

CENTRO DE ENSEÑANZA TÉCNICA Y SUPERIOR



Colegio de Ingeniería
Dirección de Posgrado
Campus Mexicali

**Sistema automatizado de adquisición y análisis dinámico
de datos para el soporte a decisiones en criptomercados**

Por

Martha Selene Solis Arellano

Tesis presentada como requisito parcial para obtener el grado de
Maestría en Ingeniería e Innovación

Director de Tesis
Dr. Ulises Orozco Rosas

Mexicali, Baja California
Junio, 2025

CENTRO DE ENSEÑANZA TÉCNICA Y SUPERIOR

Colegio de Ingeniería
Dirección de Posgrado
Campus Mexicali

**Sistema automatizado de adquisición y análisis dinámico
de datos para el soporte a decisiones en criptomercados**

Por

Martha Selene Solis Arellano

Tesis presentada como requisito parcial para obtener el grado de
Maestría en Ingeniería e Innovación

Director de Tesis
Dr. Ulises Orozco Rosas

Mexicali, Baja California
Junio, 2025

CENTRO DE ENSEÑANZA TÉCNICA Y SUPERIOR



Colegio de Ingeniería
Dirección de Posgrado
Campus Mexicali

Sistema automatizado de adquisición y análisis dinámico de datos para el soporte a decisiones en criptomercados

Por

Martha Selene Solis Arellano

Tesis presentada como requisito parcial para obtener el grado de
Maestría en Ingeniería e Innovación

Comité Evaluador

Dr. Ulises Orozco Rosas
Director de Tesis

Dra. Dania Licea Verduzco
Miembro del Comité

Dra. Karla Garduño Palomino
Miembro del Comité

Dra. Kenia Picos Espinoza
Miembro del Comité

Mexicali, Baja California a 14 de Junio de 2025

Dedicatoria

A mí misma, por aprender a navegar entre ideas que a veces parecen desconectadas, por encontrar lógica en el caos y por recordarme que no importa cuántas veces mi atención cambie de rumbo, siempre puedo regresar al camino.

A mis amigos, por seguirme el ritmo en conversaciones que saltan de un tema a otro sin previo aviso, por su paciencia cuando el contexto parece perderse y por demostrarme que la mejor manera de entender el mundo es cuestionarlo juntos.

A mi familia, por estar ahí incluso cuando no siempre entienden cómo funciona mi mente, por su apoyo incondicional y por ser, sin saberlo, el punto de referencia al que siempre puedo volver cuando todo parece moverse demasiado rápido.

Aunque la atención se disperse, cuando el contexto es el adecuado todo vuelve a tener sentido.

Agradecimientos

Expreso mi más sincero agradecimiento a quienes, a lo largo de este camino, no solo me transmitieron conocimiento técnico, sino también nuevas formas de cuestionar, interpretar y comprender el mundo y a mí misma. A quienes me enseñaron que la teoría puede abrazar a la intuición, que liderar es avanzar con humildad aun en medio de la incertidumbre, que las matemáticas son una llave para explorar la realidad, y que las diferencias no solo nos distinguen, sino que nos enriquecen.

Gracias a quienes desafiaron mis límites, despertaron en mí posibilidades que no creía tener y supieron tenderme una mano cuando la complejidad parecía desbordar. En especial, al Dr. Ulises Orozco Rosas, por su guía clara y paciente en el tramo más desafiante; a la Dra. Karla Garduño Palomino, cuyo aporte dejó una marca invaluable en este proceso; y a la Dra. Dania Licea Verduzco, cuya diferencia de perspectiva impulsó una reflexión que terminó fortaleciendo este camino.

A todas las personas que, con sus gestos, palabras, silencios y apoyo generoso, me ayudaron a avanzar incluso cuando el camino parecía incierto: gracias, de todo corazón.

Índice

Acta de Revisión de Tesis	i
Dedicatoria	ii
Agradecimientos	iii
Índice de Figuras	vii
Índice de Tablas	x
Índice de Listados	xi
Abreviaturas	xii
Resumen	xii
Abstract	xiii
1. Capítulo: Introducción	1
1.1. El Contexto del Mercado de Criptomonedas	1
1.2. Antecedentes: Aprendiendo del Pasado	2
1.3. Justificación: Relevancia de Esta Investigación	4
1.4. Planteamiento del Problema: El Desafío a Resolver	5
1.5. Objetivo: Lo Que se Busca Lograr	7
1.6. Hipótesis de Trabajo	8
1.7. Preguntas que Guían la Investigación	8
2. Capítulo: Marco Teórico	10
2.1. Métodos de Análisis en Criptomercados	10
2.1.1. Análisis Fundamental	10
2.1.2. Análisis Técnico	12

2.1.3. Métodos Tradicionales de Análisis Técnico	13
2.1.4. Indicadores de Tendencia	14
2.1.5. Indicadores de Soporte y Resistencia	19
2.1.6. Indicadores de Momento	21
2.1.7. Indicadores de Volatilidad	26
2.2. Procesamiento de Lenguaje Natural	30
2.2.1. Evolución del Procesamiento de Lenguaje Natural	30
2.2.2. Modelos Transformadores: Evolución y Aplicaciones	31
2.2.3. Modelo BERT: Arquitectura y Aplicaciones	38
2.2.4. FinBERT: Modelo Especializado para el Análisis de Sentimiento en Finanzas	41
2.2.5. LLaMA 3: Generación y Razonamiento	42
2.3. Modelos de Lenguaje para la Generación de Reportes Financieros	46
2.4. Limitaciones de los Modelos de Lenguaje: Alucinaciones y Confiabilidad . .	48
3. Capítulo: Metodología	50
3.1. Tipo de Investigación	50
3.2. Adquisición y Almacenamiento de Datos	51
3.2.1. Noticias Financieras	51
3.2.2. Resumen Automático y Evaluación de Relevancia	52
3.2.3. Datos de Mercado	54
3.3. Procesamiento de Datos	55
3.3.1. Estructura y Limpieza de la Base de Datos	56
3.3.2. Clasificación de Sentimiento	57
3.3.3. Evaluación de Reputación y Relevancia de Fuentes	57
3.3.4. Cálculo de Indicadores Técnicos	59
3.3.5. Integración de Datos	61
3.4. Generación Automática de Reportes	66
3.4.1. Arquitectura del Sistema	67
3.4.2. Contenido de los Reportes	70
3.5. Recursos Técnicos Utilizados	73
4. Capítulo: Resultados	75
4.1. Proceso de Optimización del Diseño de Instrucciones	75
4.1.1. Identificación de Errores de Interpretación Técnica	76
4.1.2. Optimización del Diseño de Instrucciones del <i>Prompt</i>	77
4.1.3. Precisión Técnica Exigida al Modelo	78

4.2. Resultados del Análisis Técnico	80
4.2.1. Caso de Análisis Técnico: Tendencia Alcista	81
4.2.2. Caso de Análisis Técnico: Tendencia Bajista	83
4.2.3. Caso de Análisis Técnico: Consolidación	85
4.2.4. Comparación de Escenarios Técnicos	87
4.3. Resultados del Análisis de Sentimiento	87
4.3.1. Caso de Análisis de Sentimiento: Consolidación Neutral	88
4.3.2. Caso de Análisis de Sentimiento: Mercado Moderadamente Optimista	90
4.3.3. Caso de Análisis de Sentimiento: Tendencia Positiva con Señales de Consolidación	91
4.3.4. Comparación de Escenarios de Sentimiento	92
4.4. Errores Residuales tras la Optimización	92
4.4.1. Ejemplo 1: Interpretación Incorrecta de Consolidación	93
4.4.2. Ejemplo 2: Contradicción entre <i>Momentum</i> y Tendencia	95
4.4.3. Ejemplo 3: Exageración de Incertidumbre y Volatilidad	96
5. Capítulo: Discusión	98
5.1. Evaluación de la Hipótesis	98
5.2. Respuesta a las Preguntas de Investigación	99
5.2.1. Precisión al Combinar NLP y Análisis Técnico	99
5.2.2. Modelos de NLP Más Efectivos	100
5.2.3. Integración de Sentimiento y Análisis Técnico	100
5.2.4. Integración de Datos Estructurados y No Estructurados	100
5.2.5. Impacto de LLaMA en la Precisión de los Reportes	101
5.3. Consideraciones sobre Errores Residuales	101
6. Capítulo: Conclusiones	102
Referencias	104

Índice de Figuras

1.1. Capitalización histórica del mercado. <i>Nota.</i> La figura representa la evolución histórica de la capitalización del mercado de criptomonedas. Datos obtenidos de CoinMarketCap.	2
1.2. Arquitectura del sistema: NLP, métricas y análisis con LLM. <i>Nota.</i> La figura muestra la estructura del sistema. Elaboración propia.	8
2.1. Tipos de tendencias en los mercados financieros. <i>Nota.</i> Representación conceptual de los tres tipos principales de tendencias en Análisis Técnico: alcista, bajista y lateral. Sin escalas ni unidades, ya que la figura es de carácter ilustrativo. Adaptado de Murphy (1999).	15
2.2. Media móvil exponencial. <i>Nota.</i> La figura muestra la EMA de 50 y 200 períodos junto con los cruces alcistas y bajistas. Elaboración propia.	16
2.3. Media móvil de convergencia/divergencia. <i>Nota.</i> La figura ilustra la línea MACD, la línea de señal y el histograma, con cruces alcistas y bajistas resaltados. Elaboración propia.	18
2.4. Niveles de Soporte y Resistencia. <i>Nota.</i> Ilustración de dos niveles en los que el precio ha tendido a detenerse o cambiar de dirección, la resistencia que limita los movimientos al alza, y el soporte que contiene las caídas. Elaboración propia.	21
2.5. Índice de fuerza relativa. <i>Nota.</i> La figura muestra el RSI de 14 períodos con los niveles de sobrecompra y sobreventa. Elaboración propia.	23
2.6. Índice de flujo de dinero. <i>Nota.</i> El gráfico muestra el comportamiento del MFI calculado con un período de 14 días, destacando las zonas de sobrecompra y sobreventa. Elaboración propia.	25
2.7. Rango promedio verdadero. <i>Nota.</i> El gráfico muestra la evolución del ATR en el mercado de criptomonedas, con líneas de referencia para alta y baja volatilidad. Elaboración propia.	27

2.8. Bandas de Bollinger. <i>Nota.</i> El gráfico muestra las Bandas de Bollinger con un período de 20 y una desviación estándar de 2. Se destacan las señales de sobrecompra y sobreventa cuando el precio alcanza las bandas superior e inferior, respectivamente. Elaboración propia.	29
2.9. Arquitectura del modelo transformador. <i>Nota.</i> La figura muestra la arquitectura general de un modelo transformador. Adaptado de Vaswani et al. (2017).	32
2.10. Analogía de vectores semánticos. <i>Nota.</i> La figura muestra la relación semántica entre las palabras <i>dog</i> , <i>puppy</i> , <i>cat</i> y <i>plane</i> , utilizando vectores obtenidos del modelo GloVe. Elaboración propia.	34
2.11. Mecanismo de atención. <i>Nota.</i> La figura muestra el producto punto entre <i>tokens</i> de la frase. Captura de pantalla del software de Cho et al. (2024).	35
2.12. Representación de <i>tokens</i> y codificación posicional. <i>Nota.</i> La figura ilustra el proceso de incorporación de información posicional mediante la combinación de los <i>embeddings</i> de <i>tokens</i> y la codificación posicional. Captura de pantalla del software de Cho et al. (2024)	36
2.13. Distribución de probabilidad de salida del transformador. <i>Nota.</i> La figura muestra las probabilidades generadas por la capa final del modelo para predecir el siguiente <i>token</i> . Captura de pantalla del software de Cho et al. (2024).	38
2.14. Arquitectura del modelo BERT. <i>Nota.</i> La figura muestra la arquitectura general de un modelo BERT. Elaboración propia.	39
2.15. Arquitectura del modelo LLaMA 3. <i>Nota.</i> La figura muestra la arquitectura general de un modelo <i>LLaMA 3</i> , elaborada por el autor con base en información disponible públicamente.	43
3.1. Embudo de filtrado de noticias del criptomercado. <i>Nota.</i> Elaboración propia.	52
3.2. Flujo de recopilación de noticias financieras. <i>Nota.</i> Elaboración propia.	53
3.3. Flujo de generación de resúmenes y validación temática con LLaMA. <i>Nota.</i> Elaboración propia.	54
3.4. Flujo de recopilación de datos estructurados. <i>Nota.</i> Elaboración propia.	55
3.5. Modelo entidad-relación de la base de datos utilizada. <i>Nota.</i> Elaboración propia.	56
3.6. Clasificación de sentimiento con FinBERT. <i>Nota.</i> Elaboración propia.	57
3.7. Flujo del cálculo de reputación y relevancia. <i>Nota.</i> Elaboración propia.	60
3.8. Flujo de cálculo de indicadores técnicos. <i>Nota.</i> Elaboración propia.	61

