modelo ANFIS preliminar

En la etapa inicial de este estudio, se desarrolló un modelo ANFIS preliminar utilizando únicamente los datos de CMPC con el propósito de evaluar su viabilidad y desempeño general antes de implementar configuraciones más complejas. Este modelo es clave para identificar limitaciones en los datos de entrada, ajustar funciones de pertenencia y reglas difusas, y garantizar que la metodología utilizada sea adecuada para los objetivos del estudio. Una vez validado el modelo, se procederá a extender la metodología para incluir la empresa en etapas posteriores.

4.5.1 Configuración del modelo preliminar

Este modelo preliminar utiliza cuatro variables derivadas de los indicadores técnicos seleccionados, las cuales fueron elegidas por su capacidad para capturar aspectos clave del comportamiento de los precios de los activos financieros. La Tabla 4.2 proporciona las entradas a utilizar.

Tabla 4.2: Entradas del modelo preliminar.

Entradas	Rango
1.- Línea MACD	[-100 100]
2.- RSI	[0 100]
3.- % K	[0 100]
4.- Banda Superior	[1100 2200]*

*Nota: El rango de las BB coincide con el rango del precio de cierre.

Ya con las variables de entrada definidas, se procede a establecer las configuraciones necesarias para generar el Sistema de Inferencia Difusa (FIS) que luego será usado para entrenar el modelo. Este FIS se genera mediante la función `genfis` que utiliza los datos de entrada como de salida.

Se optó por usar dos funciones de membresía por entrada para mantener un equilibrio entre la complejidad del modelo y su capacidad de generalización. Las funciones de membresía utilizadas en este estudio son de tipo gaussianas, seleccionadas por su capacidad para representar transiciones suaves y su amplio uso en la literatura revisada. La fórmula general de esta función es:

$$\mu(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (23)$$

Donde c representa el centro de la función y σ su ancho. Estas funciones se inicializan con valores estándar y se ajustan durante el entrenamiento para minimizar el error entre las predicciones del modelo y los valores reales. En la Figura 4.10 se observan las funciones de membresía a utilizar para las 4 entradas del modelo.




Figura 4.10: Funciones de membresía para las 4 entradas del modelo preliminar.

Las reglas difusas se generan automáticamente mediante el enfoque de *Grid Partition* el cual resulta ideal para este estudio ya que, al dividir el espacio de entrada en regiones definidas por las funciones de membresía, crea reglas exhaustivas y consistentes que cubren todas las posibles combinaciones de entradas. Esto resulta ideal para este estudio, ya que garantiza que el sistema

explore todas las interacciones posibles entre las entradas desde el inicio. Cada combinación de funciones de membresía para las entradas genera una regla del tipo:

$$\text{Si } x_1 = A_1 \wedge x_2 = B_1 \wedge x_3 = C_1 \wedge x_4 = D_1, \text{ entonces } y = f(x_1, x_2, x_3, x_4)$$

Las reglas que se obtuvieron de las funciones de membresía en la Figura 4.10, se observan en el Anexo A.1. Como último ítem a definir, se establecen las épocas en 100, un número suficiente para hacer una evaluación inicial de la convergencia de entrenamiento mientras que se previene el sobreajuste al no ser un número tan alto.

4.5.2 Entrenamiento y validación del modelo preliminar

Se procede a entrenar el FIS obtenido previamente con el conjunto de datos de entrenamiento mediante la función `anfis` en MATLAB. Este proceso se llevó a cabo utilizando un algoritmo híbrido, que combina mínimos cuadrados (6) y descenso por gradiente (7). Una vez entrenado el FIS, es posible obtener el error de entrenamiento a través de las épocas como se ilustra en la Figura 4.11.




Figura 4.11: Gráfico de error de entrenamiento a través de las épocas.

El error de entrenamiento comienza con un valor de 27.0695 en la época 1 y disminuye lentamente hasta 27.0031 en la época 100, lo que muestra una reducción gradual en el error a medida que el modelo ajusta sus parámetros. Este comportamiento sugiere que el modelo está aprendiendo y ajustando correctamente sus funciones de membresía y reglas difusas, pero la disminución modesta en el error podría indicar que se está acercando a su capacidad máxima de ajuste con los parámetros actuales.

Mediante la función `gensurf` de MATLAB, se genera y grafica la superficie de reglas de un

sistema difuso entrenado (Figura 4.12), en función de dos entradas seleccionadas. Esto permite visualizar cómo las reglas difusas y las funciones de membresía interactúan para producir la salida. Se seleccionaron las primeras dos entradas: Línea MACD y RSI para generar la superficie difusa debido a su relevancia en el modelo preliminar y para visualizar las interacciones principales. Aunque se podrían explorar otras combinaciones, este gráfico es representativo del comportamiento general del sistema: no lineal y complejo. Esto se observa debido a que su superficie no es plana, indicando así una relación no lineal entre las entradas y la salida.




Figura 4.12: Superficie de reglas generado a partir de las entradas 1 y 2.

La Tabla 4.3 entrega los resultados obtenidos, los cuales se evaluaron usando las métricas mencionadas en la sección 4.1. Gráficamente se puede ver en la Figura 4.13, en donde se logran apreciar la salida del ANFIS.

Tabla 4.3: Resultados del modelo ANFIS preliminar.

	RMSE	MAPE	R ²
Entrenamiento	27.003	1.3734	0.9868
Validación	49.745	2.4613	0.89995

Los resultados obtenidos en este modelo preliminar han mostrado un rendimiento satisfactorio, con métricas que indican un buen ajuste a los datos de entrenamiento y validación. Esto evidencia que el modelo es capaz de capturar relaciones complejas y no lineales en los datos, proporcionando una base sólida para el análisis posterior. Sin embargo, también se observan ciertas

limitaciones, ya que aunque el modelo sigue la tendencia general de los datos reales, en algunos períodos no logra adaptarse correctamente a fluctuaciones abruptas o eventos de alta volatilidad en el mercado. Esta incapacidad para responder a cambios repentinos podría abordarse mediante ajustes adicionales o incorporando variables complementarias al análisis.

Es importante señalar que estos resultados deben interpretarse como una primera aproximación, dado que el modelo actual fue diseñado principalmente para evaluar el comportamiento general de los indicadores técnicos. Por lo tanto, las predicciones generadas, basadas en los datos históricos del mismo día, no resultan directamente útiles para horizontes temporales más amplios. En el capítulo siguiente se considerarán modelos que predicen precios de cierre en distintos horizontes temporales, explorando configuraciones más completas de indicadores técnicos. Esto permitirá evaluar el impacto de las variaciones temporales sobre la precisión y utilidad de las predicciones.




Figura 4.13: Resultados del modelo ANFIS preliminar.

Capítulo 5. Desarrollo del modelo con indicadores técnicos

5.1 Introducción

El presente capítulo se centra en la construcción del modelo ANFIS utilizando únicamente indicadores técnicos como entradas. Se presentan las configuraciones evaluadas, los horizontes de predicción considerados y el diseño experimental adoptado para explorar todas las combinaciones posibles de indicadores. Además, se analizan los resultados obtenidos, comparando el desempeño del modelo para diferentes configuraciones y horizontes temporales.

5.2 Definición del modelo base

El modelo base ANFIS se configura utilizando los indicadores técnicos seleccionados (MACD, RSI, Oscilador Estocástico y Bandas de Bollinger). Dos configuraciones principales se analizan en esta etapa, modelos con 4 y 5 variables de entrada. Cada configuración está diseñada para evaluar cómo las combinaciones de entradas afectan la precisión de las predicciones.

El modelo se entrena mediante el enfoque de predicción a un paso (*one-step ahead*) [3] y predicción a múltiples pasos (*multi-step-ahead*) [20] para predecir precios de cierre en los siguientes horizontes temporales:

- Corto Plazo: $t + 1$ y $t + 5$
- Mediano Plazo: $t + 15$
- Largo Plazo: $t + 30$

La elección de estos horizontes permite analizar cómo la capacidad predictiva del modelo se ve afectada por la distancia temporal entre las entradas y las salidas. La Figura 5.1 representa como se buscan ocho modelos por empresa, para un total de 16 modelos.




Figura 5.1: Diagrama del número de modelos.

Para lograr esto se hace uso del desplazamiento temporal, esto implica ajustar las variables de

entrada para que correspondan al momento en que se realiza la predicción. En términos simples, para predecir el precio en $t + n$, los indicadores técnicos se calculan utilizando datos disponibles hasta el tiempo t . Esto asegura que el modelo utilice únicamente información pasada o presente, simulando una situación real de predicción. De acuerdo a [20], la relación entre las variables puede describirse como:

$$\hat{y}_{t+n} = f(y_t, y_{t-1}, \dots, y_{t-k}, X_t) \quad (14)$$

Donde:

- $f(\cdot)$ es la relación no lineal modelada por el ANFIS.
- $y_t, y_{t-1}, \dots, y_{t-k}$ son precios históricos del activo hasta el tiempo t .
- X_t es el conjunto de entradas (indicadores técnicos calculados) hasta el tiempo t .
- n es el horizonte de predicción.




Figura 5.2: Diagrama del desplazamiento temporal.

De manera gráfica se presenta en la Figura 5.2, donde es posible observar como el desplazamiento permite relacionar las entradas en tiempo t a la salida en tiempo $t + n$. A medida que aumenta n , mayor va a ser la separación de datos y menor se va haciendo el tamaño total del conjunto.

5.3 Desarrollo del modelo base

5.3.1 Proceso de entrenamiento

En base a lo visto en la versión preliminar del modelo, se configuraron los modelos utilizando los parámetros mostrados en la Tabla 5.1.

Tabla 5.1: Parámetros para la configuración de los modelos ANFIS.

Parámetro	Configuración
Tipo de MF	Gaussiana
N° de MF	Dos
Épocas	Diez
Propagación hacia adelante	Mínimos cuadrados
Retropropagación	Gradiente descendente

El entrenamiento se realizó de manera separada para cada combinación de entrada (4 y 5 entradas) y para cada horizonte temporal ($t + 1$, $t + 5$, $t + 15$, $t + 30$) en MATLAB utilizando el algoritmo híbrido de mínimos cuadrados y descenso por gradiente. Este proceso ajusta las funciones de membresía y los parámetros de las reglas difusas para minimizar el error entre las predicciones y los valores reales.

Se hizo un diseño experimental factorial completo [15], el cual implica probar todas las combinaciones posibles de factores (en este caso, variables de indicadores técnicos) para evaluar su impacto en el resultado (desempeño del modelo). Este enfoque permite:

- evaluar como cada entrada afecta individualmente las predicciones del modelo,
- identificar como la combinación de indicadores técnicos influye en el desempeño.
- obtener una visión completa del espacio de soluciones, asegurando que no se pasen por alto las combinaciones prometedoras.

En términos matemáticos, para un modelo de x entradas seleccionadas de un conjunto de n número de variables de indicadores, el diseño factorial completo implica evaluar todas las combinaciones posibles de acuerdo a la siguiente fórmula:

$$C(n, x) = \frac{n!}{x! (n - x)!} \quad (25)$$

A diferencia de métodos basados en correlaciones o heurísticas, que pueden pasar por alto configuraciones óptimas o interacciones relevantes, el diseño factorial completo asegura una evaluación del impacto de cada indicador en diferentes horizontes temporales. Esto resulta esencial en el contexto financiero en el cual se trabaja, ya que las relaciones entre variables suelen ser no

lineales y altamente dependientes del horizonte temporal [5]. Esta metodología adoptada garantiza que las configuraciones seleccionadas sean empíricamente validadas, maximizando la robustez del modelo y su capacidad para generalizar a nuevos escenarios de mercado.

Se tiene así un total de 70 combinaciones para 4 entradas:

$$C(8, 4) = \frac{8!}{4!(8-4)!} = 70 \quad (26)$$

Y un total de 56 combinaciones para 5 entradas:

$$C(8, 5) = \frac{8!}{5!(8-5)!} = 56 \quad (27)$$

Ahora, considerando que se busca la mejor combinación cada uno de los 4 horizontes temporales, se tiene así un total de 280 y 224 combinaciones respectivamente. La Figura 5.3 ilustra el proceso a seguir, en donde los bloques verdes representan la iteración de horizontes, mientras que los bloques naranjos representan la iteración de indicadores técnicos.




Figura 5.3: Metodología para el modelo ANFIS base.

5.3.2 Proceso de validación y predicción

La validación del modelo ANFIS se llevó a cabo utilizando el conjunto de validación previamente separado, asegurando que el modelo sea evaluado en datos no vistos durante el entrenamiento. Esto permite medir su capacidad de generalización y su desempeño en condiciones que simulan un entorno de uso real.

Los valores entregados por el ANFIS durante la validación y predicción se evalúan mediante métricas estándar que cuantifican la precisión del modelo en distintos aspectos. Estas métricas se calculan para todas las configuraciones y horizontes temporales, permitiendo una comparación detallada y robusta del desempeño.

- Raíz del Error Cuadrático Medio (RMSE): La RMSE mide la magnitud promedio de los errores entre los valores predichos y los valores reales, penalizando en mayor medida los errores grandes debido al uso del cuadrado de las diferencias. Es intuitiva ya que se expresa en las mismas unidades que los datos y útil ya que permite interpretar directamente la precisión del modelo en términos absolutos. Los valores más bajos de RMSE indican un mejor desempeño.
- Error Porcentual Absoluto Medio (MAPE): El MAPE calcula el error promedio como un porcentaje relativo respecto a los valores reales. Al ser una métrica independiente de unidades, es ideal para comparar el desempeño entre diferentes modelos y escenarios. Al igual que el RMSE, valores más bajos de MAPE reflejan un modelo más preciso y consistente.
- Coeficiente de Determinación (R^2): Esta métrica mide qué tan bien el modelo explica la variabilidad total de los datos. Es importante ya que indica la proporción de variabilidad en los datos reales que puede ser explicada por el modelo. Un R^2 cercano a 1 indica un modelo que ajusta bien los datos, mientras que un valor cercano a 0 indica lo contrario.

El uso de R^2 no fue considerado como una métrica en las predicciones debido a la limitación en la cantidad de datos disponibles para ciertos horizontes temporales. El cálculo de R^2 depende de la comparación entre la variabilidad explicada por el modelo y la variabilidad total de los datos, lo que requiere un tamaño de muestra suficiente para ser estadísticamente significativo y representativo. En las predicciones a corto y mediano plazo el número de datos es menor a lo deseado, lo que puede resultar en valores de R^2 poco confiables o altamente sensibles a pequeños errores.