3.9. Flujo de integración de datos estructurados y no estructurados. <i>Nota.</i> Elaboración propia.	62
3.10. Interfaz gráfica para la generación automática de reportes. <i>Nota.</i> Se visualizan los datos estructurados y no estructurados, y se activa el modelo de lenguaje mediante el botón <i>Analyze</i> . Elaboración propia.	67
3.11. Arquitectura general del sistema propuesto. <i>Nota.</i> Elaboración propia. . . .	69
3.12. Ejemplo de reporte automático generado para el par BTC/USDT. <i>Nota.</i> Elaboración propia.	72
5.1. Indicador MACD y línea de señal en BTC/USDT durante enero de 2025. <i>Nota.</i> Se observa un cruce bajista del MACD por debajo de la línea de señal ocurrió entre el 27 y 28 de enero, lo que sugiere pérdida de <i>momentum</i> en una fase aún alcista ($EMA\ 50 > EMA\ 200$). Esta señal refuerza una lectura de cautela en el análisis integrado.	99

Índice de Tablas

4.1. <i>Errores comunes en la interpretación técnica del modelo</i>	76
4.2. <i>Resumen comparativo de condiciones de mercado en tres reportes generados por el sistema</i>	81
4.3. Valores de indicadores técnicos para BTC/USDT en tendencia alcista (29 de enero de 2025)	82
4.4. Valores de indicadores técnicos para BTC/USDT en tendencia bajista (21 de diciembre de 2022).	84
4.5. Valores de indicadores técnicos para BTC/USDT en condición de lateralidad (5 de abril de 2025)	85
4.6. Comparación de escenarios técnicos interpretados por el sistema	87
4.7. <i>Resumen de tendencias de sentimiento en diferentes escenarios de mercado</i> 88	
4.8. Evaluación de fuentes de noticias para el Análisis de Sentimiento (12 de enero de 2025)	89
4.9. Evaluación de fuentes de noticias para el Análisis de Sentimiento (29 de enero de 2025)	90
4.10. Evaluación de fuentes de noticias para el Análisis de Sentimiento (5 de abril de 2025)	91
4.11. Comparación de escenarios de sentimiento interpretados por el sistema . .	93
4.12. <i>Errores residuales detectados tras la optimización del sistema</i>	94
4.13. Valores de indicadores técnicos para BTC/USDT en tendencia alcista débil (7 de febrero de 2025)	94
4.14. Valores de indicadores técnicos para BTC/USDT en contradicción entre tendencia y <i>momentum</i> (11 de marzo de 2025)	96
4.15. Valores de indicadores técnicos para BTC/USDT en fase de consolidación con volatilidad moderada (16 de marzo de 2025)	97

Índice de Listados

3.1. Prompt utilizado para la generación de resúmenes automáticos con validación temática.	53
3.2. Fragmento del prompt: contexto del modelo.	63
3.3. Fragmento del prompt: descripción general del mercado.	63
3.4. Fragmento del prompt: entrada estructurada para Análisis Técnico.	64
3.5. Fragmento del prompt: reglas de interpretación técnica.	65
3.6. Fragmento del <i>prompt</i> : entrada no estructurada.	66
3.7. Fragmento del <i>prompt</i> : formato resumido para la respuesta generada. . . .	66

Resumen

En los mercados financieros, la toma de decisiones depende de interpretar grandes volúmenes de datos en periodos breves y bajo incertidumbre. Similar a cómo los hablantes comprenden y generan enunciados sin conocer todas las combinaciones posibles, los inversionistas analizan datos limitados y desarrollan estrategias sin certeza del comportamiento futuro. En ambos casos, el contexto y la identificación de patrones son claves para generar predicciones.

Esta investigación presenta un sistema automatizado de adquisición y análisis dinámico de datos para apoyar la toma de decisiones en criptomercados. El prototipo combina principios del análisis técnico, que sostiene que el mercado descuenta toda la información y sigue tendencias, con técnicas de procesamiento de lenguaje natural. Recopila datos de precios de criptomonedas, indicadores técnicos y noticias financieras; aplica Análisis de Sentimiento mediante un modelo especializado en lenguaje financiero y utiliza un modelo avanzado de generación de texto para producir reportes automatizados que integran datos estructurados y no estructurados.

Los resultados obtenidos muestran que el sistema puede integrar datos heterogéneos y generar interpretaciones automatizadas que reflejan tendencias generales del mercado. Si bien los reportes producidos ofrecen información útil para inversionistas de distintos niveles de experiencia, también se identificaron limitaciones relacionadas con la precisión interpretativa y la dependencia de la calidad de las fuentes de datos. Estos hallazgos resaltan el potencial de combinar técnicas de Procesamiento de Lenguaje Natural y Análisis Técnico, al tiempo que señalan áreas de mejora para futuros desarrollos en entornos financieros altamente volátiles.

Palabras Clave: *Mercados de criptomonedas, análisis técnico, análisis de sentimiento, procesamiento de lenguaje natural, reportes automatizados*

Abstract

In financial markets, decision-making depends on the ability to interpret large volumes of data within short timeframes and under conditions of uncertainty. Similar to how language users can understand and generate utterances without having heard all possible combinations, investors analyze limited data and develop strategies without certainty about future market behavior. In both cases, context and pattern identification play a crucial role in generating predictions.

This research presents an automated system for the dynamic acquisition and analysis of data to support decision-making in cryptocurrency markets. The prototype combines principles of technical analysis, which assumes that the market reflects all available information and tends to follow trends, with natural language processing techniques. It collects cryptocurrency price data, technical indicators, and financial news, applies Sentiment Analysis using a model specialized in financial language, and employs an advanced text generation model to produce automated reports that integrate both structured and unstructured data.

The results show that the system can integrate heterogeneous data and generate automated interpretations that reflect general market trends. While the produced reports offer useful information for investors with varying levels of experience, limitations were identified regarding interpretative precision and dependence on data source quality. These findings highlight the potential of combining Natural Language Processing and technical analysis techniques while also pointing to areas for improvement in future developments within highly volatile financial environments.

Keywords: Cryptocurrency markets, technical analysis, sentiment analysis, natural language processing, automated reporting

1. Capítulo: Introducción

El estudio de los mercados financieros ha evolucionado con el uso de nuevas tecnologías. En el caso del mercado de criptomonedas, su rápida expansión y alta volatilidad hacen necesaria la implementación de herramientas, como el Procesamiento de Lenguaje Natural (NLP, por sus siglas en inglés). Sin embargo, estas tecnologías deben complementar el análisis de indicadores técnicos, estableciendo así las bases para la presente investigación.

1.1. El Contexto del Mercado de Criptomonedas

El mercado de criptomonedas ha experimentado un crecimiento exponencial en los últimos años, caracterizado por su alta volatilidad y la influencia de factores como noticias, redes sociales, indicadores de negociación (*trading*, término en inglés) y eventos globales. Desde la creación de Bitcoin en 2009 (Nakamoto, 2008), las criptomonedas han pasado de ser un concepto innovador a establecerse como un mercado global, cuya capitalización ha crecido sostenidamente, como se muestra en la Fig. 1.1. Su naturaleza descentralizada y altamente interconectada permite que responda con rapidez a eventos y noticias a nivel mundial.

Es importante diferenciar entre criptomonedas y criptoactivos:

- Las criptomonedas son un tipo de activo digital que permite realizar transacciones *peer-to-peer* sin la necesidad de intermediarios, mediante el uso de tecnologías de cadena de bloques. Ejemplos destacados incluyen Bitcoin y Ethereum, que lideran el mercado en términos de adopción y capitalización (Nakamoto, 2008).
- Los criptoactivos, en cambio, abarcan un conjunto más amplio de activos digitales basados en tecnología Blockchain, incluye criptomonedas, *stablecoins*, *tokens* no fungibles y otros instrumentos digitales con diversas funcionalidades (Flores, 2023).

Aunque esta investigación se centra en el análisis de criptomonedas, el término *criptoactivos* se empleará cuando sea necesario para describir aspectos más amplios del ecosistema financiero digital.

Asimismo, este estudio se enfocará en noticias publicadas en inglés y datos provenientes de Estados Unidos, dada la relevancia de este mercado como fuente de eventos, regulaciones y tendencias económicas que impactan el ecosistema global de criptomonedas.




Figura 1.1: Capitalización histórica del mercado. *Nota.* La figura representa la evolución histórica de la capitalización del mercado de criptomonedas. Datos obtenidos de CoinMarketCap.

1.2. Antecedentes: Aprendiendo del Pasado

El mercado de criptomonedas ha evolucionado en los últimos años, influenciado por eventos que han moldeado su desarrollo y percepción entre los inversionistas. Estos acontecimientos han evidenciado su alta volatilidad y la necesidad de herramientas avanzadas para su análisis. Comprender estos antecedentes es fundamental para contextualizar la importancia de mejorar las metodologías de evaluación del mercado mediante nuevas tecnologías como el Procesamiento de Lenguaje Natural.

Uno de los eventos más relevantes en la historia reciente de las criptomonedas fue el Cripto invierno de 2022, un periodo marcado por la fuerte caída en los precios de los principales cryptoactivos, como Bitcoin y Ethereum. Este desplome estuvo impulsado por factores macroeconómicos y específicos del mercado, entre ellos, el aumento de tasas de interés por parte de los bancos centrales, así como el colapso de Terra, una plataforma blockchain orientada a stablecoins algorítmicas cuyo fracaso provocó una pérdida de millones de dólares en capitalización de mercado, y la quiebra de la plataforma de intercambio Futures Exchange (FTX, por sus siglas en inglés) (J. Liu et al., 2023). Estos

eventos no solo evidenciaron la fragilidad del mercado, sino que también resaltaron la necesidad de enfoques más sofisticados para comprender y anticipar su comportamiento.

Además, investigaciones recientes han planteado enfoques basados en aprendizaje profundo para enfrentar la complejidad del mercado de criptomonedas. Por ejemplo, Kumlungmak y Vateekul (2023) proponen un sistema multiagente de aprendizaje por refuerzo profundo, que incorpora penalizaciones progresivas ante pérdidas sostenidas y optimización conjunta de recompensas. Su trabajo evidencia que, incluso con modelos avanzados, es necesario diseñar mecanismos que consideren el entorno volátil y multifactorial de las criptomonedas, lo que refuerza la necesidad de estrategias que integren diferentes fuentes de información estructurada y no estructurada.

Históricamente, el Análisis Técnico ha sido una herramienta fundamental para interpretar las dinámicas de precios en los mercados financieros, incluidas las criptomonedas. Indicadores como el Índice de Fuerza Relativa (RSI, por sus siglas en inglés) y la Convergencia/Divergencia de Medias Móviles (MACD, por sus siglas en inglés) se utilizan ampliamente para identificar tendencias y puntos de entrada o salida en el mercado. En el contexto de los criptomercados, estos indicadores han demostrado una correlación positiva, moderada a fuerte, con el desempeño de estrategias de *trading*, lo que refuerza su utilidad en la toma de decisiones (Tahmasbi, 2024). No obstante, la elevada volatilidad y la influencia de factores externos, como regulaciones y manipulación del mercado, pueden limitar la efectividad de estas metodologías tradicionales. Esto subraya la necesidad de complementarlas con enfoques que permitan capturar el impacto de la información no estructurada en la evolución del mercado.

En este contexto, el Análisis de Sentimientos ha surgido como una técnica complementaria para evaluar cómo las percepciones del mercado influyen en los precios de las criptomonedas. Dado que muchos de estos factores se reflejan en textos escritos, el Análisis de Sentimientos ha demostrado ser una herramienta eficaz en los mercados financieros, al capturar la relación entre emociones, noticias y fluctuaciones de precios (Du et al., 2024). Este enfoque examina datos textuales, como titulares y resúmenes de noticias, para identificar patrones emocionales y tendencias que reflejan el estado de ánimo del mercado.

Para aplicar este enfoque, se han desarrollado herramientas especializadas en el Análisis de Sentimiento financiero. Un ejemplo destacado es FinBERT (Araci, 2019), un modelo basado en arquitectura de la Representación de Codificador Bidireccional de Transformadores (BERT, por sus siglas en inglés), entrenado específicamente con textos financieros. Su capacidad para clasificar publicaciones en categorías positivas, negativas o neutrales ha mejorado la precisión del análisis del sentimiento en el ámbito financiero. Esta

tecnología proporciona una interpretación más detallada de las percepciones y emociones reflejadas en los textos financieros, contribuyendo a evaluar factores que pueden influir en la toma de decisiones estratégicas.

Estudios recientes han aplicado el Análisis de Sentimientos en criptomercados para comprender mejor los movimientos de precios. Por ejemplo, Anand y Arya (2024) analizaron la relación entre narrativas en redes sociales y las fluctuaciones en el precio de Bitcoin, encontrando una correlación significativa. De manera similar, investigaciones han demostrado que los datos de la red social X (anteriormente Twitter) pueden influir en la percepción del mercado y afectar directamente los precios de las criptomonedas. Un estudio sobre el Análisis de Sentimientos en *NEO* encontró correlaciones positivas entre el volumen de *tuits* y las variaciones diarias de precio, lo que refuerza la hipótesis de que el sentimiento en redes sociales puede servir como un indicador de mercado (Sasmaz & Tek, 2021).

Estos hallazgos sugieren que la integración del Análisis de Sentimientos con modelos de lenguaje avanzados, como LLaMA, puede proporcionar información valiosa sobre la dirección del mercado. La combinación de estas técnicas con el Análisis Técnico permitiría una comprensión más profunda del comportamiento de los criptomercados, ofreciendo herramientas más robustas para la toma de decisiones en un entorno altamente incierto y dinámico.

1.3. Justificación: Relevancia de Esta Investigación

El mercado de criptomonedas genera una gran cantidad de información relevante para comprender y anticipar sus dinámicas. Desde datos técnicos, como las series de precios *Open, High, Low, Close, Volume* (OHLCV, por sus siglas en inglés), hasta titulares de noticias y publicaciones en redes sociales, estas fuentes contienen información valiosa para interpretar tendencias y tomar decisiones estratégicas. Sin embargo, el volumen, la velocidad y la diversidad de estos datos hacen que procesarlos manualmente sea una tarea compleja y demandante en términos de tiempo. Esto limita la capacidad de los analistas para evaluar la información de manera eficiente, dificultando la identificación oportuna de oportunidades y la reacción ante fluctuaciones del mercado.

Ante este desafío, esta investigación propone la integración de técnicas de NLP y Análisis Técnico con el objetivo de analizar tendencias del mercado y generar información útil. Al combinar datos textuales no estructurados, como noticias y publicaciones especializadas, con datos financieros estructurados e indicadores técnicos, se busca desarrollar un prototipo capaz de integrar modelos avanzados como LLaMA, junto con técnicas de

Análisis Técnico, para interpretar las dinámicas complejas de los mercados volátiles de criptomonedas.

Como señalan Otabek y Choi (2024), comprender el comportamiento del mercado de criptomonedas es especialmente desafiante debido a su alta volatilidad y a la influencia de múltiples factores externos e internos. Si bien gran parte de los esfuerzos se han centrado en mejorar la predicción de precios, estos desafíos también impactan el análisis de tendencias y la toma de decisiones informadas, especialmente en entornos donde confluyen datos técnicos y noticias no estructuradas.

Los resultados de esta investigación tienen el potencial de beneficiar a diversos actores. Por un lado, las empresas de tecnologías financieras (*fintech*, término en inglés) podrían utilizar este sistema para desarrollar herramientas innovadoras, como plataformas de monitoreo automatizado, Análisis de Sentimientos y sistemas de alerta basados en eventos del mercado. Estas herramientas proporcionan a sus clientes información más precisa y oportuna, facilitando una toma de decisiones mejor fundamentada. Por otro lado, investigadores especializados en NLP encontrarán en este enfoque una oportunidad para explorar aplicaciones prácticas que integren datos heterogéneos, abordando de manera efectiva la complejidad y las dinámicas cambiantes del mercado de criptomonedas.

Por lo tanto, esta investigación busca evaluar cómo la combinación de Procesamiento de Lenguaje Natural y Análisis Técnico puede mejorar la precisión en la predicción de tendencias y la interpretación del sentimiento del mercado en criptomonedas, optimizando así la toma de decisiones en entornos altamente volátiles.

1.4. Planteamiento del Problema: El Desafío a Resolver

El mercado de criptomonedas enfrenta una creciente complejidad debido a su naturaleza volátil, la diversidad de fuentes de información y la rapidez con la que los eventos externos pueden influir en su comportamiento. Aunque existen herramientas capaces de analizar datos financieros estructurados o realizar Análisis de Sentimientos en textos, la integración efectiva de ambos tipos de datos sigue siendo un desafío importante. Esta integración es fundamental para capturar dinámicas más completas y generar información útil que apoye decisiones estratégicas.

El principal reto radica en automatizar el procesamiento de datos textuales no estructurados, como titulares de noticias y su contenido, y combinarlos con datos financieros estructurados e indicadores técnicos, como el RSI y el MACD. Actualmente, este proceso suele ser manual y requiere una cantidad considerable de tiempo, lo que limita la capacidad de reaccionar rápidamente ante eventos del mercado y de anticipar tendencias de

manera efectiva.

En este contexto, se ha seleccionado LLaMA (Meta AI, 2024) debido a sus ventajas en accesibilidad, capacidad de resumen automático de información y razonamiento contextual. A diferencia de otros modelos de lenguaje, LLaMA es *open-source*, lo que proporciona una mayor flexibilidad para su personalización y optimización en tareas específicas del análisis de criptomercados. En comparación con GPT-4, que, si bien posee una alta capacidad de generación de texto y comprensión contextual, presenta restricciones de acceso, limitaciones en la adaptación a tareas específicas y costos asociados a su uso, LLaMA ofrece una alternativa más adaptable y accesible para esta investigación. Por otro lado, aunque FinBERT ha sido diseñado específicamente para el análisis financiero y el procesamiento de sentimiento en textos económicos, su funcionalidad se limita a la clasificación de textos, sin capacidad para generar contenido ni realizar síntesis avanzada, lo que restringe su aplicabilidad en la integración de Análisis Técnico y de sentimiento en los criptomercados. En esta investigación, salvo que se indique expresamente lo contrario, toda mención al modelo LLaMA corresponde a su versión 3.1.

El papel de LLaMA en esta investigación será clave en dos instancias: primero, al generar resúmenes automatizados de noticias y publicaciones relevantes, permitiendo un análisis más eficiente de grandes volúmenes de información textual sin necesidad de intervención manual. Segundo, al aplicar razonamiento contextual para integrar datos cuantitativos provenientes del Análisis Técnico con información cualitativa derivada del Análisis de Sentimiento, facilitando la creación de reportes dinámicos más completos y contextualizados. Este enfoque permitirá evaluar en qué medida la integración de NLP con indicadores técnicos contribuye a una mejor interpretación del sentimiento del mercado y la identificación de tendencias, ofreciendo así un marco más sólido para el análisis del comportamiento del mercado.

Esta combinación permitirá mejorar la interpretación del sentimiento del mercado, reducir el ruido informativo y complementar el Análisis Técnico con una perspectiva más holística, optimizando así la toma de decisiones en entornos altamente volátiles como el de las criptomonedas.

Actualmente, los analistas de criptomercados carecen de herramientas que integren Modelos Extensos de Lenguaje (LLM, por sus siglas en inglés) como LLaMA con técnicas avanzadas de Procesamiento de Lenguaje Natural, incluyendo Análisis de Sentimiento con FinBERT, resumen automático y fusión de datos estructurados y no estructurados, para generar reportes comprensibles que apoyen la toma de decisiones. Esta investigación aborda esta necesidad mediante el desarrollo de un prototipo de sistema que demuestre la viabilidad y el valor de esta integración.

1.5. Objetivo: Lo Que se Busca Lograr

En este contexto, la presente investigación tiene como objetivo diseñar, implementar y evaluar un sistema automatizado basado en técnicas de Procesamiento de Lenguaje Natural y Análisis Técnico, capaz de identificar tendencias del mercado, generar interpretaciones automatizadas y aportar información útil para la toma de decisiones de inversión en criptomercados. Este sistema integrará datos textuales no estructurados, como noticias, con datos financieros estructurados e indicadores técnicos, utilizando un Modelo Extenso de Lenguaje y será validado mediante análisis de desempeño, identificación de limitaciones y evaluación de su capacidad interpretativa.

Para alcanzar este objetivo general, se han definido los siguientes objetivos específicos, que guían la implementación y validación del sistema propuesto:

- Resumir información utilizando el modelo LLaMA, generando resúmenes automatizados de datos textuales relevantes para reducir la carga informativa y facilitar el análisis.
- Analizar datos textuales, como noticias financieras, utilizando el modelo FinBERT para clasificar el sentimiento en positivo, negativo o neutral, y capturar percepciones relevantes en los mercados.
- Integrar datos estructurados, incluyendo precios e indicadores técnicos, y datos no estructurados, como noticias y Análisis de Sentimiento, diseñando un sistema de representación coherente que permita un análisis integral del mercado.
- Sintetizar la información integrada utilizando LLaMA, generando reportes dinámicos que presenten interpretaciones automatizadas y detecten tendencias clave del mercado.
- Desarrollar una interfaz de usuario que permita visualizar los reportes generados, facilitando la interpretación de resultados por parte del usuario final.
- Validar el sistema mediante pruebas empíricas, utilizando casos representativos y diseños experimentales alineados con los objetivos del proyecto, e incluyendo:
 - Realización de experimentos con datos reales del mercado de criptomonedas.
 - Evaluación de la capacidad interpretativa y de la utilidad práctica de los resultados generados.

- Análisis del desempeño del sistema en escenarios relevantes, identificando aciertos, limitaciones y posibles mejoras.

Finalmente, se busca no solo implementar el sistema, sino también evaluar su desempeño de forma crítica, identificando tanto sus capacidades como sus limitaciones en el contexto de uso real.