El proceso de predicción del modelo ANFIS en este estudio, se basa en la utilización de datos

históricos de precios y los indicadores técnicos calculados hasta el tiempo t . Este enfoque asegura que el modelo utilice únicamente información disponible antes del momento de la predicción, replicando las condiciones reales en las que se aplicaría a un entorno financiero. Dependiendo del horizonte de predicción establecido el modelo estará entrenado para predecir con un retraso temporal, este valor predicho al igual que en los conjuntos anteriores será comparado con su valor real (que se encuentra fuera de muestra).

5.4 Resultados

Los resultados se dividen en dos categorías: 4 y 5 entradas. Se hará uso de las abreviaciones presentadas en la Tabla 5.2 para los indicadores técnicos.

Tabla 5.2: Abreviaciones para los indicadores técnicos.

Indicador	Abreviación	Indicador	Abreviación
MACDLine	ML	RSI	RSI
SignalLine	SL	UpperBand	UB
PercentK	PK	MiddleBand	MB
PercentD	PD	LowerBand	LB

Para una mejor legibilidad y menor sobrecarga visual, Empresa 1 corresponde a CMPC y se abreviará como E1, de misma manera, Empresa 2 corresponde a ANTO y se abreviará como E2. Se tiene así la siguiente nomenclatura presentada en la Figura 5.4.




Figura 5.4: Nomenclatura para modelos de indicadores técnicos.

5.4.1 Modelos de 4 entradas

Se presenta en la Tabla 5.3 las combinaciones de indicadores técnicos que mejores métricas presentaron para el conjunto de validación en su horizonte temporal.

Tabla 5.3: Mejores combinaciones de indicadores técnicos para modelos de 4 variables.

Modelo	Horizonte temporal	Indicadores			
E1-4-T1	$t + 1$	ML	SL	MB	PK
E1-4-T5	$t + 5$	RSI	ML	MB	PK
E1-4-T15	$t + 15$	ML	LB	PK	PD
E1-4-T30	$t + 30$	ML	SL	LB	PK
E2-4-T1	$t + 1$	RSI	UB	MB	PK
E2-4-T5	$t + 5$	RSI	ML	LB	PD
E2-4-T15	$t + 15$	RSI	ML	SL	PK
E2-4-T30	$t + 30$	RSI	SL	LB	PK

En la Tabla 5.4 se presentan los resultados de dichos modelos para la validación y la predicción.

Tabla 5.4: Resultados de los mejores modelos de 4 variables.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-4-T1	38.31		2.05	0.9406	19.47
E1-4-T5	77.68		3.97	0.7556	79.31
E1-4-T15	116.56		6.42	0.4510	157.19
E1-4-T30	144.91		7.80	0.1551	107.68
E2-4-T1	44.45		2.29	0.8296	141.50
E2-4-T5	86.16		4.73	0.3502	168.14
E2-4-T15	115.97		6.03	-0.2226	150.96
E2-4-T30	122.34		6.41	-0.4571	120.31

5.4.2 Modelos de 5 entradas

La Tabla 5.5 presenta las mejores combinaciones de indicadores técnicos para los modelos de 5 entradas.

Tabla 5.5: Mejores combinaciones de indicadores técnicos para modelos de 5 variables

Modelo	Horizonte temporal	Indicadores				
E1-5-T1	$t + 1$	RSI	ML	MB	PK	PD
E1-5-T5	$t + 5$	RSI	ML	SL	LB	PK
E1-5-T15	$t + 15$	ML	SL	MB	PK	PD
E1-5-T30	$t + 30$	ML	SL	MB	PK	PD
E2-5-T1	$t + 1$	ML	UB	MB	LB	PK
E2-5-T5	$t + 5$	RSI	ML	LB	PK	PD
E2-5-T15	$t + 15$	RSI	ML	SL	MB	PK
E2-5-T30	$t + 30$	RSI	SL	UB	LB	PK

En la Tabla 5.6 se presentan los resultados de dichos modelos para la validación y la predicción.

Tabla 5.6: Resultados de los mejores modelos de 5 variables

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E1-5-T1	57.48		2.79	0.8663	8.57	0.50
E1-5-T5	98.61		4.94	0.6061	168.52	9.60
E1-5-T15	136.93		7.34	0.2424	294.04	15.28
E1-5-T30	168.09		8.83	-0.1368	125.42	6.51
E2-5-T1	49.58		2.54	0.7880	147.24	8.92
E2-5-T5	100.09		4.97	0.1231	129.48	7.12
E2-5-T15	160.22		8.00	-1.3336	129.48	7.05
E2-5-T30	193.59		9.80	-2.6486	203.28	9.76

5.5 Análisis general de resultados

Se evaluaron configuraciones con cuatro y cinco entradas seleccionadas de los indicadores técnicos, y cada configuración fue sometida a pruebas en cuatro horizontes temporales. Los resultados muestran a grandes rasgos que el desempeño del modelo ANFIS depende significativamente de la combinación de entradas y del horizonte de predicción seleccionado.

En promedio, las configuraciones con cuatro entradas mostraron una ligera mejora en las métricas de validación con respecto a su equivalente en los modelos de cinco entradas. Por ejemplo, para el horizonte $t + 1$ en CMPC, se obtuvo un RMSE de 38.31 para el modelo de cuatro entradas versus un RMSE de 57.48 para el de cinco entradas. Esta tendencia se repite en horizontes más largos, aunque con diferencias más sutiles.

5.5.1 Impacto del horizonte temporal

El horizonte temporal influye marcadamente tanto en el desempeño de validación como el predictivo. Para los horizontes más cortos ($t + 1$ y $t + 5$), los modelos muestran un mejor ajuste, como lo reflejan los valores más bajos de RMSE y MAPE, y un elevado R^2 . Esto se debe a la mayor correlación entre los datos de entrada y la salida en intervalos de tiempo más cercanos. Sin embargo, al extender el horizonte temporal ($t + 15$ y $t + 30$), el error aumenta significativamente. En el caso de ANTO, el RMSE para los modelos de cinco variables pasa de 49.58 ($t + 1$) a 53.89 ($t + 30$), evidenciando la dificultad del modelo para capturar patrones a largo plazo.

La incorporación de entradas adicionales parece agravar esta degradación. Por ejemplo, el modelo con cuatro entradas para el horizonte $t + 30$ logró un RMSE 27.80% menor en comparación con su contraparte de cinco entradas, sugiriendo que el uso de más información puede

empeorar el desempeño en predicciones de largo plazo.

5.5.2 Influencia de los indicadores técnicos

El impacto de los indicadores técnicos individuales también fue evaluado, se observó que el MACD es un indicador técnico que contribuye significativamente a reducir el error en horizontes cortos para los modelos de cuatro entradas, presentándose en cinco ocasiones sus variables. De igual manera el MACD con las Bandas de Bollinger se encuentran presentes en los horizontes cortos para los modelos de cinco entradas. Se observa el caso de CMPC con cuatro entradas, para el horizonte $t + 1$ con una configuración de los dos componentes de MACD, la Banda Media y el Porcentaje K se obtuvo un MAPE de 2.05, el más bajo para los datos de validación.

Por otro lado, la combinación de RSI y Bandas de Bollinger demostró ser particularmente útil para horizontes de corto plazo de ANTO con cuatro entradas, sugiriendo que estos indicadores capturan mejor las tendencias subyacentes del mercado en este rango temporal. Esto se demostró con un R^2 de 0.8296, indicando un alto grado de explicación de la variabilidad de los datos.

5.5.3 Comparación entre empresas

Los resultados también evidencian diferencias en el desempeño del modelo según la empresa analizada. En general, las predicciones para CMPC mostraron errores menores en comparación con ANTO. Esto podría atribuirse a la mayor volatilidad y complejidad de los datos de ANTO, influenciados por factores externos. Esto se evidencia más claramente para los modelos de cinco entradas, en donde para 3 de 4 horizontes temporales, CMPC presenta mejores métricas. No obstante, para los modelos de cuatro entradas, sus rendimientos son similares.

5.5.4 Conclusiones

En conclusión, los resultados de esta comparación destacan la importancia de seleccionar cuidadosamente las configuraciones del modelo ANFIS en función del horizonte temporal y las características de los datos analizados. Las configuraciones de cuatro entradas tienden a tener un mejor desempeño, notoriamente en todos los horizontes tanto para los conjuntos de validación como para la predicción. Por último, las diferencias entre empresas subrayan la necesidad de ajustar el modelo a las particularidades de cada activo, maximizando así su capacidad predictiva.

Capítulo 6. Extensión del modelo con variables macroeconómicas

6.1 Introducción

En este capítulo se extiende el modelo ANFIS, integrando variables macroeconómicas como entradas adicionales. Se justifica la selección de estas variables y se detalla su integración en el modelo base. A través de un análisis comparativo, se evalúa el impacto de estas variables en la capacidad predictiva del modelo.

6.2 Selección de variables macroeconómicas

Las variables macroeconómicas seleccionadas se agrupan en tres categorías principales: índices, monedas y *commodities*. Estas variables fueron elegidas debido a su relevancia en el contexto económico chileno y su impacto en los precios de las acciones de CMPC y ANTO.

Las variables seleccionadas en su mayoría poseen una frecuencia diaria que coincide con los datos previamente utilizados, pero hay ciertas variables cuya frecuencia es mensual. Se procedió a interpolar estos valores acorde a los días de la semana para poseer así una frecuencia diaria.

6.2.1 Índices

Los índices seleccionados representan distintos aspectos de la economía chilena y la percepción de los consumidores y empresarios. Estos indicadores son cruciales para comprender el entorno económico local, que afecta tanto al mercado accionario como a las operaciones de las empresas estudiadas.

❖ Índice de Precios Selectivo de Acciones (IPSA)

Es el principal índice bursátil de Chile, compuesto por las 28 acciones más transadas en la Bolsa de Santiago. Este índice sirve como barómetro del desempeño general del mercado accionario chileno, reflejando las expectativas de los inversionistas sobre la economía y las empresas más relevantes del país. Para CMPC, el IPSA proporciona una medida del sentimiento general del mercado, ya que su comportamiento puede estar correlacionado con las condiciones económicas que influyen en sus operaciones y valoraciones.



Figura 6.1: Gráfico del IPSA.

❖ Índice de Confianza Empresarial (IMCE)

El IMCE mide la percepción de los empresarios sobre las condiciones económicas actuales y futuras, incluyendo aspectos como la inversión, el empleo y la producción. Este índice es relevante para evaluar cómo las expectativas empresariales influyen en decisiones estratégicas que afectan la demanda de bienes y servicios.




Figura 6.2: Gráfico del IMCE.

❖ Índice de Confianza del Consumidor (ICC)

El ICC captura la percepción de los consumidores sobre su situación económica, las condiciones de empleo y las expectativas futuras. La sensibilidad del ICC a las condiciones macroeconómicas lo convierte en un indicador crucial para predecir variaciones en los ingresos de las empresas.




Figura 6.3: Gráfico del ICC.

❖ Índice de Percepción de la Economía (IPEC)

El IPEC mide la percepción general de los consumidores sobre la economía nacional, incluyendo temas como la estabilidad económica y las oportunidades laborales. Este índice complementa al ICC al proporcionar una visión más amplia de las expectativas de los consumidores. Cambios en el IPEC pueden anticipar variaciones en el consumo interno del país y, por ende, en el desempeño de las empresas chilenas.




Figura 6.4: Gráfico del IPEC.

6.2.2 Monedas

Las monedas seleccionadas reflejan la interacción entre los mercados locales e internacionales y su impacto en las operaciones financieras de las empresas. Estas variables son fundamentales para evaluar cómo los flujos comerciales y las condiciones cambiarias afectan los márgenes de ganancias y el comercio internacional.

❖ Dólar Estadounidense / Peso Chileno (USD/CLP)

El tipo de cambio USD/CLP es uno de los indicadores más relevantes para la economía chilena, ya que gran parte de las exportaciones e importaciones se realizan en dólares. Para las empresas seleccionadas, la relación entre el dólar y el peso chileno tiene un impacto directo en sus ingresos y costos. Un aumento en el valor del USD frente al CLP mejora la competitividad de sus exportaciones, pero también puede elevar el costo de bienes importados necesarios para sus operaciones.



Figura 6.5: Gráfico del tipo de cambio USD/CLP.

❖ Euro / Peso Chileno (EUR/CLP)

El tipo de cambio EUR/CLP al igual que el anterior, es uno de los indicadores más relevantes para las empresas chilenas, principalmente para las que exportan productos a países europeos. Fluctuaciones en esta tasa de cambio afectan la competitividad de los productos chilenos en el mercado europeo, así como la rentabilidad de las exportaciones.




Figura 6.6: Gráfico del tipo de cambio EUR/CLP.

❖ Yuan Chino / Peso Chileno (CNY/CLP)

El yuan chino es una moneda clave debido a la importancia de China como principal destino de las exportaciones de cobre chileno. Para ANTO, un yuan más fuerte frente a la moneda nacional puede aumentar la demanda de materias primas, mejorando así sus ingresos. Además, este tipo de cambio refleja la relación comercial entre Chile y China, dos economías interdependientes.




Figura 6.7: Gráfico del tipo de cambio CNY/CLP.

❖ Índice de Precios al Consumidor (IPC 2018=100)

El IPC es el principal indicador de inflación en Chile, se considera dentro de las categoría de monedas debido a su estrecha relación con el poder adquisitivo de la moneda local y su impacto en la economía. Aunque el IPC no es una moneda en sí misma, mide la inflación, un factor clave que afecta el valor real del CLP y su capacidad para intercambiar bienes y servicios.




Figura 6.8: Gráfico de la variación mensual del IPC (%) 2018=100

6.2.3 Commodities

Los commodities son bienes básicos que se comercializan en mercados internacionales y que tienen precios estandarizados. Estos incluyen productos agrícolas, metales, energía, entre otros, y son fundamentales para las economías debido a su uso generalizado en diversas industrias.

Los futuros son contratos financieros que obligan a las partes involucradas a comprar y vender un activo subyacente a un precio acordado en una fecha futura específica. En este caso el activo subyacente de un contrato de futuros es un *commodity*.

❖ Futuros de Cobre

El cobre es el principal producto de exportación de ANTO y uno de los pilares de la economía chilena. Su precio está determinado por la oferta y la demanda global, así como por factores como las políticas comerciales, la producción minera y las inversiones en infraestructura.




Figura 6.9: Gráfico de Futuros de Cobre (HGZ4).

❖ Futuros de Oro

El oro, además de ser un subproducto importante dentro de las operaciones mineras chilenas, es considerado un activo refugio en tiempos de incertidumbre económica. Su precio está influenciado por factores como las tasas de interés, las políticas monetarias y la estabilidad económica global.




Figura 6.10: Gráfico de Futuros de Oro (GC1).

❖ Futuros de Plata

Al igual que el oro, la plata es un subproducto de las operaciones mineras chilenas. Sin embargo, su precio está más vinculado al uso industrial, como la fabricación de productos electrónicos, paneles solares y equipos médicos. Este doble rol como metal precioso e industrial hace que la plata sea un indicador sensible tanto a las condiciones económicas globales como a la innovación tecnológica.




Figura 6.11: Gráfico de Futuros de Plata (SI1)

❖ Futuros de Petróleo Crudo WTI

El petróleo crudo es un *commodity* esencial para la economía mundial, ya que afecta los costos de transporte, producción y energía. Para las empresas seleccionadas, los cambios en el precio del petróleo tienen un impacto indirecto en sus costos operativos, como el transporte de materias primas y productos terminados. Además, las fluctuaciones en el precio del petróleo son un reflejo de las condiciones económicas globales, lo que las convierte en un indicador relevante para anticipar

cambios en la demanda de productos básicos.




Figura 6.12: Gráfico de Futuros de Petróleo WTI (CL1).

6.3 Integración de las variables

El modelo base, configurado inicialmente con 4 o 5 entradas de variables de indicadores técnicos, se extiende incorporando las variables macroeconómicas seleccionadas como entradas adicionales. Estas se integran al modelo manteniendo el número total de variables de entrada, reemplazando un indicador técnico por una variable macroeconómica en cada configuración. Este enfoque permite evaluar de manera sistemática cómo las variables macroeconómicas influyen en el desempeño del modelo, manteniendo constante la complejidad estructural del sistema.

En este nuevo conjunto de entradas se busca obtener el mejor rendimiento del modelo para la variable macroeconómica de turno, por lo que se adopta una metodología de diseño experimental parcial que combina indicadores técnicos con una variable macroeconómica fija para cada configuración del modelo. Este enfoque permite aislar el efecto de las variables macroeconómicas seleccionadas, analizando su interacción con diferentes combinaciones de indicadores técnicos. El diagrama de flujo del enfoque se presenta en la Figura 6.13.

De misma manera que para el modelo base, se seleccionan funciones gaussianas para cada variable macroeconómica, ajustadas durante el entrenamiento del modelo. La inclusión de diferentes entradas si bien cambia su interpretación, no cambia el número total de reglas difusas debido a que se mantienen el mismo número de entradas para las configuraciones de modelo. Esto garantiza que la complejidad del modelo no aumente, facilitando su entrenamiento y análisis.




Figura 6.13: Metodología para el modelo ANFIS extendido.

A diferencia de los indicadores técnicos, que se calculan exclusivamente a partir de los datos históricos de precios, estas variables poseen distribución temporal diferente entre sí. Por esta razón, es fundamental alinear las series temporales de las variables macroeconómicas con las de los indicadores técnicos, utilizando únicamente las fechas en las que ambas fuentes de datos poseen información disponible. Este paso asegura que el modelo opere con un conjunto consistente y homogéneo de datos, reduciendo el riesgo de sesgos o inconsistencias en las predicciones.

El proceso de entrenamiento, validación y predicción del modelo extendido sigue la misma metodología descrita en el Capítulo 5. Esto incluye el uso del algoritmo híbrido para ajustar los parámetros del modelo, así como la evaluación de su desempeño en términos de las métricas seleccionadas.

6.4 Resultado del modelo extendido

Los resultados obtenidos se categorizan en el número de variable para luego separarse por horizonte temporal. Se hacen uso de las mismas abreviaciones para los indicadores técnicos

presentadas en la Tabla 5.2. Las variables macroeconómicas se abrevian como se muestra en la Tabla 6.1.

Tabla 6.1: Abreviación de las variables macroeconómicas.

Variable Macro	Abreviación	Variable Macro	Abreviación
IPSA	IPSA	CNY/CLP	CNY
IMCE	IMCE	IPC 2018=100	IPC
ICC	ICC	Futuro Cobre	COB
IPEC	IPEC	Futuro Oro	ORO
USD/CLP	USD	Futuro Plata	PLAT
EUR/CLP	EUR	Futuro Petróleo WTI	PET

La Figura 5.4 presenta la nomenclatura a seguir para los nombres de los modelos. Debido a la gran cantidad de resultados se separan los modelos en horizontes temporales, en donde se presentan las mejores combinaciones de indicadores técnicos más una variable macroeconómica.




Figura 6.14: Nomenclatura para los modelos de variables macroeconómicas.

6.4.1 Modelos de 4 entradas

La Tabla 6.2 presenta los modelos que mejores resultados entregaron para CMPC y su configuración de indicadores técnicos para los cuatro horizontes temporales.

Tabla 6.2: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 4 variables para CMPC.

Modelo	Variables				Modelo	Variables			
E1-4-USD-T1	USD	ML	MB	PK	E1-4-USD-T5	USD	ML	SL	LB
E1-4-EUR-T1	EUR	ML	SL	MB	E1-4-EUR-T5	EUR	MB	PK	PD
E1-4-CNY-T1	CNY	RSI	MB	PK	E1-4-CNY-T5	CNY	ML	SL	UB
E1-4-IPC-T1	IPC	UB	MB	PD	E1-4-IPC-T5	IPC	ML	UB	PK
E1-4-COB-T1	COB	ML	LB	PD	E1-4-COB-T5	COB	ML	SL	LB
E1-4-ORO-T1	ORO	RSI	MB	PD	E1-4-ORO-T5	ORO	SL	UB	PD
E1-4-PLAT-T1	PLAT	ML	MB	PD	E1-4-PLAT-T5	PLAT	MB	PK	PD
E1-4-PET-T1	PET	MB	PK	PD	E1-4-PET-T5	PET	MB	LB	PK
E1-4-ICC-T1	ICC	MB	LB	PD	E1-4-ICC-T5	ICC	LB	PK	PD
E1-4-IMCE-T1	IMCE	RSI	ML	LB	E1-4-IMCE-T5	IMCE	LB	PK	PD
E1-4-IPEC-T1	IPEC	RSI	ML	MB	E1-4-IPEC-T5	IPEC	MB	PK	PD
E1-4-IPSA-T1	IPSA	RSI	MB	PD	E1-4-IPSA-T5	IPSA	RSI	UB	PK

Modelo	Variables				Modelo	Variables			
E1-4-USD-T15	USD	ML	LB	PD	E1-4-USD-T30	USD	ML	SL	LB
E1-4-EUR-T15	EUR	LB	PK	PD	E1-4-EUR-T30	EUR	SL	PK	PD
E1-4-CNY-T15	CNY	ML	SL	LB	E1-4-CNY-T30	CNY	UB	LB	PK
E1-4-IPC-T15	IPC	LB	PK	PD	E1-4-IPC-T30	IPC	ML	LB	PD
E1-4-COB-T15	COB	ML	LB	PK	E1-4-COB-T30	COB	ML	SL	UB
E1-4-ORO-T15	ORO	LB	PK	PD	E1-4-ORO-T30	ORO	ML	MB	LB
E1-4-PLAT-T15	PLAT	ML	SL	LB	E1-4-PLAT-T30	PLAT	RSI	SL	LB
E1-4-PET-T15	PET	RSI	SL	LB	E1-4-PET-T30	PET	UB	LB	PK
E1-4-ICC-T15	ICC	SL	LB	PK	E1-4-ICC-T30	ICC	SL	LB	PK
E1-4-IMCE-T15	IMCE	RSI	MB	PK	E1-4-IMCE-T30	IMCE	ML	SL	LB
E1-4-IPEC-T15	IPEC	ML	SL	UB	E1-4-IPEC-T30	IPEC	UB	MB	LB
E1-4-IPSA-T15	IPSA	UB	PK	PD	E1-4-IPSA-T30	IPSA	ML	SL	UB

Todos los resultados obtenidos se presentan en el Anexo A.2. En la Tabla 6.3 se presentan los modelos que mejores valores presentaron tanto para la validación como la predicción.

Tabla 6.3: Modelos que presentaron mejores resultados de 4 variables para CMPC.

	Modelo	Var. Macro	Indicadores	Validación			Predicción		
				RMSE	MAPE	R2	Hor.	RMSE	MAPE
Mejores Val.	E1-4-USD-T1	USD	ML MB PK	49,37	2,57	0,9014	1	7,87	0,46
	E1-4-COB-T5	COB	ML SL LB	78,47	4,17	0,7506	5	72,13	4,16
	E1-4-PLAT-T15	PLAT	ML SL LB	102,55	5,51	0,5751	15	81,42	3,72
	E1-4-USD-T30	USD	ML SL LB	143,49	7,77	0,1716	30	133,07	6,77
Mejores Pred.	E1-4-USD-T1	USD	ML MB PK	49,37	2,57	0,9014	1	7,87	0,46
	E1-4-PLAT-T5	PLAT	MB PK PD	83,88	4,32	0,7150	5	57,77	3,27
	E1-4-ICC-T15	ICC	SL LB PK	124,69	6,76	0,3718	15	69,05	3,58
	E1-4-COB-T30	COB	ML SL UB	159,72	8,68	-0,0264	30	72,41	3,83

De la misma manera, la Tabla 6.4 presenta los resultados para ANTO.

Tabla 6.4: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 4 variables para ANTO.

Modelo	Variables				Modelo	Variables			
E2-4-USD-T1	USD	ML	MB	PK	E2-4-USD-T5	USD	RSI	UB	PK
E2-4-EUR-T1	EUR	ML	UB	PK	E2-4-EUR-T5	EUR	ML	UB	LB
E2-4-CNY-T1	CNY	RSI	MB	PK	E2-4-CNY-T5	CNY	RSI	UB	LB
E2-4-IPC-T1	IPC	RSI	MB	PK	E2-4-IPC-T5	IPC	ML	UB	LB
E2-4-COB-T1	COB	RSI	UB	LB	E2-4-COB-T5	COB	RSI	MB	PK
E2-4-ORO-T1	ORO	MB	LB	PD	E2-4-ORO-T5	ORO	MB	LB	PK
E2-4-PLAT-T1	PLAT	RSI	SL	MB	E2-4-PLAT-T5	PLAT	ML	LB	PK
E2-4-PET-T1	PET	RSI	MB	LB	E2-4-PET-T5	PET	UB	MB	PK
E2-4-ICC-T1	ICC	RSI	MB	PK	E2-4-ICC-T5	ICC	RSI	MB	PK
E2-4-IMCE-T1	IMCE	RSI	MB	PD	E2-4-IMCE-T5	IMCE	RSI	UB	PK
E2-4-IPEC-T1	IPEC	RSI	MB	PK	E2-4-IPEC-T5	IPEC	UB	PK	PD
E2-4-IPSA-T1	IPSA	RSI	MB	PK	E2-4-IPSA-T5	IPSA	SL	UB	PK

Modelo	Variables					Modelo	Variables				
E2-4-USD-T15	USD	RSI	SL	PD		E2-4-USD-T30	USD	RSI	PK	PD	
E2-4-EUR-T15	EUR	RSI	ML	SL		E2-4-EUR-T30	EUR	RSI	UB	PK	
E2-4-CNY-T15	CNY	RSI	UB	LB		E2-4-CNY-T30	CNY	RSI	PK	PDD	
E2-4-IPC-T15	IPC	RSI	LB	PK		E2-4-IPC-T30	IPC	RSI	PK	PD	
E2-4-COB-T15	COB	ML	SL	LB		E2-4-COB-T30	COB	RSI	UB	LB	
E2-4-ORO-T15	ORO	RSI	MB	LB		E2-4-ORO-T30	ORO	RSI	MB	LB	
E2-4-PLAT-T15	PLAT	SL	PK	PD		E2-4-PLAT-T30	PLAT	SL	PK	PD	
E2-4-PET-T15	PET	ML	SL	PK		E2-4-PET-T30	PET	ML	LB	PK	
E2-4-ICC-T15	ICC	RSI	UB	PK		E2-4-ICC-T30	ICC	RSI	LB	PD	
E2-4-IMCE-T15	IMCE	ML	SL	PD		E2-4-IMCE-T30	IMCE	ML	PK	PD	
E2-4-IPEC-T15	IPEC	SL	MB	LB		E2-4-IPEC-T30	IPEC	RSI	MB	PK	
E2-4-IPSA-T15	IPSA	SL	UB	LB		E2-4-IPSA-T30	IPSA	SL	UB	MB	

Todos los resultados obtenidos de los mejores modelos se presentan en el Anexo A.3. En la Tabla 6.5 se presentan los modelos que mejores valores presentaron tanto para la validación como la predicción.

Tabla 6.5: Modelos que presentaron mejores resultados de 4 variables para ANTO.

	Modelo	Var. Macro	Indicadores	Validación			Predicción			
				RMSE	MAPE	R2	Hor.	RMSE	MAPE	
Mejores Val.	E2-4-ICC-T1	ICC	RSI MB PK	42,49	2,26	0,8443	1	174,19	10,55	
	E2-4-CNY-T5	CNY	RSI UB LB	80,58	4,37	0,4316	5	143,71	7,81	
	E2-4-CNY-T15	CNY	RSI UB LB	108,08	5,87	-0,0618	15	211,69	12,69	
	E2-4-PET-T30	PET	ML LB PK	119,09	6,10	-0,4136	30	173,99	9,44	
Mejores Pred.	E2-4-COB-T1	COB	RSI UB LB	57,43	3,06	0,7156	1	58,30	3,53	
	E2-4-PLAT-T5	PLAT	ML LB PK	97,79	4,77	0,1630	5	79,64	4,65	
	E2-4-IPEC-T15	IPEC	SL MB LB	195,43	10,53	-2,4717	15	78,49	4,27	
	E2-4-ICC-T30	ICC	RSI LB PD	131,40	6,70	-0,6809	30	104,59	4,95	

6.4.2 Modelos de 5 entradas

La Tabla 6.6 presenta los modelos que mejores resultados entregaron para CMPC y su configuración de indicadores técnicos para los cuatro horizontes temporales.