Para ilustrar la integración de estos componentes y su flujo dentro del sistema propuesto, la Fig. 1.2 presenta la arquitectura del sistema, donde se visualizan los módulos principales, incluyendo el procesamiento de datos con NLP, la generación de métricas y el uso de modelos LLM para la interpretación de información.




Figura 1.2: Arquitectura del sistema: NLP, métricas y análisis con LLM. *Nota.* La figura muestra la estructura del sistema. Elaboración propia.

1.6. Hipótesis de Trabajo

Con base en los objetivos planteados, se establece la siguiente hipótesis: El uso combinado de técnicas de Procesamiento de Lenguaje Natural y Análisis Técnico, mediante modelos avanzados de lenguaje como LLaMA y herramientas de análisis de mercado, mejorará de manera consistente la precisión en la predicción de tendencias, la utilidad de los reportes analíticos y la capacidad para interpretar el impacto del sentimiento del mercado en los criptomercados, en comparación con los métodos tradicionales basados únicamente en Análisis Técnico.

1.7. Preguntas que Guían la Investigación

- Pregunta principal:

- ¿En qué medida la combinación de Procesamiento de Lenguaje Natural y Análisis Técnico mejora la precisión en la predicción de tendencias y la interpretación del sentimiento del mercado en criptomonedas?

■ Preguntas específicas:

- ¿Qué técnicas y modelos de NLP son más efectivos para analizar datos textuales en criptomercados y mejorar la identificación de tendencias?
- ¿Cómo puede la integración del Análisis de Sentimiento con indicadores técnicos como RSI y MACD mejorar la predicción de tendencias en criptomercados?
- ¿Cómo pueden integrarse datos estructurados, como los indicadores técnicos, y datos no estructurados, como las noticias y el Análisis de Sentimiento, para generar reportes dinámicos y efectivos en el análisis de criptomercados?
- ¿En qué medida el uso de NLP y modelos de lenguaje como LLaMA mejora la precisión de los reportes analíticos en criptomercados?

2. Capítulo: Marco Teórico

Este capítulo tiene como objetivo establecer los fundamentos conceptuales y teóricos que sustentan esta investigación.

Es importante señalar que el término *token* se empleará en dos contextos diferentes a lo largo de este capítulo. En el ámbito de las criptomonedas, un *token* representa un activo digital basado en tecnología Blockchain. En el Procesamiento de Lenguaje Natural, un *token* se refiere a una unidad mínima de texto, como una palabra o subpalabra, utilizada en el análisis de datos lingüísticos. Esta diferenciación será mantenida a lo largo del documento para evitar confusiones.

2.1. Métodos de Análisis en Criptomercados

El mercado de criptomonedas presenta una dinámica única, caracterizada por alta volatilidad, descentralización y factores de adopción específicos. Para comprender y evaluar estos activos, se emplean diversos enfoques de análisis que permiten interpretar su comportamiento y determinar su valor de manera más precisa.

2.1.1. Análisis Fundamental

El análisis fundamental en los criptomercados busca evaluar el valor intrínseco de un activo digital mediante el estudio de sus fundamentos económicos, tecnológicos y de adopción. El valor intrínseco es un indicador del valor de un activo basado en la ley de oferta y demanda (Murphy, 1999).

Uno de los aspectos clave de este análisis es el concepto de *Tokenomics*, que define la estructura económica de un *token*, incluyendo su oferta total, los mecanismos de emisión, la distribución y la demanda dentro de su ecosistema (Rees-Evans, 2024).

A diferencia de los mercados financieros tradicionales, donde se emplean métricas como la razón precio-beneficio (P/E, por sus siglas en inglés), que mide la relación entre el precio de una acción y sus ganancias por acción (*earnings per share*, término en inglés), en las criptomonedas la valoración depende en gran medida de la economía del *token* y

su utilidad dentro del ecosistema.

Los proyectos basados en Blockchain diseñan sus modelos de *tokenomics* para incentivar la participación y garantizar la estabilidad del activo. Estos modelos pueden incluir una oferta fija, como es el caso de Bitcoin, que cuenta con un suministro máximo de 21 millones de BTC (Nakamoto, 2008), o a través de mecanismos deflacionarios, como la quema de tokens (*token burning*, término en inglés), que busca reducir la circulación de activos con el fin de controlar la inflación y aumentar su escasez. Además, métricas como la capitalización de mercado, la oferta circulante, el volumen de *trading* y la gobernanza del *token* juegan un papel fundamental en la evaluación de su potencial de crecimiento (Cong et al., 2020).

Otro elemento fundamental en la evaluación de criptomonedas es la psicología del mercado y la percepción del inversor. Según Rees-Evans (2024), la confianza de la comunidad y el grado de adopción son factores determinantes en la viabilidad y sostenibilidad de un proyecto basado en Blockchain. A diferencia de los mercados tradicionales, donde los activos están respaldados por estructuras empresariales y métricas financieras predecibles, en los criptoactivos los movimientos de precios pueden verse influenciados por factores como tendencias en redes sociales, cambios regulatorios y la percepción del ecosistema en general (Billade et al., 2024).

Además, el análisis fundamental en criptomonedas considera aspectos cualitativos como la revisión del libro blanco (*whitepaper*, término en inglés), que detalla la propuesta técnica y económica del proyecto, y la evaluación del equipo de desarrollo, incluyendo su experiencia y credibilidad en el sector. También es relevante examinar la hoja de ruta (*roadmap*, término en inglés), la cual proporciona información sobre la evolución del proyecto.

Sin embargo, es importante aclarar que, debido a que esta metodología requiere un análisis exhaustivo y, a su vez, la limitada disponibilidad de datos, el análisis fundamental no será utilizado en esta investigación. Su mención se realiza únicamente con fines ilustrativos, para ejemplificar los enfoques existentes en la evaluación de criptomonedas.

En contraste con el análisis fundamental, que se basa en evaluar los aspectos económicos y tecnológicos de un activo, el Análisis Técnico se enfoca en la acción del precio y en patrones históricos de mercado. En el contexto de criptomonedas, donde los fundamentos son complejos de cuantificar y los datos escasean, resulta razonable aplicar enfoques más adaptados a señales de mercado observables (Kensuke, 2024).

2.1.2. *Análisis Técnico*

El Análisis Técnico es una metodología ampliamente utilizada en los mercados financieros para analizar datos históricos con el fin de identificar patrones y tendencias que puedan ayudar a predecir movimientos futuros de los precios. Su fundamento radica en la idea de que la acción del precio refleja toda la información relevante del mercado, por lo que su estudio permite evaluar el comportamiento de los activos financieros (Kirkpatrick & Dahlquist, 2010; Murphy, 1999).

Este enfoque tiene sus bases en la Teoría de Dow, formulada a partir de los escritos de Charles Dow y posteriormente refinada por analistas como William Peter Hamilton y Robert Rhea. Según esta teoría, el mercado sigue tres tipos de tendencias: primaria, secundaria y menor, y cada una de ellas se desarrolla en diferentes escalas de tiempo (Hamilton, 1922; Rhea, 1932).

Además, establece que una tendencia sigue vigente hasta que haya evidencia clara de su reversión, lo que suele confirmarse a través del análisis del precio y del volumen de negociación (Kirkpatrick & Dahlquist, 2010). Aunque la Teoría de Dow ha sido objeto de críticas debido a su carácter retrospectivo en la identificación de cambios de tendencia (Murphy, 1999), sigue siendo un pilar del Análisis Técnico moderno y su aplicación es especialmente relevante en mercados altamente volátiles, como el de criptomonedas.

El Análisis Técnico se basa en tres premisas fundamentales:

- El mercado descuenta todo: El precio de un activo refleja toda la información disponible, incluyendo factores económicos, políticos y psicológicos.
- Los precios siguen tendencias: Los movimientos de precio no son aleatorios, sino que tienden a seguir patrones identificables en distintas escalas temporales.
- La historia tiende a repetirse: Los patrones gráficos y las tendencias de los precios responden a ciclos recurrentes influenciados por la psicología de los inversores.

A partir de estos principios, se han desarrollado herramientas técnicas para analizar los mercados financieros. Estas herramientas incluyen indicadores de tendencia, volatilidad, soporte y resistencia, y momento del mercado, que permiten a los analistas evaluar la dinámica del mercado y tomar decisiones de inversión informadas (Kirkpatrick & Dahlquist, 2010; Murphy, 1999).

Su aplicabilidad ha trascendido los mercados tradicionales, como el de acciones y divisas (*Forex*, término en inglés), extendiéndose a materias primas (*commodities*, término en inglés) y, más recientemente, a los criptomercados. En estos entornos, herramientas

como los indicadores técnicos y los patrones gráficos han demostrado ser útiles para identificar oportunidades de inversión (Murphy, 1999). Sin embargo, los criptomercados presentan características únicas, como alta volatilidad, menor eficiencia de mercado y operación continua las 24 horas del día, los 7 días de la semana, lo que puede afectar la efectividad de algunos indicadores técnicos diseñados originalmente para mercados tradicionales.

En el caso particular de los criptomercados, los analistas técnicos emplean diversas herramientas para evaluar la dirección de los precios y detectar señales de compra o venta. Algunos de los indicadores más utilizados incluyen:

- Medias móviles: Suavizan fluctuaciones de precios y ayudan a identificar la dirección de la tendencia.
- Índice de Fuerza Relativa: Evalúa la velocidad y magnitud de los cambios en los precios para detectar niveles de sobrecompra o sobreventa.
- Bandas de Bollinger: Determinan niveles de volatilidad y posibles rupturas de precio.
- Media Móvil de Convergencia/Divergencia: Ayuda a identificar cambios en la fuerza, dirección y duración de una tendencia.

Dado que los mercados de criptomonedas operan sin interrupciones y presentan una alta volatilidad, el Análisis Técnico se ha convertido en una herramienta clave para los corredores de bolsa (*traders*, término en inglés) que buscan identificar oportunidades en períodos de tiempo reducidos (Fang et al., 2024). Sin embargo, al basarse en datos históricos, su efectividad puede estar limitada en entornos altamente especulativos, por lo que su aplicación debe complementarse con un análisis adecuado de gestión de riesgos y, en algunos casos, con enfoques adicionales como el Análisis de Sentimiento del mercado y el uso de algoritmos de aprendizaje máquina (ML, por sus siglas en inglés).

2.1.3. *Métodos Tradicionales de Análisis Técnico*

El Análisis Técnico tradicional en criptomercados se basa en la identificación de patrones en los datos históricos de precios y volumen, sin considerar información cualitativa derivada de fuentes externas. Los inversionistas utilizan indicadores como medias móviles, MACD, RSI y bandas de Bollinger para tomar decisiones de compra o venta, fundamentadas en reglas heurísticas y en la observación de tendencias pasadas (Kirkpatrick & Dahlquist, 2010; Murphy, 1999).

Estos métodos han demostrado utilidad en la identificación de movimientos de mercado, pero presentan limitaciones en entornos altamente especulativos y volátiles como el de las criptomonedas, donde los precios pueden estar influenciados por factores externos, como noticias, regulación y sentimiento del mercado. A diferencia de enfoques más avanzados que incorporan Procesamiento de Lenguaje Natural para interpretar el impacto del sentimiento de los inversores, el Análisis Técnico tradicional no tiene en cuenta estos elementos y se basa exclusivamente en el estudio de datos cuantitativos históricos.

En esta investigación, se evaluará cómo la integración de modelos avanzados de lenguaje con Análisis Técnico puede mejorar la capacidad de interpretación del mercado en comparación con estos métodos tradicionales.