Tabla 6.6: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 5 variables para CMPC.

Modelo	Variables					Modelo	Variables				
E1-5-USD-T1	USD	RSI	ML	SL	MB	E1-5-USD-T5	USD	RSI	ML	MB	PK
E1-5-EUR-T1	EUR	SL	MB	PK	PD	E1-5-EUR-T5	EUR	ML	UB	PK	PD
E1-5-CNY-T1	CNY	RSI	ML	UB	PK	E1-5-CNY-T5	CNY	ML	SL	LB	PK
E1-5-IPC-T1	IPC	RSI	ML	LB	PK	E1-5-IPC-T5	IPC	RSI	UB	MB	PK
E1-5-COB-T1	COB	RSI	ML	MB	PK	E1-5-COB-T5	COB	ML	SL	UB	PK
E1-5-ORO-T1	ORO	RSI	ML	UB	PD	E1-5-ORO-T5	ORO	RSI	ML	UB	PK
E1-5-PLAT-T1	PLAT	RSI	ML	MB	PK	E1-5-PLAT-T5	PLAT	ML	SL	LB	PK
E1-5-PET-T1	PET	RSI	ML	SL	LB	E1-5-PET-T5	PET	RSI	MB	LB	PD

E1-5-ICC-T1	ICC	RSI	MB	PK	PD	E1-5-ICC-T5	ICC	MB	LB	PK	PD
E1-5-IMCE-T1	IMCE	RSI	MB	LB	PD	E1-5-IMCE-T5	IMCE	SL	UB	PK	PD
E1-5-IPEC-T1	IPEC	RSI	ML	MB	PK	E1-5-IPEC-T5	IPEC	ML	LB	PK	PD
E1-5-IPSA-T1	IPSA	RSI	UB	LB	PK	E1-5-IPSA-T5	IPSA	RSI	MB	PK	PD

Modelo	Variables					Modelo	Variables				
E1-5-USD-T15	USD	ML	SL	MB	PK	E1-5-USD-T30	USD	SL	LB	PK	PD
E1-5-EUR-T15	EUR	RSI	SL	UB	PK	E1-5-EUR-T30	EUR	ML	SL	UB	LB
E1-5-CNY-T15	CNY	RI	SL	LB	PK	E1-5-CNY-T30	CNY	RSI	ML	SL	MB
E1-5-IPC-T15	IPC	RSI	LB	PK	PD	E1-5-IPC-T30	IPC	SL	LB	PK	PD
E1-5-COB-T15	COB	ML	LB	PK	PD	E1-5-COB-T30	COB	SL	UB	PK	PD
E1-5-ORO-T15	ORO	RSI	LB	PK	PD	E1-5-ORO-T30	ORO	RSI	ML	UB	PK
E1-5-PLAT-T15	PLAT	RSI	ML	SL	MB	E1-5-PLAT-T30	PLAT	ML	SL	LB	PK
E1-5-PET-T15	PET	RSI	LB	PK	PD	E1-5-PET-T30	PET	ML	SL	MB	PK
E1-5-ICC-T15	ICC	RSI	ML	LB	PK	E1-5-ICC-T30	ICC	RSI	SL	LB	PD
E1-5-IMCE-T15	IMCE	RSI	SL	UB	MB	E1-5-IMCE-T30	IMCE	RSI	SL	LB	PK
E1-5-IPEC-T15	IPEC	ML	SL	MB	PK	E1-5-IPEC-T30	IPEC	SL	LB	PK	PD
E1-5-IPSA-T15	IPSA	ML	SL	UB	PD	E1-5-IPSA-T30	IPSA	RSI	ML	SL	MB

Todos los resultados obtenidos de los mejores modelos se presentan en el Anexo A.4. En la Tabla 6.7 se presentan los modelos que mejores valores presentaron tanto para la validación como la predicción.

Tabla 6.7: Modelos que presentaron mejores resultados de 5 variables para CMPC.

	Modelo	Var. Macro	Indicadores	Validación			Predicción		
				RMSE	MAPE	R2	Hor.	RMSE	MAPE
Mej. Val.	E1-5-COB-T1	COB	RSI ML MB PK	57,65	3,08	0,8655	1	25,07	1,46
	E1-5-COB-T5	COB	ML SL UB PK	98,29	5,22	0,6087	5	85,46	3,61
	E1-5-ICC-T15	ICC	RSI ML LB PK	123,92	6,60	0,3795	15	111,23	6,01
	E1-5-PET-T30	PET	ML SL MB PK	151,36	7,66	0,0782	30	121,36	5,54
Mej. Pred.	E1-5-USD-T1	USD	RSI ML SL MB	72,84	3,79	0,7853	1	7,35	0,43
	E1-5-CNY-T5	CNY	ML SL LB PK	156,23	8,19	0,0114	5	52,72	2,48
	E1-5-PLAT-T15	PLAT	RSI ML SL MB	135,38	7,10	0,2595	15	107,21	5,68
	E1-5-CNY-T30	CNY	RSI ML SL MB	260,90	11,35	-1,7387	30	95,76	5,04

De la misma manera, la Tabla 6.8 presenta los resultados para ANTO.

Tabla 6.8: Mejores combinaciones de variables macroeconómicas con indicadores técnicos para modelos de 5 variables para ANTO.

Modelo	Variables					Modelo	Variables				
E2-5-USD-T1	USD	RSI	UB	PK	PD	E2-5-USD-T5	USD	RSI	UB	PK	PD
E2-5-EUR-T1	EUR	ML	MB	PK	PD	E2-5-EUR-T5	EUR	ML	LB	PK	PD
E2-5-CNY-T1	CNY	UB	MB	PK	PD	E2-5-CNY-T5	CNY	RSI	UB	PK	PD
E2-5-IPC-T1	IPC	RSI	UB	PK	PD	E2-5-IPC-T5	IPC	RSI	LB	PK	PD
E2-5-COB-T1	COB	RSI	SL	MB	PK	E2-5-COB-T5	COB	RSI	UB	MB	PD
E2-5-ORO-T1	ORO	RSI	ML	MB	PD	E2-5-ORO-T5	ORO	RSI	LB	PK	PD
E2-5-PLAT-T1	PLAT	RSI	ML	LB	PK	E2-5-PLAT-T5	PLAT	RSI	MB	PK	PD

E2-5-PET-T1	PET	RSI	UB	MB	PD	E2-5-PET-T5	PET	RSI	UB	MB	PD
E2-5-ICC-T1	ICC	RSI	ML	MB	PK	E2-5-ICC-T5	ICC	RSI	MB	PK	PD
E2-5-IMCE-T1	IMCE	RSI	MB	PK	PD	E2-5-IMCE-T5	IMCE	RSI	UB	PK	PD
E2-5-IPEC-T1	IPEC	RSI	MB	PK	PD	E2-5-IPEC-T5	IPEC	RSI	MB	PK	PD
E2-5-IPSA-T1	IPSA	ML	UB	LB	PK	E2-5-IPSA-T5	IPSA	RSI	ML	SL	UB

Modelo	Variables					Modelo	Variables				
E2-5-USD-T15	USD	RSI	ML	SL	PK	E2-5-USD-T30	USD	RSI	ML	SL	PK
E2-5-EUR-T15	EUR	MB	LB	PK	PD	E2-5-EUR-T30	EUR	SL	LB	PK	PD
E2-5-CNY-T15	CNY	RSI	MB	PK	PD	E2-5-CNY-T30	CNY	ML	MB	LB	PD
E2-5-IPC-T15	IPC	RSI	LB	PK	PD	E2-5-IPC-T30	IPC	RSI	ML	PK	PD
E2-5-COB-T15	COB	ML	UB	MB	LB	E2-5-COB-T30	COB	SL	UB	PK	PD
E2-5-ORO-T15	ORO	ML	SL	UB	PD	E2-5-ORO-T30	ORO	RSI	ML	SL	PK
E2-5-PLAT-T15	PLAT	RSI	ML	PK	PD	E2-5-PLAT-T30	PLAT	RSI	ML	PK	PD
E2-5-PET-T15	PET	RSI	SL	UB	PK	E2-5-PET-T30	PET	RSI	ML	UB	PK
E2-5-ICC-T15	ICC	ML	SL	PK	PD	E2-5-ICC-T30	ICC	RSI	LB	PK	PD
E2-5-IMCE-T15	IMCE	RSI	ML	SL	PD	E2-5-IMCE-T30	IMCE	RSI	ML	SL	PK
E2-5-IPEC-T15	IPEC	RSI	SL	UB	MB	E2-5-IPEC-T30	IPEC	RSI	ML	UB	MB
E2-5-IPSA-T15	IPSA	SL	MB	PK	PD	E2-5-IPSA-T30	IPSA	RSI	ML	UB	MB

Todos los resultados obtenidos de los mejores modelos se presentan en el Anexo A.5. En la Tabla 6.9 se presentan los modelos que mejores valores presentaron tanto para la validación como la predicción.

Tabla 6.9: Modelos que presentaron mejores resultados de 5 variables para ANTO.

	Modelo	Var. Macro	Indicadores	Validación			Predicción		
				RMSE	MAPE	R2	Hor.	RMSE	MAPE
Mej. Val.	E2-5-ICC-T1	ICC	RSI ML MB PK	52,12	2,72	0,7657	1	147,67	8,94
	E2-5-CNY-T5	CNY	RSI UB PK PD	94,58	4,89	0,2170	5	180,54	10,76
	E2-5-CNY-T15	CNY	RSI MB PK PD	140,97	7,34	-0,8065	15	142,94	6,81
	E2-5-PET-T30	PET	RSI ML UB PK	174,43	9,68	-2,0329	30	187,83	9,18
Mej. Pred.	E2-5-COB-T1	COB	RSI SL MB PK	71,93	3,91	0,5538	1	39,95	2,42
	E2-5-PLAT-T5	PLAT	RSI MB PK PD	123,21	5,75	-0,3287	5	61,03	2,88
	E2-5-USD-T15	USD	RSI ML SL PK	166,47	8,64	-1,5192	15	129,45	7,23
	E2-5-USD-T30	USD	RSI ML SL PK	221,74	10,93	-3,7870	30	124,95	6,61

6.5 Análisis general de resultados

Los resultados del modelo extendido que incorpora variables macroeconómicas evidencian una clara mejora en la capacidad predictiva del ANFIS al incluir factores económicos clave. Para CMPC, la incorporación del tipo de cambio USD/CLP tuvo un efecto directo en la precisión de las predicciones de precios de cierre, al capturar la influencia de las fluctuaciones monetarias en una empresa con operaciones internacionales. Con esta variable, el modelo redujo el error de predicción,

alcanzando un RMSE de 7.87 y un MAPE de 0.46%, demostrando que la relación entre el precio de las acciones y el tipo de cambio es esencial para gestionar riesgos financieros.

De manera similar, en ANTO la integración del tipo de cambio CNY/CLP mejoró la precisión de las predicciones, dada la influencia del valor del yuan sobre los precios de los metales en el mercado global. La incorporación de esta variable permitió capturar con mayor precisión las fluctuaciones del mercado de commodities, logrando un MAPE de 2.42% y resaltando la importancia de incluir variables macroeconómicas para predecir el comportamiento de empresas expuestas a mercados internacionales.

Es relevante destacar que los modelos con horizontes de predicción a corto plazo mostraron un desempeño superior en comparación con aquellos que consideraron horizontes de mediano y largo plazo. Este fenómeno es consistente con lo esperado en el análisis de series temporales, ya que las correlaciones entre los datos pasados son más fuertes a medida que el horizonte temporal es más cercano. En predicciones de corto plazo, el modelo tiene acceso a datos más recientes, lo que le permite captar mejor las tendencias actuales del mercado y ofrecer predicciones más precisas. Sin embargo, a medida que el horizonte de predicción se amplía, la incertidumbre inherente a los mercados financieros crece, lo que se refleja en una mayor dificultad para prever eventos a mediano y largo plazo con la misma precisión.

Este comportamiento también está relacionado con la volatilidad del mercado, que tiene un impacto directo en los modelos predictivos. En periodos de alta volatilidad, las fluctuaciones de los precios son más difíciles de predecir, lo que puede llevar a una mayor variabilidad en los errores de predicción a largo plazo.

El análisis de los resultados obtenidos también resalta la importancia de seleccionar adecuadamente las variables de entrada. La combinación de indicadores técnicos y variables macroeconómicas es crucial para mejorar la precisión de las predicciones. En este estudio, los indicadores técnicos proporcionaron señales clave para capturar patrones a corto plazo. Sin embargo, la adición de variables macroeconómicas permitió que el modelo abarcara un espectro más amplio de influencias, capturando factores externos que los indicadores técnicos por si solos no pueden reflejar. En particular, las monedas y los *commodities* resultaron ser variables determinantes para mejorar la precisión del modelo.

Capítulo 7. Resultados y análisis general

7.1 Introducción

Este capítulo presenta un análisis global de los resultados obtenidos, comparando el desempeño del modelo en las dos empresas estudiadas y evaluando la influencia de los horizontes temporales y las variables seleccionadas. Se discuten los hallazgos clave y su relevancia en el contexto del mercado financiero chileno. Para tratar de mantener los gráficos más limpios, se abreviará indicadores técnicos como IT y variables macroeconómicas como VM.

7.2 Comparación entre empresas

Los resultados obtenidos destacan diferencias clave entre las empresas analizadas, las cuales están asociadas a la naturaleza de sus operaciones y su exposición a factores macroeconómicos. Se observa que para los modelos de cuatro entradas, el rendimiento entre las empresas es más equilibrado (ver Figura 7.1), con diferencias marginales en las métricas de validación. Sin embargo, en los modelos de cinco entradas (ver Figura 7.2), CMPC muestra mejores resultados, especialmente en los horizontes de mediano y largo plazo




Figura 7.1: Gráfico de error de validación para distintos modelos de 4 variables.

Al comparar el desempeño del modelo ANFIS para las dos empresas, se observa que las predicciones para CMPC tienden a ser más precisas que las de ANTO, especialmente cuando se

utilizan modelos de cuatro entradas. Para la validación se tiene que el modelo E1-4-T1 obtuvo un MAPE de 2.05, un RMSE de 38.31 y un R2 de 0.9406, el mejor resultado en validación entre todos los modelos. En general para la validación, los modelos de 4 variables técnicas fueron mejores, ya que las variables seleccionadas estaban ajustadas para captar tendencias inmediatas. Sin embargo en la predicción, los modelos macroeconómicos con 5 variables destacaron porque integran información contextual adicional, lo que les permitió un mejor desempeño en horizontes más largos.

Para el caso de la predicción, el modelo E1-5-USD-T1 se destacó con un RMSE de 7.35 y un MAPE de 0.43, reflejando la importancia del tipo de cambio USD/CLP para esta empresa. La incorporación de esta variable permitió al modelo adaptarse mejor a fluctuaciones externas y realizar predicciones más precisas.

El aumento del error en horizontes más largos es notable. Esto puede deberse a que las tendencias identificadas por los indicadores técnicos pierden relevancia a medida que el horizonte temporal se amplía, mientras que las variables macroeconómicas son menos sensibles a estos cambios.




Figura 7.2: Gráfico de error de validación para distintos modelos de 5 variables.

En el caso de ANTO, se tiene la mejor validación entregada por el modelo E2-4-ICC-T1 obtuvo un MAPE de 2.26, un RMSE de 42.49 y un R2 de 0.8843. Mientras que para la predicción el modelo E2-5-COB-T1 entregó un RMSE de 39.95 y un MAPE de 2.42. Para ANTO se tiene un caso similar a CMPC, en donde los modelos de 4 variables técnicas fueron más efectivos en la validación, mientras que los modelos macroeconómicos con 5 variables dominaron en predicción.

Esto refleja que el comportamiento del cobre introduce una capa de complejidad que es mejor captada por variables macroeconómicas en horizontes más largos.

El aumento del error en horizontes largos también es evidente, aunque menos pronunciado que en CMPC. Esto podría deberse a la influencia estabilizadora del precio del cobre, que introduce una base predecible en el comportamiento de los precios de acciones.

7.3 Impacto de los horizontes de predicción

En los horizontes cortos, los modelos de indicadores técnicos mostraron un mejor desempeño, con valores bajos de RMSE y MAPE. Esto se debe a que los indicadores técnicos, como MACDLine y PercentK, están diseñados para captar tendencias inmediatas, lo que los hace ideales para predicciones en horizontes cercanos. Un ejemplo de esto es el modelo E1-4-T1.




Figura 7.3: Gráfico de R2 de modelos de (a) 4 entradas y (b) 5 entradas.

De acuerdo a la Figura 7.3, se puede observar que a medida aumentan el horizonte de predicción, peor es el R2 que entregan los modelos en la validación, especialmente los modelos macroeconómicos de ANTO. De igual manera a medida que los horizontes temporales aumentan, se observa un incremento en el error de predicción (ver Figura 7.4). Esto es más evidente en los modelos basados exclusivamente en indicadores técnicos, ya que las tendencias identificadas en corto plazo se diluyen en horizontes más largos.




Figura 7.4: Error de predicción para distintos modelos de 4 variables.

Sin embargo, los modelos macroeconómicos mostraron mayor robustez en $t + 15$ y $t + 30$, especialmente en CMPC y ANTO, donde variables como el tipo de cambio y el precio del cobre desempeñaron un papel estabilizador. En los gráficos de error, se observa que en algunos modelos técnicos (por ejemplo, ANTO $t + 30$), el error disminuyó ligeramente. Esto puede deberse a que el modelo capturó un patrón general del mercado que se mantuvo estable en horizontes más largos.

7.4 Relevancia de las variables seleccionadas

La selección de variables desempeñó un papel clave en el desempeño de los modelos ANFIS, tanto en la validación como en la predicción. La combinación de indicadores técnicos y variables macroeconómicas permitió capturar tanto los patrones internos del mercado como los factores externos que influyen en los precios de las acciones.

En cuanto a los indicadores técnicos, los gráficos de conteo (ver Figura 7.5) reflejan que PercentK y MACDLine fueron los más utilizados en los modelos con mejor desempeño. En validación, PercentK apareció en 26 ocasiones, seguido de MACDLine con 23 apariciones, lo que sugiere que estos indicadores fueron particularmente efectivos para captar la dinámica de los mercados financieros. Esto es consistente con su función en el análisis técnico: PercentK, como parte del oscilador estocástico, permite identificar sobrecompras y sobreventas en el mercado, mientras que MACDLine es un indicador de *momentum* que ayuda a detectar cambios en la

tendencia. En los modelos de predicción, PercentK y MACDLine continuaron siendo los indicadores más utilizados, con 24 y 21 ocurrencias respectivamente, lo que reafirma su importancia no solo para la validación sino también para la proyección futura del comportamiento del precio de las acciones.




Figura 7.5: Gráfico de conteo de indicadores técnicos en modelos de validación.




Figura 7.6: Gráfico de conteo de indicadores técnicos en modelos de predicción.

7.5 Contexto del mercado financiero chileno

El mercado chileno, aunque relativamente pequeño en comparación con otros mercados internacionales, desempeña un papel crucial en la economía del país y está influenciado por una combinación de factores locales y globales.

7.5.1 Desempeño de los modelos en el contexto local

Las predicciones obtenidas a través de los modelos mostraron que para CMPC, la incorporación de indicadores técnicos fue especialmente útil para capturar las tendencias a corto y media plazo, dada la naturaleza estable y local de la empresa. Como una de las principales empresas en el sector forestal y papelerero, está más expuesta a los cambios económicos internos, lo que otorga una menor sensibilidad a las variables internacionales.

Por otro lado, Antofagasta Minerals, siendo una empresa minera con fuerte presencia internacional, está más influenciada por variables macroeconómicas globales, como los precios de los metales y los tipos de cambios, que representan factores clave en la economía chilena debido a la importancia de las exportaciones para el país. Los resultados mostraron que las variables macroeconómicas mejoraron la precisión de las predicciones a mediano y largo plazo, lo que destaca la importancia de incorporar estos factores al desarrollar modelos predictivos para empresas que dependen de la exportación de *commodities*.

7.5.2 Impacto de los factores externos

El mercado chileno está expuesto a una alta volatilidad debido a factores globales, como los precios internacionales de *commodities* y las políticas económicas de países con los que mantiene relaciones comerciales, como Estados Unidos y China. Este estudio destaca la relevancia de incorporar variables macroeconómicas internacionales en los modelos predictivos, especialmente para empresas nacionales con exposición a mercados globales. Los modelos basados solo en indicadores técnicos no lograron capturar completamente las fluctuaciones impulsadas por factores externo.

Capítulo 8. Conclusión

El presente estudio abordó la problemática de la predicción de precios en el mercado financiero mediante la implementación de un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS), combinando indicadores técnicos y variables macroeconómicas para mejorar la precisión de las predicciones en distintos horizontes temporales. A través de una metodología estructurada en varias etapas, se desarrolló un modelo base con indicadores técnicos y posteriormente se extendió con variables macroeconómicas, evaluando su impacto en el desempeño predictivo.

Los resultados obtenidos demuestran que los modelos ANFIS con indicadores técnicos pueden capturar tendencias de corto plazo de manera efectiva, con errores relativamente bajos en horizontes de predicción cortos ($t + 1$ y $t + 5$). No obstante, a medida que el horizonte temporal se amplía ($t + 15$ y $t + 30$), el error de predicción tiende a aumentar significativamente, lo que indica que la capacidad del modelo para mantener precisión en el largo plazo se ve limitada por la complejidad y volatilidad del mercado.

La incorporación de variables macroeconómicas permitió mejorar la precisión de las predicciones en ciertos escenarios, especialmente en horizontes temporales más largos. Sin embargo, la relevancia de estas variables varió según la empresa analizada. Para CMPC, tanto el tipo de cambio USD/CLP como el precio del cobre fueron determinantes en la predicción del valor de sus acciones, mientras que para Antofagasta Minerals (ANTO), el precio del cobre y el tipo de cambio CNY/CLP tuvieron mayor relevancia. Estos resultados sugieren que la combinación de indicadores técnicos y variables macroeconómicas aporta una visión más integral del comportamiento de los activos financieros, aunque su efectividad varía según la empresa y el contexto del mercado. Asimismo, se evidenció que la selección de indicadores técnicos juega un papel fundamental en la precisión del modelo. %K y la Línea MACD fueron los indicadores más recurrentes en los modelos con mejor desempeño, lo que respalda su utilidad en la identificación de tendencias. En contraste, el uso de cinco variables de entrada no siempre mejoró la precisión del modelo, sugiriendo que la incorporación de variables adicionales debe realizarse con un análisis cuidadoso para evitar redundancias o sobreajuste.

Otro hallazgo relevante fue la diferencia en el desempeño predictivo entre CMPC y ANTO. Mientras que los modelos de CMPC lograron mayores valores de R^2 en validación, indicando un mejor ajuste a los datos históricos, los modelos de ANTO presentaron mayores fluctuaciones en el

error de predicción, reflejando la fuerte dependencia de esta empresa a la economía global.

En términos de impacto de los horizontes de predicción, se confirmó que la precisión disminuye conforme el horizonte temporal se amplía. Si bien en algunos casos los modelos con horizontes más largos mostraron mejoras en ciertas métricas, esto se debió a ajustes específicos del modelo y no a una tendencia generalizable. Este resultado destaca la importancia de considerar la incertidumbre del mercado al establecer estrategias de inversión basadas en modelos predictivos.

En conclusión, este trabajo confirma que ANFIS es una herramienta efectiva para la predicción de precios en el mercado financiero, especialmente en el corto plazo y cuando se combinan indicadores técnicos con variables macroeconómicas relevantes. Sin embargo, el desempeño del modelo está condicionado por la empresa analizada, la selección de variables y la duración del horizonte de predicción.

Para estudios futuros, sería pertinente evaluar la incorporación de datos de alta frecuencia y la inclusión de factores exógenos, como noticias financieras, eventos macroeconómicos inesperados o sentimiento del mercado basado en análisis de texto, de modo que el modelo pueda reaccionar con mayor precisión a cambios súbitos y noticias relevantes. Del mismo modo, podrían investigarse mecanismos de *ensemble* que combinen distintos subsistemas ANFIS, permitiendo una mayor adaptabilidad ante escenarios de mayor volatilidad. Finalmente, la exploración de enfoques híbridos, combinando ANFIS con modelos de aprendizaje profundo o técnicas de series temporales como ARIMA o LSTM, podría proporcionar un marco de predicción más robusto.

Referencias

- [1] R. Lawrence, «Using neural networks to forecast stock market prices,» 1998.
- [2] V. Nagarajan, Y. Wu, M. Liu y Q.-G. Wang, «Forecast studies for financial markets using technical analysis,» de *2005 International Conference on Control and Automation*, Budapest, Hungary , 2005.
- [3] C.-H. Cheng y L.-Y. Wei, «One step-ahead ANFIS time series model for forecasting electricity loads,» *Optimization and Engineering*, vol. 11, pp. 303-317, 2009.
- [4] N. Gradojevic y R. Gençay, «Fuzzy logic, trading uncertainty and technical trading,» *Journal of Banking & Finance*, vol. 37, nº 2, pp. 578-586, 2013.
- [5] M. A. Boyacioglu y D. Avci, «An Adaptive Network-Based Fuzzy Inference System (ANFIS) for the prediction of stock market return: The case of the Istanbul Stock Exchange,» *Expert Systems with Applications*, vol. 37, nº 12, pp. 7908-7912, 2010.
- [6] R. Nopianti, A. T. Panudju y A. Permana, «Stock Price Index Prediction Using Adaptive Neural Fuzzy Inference System,» *International Journal of Management, Accounting and Economics*, vol. 8, nº 10, pp. 715-732, 2021.
- [7] I. Svalina, V. Galzina, R. Lujčić y G. Šimunović, «An adaptive network-based fuzzy inference system (ANFIS) for the forecasting: The case of close price indices,» *Expert Systems with Applications*, vol. 40, nº 15, pp. 6055-6063, 2013.
- [8] A. Kablan, «Adaptive Neuro Fuzzy Inference Systems for High Frequency Financial Trading and Forecasting,» de *2009 Third International Conference on Advanced Engineering Computing and Applications in Sciences*, Sliema, Malta , 2009.
- [9] M. Billah, S. Waheed y A. Hanifa, «Predicting Closing Stock Price using Artificial Neural Network and Adaptive Neuro Fuzzy Inference System (ANFIS): The Case of the Dhaka Stock

- Exchange,» *International Journal of Computer Applications*, vol. 129, nº 11, pp. 1-5, 2015.
- [10] A. Azadeh, M. Saberi y S. Asadzadeh, «An adaptive network based fuzzy inference system—auto regression—analysis of variance algorithm for improvement of oil consumption estimation and policy making: The cases of Canada, United Kingdom, and South Korea,» *Applied Mathematical Modelling*, vol. 35, nº 2, pp. 581-593, 2011.
- [11] S. A. Mohaddes y S. M. Fahimifard, «Application of Adaptive Neuro-Fuzzy Inference System (ANFIS) in Forecasting Agricultural Products Export Revenues (Case of Iran's Agriculture Sector),» *Journal of Agricultural Science and Technology*, vol. 17, pp. 1-10, 2015.
- [12] W. M. Cheung y U. Kaymak, «A Fuzzy Logic Based Trading System,» de *In Proceedings of the Third European Symposium on Nature Inspired Smart Information Systems*, Malta, 2007.
- [13] R. Morta, S. Morta y E. Dadios, «Modeling market data and technical indicators with Fuzzy Logic to develop a trading algorithm for an individual stock in the Philippines,» de *2015 International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM)*, Cebu, Philippines , 2015.
- [14] X.-S. Zhou y M. Dong, «Can Fuzzy Logic Make Technical Analysis 20/20?,» *Financial Analysts Journal*, vol. 60, nº 4, pp. 54-75, 2004.
- [15] M. Alizadeh, M. Gharakhani, E. Fotoohi y R. Rada, « Design and analysis of experiments in ANFIS modeling for stock price prediction,» *International Journal of Industrial Engineering Computations* , vol. 2, nº 2, pp. 409-418, 2011.
- [16] M. B. Mahboubbeh Pishnamazi, A. T. Nakhjiri, M. Rezakazemi, A. Marjani y S. Shirazian, «ANFIS grid partition framework with difference between two sigmoidal membership functions structure for validation of nanofluid flow,» *Scientific reports*, vol. 10, p. 15395, 21 September 2020.