2.1.4. Indicadores de Tendencia

En el Análisis Técnico, la tendencia describe la dirección predominante en la que se mueve el precio de un activo financiero durante un período determinado. Sin embargo, los mercados rara vez siguen un trayecto lineal ascendente o descendente. En su lugar, los precios presentan movimientos en zigzag, formando una serie de máximos y mínimos sucesivos. La estructura de estos puntos determina la tendencia predominante en un marco temporal específico.

Cuando los máximos y mínimos son crecientes, la tendencia se considera alcista (*bullish*, término en inglés). Por el contrario, si los máximos y mínimos son decrecientes, la tendencia es bajista (*bearish*, término en inglés). Finalmente, cuando no existe una dirección clara y los precios fluctúan dentro de un rango definido, se habla de una tendencia lateral (*sideways market*, términos en inglés), que suele indicar un período de consolidación antes de una posible ruptura al alza o a la baja, como se muestra en la Fig. 2.1

Las tendencias en los mercados financieros pueden clasificarse en tres categorías principales: alcista, bajista y lateral (Murphy, 1999). Cada una de estas tendencias se asocia con diferentes condiciones de mercado y factores que impulsan los movimientos de los precios:

- Tendencia alcista: Se caracteriza por una secuencia de máximos y mínimos cada vez más altos. Suele estar impulsada por un aumento en la demanda, expectativas optimistas y una mayor participación de inversionistas compradores. Además, el volumen de negociación tiende a incrementarse durante los movimientos ascendentes, lo que confirma la solidez de la tendencia (Kirkpatrick & Dahlquist, 2010).
- Tendencia bajista: Se define por máximos y mínimos decrecientes, reflejando una mayor presión vendedora. Los inversionistas muestran incertidumbre o pesimismo,




Figura 2.1: Tipos de tendencias en los mercados financieros. *Nota.* Representación conceptual de los tres tipos principales de tendencias en Análisis Técnico: alcista, bajista y lateral. Sin escalas ni unidades, ya que la figura es de carácter ilustrativo. Adaptado de Murphy (1999).

lo que genera ventas masivas y provoca caídas en los precios. Durante estas fases, el volumen de negociación tiende a aumentar en los descensos, lo que refuerza la fuerza de la tendencia bajista (Murphy, 1999).

- Tendencia lateral: Ocurre cuando los precios oscilan dentro de un rango sin una dirección clara. Este comportamiento indica una fase de consolidación, en la que los participantes del mercado están evaluando la próxima dirección del activo. Una ruptura fuera del rango de consolidación puede dar lugar al inicio de una nueva tendencia (Kirkpatrick & Dahlquist, 2010).

La correcta identificación de las tendencias del mercado es fundamental para la toma de decisiones en los mercados financieros. Para ello, se emplean herramientas cuantitativas denominadas indicadores de tendencia, los cuales permiten evaluar la dirección predominante del mercado y determinar posibles puntos de entrada y salida en operaciones financieras. Estos indicadores se basan en cálculos matemáticos aplicados sobre los precios históricos de un activo y son ampliamente utilizados para complementar otros enfoques de análisis, proporcionando información estructurada que puede ser útil en mercados con alta volatilidad (Murphy, 1999).

Media Móvil Exponencial

Entre los indicadores de tendencia más relevantes se encuentra la Media Móvil Exponencial (EMA, por sus siglas en inglés), la cual suaviza las fluctuaciones de precios al calcular el promedio ponderado de los valores pasados, asignando mayor peso a los

datos más recientes (Kirkpatrick & Dahlquist, 2010). Su cálculo se expresa mediante la ecuación:

$$EMA_t = \alpha \cdot P_t + (1 - \alpha) \cdot EMA_{t-1} \quad (2.1)$$

donde EMA_t es el valor de la EMA en el tiempo t y P_t representa el precio actual, α es el coeficiente de suavizado ($\alpha = \frac{2}{N+1}$), y N es el número de períodos considerados en el cálculo. Las EMA con diferentes períodos, como la EMA de 50 y 200, se utilizan para identificar tendencias a corto y largo plazo. Un cruce alcista ocurre cuando la EMA de corto plazo supera a la EMA de largo plazo, mientras que un cruce bajista sucede cuando ocurre lo contrario (Murphy, 1999).




Figura 2.2: Media móvil exponencial. *Nota.* La figura muestra la EMA de 50 y 200 períodos junto con los cruces alcistas y bajistas. Elaboración propia.

La Fig. 2.2 ilustra la interacción entre la EMA de 50 y 200 períodos, resaltando los momentos en los que se producen cruces alcistas y bajistas.

Una forma intuitiva de entender el comportamiento de la EMA es compararla con un avión en vuelo: la EMA de corto plazo reacciona rápidamente a las turbulencias o los cambios en el precio, mientras que la EMA de largo plazo representa el trayecto general del avión, reflejando la tendencia principal del mercado. Cuando la EMA de corto plazo cruza por encima de la de largo plazo, es como si el avión estuviera ganando altitud con condiciones favorables o en tendencia alcista. Por el contrario, un cruce bajista sugiere que el avión podría estar perdiendo sustentación y enfrentando mayor resistencia en su trayectoria o una tendencia bajista.

Estudios recientes han demostrado que la Media Móvil Exponencial puede ser una

herramienta efectiva para representar dinámicas del mercado, y su incorporación como variable en modelos de análisis, incluyendo redes neuronales profundas como LSTM, ha mejorado la capacidad de estos modelos para capturar patrones relevantes en los precios bursátiles (Dhokane & Agarwal, 2024).

Media Móvil de Convergencia/Divergencia

Otro indicador ampliamente utilizado es el MACD o Media Móvil de Convergencia/Divergencia, el cual combina dos medias móviles para evaluar la fuerza y dirección de la tendencia. Se calcula como la diferencia entre una EMA rápida generalmente de 12 períodos y una EMA lenta de 26 períodos:

$$MACD_t = EMA_{12} - EMA_{26} \quad (2.2)$$

Además, se incorpora una línea de señal, que es el promedio móvil exponencial del MACD:

$$Señal_t = EMA_9(MACD) \quad (2.3)$$

El histograma del MACD, que representa la diferencia entre el MACD y su línea de señal, se expresa como:

$$Histograma_t = MACD_t - Señal_t \quad (2.4)$$

El MACD es útil en mercados con tendencia, ya que permite identificar la relación entre el promedio de precios recientes y los movimientos históricos del activo. Cuando el MACD está por encima de cero, indica que la EMA de 12 períodos está por encima de la EMA de 26 períodos, lo que sugiere una tendencia alcista. Por el contrario, valores por debajo de cero indican una tendencia bajista. Un cruce del MACD con la línea de señal puede generar señales de compra o venta, aunque estos cruces son más efectivos dentro de mercados con una tendencia clara (Kirkpatrick & Dahlquist, 2010).

La Fig. 2.3 ilustra la interacción entre la línea MACD, la línea de señal y el histograma, destacando los momentos en los que se producen cruces alcistas y bajistas.

Una forma intuitiva de comprender el MACD es compararlo con un avión en vuelo, donde el MACD representa la altitud y la línea de señal actúa como el sistema de navegación que guía su trayectoria. Cuando el MACD está por encima de la línea de señal, el avión está ascendiendo, lo que indica una tendencia alcista con impulso creciente. Por el contrario, cuando el MACD cae por debajo de la línea de señal, es como si el




Figura 2.3: Media móvil de convergencia/divergencia. *Nota.* La figura ilustra la línea MACD, la línea de señal y el histograma, con cruces alcistas y bajistas resaltados. Elaboración propia.

avión comenzara a descender, sugiriendo una tendencia bajista. El histograma, que mide la diferencia entre ambos, refleja la velocidad de ascenso o descenso: si el histograma es positivo y creciente, el avión gana altitud rápidamente, mientras que si es negativo y decreciente, el descenso es más pronunciado. Un cruce alcista del MACD con la línea de señal es como aumentar la potencia de los motores para ganar altitud y continuar la tendencia alcista, mientras que un cruce bajista es como reducir la potencia, lo que podría anticipar una pérdida de impulso y un posible cambio de dirección en el mercado.

Estudios previos han evaluado la efectividad del MACD en distintos mercados financieros y su capacidad para generar señales de *trading* rentables (Anghel, 2015). En particular, la investigación de Anghel (2015) examinó el rendimiento del MACD en 75 mercados globales, concluyendo que, si bien en muchos casos los mercados son eficientes y no permiten obtener ganancias sistemáticas, en ciertos contextos específicos el MACD ha demostrado ser útil para identificar patrones de precios que pueden ser aprovechados en estrategias de *trading*.

En los criptomercados, donde la alta volatilidad, la baja liquidez y el comportamiento especulativo pueden generar ineficiencias, los indicadores de tendencia adquieren un papel muy importante. Un sistema de análisis basado en estos indicadores puede detectar y evaluar patrones en los movimientos de precios, proporcionando información estructurada que facilite la toma de decisiones estratégicas.

Aunque los indicadores de tendencia identifican la dirección del mercado, no siempre confirman la fuerza o sostenibilidad del movimiento, lo que puede generar señales erró-

neas. Los indicadores de momento complementan este análisis al medir la velocidad y el impulso del precio, ayudando a determinar si una tendencia se mantiene o está perdiendo fuerza, lo que podría anticipar una reversión (Murphy, 1999).

2.1.5. Indicadores de Soporte y Resistencia

Los niveles de soporte y resistencia son conceptos fundamentales en el Análisis Técnico, ya que representan zonas donde el precio de un activo tiende a detenerse o revertirse debido a la interacción entre la oferta y la demanda. Murphy (1999) explica que un soporte es un nivel de precios en el que la demanda se vuelve lo suficientemente fuerte como para evitar una caída mayor del precio, generando presión alcista y una posible recuperación. Por el contrario, una resistencia es un nivel en el que la oferta supera la demanda, impidiendo que el precio continúe subiendo. En estos casos, los vendedores suelen aprovechar para liquidar posiciones, lo que provoca un retroceso en el precio.

Según Murphy (1999), la efectividad de un nivel de soporte o resistencia depende de diversos factores, entre ellos el número de veces que ha sido probado, la duración del tiempo en que el precio se ha mantenido en ese nivel y el volumen de negociación registrado. Cuanto más fuerte es la reacción del precio en una zona determinada, mayor es la probabilidad de que dicho nivel se respete en futuras sesiones. Además, cuando una resistencia es superada, puede convertirse en un nuevo soporte, mientras que un soporte que es quebrado, puede transformarse en una resistencia. Este fenómeno es clave en la interpretación del comportamiento del mercado y es ampliamente utilizado por los analistas técnicos.

Uno de los métodos más utilizados para calcular estos niveles es el de los Puntos Pivote, los cuales permiten identificar zonas de soporte y resistencia en función del comportamiento del precio en el período anterior (Kirkpatrick & Dahlquist, 2006). Este método, atribuido por Kirkpatrick y Dahlquist (2006) a Kaufman (1998), define el Punto Pivote Principal (*PP*) con la siguiente ecuación:

$$PP = \frac{H_{\text{previo}} + L_{\text{previo}} + C_{\text{previo}}}{3} \quad (2.5)$$

donde:

- H_{previo} es el precio máximo del período anterior,
- L_{previo} es el precio mínimo del período anterior,
- C_{previo} es el precio de cierre del período anterior.