- [17] F. Ghashami y K. Kamyar, «Performance Evaluation of ANFIS and GA-ANFIS for Predicting Stock Market Indices,» *International Journal of Economics and Finance*, vol. 13, n° 7, pp. 1-6, 2021.
- [18] A. Bagheri, H. M. Peyhani y M. Akbari, «Financial forecasting using ANFIS networks with Quantum-behaved Particle Swarm Optimization,» *Expert Systems with Applications*, vol. 41, n° 14, pp. 6235-6250, 2014.
- [19] Z. Tan, C. Quek y P. Y. Cheng, «Stock trading with cycles: A financial application of ANFIS and reinforcement learning,» *Expert Systems with Applications*, vol. 38, n° 11, pp. 4741-4755, 2011.
- [20] Y. Zhou, S. Guo y F.-J. Chang, «Explore an evolutionary recurrent ANFIS for modelling multi-step-ahead flood forecasts,» *Journal of Hydrology*, vol. 570, pp. 343-355, 2019.
- [21] J.-S. R. Jang, «ANFIS Adaptive-Network-based Fuzzy Inference System,» *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, n° 3, pp. 665-685, 1993.
- [22] L. Zadeh, «Fuzzy sets,» *Information and Control*, vol. 8, n° 3, pp. 338-353, 1965.
- [23] W. S. McCulloch y W. Pitts, «A logical calculus of the ideas immanent in nervous activity,» *Bulletin of Mathematical Biophysics*, vol. 5, pp. 115-133, 1943.
- [24] Frank Rosenblatt, «The perceptron: a probabilistic model for information storage and organization in the brain,» *Psychological Review*, vol. 65, n° 6, pp. 386-408, 1958.
- [25] T. Takagi y M. Sugeno, «Fuzzy identification of systems and its applications to modeling and control,» *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 15, n° 1, pp. 116-132, 1985.
- [26] G. Appel, *Technical Analysis: Power Tools for Active Investors*, Upper Saddle River, NJ, USA: Financial Times Press, 2005.

- [27] J. W. Wilder, New concepts in technical trading systems, Winston-Salem, NC, USA: Trend Research, 1978.
- [28] J. Murphy, Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications, Paramus, NJ: New York Institute of Finance, 1999.
- [29] J. Bollinger, Bollinger on Bollinger Bands, New York, NY, USA: McGraw-Hill, 2002.
-

Anexo A. Resultados

A.1 Datos relevantes del modelo ANFIS preliminar

La Figura A. 1 presenta las series temporales de los precios de apertura, cierre, alto y bajo para la empresa CMPC. De la misma manera, la Figura A. 2 presenta los datos para ANTO.




Figura A. 1: Datos históricos de CMPC en CLP.




Figura A. 2: Datos históricos de ANTO en GBP.

La Tabla A.1 presenta las reglas obtenidas del sistema de inferencia difusa para el modelo preliminar.

Tabla A. 1: Reglas generadas mediante Grid Partition.

Reglas generadas	
1.	If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf1) and (input4 is in4mf1) then (output is out1mf1)
2.	If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf1) and (input4 is in4mf2) then (output is out1mf2)
3.	If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf1) then (output is out1mf3)
4.	If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf4)
5.	If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf1) then (output is out1mf5)
6.	If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf2) then (output is out1mf6)
7.	If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf1) then (output is out1mf7)
8.	If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf8)
9.	If (input1 is in1mf2) and (input2 is in2mf1) and (input3 is in3mf1) and (input4 is in4mf1) then (output is out1mf9)
10.	If (input1 is in1mf2) and (input2 is in2mf1) and (input3 is in3mf1) and (input4 is in4mf2) then (output is out1mf10)
11.	If (input1 is in1mf2) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf1) then (output is out1mf11)
12.	If (input1 is in1mf2) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf12)
13.	If (input1 is in1mf2) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf1) then (output is out1mf13)
14.	If (input1 is in1mf2) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf2) then (output is out1mf14)
15.	If (input1 is in1mf2) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf1) then (output is out1mf15)
16.	If (input1 is in1mf2) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf16)

A.2 Resultados de los mejores modelos de 4 variables para CMPC

Tabla A. 2: Resultados de los mejores modelos de 4 variables (t+1) para CMPC.

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E1-4-USD-T1	49,37		2,57	0,9014	7,87	0,46
E1-4-EUR-T1	47,48		2,37	0,9088	36,74	2,14
E1-4-CNY-T1	46,16		2,44	0,9138	41,02	2,39
E1-4-IPC-T1	111,29		5,90	0,4989	343,12	20,01
E1-4-COB-T1	49,00		2,56	0,9029	101,39	5,91
E1-4-ORO-T1	76,37		3,69	0,7640	37,41	2,18
E1-4-PLAT-T1	47,57		2,41	0,9084	8,71	0,51
E1-4-PET-T1	49,92		2,62	0,8992	19,20	1,12
E1-4-ICC-T1	43,53		2,18	0,9233	26,11	1,52
E1-4-IMCE-T1	74,67		3,71	0,7745	117,06	6,83
E1-4-IPEC-T1	53,19		2,90	0,8855	80,01	4,67
E1-4-IPSA-T1	80,93		4,20	0,7347	138,59	8,08

Tabla A. 3: Resultados de los mejores modelos de 4 variables (t+5) para CMPC.

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E1-4-USD-T5	88,47		4,81	0,6830	78,56	4,38
E1-4-EUR-T5	107,15		5,57	0,5350	122,89	6,95
E1-4-CNY-T5	114,75		5,63	0,4667	66,50	2,66
E1-4-IPC-T5	199,73		11,26	-0,6156	369,50	20,23
E1-4-COB-T5	78,47		4,17	0,7506	72,13	4,16
E1-4-ORO-T5	162,20		8,47	-0,0652	340,90	19,33
E1-4-PLAT-T5	83,88		4,32	0,7150	57,77	3,27
E1-4-PET-T5	115,71		6,25	0,4577	214,03	11,02
E1-4-ICC-T5	86,50		4,57	0,6969	58,68	3,02
E1-4-IMCE-T5	116,79		5,66	0,4476	146,69	6,85
E1-4-IPEC-T5	99,65		5,15	0,5978	154,62	8,89
E1-4-IPSA-T5	137,74		7,53	0,2319	95,74	5,59

Tabla A. 4: Resultados de los mejores modelos de 4 variables (t+15) para CMPC.

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E1-4-USD-T15	107,98		5,91	0,5288	135,56	6,88
E1-4-EUR-T15	125,07		6,26	0,3679	145,99	6,42
E1-4-CNY-T15	136,37		7,29	0,2486	76,65	3,40
E1-4-IPC-T15	250,55		12,24	-1,5366	242,79	12,58
E1-4-COB-T15	117,70		6,37	0,4402	185,35	9,90
E1-4-ORO-T15	147,48		7,64	0,1211	178,32	8,12
E1-4-PLAT-T15	102,55		5,51	0,5751	81,42	3,72
E1-4-PET-T15	141,66		7,59	0,1892	148,41	8,26
E1-4-ICC-T15	124,69		6,76	0,3718	69,05	3,58
E1-4-IMCE-T15	141,77		7,95	0,1879	121,56	5,98

E1-4-IPEC-T15	124,48	6,44	0,3739	280,16	16,38
E1-4-IPSA-T15	269,98	14,74	-1,9455	463,50	24,20

Tabla A. 5: Resultados de los mejores modelos de 4 variables (t+30) para CMPC.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-4-USD-T30	143,49	7,77	0,1716	133,07	6,77
E1-4-EUR-T30	172,44	9,01	-0,1964	128,14	6,78
E1-4-CNY-T30	202,92	10,51	-0,6567	261,52	11,54
E1-4-IPC-T30	148,32	7,98	0,1149	252,19	14,40
E1-4-COB-T30	159,72	8,68	-0,0264	72,41	3,83
E1-4-ORO-T30	203,66	10,31	-0,6675	414,84	23,98
E1-4-PLAT-T30	157,52	8,91	0,0017	131,23	7,15
E1-4-PET-T30	149,25	7,34	0,1037	265,50	14,51
E1-4-ICC-T30	153,06	8,26	0,0574	155,74	8,73
E1-4-IMCE-T30	161,82	8,49	-0,0536	154,88	8,26
E1-4-IPEC-T30	154,41	7,67	0,0407	419,32	23,64
E1-4-IPSA-T30	195,60	11,07	-0,5382	332,00	18,95

A.3 Resultados de los mejores modelos de 4 variables para ANTO

Tabla A. 6: Resultados de los mejores modelos de 4 variables (t+1) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-4-USD-T1	60,00	3,05	0,6895	65,79	3,98
E2-4-EUR-T1	51,10	2,77	0,7748	97,99	5,93
E2-4-CNY-T1	46,32	2,44	0,8149	119,19	7,22
E2-4-IPC-T1	59,65	3,12	0,6931	129,46	7,84
E2-4-COB-T1	57,43	3,06	0,7156	58,30	3,53
E2-4-ORO-T1	58,61	3,13	0,7037	86,06	5,21
E2-4-PLAT-T1	52,60	2,75	0,7614	141,59	8,57
E2-4-PET-T1	47,74	2,55	0,8035	122,08	7,39
E2-4-ICC-T1	42,49	2,26	0,8443	174,19	10,55
E2-4-IMCE-T1	58,16	3,02	0,7082	127,70	7,73
E2-4-IPEC-T1	54,95	2,99	0,7396	105,82	6,41
E2-4-IPSA-T1	121,10	5,26	-0,2094	262,15	15,87

Tabla A. 7: Resultados de los mejores modelos de 4 variables (t+5) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-4-USD-T5	112,28	5,96	-0,1035	90,76	5,36
E2-4-EUR-T5	103,26	5,81	0,0667	119,87	7,29
E2-4-CNY-T5	80,58	4,37	0,4316	143,71	7,81
E2-4-IPC-T5	155,21	8,00	-1,1084	112,39	6,82
E2-4-COB-T5	104,77	5,73	0,0393	220,59	12,04
E2-4-ORO-T5	122,63	6,80	-0,3161	86,61	5,22

E2-4-PLAT-T5	97,79	4,77	0,1630	79,64	4,65
E2-4-PET-T5	86,27	4,30	0,3486	130,91	7,96
E2-4-ICC-T5	86,85	4,61	0,3398	240,40	14,30
E2-4-IMCE-T5	142,28	7,35	-0,7718	219,66	13,49
E2-4-IPEC-T5	113,66	6,23	-0,1306	221,23	13,58
E2-4-IPSA-T5	216,16	10,30	-2,9716	1090,22	66,83

Tabla A. 8: Resultados de los mejores modelos de 4 variables (t+15) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-4-USD-T15	170,38	9,41	-1,6387	135,82	7,53
E2-4-EUR-T15	153,31	8,23	-1,1365	91,69	4,58
E2-4-CNY-T15	108,08	5,87	-0,0618	211,69	12,69
E2-4-IPC-T15	233,31	12,07	-3,9483	125,73	6,33
E2-4-COB-T15	184,44	10,23	-2,0924	114,63	6,71
E2-4-ORO-T15	174,74	9,22	-1,7758	90,53	4,27
E2-4-PLAT-T15	144,14	7,72	-0,8886	89,12	4,80
E2-4-PET-T15	132,07	6,98	-0,5856	127,34	6,90
E2-4-ICC-T15	133,53	7,44	-0,6209	110,29	5,93
E2-4-IMCE-T15	304,47	17,60	-7,4267	152,61	6,60
E2-4-IPEC-T15	195,43	10,53	-2,4717	78,49	4,27
E2-4-IPSA-T15	512,67	25,35	-22,3074	1877,77	98,55

Tabla A. 9: Resultados de los mejores modelos de 4 variables (t+30) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-4-USD-T30	176,87	8,50	-2,0455	238,63	12,09
E2-4-EUR-T30	172,98	8,74	-1,9131	201,98	10,74
E2-4-CNY-T30	133,97	7,12	-0,7473	119,63	6,30
E2-4-IPC-T30	200,09	11,17	-2,8977	341,53	18,03
E2-4-COB-T30	161,81	8,83	-1,5490	249,32	11,48
E2-4-ORO-T30	229,47	12,61	-4,2487	238,54	11,92
E2-4-PLAT-T30	144,62	7,84	-1,0848	123,17	6,93
E2-4-PET-T30	119,09	6,10	-0,4136	173,99	9,44
E2-4-ICC-T30	131,40	6,70	-0,6809	104,59	4,95
E2-4-IMCE-T30	264,64	15,80	-5,8184	280,04	14,84
E2-4-IPEC-T30	185,33	9,65	-2,3440	232,91	13,08
E2-4-IPSA-T30	369,42	20,96	-11,8165	429,89	23,46

A.4 Resultados de los mejores modelos de 5 variables para CMPC

Tabla A. 10: Resultados de los mejores modelos de 5 variables (t+1) para CMPC.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-5-USD-T1	72,84	3,79	0,7853	7,35	0,43
E1-5-EUR-T1	95,88	4,33	0,6281	27,97	1,63

E1-5-CNY-T1	81,36	4,28	0,7322	64,67	3,77
E1-5-IPC-T1	150,97	7,95	0,0780	35,43	2,07
E1-5-COB-T1	57,65	3,08	0,8655	25,07	1,46
E1-5-ORO-T1	148,75	6,91	0,1049	285,60	16,65
E1-5-PLAT-T1	74,83	3,83	0,7735	52,55	3,06
E1-5-PET-T1	91,33	4,81	0,6626	55,51	3,24
E1-5-ICC-T1	71,46	3,43	0,7934	39,20	2,29
E1-5-IMCE-T1	108,92	4,81	0,5201	90,88	5,30
E1-5-IPEC-T1	70,00	3,60	0,8018	58,80	3,43
E1-5-IPSA-T1	128,75	6,10	0,3286	29,06	1,69