A partir de este valor, se calculan los niveles de resistencia y soporte mediante las siguientes fórmulas:

Resistencias:

$$R_1 = (2 \times PP) - L_{\text{previo}} \quad (2.6)$$

$$R_2 = (PP - S_1) + R_1 \quad (2.7)$$

Soportes:

$$S_1 = (2 \times PP) - H_{\text{previo}} \quad (2.8)$$

$$S_2 = PP - (R_1 - S_1) \quad (2.9)$$

Estos cálculos permiten proyectar los niveles en los que el precio podría encontrar resistencia o soporte en función de la volatilidad registrada en el período previo. En la Fig. 2.4 se muestra un gráfico de velas en el que se identifican estos niveles. Cada vela representa una sesión, es decir, un intervalo de tiempo definido como una hora, un día o cualquier otra unidad temporal utilizada en el análisis. Las velas verdes indican sesiones con cierre por encima de la apertura, mientras que las rojas representan lo contrario. La línea punteada azul marca un nivel de resistencia, que actúa como techo del precio; la línea punteada naranja indica un nivel de soporte, que funciona como suelo. El eje horizontal representa el tiempo, y el eje vertical, el precio del activo. Estos niveles son utilizados por los operadores para diseñar estrategias de entrada y salida en el mercado.

Una manera intuitiva de comprender los niveles de soporte y resistencia es compararlos con el piso y el techo de una habitación. El precio actúa como una pelota que rebota entre estas superficies: cuando cae y golpea el piso, suele rebotar, similar a cómo el soporte evita que el precio siga bajando. De la misma manera, cuando la pelota asciende y choca con el techo, tiende a devolverse, reflejando el papel de la resistencia al impedir un avance mayor del precio. Sin embargo, si la pelota adquiere suficiente fuerza y rompe el techo, este se convierte en el nuevo piso, al igual que un nivel de resistencia que es superado y pasa a actuar como soporte. Esta analogía ayuda a visualizar por qué los precios reaccionan de manera predecible en ciertas zonas clave del mercado.

El uso de puntos pivote es ampliamente reconocido en los mercados financieros. Murphy (1999) señala que los operadores los emplean para identificar zonas estratégicas de entrada y salida, considerando que estos niveles pueden actuar como barreras



Figura 2.4: Niveles de Soporte y Resistencia. *Nota.* Ilustración de dos niveles en los que el precio ha tendido a detenerse o cambiar de dirección, la resistencia que limita los movimientos al alza, y el soporte que contiene las caídas. Elaboración propia.

psicológicas en el comportamiento del mercado. De acuerdo con Kirkpatrick y Dahlquist (2006), su efectividad aumenta cuando se combinan con otros indicadores técnicos, como las Bandas de Bollinger o el Índice de Fuerza Relativa, proporcionando una visión más integral de la tendencia y la volatilidad del mercado.

La utilidad práctica de estos niveles ha sido validada en estudios recientes. Por ejemplo, Aggarwal et al. (2023) demostraron que el uso conjunto de soporte, resistencia y puntos pivote puede mejorar significativamente las decisiones de compra y venta en índices bursátiles como el Bank Nifty, especialmente en contextos de alta volatilidad. Su modelo logró identificar rupturas efectivas en marcos temporales de 5 minutos, lo que permitió optimizar puntos de entrada y salida en operaciones intradía.

Estos hallazgos respaldan la relevancia del análisis de soporte y resistencia dentro del conjunto de herramientas del Análisis Técnico moderno, especialmente cuando se integran con otros indicadores para la toma de decisiones informadas en mercados volátiles como el de criptomonedas.

2.1.6. Indicadores de Momento

En el Análisis Técnico, no solo es fundamental identificar la dirección de la tendencia, sino también evaluar su fortaleza y continuidad. Los indicadores de momento permiten medir la rapidez y magnitud del cambio en el precio de un activo, proporcionando información sobre el equilibrio entre compradores y vendedores. Su correcta interpretación

ayuda a confirmar la validez de una tendencia y detectar posibles puntos de agotamiento o reversión (Kirkpatrick & Dahlquist, 2010; Murphy, 1999).

Dentro de esta categoría, los osciladores son herramientas clave que fluctúan dentro de un rango predefinido y facilitan la identificación de condiciones de sobrecompra o sobreventa. Estos niveles indican cuándo un activo puede estar sobrevalorado o infravalorado en función del comportamiento reciente del mercado, lo que podría señalar oportunidades de compra o venta (Murphy, 1999).

Entre los indicadores de momento más utilizados se encuentran el Índice de Fuerza Relativa y el Índice de Flujo de Dinero (MFI, por sus siglas en inglés). Ambos miden la fuerza del mercado, pero con enfoques diferentes.

Índice de Fuerza Relativa

El Índice de Fuerza Relativa es un oscilador desarrollado por J. Welles Wilder en 1978 para evaluar la intensidad de los cambios recientes en los precios y determinar si un activo se encuentra en una condición de sobrecompra o sobreventa.

En el contexto de los criptomercados, caracterizados por alta volatilidad y movimientos impulsivos, el RSI resulta útil para anticipar posibles agotamientos de tendencia o correcciones bruscas. Su cálculo se expresa mediante la siguiente fórmula:

$$RSI = 100 - \left(\frac{100}{1 + RS} \right) \quad (2.10)$$

donde RS representa la relación entre la media de las ganancias y la media de las pérdidas en un período determinado, generalmente de 14 días (Kirkpatrick & Dahlquist, 2010).

Según Kirkpatrick y Dahlquist (2010), el RSI oscila entre 0 y 100, con valores superiores a 70 indicando sobrecompra y valores inferiores a 30 señalando sobreventa. Algunos analistas ajustan estos umbrales en función de la tendencia del mercado, estableciendo niveles de 75 y 25, o incluso 90 y 40 en tendencias alcistas, y 60 y 10 en tendencias bajistas, con el objetivo de mejorar la precisión de las señales. Sin embargo, en mercados con tendencias fuertes, el RSI puede permanecer en niveles extremos durante largos períodos, lo que puede generar señales prematuras de reversión (Kirkpatrick & Dahlquist, 2010).

Aunque el RSI es ampliamente utilizado, su efectividad varía según las condiciones del mercado. Para mitigar el riesgo de señales falsas en tendencias fuertes, algunos analistas lo combinan con otros indicadores técnicos, como el MACD o el MFI, para mejorar su precisión.

Esta necesidad de complementar el RSI con otras herramientas ha sido respaldada por estudios recientes donde emplean el RSI como una de las variables de entrada en modelos de predicción basados en redes neuronales recurrentes, como LSTM, los cuales han mostrado mejoras en la identificación de patrones relevantes, particularmente cuando se combinan múltiples indicadores técnicos (Deb et al., 2024).

Además de identificar condiciones de sobrecompra y sobreventa, el RSI también se emplea para detectar divergencias con el precio. Cuando el precio de un activo alcanza un nuevo máximo, pero el RSI no logra superar su nivel anterior, esto puede ser una señal de debilidad en la tendencia alcista y una posible reversión bajista. De manera similar, si el precio marca un nuevo mínimo y el RSI no lo confirma con un valor más bajo, se interpreta como una señal de agotamiento en la tendencia bajista y una posible reversión alcista (Kirkpatrick & Dahlquist, 2010).




Figura 2.5: Índice de fuerza relativa. *Nota.* La figura muestra el RSI de 14 períodos con los niveles de sobrecompra y sobreventa. Elaboración propia.

La Fig. 2.5 ilustra la evolución del RSI con un período de 14 días, destacando los niveles de sobrecompra y sobreventa. Este indicador, que oscila entre 0 y 100, permite identificar condiciones en las que un activo podría estar sobrevalorado cuando el RSI se encuentra por encima de 70 o infravalorado cuando se sitúa por debajo de 30.

Una forma intuitiva de comprender el RSI es compararlo con el nivel de combustible en el tanque de un automóvil. Cuando el tanque está lleno, es decir, cuando el RSI supera el umbral de 70, no hay espacio para más combustible y es probable que el automóvil necesite recorrer una distancia considerable antes de repostar nuevamente. Esto refleja un mercado sobrecomprado y propenso a una corrección. Por el contrario, cuando el tanque está casi vacío, o cuando el RSI cae por debajo de 30, el automóvil necesita repostar

urgentemente, lo que sugiere una posible sobreventa y una inminente recuperación del precio del activo. Además, si el indicador de gasolina muestra inconsistencias, como una disminución del nivel de combustible incluso cuando el vehículo no se ha movido, esto es similar a una divergencia en el RSI, lo que podría advertir sobre una reversión de la tendencia antes de que ocurra.

Si bien el RSI se enfoca en la fuerza relativa de los precios, otros indicadores como el Índice de Flujo de Dinero integran también el volumen, proporcionando una perspectiva adicional sobre la presión de compra y venta en el mercado, lo cual es fundamental para validar la fuerza real de una tendencia.

Índice de Flujo de Dinero

Por otro lado, el Índice de Flujo de Dinero (MFI, por sus siglas en inglés) es un oscilador técnico que mide la presión de compra y venta en el mercado al incorporar el volumen de negociación en su cálculo. Se obtiene a partir del Flujo de Dinero, definido como:

$$\text{Flujo de Dinero} = \text{Precio Típico} \times \text{Volumen} \quad (2.11)$$

donde el Precio Típico se obtiene como:

$$\text{Precio Típico} = \frac{\text{Máximo} + \text{Mínimo} + \text{Cierre}}{3} \quad (2.12)$$

A partir de estos valores, se determina el Flujo de Dinero Positivo (PMF, por sus siglas en inglés) y el Flujo de Dinero Negativo (NMF, por sus siglas en inglés), según si el Precio Típico del día es mayor o menor que el del día anterior. Luego, se calcula la relación de flujo de dinero (MFR, por sus siglas en inglés):

$$\text{MFR} = \frac{\sum \text{PMF}}{\sum \text{NMF}} \quad (2.13)$$

Finalmente, el MFI se obtiene con la ecuación:

$$\text{MFI} = 100 - \left(\frac{100}{1 + \text{MFR}} \right) \quad (2.14)$$

Este indicador oscila entre 0 y 100, con valores superiores a 80 indicando sobrecompra y valores inferiores a 20 señalando sobreventa (Kirkpatrick & Dahlquist, 2010).

La Fig. 2.6 muestra la evolución del MFI en un período de 14 días, resaltando los momentos en los que el indicador alcanza niveles de sobrecompra y sobreventa. Al igual que el RSI, el MFI permite evaluar la fuerza de los movimientos de precio; sin embargo,




Figura 2.6: Índice de flujo de dinero. *Nota.* El gráfico muestra el comportamiento del MFI calculado con un período de 14 días, destacando las zonas de sobrecompra y sobreventa. Elaboración propia.

su principal ventaja radica en la incorporación del volumen de negociación. Mientras que el RSI solo se basa en los cambios de precio, el MFI considera la cantidad de dinero que entra o sale del activo, proporcionando una visión más completa de la presión compradora o vendedora en el mercado.

Una forma intuitiva de entender el MFI es compararlo con un tanque de almacenamiento de agua, cuyo nivel varía en función de la cantidad de líquido que entra y sale. Cuando recibe un flujo constante y abundante de agua, el nivel del tanque sube rápidamente hasta acercarse a su capacidad máxima. En este punto, existe un riesgo de desbordamiento, lo que en el mercado financiero equivale a una condición de sobrecompra, donde el activo ha acumulado demasiado impulso alcista y podría experimentar una corrección. Por el contrario, si la entrada de agua es escasa y el nivel del tanque disminuye de manera drástica, se acerca a un punto crítico en el que necesita ser reabastecido. En términos del mercado, esta situación representa una condición de sobreventa, donde la fuerte caída en el precio y el volumen podría generar una oportunidad para un rebote alcista impulsado por nueva demanda. Esta analogía permite visualizar cómo la relación entre volumen y precio ayuda a detectar oportunidades estratégicas de compra o venta.