Tabla A. 11: Resultados de los mejores modelos de 5 variables (t+5) para CMPC.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-5-USD-T5	132,41	6,81	0,2899	141,52	6,81
E1-5-EUR-T5	171,82	7,84	-0,1957	307,21	16,51
E1-5-CNY-T5	156,23	8,19	0,0114	52,72	2,48
E1-5-IPC-T5	232,35	11,33	-1,1866	860,38	50,10
E1-5-COB-T5	98,29	5,22	0,6087	85,46	3,61
E1-5-ORO-T5	230,97	11,83	-1,1599	409,92	21,08
E1-5-PLAT-T5	128,61	6,86	0,3300	205,79	11,74
E1-5-PET-T5	150,64	8,41	0,0809	86,58	4,54
E1-5-ICC-T5	110,07	5,92	0,5093	131,67	5,98
E1-5-IMCE-T5	121,38	6,20	0,4033	79,41	3,63
E1-5-IPEC-T5	126,19	6,71	0,3550	198,07	10,37
E1-5-IPSA-T5	240,46	12,74	-1,3411	257,74	12,13

Tabla A. 12: Resultados de los mejores modelos de 5 variables (t+15) para CMPC.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-5-USD-T15	135,27	7,51	0,2606	130,88	6,88
E1-5-EUR-T15	173,13	9,45	-0,2112	208,31	11,77
E1-5-CNY-T15	188,58	9,49	-0,4370	132,53	6,97
E1-5-IPC-T15	256,90	12,61	-1,6668	139,80	5,51
E1-5-COB-T15	140,05	7,28	0,2074	403,47	18,43
E1-5-ORO-T15	269,15	12,27	-1,9273	507,38	16,87
E1-5-PLAT-T15	135,38	7,10	0,2595	107,21	5,68
E1-5-PET-T15	155,71	8,14	0,0203	213,09	10,91
E1-5-ICC-T15	123,92	6,60	0,3795	111,23	6,01
E1-5-IMCE-T15	169,39	8,89	-0,1594	441,77	22,15
E1-5-IPEC-T15	159,88	7,83	-0,0329	416,99	24,92
E1-5-IPSA-T15	276,44	14,93	-2,0880	933,24	51,72

Tabla A. 13: Resultados de los mejores modelos de 5 variables (t+30) para CMPC.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E1-5-USD-T30	164,18	8,47	-0,0845	292,93	15,55

E1-5-EUR-T30	169,30	8,72	-0,1533	557,27	32,33
E1-5-CNY-T30	260,90	11,35	-1,7387	95,76	5,04
E1-5-IPC-T30	207,19	10,31	-0,7272	424,09	20,01
E1-5-COB-T30	174,34	9,45	-0,2229	126,15	5,84
E1-5-ORO-T30	257,49	14,10	-1,6654	283,76	14,56
E1-5-PLAT-T30	167,07	8,79	-0,1231	189,17	10,67
E1-5-PET-T30	151,36	7,66	0,0782	121,36	5,54
E1-5-ICC-T30	175,78	9,07	-0,2432	193,02	10,78
E1-5-IMCE-T30	173,80	9,04	-0,2153	346,43	18,23
E1-5-IPEC-T30	175,87	8,88	-0,2444	458,58	22,25
E1-5-IPSA-T30	293,39	13,11	-2,4604	286,10	16,07

A.5 Resultados de los mejores modelos de 5 variables para ANTO

Tabla A. 14: Resultados de los mejores modelos de 5 variables (t+1) para ANTO.

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E2-5-USD-T1	83,58	4,18	0,3976	125,69	7,61	
E2-5-EUR-T1	70,57	3,40	0,5705	106,64	6,46	
E2-5-CNY-T1	58,67	3,11	0,7032	247,38	14,98	
E2-5-IPC-T1	87,47	4,54	0,3401	106,51	6,45	
E2-5-COB-T1	71,93	3,91	0,5538	39,95	2,42	
E2-5-ORO-T1	114,78	5,62	-0,1362	129,87	7,86	
E2-5-PLAT-T1	66,82	3,24	0,6149	260,73	15,79	
E2-5-PET-T1	57,34	2,93	0,7164	146,33	8,86	
E2-5-ICC-T1	52,12	2,72	0,7657	147,67	8,94	
E2-5-IMCE-T1	90,75	4,35	0,2897	162,98	9,87	
E2-5-IPEC-T1	61,26	3,28	0,6763	125,72	7,61	
E2-5-IPSA-T1	200,00	10,25	-2,2984	166,17	10,06	

Tabla A. 15: Resultados de los mejores modelos de 5 variables (t+5) para ANTO.

Modelo	Validación			Predicción		
	RMSE	MAPE	R2	RMSE	MAPE	
E2-5-USD-T5	151,66	7,56	-1,0133	152,52	8,47	
E2-5-EUR-T5	128,89	6,68	-0,4540	169,40	10,23	
E2-5-CNY-T5	94,58	4,89	0,2170	180,54	10,76	
E2-5-IPC-T5	169,04	8,77	-1,5011	220,36	12,47	
E2-5-COB-T5	116,17	6,05	-0,1812	556,68	29,23	
E2-5-ORO-T5	214,68	10,77	-3,0339	83,98	4,73	
E2-5-PLAT-T5	123,21	5,75	-0,3287	61,03	2,88	
E2-5-PET-T5	101,99	5,35	0,0896	124,66	5,30	
E2-5-ICC-T5	111,76	5,65	-0,0932	234,78	13,89	
E2-5-IMCE-T5	176,94	9,10	-1,7401	192,01	11,37	
E2-5-IPEC-T5	129,15	7,05	-0,4600	248,64	14,92	
E2-5-IPSA-T5	347,84	20,15	-9,2842	739,06	42,94	

Tabla A. 16: Resultados de los mejores modelos de 5 variables (t+15) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-5-USD-T15	166,47	8,64	-1,5192	129,45	7,23
E2-5-EUR-T15	203,56	10,59	-2,7668	247,42	12,95
E2-5-CNY-T15	140,97	7,34	-0,8065	142,94	6,81
E2-5-IPC-T15	247,64	12,69	-4,5747	138,42	6,82
E2-5-COB-T15	222,45	12,44	-3,4982	378,76	19,31
E2-5-ORO-T15	452,36	22,13	-17,6011	200,73	11,20
E2-5-PLAT-T15	187,25	9,30	-2,1872	210,21	9,53
E2-5-PET-T15	151,60	7,71	-1,0891	159,12	7,86
E2-5-ICC-T15	154,76	8,16	-1,1771	135,97	7,29
E2-5-IMCE-T15	307,51	17,13	-7,5960	196,82	9,29
E2-5-IPEC-T15	225,75	13,17	-3,6327	208,71	11,87
E2-5-IPSA-T15	710,94	34,30	-43,8225	740,17	41,89

Tabla A. 17: Resultados de los mejores modelos de 5 variables (t+30) para ANTO.

Modelo	Validación			Predicción	
	RMSE	MAPE	R2	RMSE	MAPE
E2-5-USD-T30	221,74	10,93	-3,7870	124,95	6,61
E2-5-EUR-T30	249,38	13,27	-5,0543	226,29	10,50
E2-5-CNY-T30	176,86	9,06	-2,0452	276,14	14,52
E2-5-IPC-T30	240,05	13,33	-4,6098	340,95	15,16
E2-5-COB-T30	219,85	11,88	-3,7057	299,45	14,20
E2-5-ORO-T30	424,11	20,61	-16,9295	253,12	11,60
E2-5-PLAT-T30	213,75	10,62	-3,5543	180,94	8,20
E2-5-PET-T30	174,43	9,68	-2,0329	187,83	9,18
E2-5-ICC-T30	190,59	9,21	-2,5363	137,41	6,05
E2-5-IMCE-T30	311,75	15,51	-8,4617	248,80	12,52
E2-5-IPEC-T30	202,28	10,92	-2,9833	254,96	13,49
E2-5-IPSA-T30	668,43	32,41	-40,9613	1655,41	60,31

ANEXO B. Códigos relevantes

B.1 Código modelo ANFIS preliminar

```
% Código de entrenamiento y validación ANFIS preliminar
clear all; close all; clc;
tic;

%% Cargar los datos
load('datos/CMPC_Procesado.mat');

TT = sortrows(TT, 'dates');
fechaInicio = datetime('04/01/2021', 'InputFormat', 'dd/MM/yyyy');
fechaFin = datetime('29/12/2023', 'InputFormat', 'dd/MM/yyyy');
TT_filtrada = TT(TT.dates >= fechaInicio & TT.dates <= fechaFin, :);

%% Entradas - Indicadores técnicos
indicadores_seleccionados = {'MACDLine', 'RSI', 'PercentK', 'UpperBand'};
num_indicadores = length(indicadores_seleccionados);
ranges = cell(num_indicadores, 1);

% Calcular los rangos y almacenarlos
for i = 1:num_indicadores
    data = TT_filtrada.(indicadores_seleccionados{i});
    minValue = min(data);
    maxValue = max(data);
    ranges{i} = [minValue, maxValue];
end
fprintf('Rangos de las variables:\n');
for i = 1:num_indicadores
    fprintf('%s: [%2f %2f]\n', indicadores_seleccionados{i}, ranges{i}(1),
    ranges{i}(2));
end

%% Configuración del modelo preliminar
% Vectores de entrada y salida
num_muestras = height(TT_filtrada);
inputs = zeros(num_muestras, num_indicadores);
output = zeros(num_muestras, 1);
for i = 1:num_muestras
    inputs(i, :) = TT_filtrada{i, indicadores_seleccionados};
    output(i) = TT_filtrada.Close(i);
end

% Elimina valores nan
idx_validos = all(~isnan(inputs), 2) & ~isnan(output);
inputs = inputs(idx_validos, :);
output = output(idx_validos);

% Separa conjuntos de entrenamiento y validación
trainSize = floor(0.7 * size(inputs, 1));
trainInputs = inputs(1:trainSize, :);
```



```

trainOutput = output(1:trainSize);
validationInputs = inputs(trainSize + 1:end, :);
validationOutput = output(trainSize + 1:end);
trainData = [trainInputs, trainOutput];
validationData = [validationInputs, validationOutput];

% Configuración del FIS
opt = genfisOptions('GridPartition');
opt.NumMembershipFunctions = 2;
opt.InputMembershipFunctionType = 'gaussmf';
epochs = 100;
inFIS = genfis(trainInputs, trainOutput, opt);

% Graficar funciones de membresía para cada entrada
numInputs = length(inFIS.input); % Número de entradas
figure;
for i = 1:numInputs
    subplot(2, 2, i); % Crear subgráfico en una matriz 2x2
    plotmf(inFIS, 'input', i); % Graficar funciones de membresía
    title(['MF de la entrada ', indicadores_seleccionados(i)]);
    xlabel('Rango de la entrada');
    ylabel('Grado de pertenencia');
    grid on;
end

% Mostrar las reglas del modelo ANFIS
disp('Reglas del modelo ANFIS:');
showrule(inFIS)

%% Entrenamiento y validación del modelo ANFIS
% Entrenamiento
[outFIS, trainError] = anfis(trainData, inFIS, epochs)

anfisOutput = evalfis(outFIS, validationInputs);
trainPred = evalfis(outFIS, trainInputs);

% Graficar superficie de reglas difusas
figure;
gensurf(outFIS);
title('Superficie de reglas ');
xlabel('Entrada 1 - Línea MACD');
ylabel('Entrada 2 - RSI');
zlabel('Salida - Precio de cierre');
grid on;

% Graficar el error a través de las épocas
figure;
plot(1:epochs, trainError, '-o', 'Color', '#27aeeef');
xlabel('Épocas');
ylabel('Error');
title('Error de entrenamiento a través de las épocas');
grid on;

% Métricas de entrenamiento

```

```

trainingError = trainPred - trainOutput;
mse_train = mean(trainingError.^2);
rmse_train = sqrt(mse_train);
r2_train = 1 - sum(trainingError.^2) / sum((trainPred - mean(trainPred)).^2);
mape_train = mean(abs((trainingError) ./ trainPred)) * 100;
fprintf('Resultados del modelo ANFIS:\n');
fprintf('RMSE: %.4f\n', rmse_train);
fprintf('R^2: %.5f\n', r2_train);
fprintf('MAPE: %.4f\n', mape_train);

% Métricas de validación
predictionError = validationOutput - anfisOutput;
mse_val = mean(predictionError.^2);
rmse_val = sqrt(mse_val);
r2_val = 1 - sum(predictionError.^2) / sum((validationOutput -
mean(validationOutput)).^2);
mape_val = mean(abs((predictionError) ./ validationOutput)) * 100;
fprintf('Resultados del modelo ANFIS:\n');
fprintf('RMSE: %.4f\n', rmse_val);
fprintf('R^2: %.5f\n', r2_val);
fprintf('MAPE: %.4f\n', mape_val);

% Graficar
fechas = [TT_filtrada.dates(1:trainSize); TT_filtrada.dates(trainSize+1:end)];
fechasTrain = TT_filtrada.dates(1:trainSize);
fechasVal = TT_filtrada.dates(trainSize+1:end);

figure;
subplot(2, 2, [1, 2]);
hold on;
plot(fechas, output, 'k', 'LineWidth', 1);
plot(fechasTrain, trainPred, 'Color', '#ea5545', 'LineWidth', 1);
plot(fechasVal, anfisOutput, 'Color', '#87bc45', 'LineWidth', 1);
hold off;
grid on;
title('Resultados del modelo ANFIS preliminar');
xlabel('Fecha');
ylabel('Precio de cierre');
legend('Output Real (Precio de cierre)', 'Output Entrenamiento', 'Output Validación',
'Location', 'Best');

subplot(2, 2, 3)
plot(fechasTrain, trainingError, 'Color', '#27aef', 'LineWidth', 1);
grid on;
title('Error de entrenamiento');
xlabel('Fecha');
ylabel('Error');
yline(0, '--', 'LineWidth', 1, 'HandleVisibility', 'off')

subplot(2, 2, 4);
plot(fechasVal, predictionError, 'Color', '#27aef', 'LineWidth', 1);
grid on;
title('Error de validación');

```

```

xlabel('Fecha');
ylabel('Error');
yline(0, '--', 'LineWidth', 1, 'HandleVisibility', 'off')
toc;

model_results = [rmse_val, mape_val, r2_val];
columnNames = {'RMSE Entrenamiento', 'MAPE Entrenamiento', 'R2 Entrenamiento', 'RMSE Validación', 'MAPE Validación', 'R2 Validación'};
modelResultsTable = table(rmse_train, mape_train, r2_train, rmse_val, mape_val, r2_val, 'VariableNames', columnNames);
disp(modelResultsTable);