Estudios recientes han sugerido la relevancia del MFI en contextos predictivos avanzados. Por ejemplo, de Oliveira Carosia et al. (2024) han utilizado el MFI como uno de los indicadores técnicos en un modelo de aprendizaje profundo para predecir rendimientos del mercado bursátil brasileño, combinándolo con Análisis de Sentimiento y precios históricos. Los resultados mostraron que la inclusión del MFI y otros indicadores basados en volumen

mejoró la precisión de las predicciones, destacando la importancia de considerar no solo la dirección del precio, sino también la intensidad del flujo monetario detrás de los movimientos de mercado.

Aunque el RSI y el MFI comparten el mismo principio de oscilación, su diferencia radica en la información utilizada:

- El RSI solo considera cambios en los precios, por lo que es más útil en mercados con bajo volumen o activos con alta volatilidad sin un volumen significativo.
- El MFI incorpora volumen, alineándose con la Teoría de Dow, que establece que el volumen debe confirmar la tendencia. Esto lo hace más efectivo cuando se necesita evaluar si los movimientos de precio están respaldados por una actividad significativa de compra o venta, reduciendo la probabilidad de señales falsas.

Por ejemplo, si una criptomoneda muestra un RSI superior a 70, lo que indicaría sobrecompra, pero con un volumen bajo, la señal podría ser débil y no necesariamente indicar una caída inminente. Sin embargo, si el MFI también está por encima de 80, con volumen alto, hay una mayor confirmación de que el activo está en sobrecompra con presión vendedora, lo que refuerza la señal bajista.

Estudios recientes, como el de Hafid et al. (2024), han demostrado que la integración de indicadores técnicos en modelos de aprendizaje automático mejora la precisión en la predicción de precios de criptomonedas. En particular, este estudio implementó un modelo basado en XGBoost Regressor, combinando indicadores como EMA, MACD y RSI para identificar patrones de mercado y generar señales más confiables en entornos de alta volatilidad (Hafid et al., 2024).

2.1.7. Indicadores de Volatilidad

La volatilidad en los mercados financieros refleja la intensidad de las fluctuaciones en el precio de un activo en un período determinado. Es una medida clave del riesgo y la incertidumbre del mercado, ya que refleja la velocidad y la amplitud con la que cambian los precios. Una mayor volatilidad indica movimientos de precio más extremos, mientras que una menor volatilidad sugiere estabilidad y consolidación.

Para evaluar la volatilidad del mercado, se utilizan diversos indicadores técnicos, los cuales permiten medir la magnitud de los movimientos de los precios y anticipar posibles cambios de tendencia. Entre los principales indicadores de volatilidad se encuentran:

Rango Promedio Verdadero

El Rango Promedio Verdadero (ATR, por sus siglas en inglés) es un indicador desarrollado por J. Welles Wilder para medir la volatilidad del mercado. Se calcula como el promedio del Rango Verdadero (TR, por sus siglas en inglés) en un período determinado, generalmente de 14 días. El Rango Verdadero se define como el mayor valor entre:

- La diferencia entre el máximo y el mínimo del período actual.
- El valor absoluto de la diferencia entre el cierre del período anterior y el máximo del período actual.
- El valor absoluto de la diferencia entre el cierre del período anterior y el mínimo del período actual.

El ATR se obtiene promediando estos valores a lo largo del período seleccionado, utilizando una fórmula que otorga mayor peso a los datos recientes, lo que permite reflejar de manera más precisa los cambios en la volatilidad del activo según Kirkpatrick y Dahlquist (2010).




Figura 2.7: Rango promedio verdadero. *Nota.* El gráfico muestra la evolución del ATR en el mercado de criptomonedas, con líneas de referencia para alta y baja volatilidad. Elaboración propia.

Para comprender mejor la utilidad del ATR, podemos compararlo con el tráfico en una autopista. Cuando el ATR es alto por encima de la línea roja en la Fig. 2.7, es como si la carretera estuviera congestionada, con autos acelerando y frenando constantemente. Esto indica una fase de alta volatilidad en el mercado, donde los precios experimentan

cambios bruscos y repentinos. Por el contrario, cuando el ATR es bajo por debajo de la línea verde en la Fig. 2.7, la carretera está despejada y los autos pueden mantener una velocidad constante, reflejando una fase de estabilidad en el mercado con menor riesgo de fluctuaciones extremas.

En la Fig. 2.7, se observa la evolución del ATR aplicado al mercado de Bitcoin. Las líneas de referencia indican los niveles de alta y baja volatilidad, calculados a partir de la desviación estándar del ATR. Los períodos en los que el ATR supera la línea roja reflejan momentos de alta volatilidad, lo que sugiere posibles cambios bruscos en el precio. Por el contrario, cuando el ATR se encuentra por debajo de la línea verde, el mercado muestra estabilidad y menor riesgo de fluctuaciones extremas.

El ATR ha demostrado ser una herramienta útil para evaluar la volatilidad de los mercados financieros, especialmente en contextos dinámicos como los criptomercados. Sin embargo, su carácter estrictamente retrospectivo puede limitar su capacidad para capturar cambios repentinos en los precios. En respuesta a estas limitaciones, Fu et al. (2025) proponen un enfoque mejorado que amplía la capacidad del ATR para adaptarse a condiciones de mercado volátiles, incrementando su sensibilidad a las variaciones de corto plazo. Este tipo de mejoras refuerzan el valor del ATR como indicador base en el Análisis Técnico, particularmente en entornos con alta variabilidad.

Un ATR alto indica un mercado más volátil, donde los precios experimentan amplios rangos de movimiento, mientras que un ATR bajo sugiere estabilidad con fluctuaciones de precios más reducidas. Este indicador es especialmente útil cuando se combina con otros indicadores técnicos, ya que permite identificar tendencias y filtrar señales falsas, mejorando la precisión del análisis de mercado.

Bandas de Bollinger

Las Bandas de Bollinger son un indicador técnico desarrollado por John Bollinger para medir la volatilidad del mercado e identificar condiciones de sobrecompra y sobreventa (Murphy, 1999). Este indicador se compone de una media móvil simple (SMA, por sus siglas en inglés) de 20 períodos, acompañada de dos bandas que reflejan la desviación estándar del precio:

- Banda superior: Situada a dos desviaciones estándar por encima de la SMA.
- Banda inferior: Ubicada a dos desviaciones estándar por debajo de la SMA.

La Fig. 2.8 ilustra cómo las Bandas de Bollinger se expanden y contraen en respuesta a la volatilidad del mercado. Cuando la volatilidad es alta, las bandas se ensanchan,




Figura 2.8: Bandas de Bollinger. *Nota.* El gráfico muestra las Bandas de Bollinger con un período de 20 y una desviación estándar de 2. Se destacan las señales de sobrecompra y sobreventa cuando el precio alcanza las bandas superior e inferior, respectivamente. Elaboración propia.

reflejando movimientos de precio más amplios. Por el contrario, cuando la volatilidad disminuye, las bandas se contraen, lo que suele indicar una fase de consolidación antes de un posible movimiento brusco del precio (Kirkpatrick & Dahlquist, 2010).

Una analogía útil para comprender este comportamiento es imaginar las bandas como un paracaídas en vuelo. Cuando el viento es fuerte y turbulento, el paracaídas se expande, permitiendo mayor libertad de movimiento. Sin embargo, en condiciones de viento calmo, el paracaídas se pliega y se mantiene más compacto, listo para reaccionar a cualquier ráfaga inesperada. De manera similar, en los mercados financieros, el estrechamiento de las Bandas de Bollinger, conocido como *Bollinger Squeeze*, sugiere que el precio está acumulando presión y es probable que se produzca una ruptura significativa en cualquier dirección.

El análisis de las Bandas de Bollinger permite identificar momentos clave en el mercado. Cuando el precio alcanza o supera la banda superior, el activo puede considerarse en sobrecompra, lo que indica un posible sobrevaloramiento y un mayor riesgo de corrección. Por el contrario, si el precio toca o cae por debajo de la banda inferior, se interpreta como una posible señal de sobreventa, sugiriendo que el activo podría estar infravalorado y susceptible a un rebote alcista. En la práctica, este indicador suele utilizarse en conjunto con herramientas técnicas adicionales, como el RSI o el MFI, lo que permite una mejor evaluación del contexto del mercado y una toma de decisiones más fundamentada.

Además, estudios recientes han explorado la implementación práctica de las Bandas

de Bollinger en sistemas automáticos de toma de decisiones para la compra y venta de acciones. Un ejemplo es el trabajo de Firza et al. (2021), quienes desarrollaron un sistema que combina las Bandas de Bollinger con el método de suavizamiento exponencial simple (SES, por sus siglas en inglés) para analizar patrones de mercado y generar señales automáticas de *trading*. En este estudio, los resultados experimentales mostraron que, al aplicar esta combinación en periodos de 30 minutos, se alcanzó una tasa de éxito de hasta un 75 %, destacando la efectividad del enfoque para capturar momentos clave de volatilidad y mejorar las decisiones computacionales en estrategias de Análisis Técnico.

2.2. Procesamiento de Lenguaje Natural

El Procesamiento de Lenguaje Natural ha experimentado una transformación en las últimas décadas, pasando de métodos basados en reglas y estadística a modelos avanzados de aprendizaje profundo. Su evolución ha estado marcada por la búsqueda de una mayor capacidad para comprender, interpretar y generar lenguaje de manera natural y coherente, permitiendo aplicaciones en traducción automática, Análisis de Sentimiento, búsqueda semántica, generación de contenido y asistentes virtuales (Yamamoto, 2023).

2.2.1. Evolución del Procesamiento de Lenguaje Natural

Los primeros intentos de modelar el lenguaje natural adoptaron un enfoque determinista, basado en reglas lingüísticas y gramáticas formales, influenciados por teorías como la gramática generativa transformacional, propuesta por Chomsky (1957). Este enfoque sostenía que el lenguaje humano se estructura mediante un conjunto finito de reglas que pueden generar un número infinito de oraciones.

A partir de esta teoría, tres argumentos clave sentaron las bases para el desarrollo de modelos computacionales del lenguaje: la pobreza del estímulo, la creatividad del lenguaje y el concepto de competencia lingüística.

- La pobreza del estímulo sugiere que los niños pueden aprender estructuras lingüísticas complejas sin recibir ejemplos suficientes de todas las posibles combinaciones.
- La creatividad del lenguaje indica que los hablantes pueden construir oraciones que nunca han escuchado antes, lo que implica la existencia de una gramática interna.
- El concepto de competencia lingüística distingue entre el conocimiento implícito de la gramática y su aplicación en la comunicación cotidiana.

Estos principios desafiaron los enfoques previos basados en reglas estrictas, promoviendo el desarrollo de modelos más flexibles, como los enfoques probabilísticos y, posteriormente, redes neuronales.

Con la evolución de las computadoras y el acceso a volúmenes de datos, surgieron nuevos enfoques de probabilísticos, como los modelos de Campos Aleatorios Condicionales (CRFs, por sus siglas en inglés). Los CRFs son modelos que usan grafos para representar relaciones entre palabras en una secuencia, lo que les permite capturar dependencias contextuales (Lafferty et al., 2001). A diferencia de los clasificadores independientes, los CRFs consideran el contexto global de una oración, lo que los hace especialmente efectivos en tareas como el reconocimiento de entidades nombradas (NER, por sus siglas en inglés).

El desarrollo de las redes neuronales artificiales introdujo una nueva forma de representar las palabras, como vectores de palabras o *word embeddings*. Modelos como Word2Vec (Mikolov et al., 2013) y GloVe (Pennington et al., 2014) demostraron que era posible capturar relaciones semánticas entre palabras mediante el análisis de su contexto en grandes conjuntos de datos textuales.