```

B.2 Código iteración modelo ANFIS base

```

%% Código de iteración del modelo ANFIS extendido
clear all; close all; clc;
tic

%% Cargar los datos
% load('datos/CMPC_Procesado.mat');
load('datos/ANTO_Procesado.mat');

fileName1 = 'excel/Iteracion_ANTO_4var.xlsx';
fileName2 = 'excel/Iteracion_ANTO_4var_mejores.xlsx';

n_indicadores = 4;
desplazamientos = [1, 5, 15, 30];

TT = sortrows(TT, 'dates');
fechaInicio = datetime('04/01/2021', 'InputFormat', 'dd/MM/yyyy');
fechaFin = datetime('29/12/2023', 'InputFormat', 'dd/MM/yyyy');
TT_filtrada = TT(TT.dates >= fechaInicio & TT.dates <= fechaFin, :);

%% Lista de indicadores técnicos a probar
indicadores_disponibles = {'RSI', 'MACDLine', 'SignalLine', 'UpperBand', 'MiddleBand', 'LowerBand', 'PercentK', 'PercentD'};
num_indicadores = length(indicadores_disponibles);

% Inicializar matriz para almacenar los resultados
combinations = nchoosek(1:num_indicadores, n_indicadores);
all_results = [];
best_results = [];

%% Bucle para probar combinaciones de indicadores
for k = 1:length(desplazamientos)

    n_desplazamiento = desplazamientos(k);
    n_dias = n_desplazamiento;

    results = [];
    results_aux = [];

    for i = 1:size(combinations, 1)

```

```

selected_indicators = indicadores_disponibles(combinations(i, :));

inputs = zeros(height(TT_filtrada)-n_desplazamiento,
length(selected_indicators));
for j = 1:length(selected_indicators)
    inputs(:, j) = TT_filtrada.(selected_indicators{j})(1:end-
n_desplazamiento); % Cada indicador en tiempo t
end
outputs = TT_filtrada.Close(1+n_desplazamiento:end); % El precio de cierre en
tiempo t+1

% Eliminar filas con nan
idx_validos = all(~isnan(inputs), 2) & ~isnan(outputs);
inputs = inputs(idx_validos, :);
outputs = outputs(idx_validos);

% Dividir los datos en entrenamiento y validación
trainSize = floor(0.7 * size(inputs, 1));
trainInputs = inputs(1:trainSize, :);
trainOutputs = outputs(1:trainSize);
validationInputs = inputs(trainSize + 1:end, :);
validationOutputs = outputs(trainSize + 1:end);

% Entrenar el modelo ANFIS
trainData = [trainInputs, trainOutputs];
validationData = [validationInputs, validationOutputs];

opt = genfisOptions('GridPartition');
opt.NumMembershipFunctions = 2;
opt.InputMembershipFunctionType = 'gaussmf';
epochs = 10;

inFIS = genfis(trainInputs, trainOutputs, opt);
[outFIS, trainError] = anfis(trainData, inFIS, epochs);

% Realizar la validación
anfisOutput = evalfis(outFIS, validationInputs);
validationError = validationOutputs - anfisOutput;

% Calcular métricas validación
mse = mean(validationError.^2);
rmse = sqrt(mse);
mape = mean(abs((validationError) ./ validationOutputs)) * 100;
r2 = 1 - sum(validationError.^2) / sum((validationOutputs -
mean(validationOutputs)).^2);

% Realizar la predicción
indiceFechaFin = find(TT.dates == fechaFin);
indices_prediccion = indiceFechaFin - n_dias + (1:n_dias);
indices_prediccion_out = indiceFechaFin + (1:n_dias);
TT_pred = TT(indices_prediccion, :);

inputs_pred = zeros(n_dias, length(selected_indicators));

```

```

    for j = 1:length(selected_indicators)
        inputs_pred(:, j) = TT_pred.(selected_indicators{j});
    end

    anfis_pred = evalfis(outFIS, inputs_pred);
    outputs_pred = TT.Close(indices_prediccion_out);
    predictionError = outputs_pred - anfis_pred;

    mse_pred = mean(predictionError.^2);
    rmse_pred = sqrt(mse_pred);
    mape_pred = mean(abs((predictionError) ./ outputs_pred)) * 100;

    results_aux = [results_aux; rmse];
    results = [results; selected_indicators, rmse, mape, r2, n_desplazamiento,
rmse_pred, mape_pred];
    end

    all_results = [all_results; results];

    [~, best_idx] = min(results_aux(:,1));
    best_result = results(best_idx, :);

    best_results = [best_results; best_result];

end

%% Resultados en tablas
columnNames = [arrayfun(@(x) ['Indicador ' num2str(x)], 1:n_indicadores,
'UniformOutput', false), 'RMSE', 'MAPE', 'R2', 'Horizonte', 'RMSE Pred', 'MAPE Pred',
'R2 Pred'];
resultTable = array2table(all_results, 'VariableNames', columnNames);
bestTable = array2table(best_results, 'VariableNames', columnNames);

disp(bestTable);

toc

% writetable(resultTable, fileName1, 'WriteMode', "overwrite");
% writetable(bestTable, fileName2, 'WriteMode', "overwrite");

```

B.3 Código iteración modelo ANFIS extendido

```

%% Código de iteración del modelo ANFIS extendido
clear all; close all; clc;
tic;

%% Cargar los datos
% load('datos/CMPC_Procesado.mat');
load('datos/ANTO_Procesado.mat');

fileName1 = 'excel/Iteracion_ANTO_macro_5var.xlsx';

```

```

fileName2 = 'excel/Iteracion_ANTO_macro_5var_mejores.xlsx';

n_indicadores = 4; % 3 para modelos con 4 entradas total; 4 para modelos con 5 entradas
total
desplazamientos = [1, 5, 15, 30];

% Lista de variables macroeconómicas a probar
macroeconomicas = {
    'DH_USD_CLP.mat',
    'DH_EUR_CLP.mat',
    'DH_CNY_CLP.mat',
    'DH_IPC.mat',
    'DH_FUT_COBRE.mat',
    'DH_FUT_ORO.mat',
    'DH_FUT_PLATA.mat',
    'DH_FUT_PETROLEO.mat',
    'DH_ICC.mat',
    'DH_IMCE.mat',
    'DH_IPEC.mat',
    'DH_IPSA.mat'
};

% Indicadores técnicos disponibles
indicadores_disponibles = {'RSI', 'MACDLine', 'SignalLine', 'UpperBand',
    'MiddleBand', 'LowerBand', 'PercentK', 'PercentD'};
num_indicadores = length(indicadores_disponibles);
indicadores_combinaciones = nchoosek(1:num_indicadores, n_indicadores);

% Inicializar matrices para almacenar resultados
all_combinations_results = [];
best_combinations_summary = [];

%% Bucle para procesar cada variable macroeconómica

% Iteración de variable macroeconómica
for macro_idx = 1:length(macroeconomicas)
    % Cargar la variable macroeconómica
    load(['datos/', macroeconomicas{macro_idx}]);

    % Ordenar fechas
    TT = sortrows(TT, 'dates');
    tt = sortrows(tt, 'Fecha');
    fechaInicio = datetime('04/01/2021', 'InputFormat', 'dd/MM/yyyy');
    fechaFin = datetime('29/12/2023', 'InputFormat', 'dd/MM/yyyy');
    TT_filtrada = TT(TT.dates >= fechaInicio & TT.dates <= fechaFin, :);
    tt_filtrada = tt(tt.Fecha >= fechaInicio & tt.Fecha <= fechaFin, :);

    macro_variable = macroeconomicas{macro_idx}(1:end-4); % Extraer el nombre sin
    ".mat"

    % Unir los datos de TT y la variable macroeconómica por fechas comunes
    fechas_comunes = intersect(TT_filtrada.dates, tt_filtrada.Fecha);
    TT_filtrada = TT_filtrada(ismember(TT_filtrada.dates, fechas_comunes), :);
    tt_filtrada = tt_filtrada(ismember(tt_filtrada.Fecha, fechas_comunes), :);

```

```

all_results = [];
best_results = [];
% Iteración de horizontes temporales
for k = 1:length(desplazamientos)

    n_desplazamiento = desplazamientos(k);
    n_dias = n_desplazamiento;

    results = [];
    results_aux = [];
    % Iteración de indicadores técnicos
    for i = 1:size(indicadores_combinaciones, 1)

        selected_indicators = indicadores_disponibles(indicadores_combinaciones(i,
:));

        inputs = zeros(height(TT_filtrada)-n_desplazamiento,
length(selected_indicators) + 1); % N indicadores + 1 variable macroeconómica
        for j = 1:length(selected_indicators)
            inputs(:, j) = TT_filtrada.(selected_indicators{j})(1:end-
n_desplazamiento); % Asignar cada indicador en tiempo t
        end
        inputs(:, end) = tt_filtrada.PrecioCierre(1:end-n_desplazamiento); % La
variable macroeconómica en tiempo t
        outputs = TT_filtrada.Close(1+n_desplazamiento:end); % La salida es el
precio de cierre del día siguiente (t+n_desplazamiento)

        % Filtrar valores nan
        idx_validos = all(~isnan(inputs), 2) & ~isnan(outputs);
        inputs = inputs(idx_validos, :);
        outputs = outputs(idx_validos);

        % Dividir los datos en entrenamiento y validación
        trainSize = floor(0.7 * size(inputs, 1));
        trainInputs = inputs(1:trainSize, :);
        trainOutputs = outputs(1:trainSize);
        validationInputs = inputs(trainSize + 1:end, :);
        validationOutputs = outputs(trainSize + 1:end);

        % Entrenar el modelo ANFIS
        trainData = [trainInputs, trainOutputs];
        validationData = [validationInputs, validationOutputs];

        opt = genfisOptions('GridPartition');
        opt.NumMembershipFunctions = 2;
        opt.InputMembershipFunctionType = 'gaussmf';
        epochs = 10;

        inFIS = genfis(trainInputs, trainOutputs, opt);

        [outFIS, trainError] = anfis(trainData, inFIS, epochs);

        % Realizar la validación

```

```

anfisOutput = evalfis(outFIS, validationInputs);
validationError = validationOutputs - anfisOutput;

% Calcular métricas validación
mse = mean(validationError.^2);
rmse = sqrt(mse);
mape = mean(abs(validationError) ./ validationOutputs) * 100;
r2 = 1 - sum(validationError.^2) / sum((validationOutputs -
mean(validationOutputs)).^2);

% Realizar la predicción
indiceFechaFin = find(TT.dates == fechaFin);
indices_prediccion = indiceFechaFin - n_dias + (1:n_dias);
indices_prediccion_out = indiceFechaFin + (1:n_dias);
TT_pred = TT(indices_prediccion, :);
tt_pred = tt(indices_prediccion, :);

inputs_pred = zeros(n_dias, length(selected_indicators) + 1);
for j = 1:length(selected_indicators)
    inputs_pred(:, j) = TT_pred.(selected_indicators{j});
end
inputs_pred(:, end) = tt_pred.PrecioCierre;

anfis_pred = evalfis(outFIS, inputs_pred);
outputs_pred = TT.Close(indices_prediccion_out);
predictionError = outputs_pred - anfis_pred;

mse_pred = mean(predictionError.^2);
rmse_pred = sqrt(mse_pred);
mape_pred = mean(abs(predictionError) ./ outputs_pred) * 100;

results_aux = [results_aux; rmse];
results = [results; macro_variable, selected_indicators, rmse, mape, r2,
n_desplazamiento, rmse_pred, mape_pred];
end

all_results = [all_results; results];

[~, best_idx] = min(results_aux(:,1));
best_result = results(best_idx, :);
best_results = [best_results; best_result];
end

% Guardar los resultados de todas las combinaciones para esta variable
macroeconómica
all_combinations_results = [all_combinations_results; all_results];
best_combinations_summary = [best_combinations_summary; best_results];
end

%% Resultados en una tabla
columnNames = ['Macro Variable', arrayfun(@(x) ['Indicador ' num2str(x)],
1:n_indicadores, 'UniformOutput', false), 'RMSE', 'MAPE', 'R2', 'Horizonte', 'RMSE
Pred', 'MAPE Pred'];
resultTable = array2table(all_combinations_results, 'VariableNames', columnNames);

```



```
bestTable = cell2table(best_combinations_summary, 'VariableNames', columnNames);  
disp(bestTable);  
toc;  
  
% writetable(resultTable, fileName1, 'WriteMode', "overwrite");  
% writetable(bestTable, fileName2, 'WriteMode', "overwrite");
```

UNIVERSIDAD DE CONCEPCION – FACULTAD DE INGENIERIA
RESUMEN DE MEMORIA DE TITULO

Departamento : Departamento de Ingeniería Eléctrica
Carrera : Ingeniería civil electrónica
Nombre del memorista : Pablo Ignacio Fajardo Bernal
Título de la memoria : Predicción de Precios en el Mercado Financiero mediante Indicadores Técnicos y un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS)
Fecha de la presentación oral: 27/03/2025

Profesor(es) guía : Juan Pablo Segovia V.
Profesor(es) revisor(es) : Sebastián Godoy M., Enrique López P.
Concepto :
Calificación :

Resumen (máximo 200 palabras)

La presente memoria aborda la predicción de precios en mercados financieros mediante un Sistema de Inferencia Neuro-Difuso Adaptativo (ANFIS). El modelo combina indicadores técnicos y variables macroeconómicas para mejorar su capacidad predictiva en distintos horizontes temporales. Las empresas estudiadas fueron CMPC y Antofagasta Minerals, representativas de los sectores forestal y minero en Chile.

El trabajo se estructuró en tres fases: desarrollo inicial del modelo con indicadores técnicos, evaluación del modelo base con combinaciones de 4 y 5 variables, e integración de variables macroeconómicas como el tipo de cambio, precios de *commodities* e índices económicos. La evaluación del desempeño se realizó utilizando métricas como RMSE, MAPE y R^2 , comparando su precisión en validación y predicción.

Los resultados mostraron que los modelos con indicadores técnicos son más precisos en horizontes cortos ($t + 1$, $t + 5$), mientras que la inclusión de variables macroeconómicas mejoró la estabilidad y precisión en horizontes largos ($t + 15$, $t + 30$). CMPC mostró una alta dependencia del tipo de cambio, mientras que en Antofagasta Minerals el precio del cobre fue determinante.

Esta memoria aporta una metodología híbrida que combina técnicas de análisis técnico y factores macroeconómicos, contribuyendo al desarrollo de herramientas robustas para la predicción financiera.