Con arquitecturas más profundas, como las redes neuronales recurrentes (RNN, por sus siglas en inglés) y las redes neuronales convolucionales (CNN, por sus siglas en inglés), se desarrollaron modelos para tareas como traducción automática y Análisis de Sentimientos, sin embargo, estas arquitecturas tenían limitaciones para manejar relaciones contextuales en secuencias largas, lo que impulsó el desarrollo de modelos más avanzado, como los transformadores.

2.2.2. Modelos Transformadores: Evolución y Aplicaciones

Un transformador es una arquitectura de modelo de aprendizaje profundo introducida por primera vez en el artículo *Attention Is All You Need* (Vaswani et al., 2017), cuyo objetivo original era mejorar la traducción automática. Su impacto en el campo del procesamiento del lenguaje natural ha sido muy relevante, ya que permite un procesamiento eficiente y altamente contextualizado del lenguaje mediante su mecanismo de atención (*self-attention*, término en inglés).

El funcionamiento de los transformadores se basa en una combinación de varios mecanismos como se muestra en Fig. 2.9, siendo el más importante la atención, el cual asigna pesos de importancia a diferentes partes del texto de entrada para capturar relaciones contextuales de manera efectiva. A diferencia de los modelos secuenciales tradicionales, como las redes neuronales recurrentes, los transformadores permiten que

cada palabra en una oración se relacione con todas las demás simultáneamente, en lugar de depender únicamente de la información precedente. Esto mejora la capacidad del modelo para capturar dependencias a largo plazo y mejora la comprensión contextual del texto.

Los transformadores están compuestos por dos componentes principales: el codificador (*encoder*, término en inglés) y el decodificador (*decoder*, término en inglés). El codificador procesa la entrada aplicando múltiples capas de atención y redes neuronales completamente conectadas para generar una representación contextualizada del texto. Por su parte, el decodificador recibe estas representaciones y emplea mecanismos de atención adicionales para generar una salida de una manera secuencial. La combinación de estos dos módulos permite que los transformadores capturen dependencias globales en la entrada y generen respuestas precisas y coherentes.




Figura 2.9: Arquitectura del modelo transformador. *Nota.* La figura muestra la arquitectura general de un modelo transformador. Adaptado de Vaswani et al. (2017).

Antes de que un transformador pueda procesar texto, es necesario dividirlo en unidades más pequeñas llamadas *tokens*, que representan la unidad mínima en que se segmenta un texto para su procesamiento. Dependiendo del modelo y la tarea específica, un *token* puede corresponder a una palabra completa, una subpalabra o incluso un solo carácter. A este proceso se le conoce como tokenización.

Los métodos actuales utilizados incluyen *WordPiece* (Wu et al., 2016), *SentencePiece* (Kudo & Richardson, 2018) y *Byte Pair Encoding* (Sennrich et al., 2015), que descomponen palabras en subunidades morfológicas con el fin de mejorar la generalización del modelo y manejar vocabularios abiertos. Esto significa que el modelo no están limitados a una lista fija de palabras, sino que puede procesar términos desconocido al segmentarlo en unidades más pequeñas, preservando su significado dentro del contexto.

Un ejemplo del método *WordPiece*, utilizado en BERT, segmenta palabras en unidades más pequeñas según su frecuencia del corpus de entrenamiento, lo que permite manejar palabras raras o desconocidas y reducir el tamaño del vocabulario sin perder información semántica. Esto significa que, en lugar de representar la palabra “transformador” como un único *token*, el modelo podría dividirla en “*trans*”, “*##form*”, “*##ador*”

Para efectos prácticos en esta investigación, se considerará que cada *token* corresponde a una palabra.

Por ejemplo, en la frase “*She loves her dog because it is so*”, el proceso de tokenización generará la siguiente secuencia: “*She*”, “*loves*”, “*her*”, “*dog*”, “*because*”, “*it*”, “*is*”, “*so*”. Esta representación permite que el modelo procese la oración en partes estructuradas, facilitando la captura de relaciones semánticas entre palabras.

Una vez que el texto ha sido tokenizado, cada *token* se convierte en una representación numérica para que el modelo pueda procesarlo. En los transformadores, esta representación se conoce como *word embedding* o simplemente *embedding*. Un *embedding* es un vector en un espacio multidimensional que captura el significado de una palabra, donde términos con significados similares tienen representaciones cercanas. Esto permite que el modelo entienda relaciones semánticas entre palabras basándose en su contexto dentro de un conjunto de datos. El modelo *Global Vectors for Word Representation* (GloVe, por sus siglas en inglés), propuesto por Pennington et al. (2014), permite capturar relaciones semánticas de manera efectiva al combinar técnicas de factorización de matrices con métodos basados en ventanas de contexto. Este modelo ha sido utilizado en la generación de la Fig. 2.10, donde se observa que en un espacio de *embeddings*, el vector de la palabra “perro” estará más cerca del de “cachorro” o “gato” que del de “avión”, reflejando la relación semántica entre estas palabras.

El mecanismo de atención permite modelar la relación entre cada palabra del texto y




Figura 2.10: Analogía de vectores semánticos. *Nota.* La figura muestra la relación semántica entre las palabras *dog*, *puppy*, *cat* y *plane*, utilizando vectores obtenidos del modelo GloVe. Elaboración propia.

las demás para capturar relaciones contextuales. A diferencia de modelos tradicionales como RNN, que procesan el texto en orden secuencial, los transformadores analizan simultáneamente todas las palabras de una oración, identificando qué términos son más relevantes entre sí.

Por ejemplo, si se considera la palabra polisémica “banco”, su significado en la frase “He depositado dinero en la cuenta del banco” es diferente al de “Se ha pintado el banco del parque”. Gracias al mecanismo de atención, el modelo puede distinguir entre estos significados al analizar las relaciones contextuales entre las palabras.

En el caso de la oración “*She loves her dog because it is so*”, el mecanismo de atención permite identificar una relación entre “*She*” y “*loves*”, donde son sujeto y verbo respectivamente, asimismo se observa que también existe una relación con “*dog*” que funciona como objeto directo en la oración, como se ilustra en la Fig. 2.11, donde se calcula el producto punto entre los vectores de cada palabra, generando una matriz de atención. Esta matriz, representada por círculos de distintas intensidades de morado, refleja la relevancia entre palabras en la secuencia. Luego se le aplica un escalado y una máscara para evitar que el modelo mire al futuro en arquitecturas autoregresivos como GPT-2, finalmente, se realiza una normalización mediante *softmax* y *dropout*, afinando los pesos de atención antes de generar la salida.




Figura 2.11: Mecanismo de atención. *Nota.* La figura muestra el producto punto entre *tokens* de la frase. Captura de pantalla del software de Cho et al. (2024).

Dado que los modelos de transformadores procesan los *tokens* en paralelo y no cuentan con una memoria secuencial explícita, necesitan incorporar información posicional para preservar la estructura de la oración. Para ello, utilizan un mecanismo de codificación posicional (*positional encoding*, término en inglés), que agrega vectores de posición a los *embeddings* de las palabras. Esto permite que el modelo distinga entre frases que contienen las mismas palabras pero en distinto orden, como se observa en la Fig. 2.12. Por ejemplo, sin codificación posicional, el modelo no podría diferenciar entre las frases “El perro persiguió al gato” y “El gato persiguió al perro”, ya que ambas oraciones contienen las mismas palabras, pero con una sintaxis y significados completamente distintos. La codificación posicional garantiza que el modelo comprenda la estructura y dirección de la acción en cada caso.

El modelo propuesto por Vaswani et al. (2017) utiliza funciones trigonométricas, específicamente seno y coseno, que permiten representar la posición de los *tokens* en el espacio de manera continua y diferenciable. Las fórmulas utilizadas para calcular los valores de la codificación posicional son las siguientes:

$$PE_{(pos,2i)} = \sin\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (2.15)$$

$$PE_{(pos,2i+1)} = \cos\left(\frac{pos}{10000^{2i/d_{model}}}\right) \quad (2.16)$$

Donde:

- *pos* representa la posición del *token* en la secuencia.

- i es el índice de la dimensión dentro del vector de codificación posicional.
- d_{model} es la dimensión del espacio de *embeddings*.

Estas funciones permiten que el modelo diferencie las posiciones de los *tokens* sin necesidad de aprender nuevos parámetros, asegurando que relaciones espaciales entre palabras mantengan.



Figura 2.12: Representación de *tokens* y codificación posicional. *Nota.* La figura ilustra el proceso de incorporación de información posicional mediante la combinación de los *embeddings* de *tokens* y la codificación posicional. Captura de pantalla del software de Cho et al. (2024)

Después de la etapa de atención, cada vector de palabra pasa por un perceptrón multicapa (MLP, por sus siglas en inglés), que introduce dos transformaciones no lineales con función de activación ReLu (*Rectified Linear Unit*, término en inglés) entre cada una para refinar la representación de cada *token* y permiten capturar patrones semánticos más complejos en el texto. En cada bloque del transformador, la atención modela dependencias globales entre palabras, permitiendo que cada término en la secuencia incorpore información contextual sin restricciones de distancia. Posteriormente, la normalización por capas (*layer normalization*, término en inglés) mantiene la escala óptima de los valores evitando que los valores de los vectores crezcan demasiado o se reduzcan a niveles insignificantes.

En el mecanismo de atención, cada entrada del modelo de transformador se representa mediante un vector de *embeddings*, el cual es transformado en tres matrices, consulta Q , llave K y valores V . Estas matrices no son directamente las representaciones de entrada, sino que se obtienen mediante proyecciones lineales aprendibles aplicadas a los *embeddings* de la secuencia de entrada. Matemáticamente, esto se expresa como:

$$Q = XW_Q, K = XW_K, V = XW_V \quad (2.17)$$

Donde:

- X representa la matriz de *embeddings* de la entrada,
- W_Q, W_K, W_V son matrices de peso aprendibles durante el entrenamiento,
- Q, K, V son los vectores resultantes que capturan diferentes aspectos de la información contenida en la entrada.

Luego, la atención se calcula a través del producto escalar entre Q y K , escalado por $\sqrt{d_k}$ y normalizado mediante la función softmax, ecuación presentada por Vaswani et al. (2017):

$$\text{Atención}(Q, K, V) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) V \quad (2.18)$$

La normalización con $\sqrt{d_k}$ es fundamental, ya que d_k representa la dimensión de los vectores de consulta y llave dentro del mecanismo de atención. Al aumentar d_k , los valores del producto QK^T pueden crecer significativamente, lo que podría generar distribuciones de atención sesgadas al aplicar la función *softmax*. La división por $\sqrt{d_k}$ previene este efecto al mantener los valores dentro de una escala estable, evitando que algunos elementos dominen excesivamente la atención mientras que otros sean ignorados.

Después de procesar la entrada a través de los bloques del transformador, el resultado pasa por una capa lineal final que convierte la representación en una distribución de probabilidad sobre el vocabulario. Este modelo se emplea en sistemas generativos, ya que permite calcular la probabilidad de cada posible *token* de salida. Gracias a su capacidad para capturar y comprender el contexto a lo largo de la secuencia de entrada, el modelo asigna mayor peso a palabras que mantienen la coherencia semántica con el texto previo. Finalmente, la función *softmax* normaliza estos valores para asignar una distribución de probabilidad, permitiendo que el modelo genere texto de manera autoregresiva y sea útil en tareas como la síntesis de noticias y la generación de reportes. En la Fig. 2.13, se muestra la distribución de probabilidad generada para la oración de ejemplo “*She loves her dog because it is so*”, donde “*cute*” es la palabra con mayor probabilidad de ser la siguiente palabra.

Para ilustrar el funcionamiento de los transformadores y facilitar la comprensión de sus componentes internos, se utilizaron imágenes generadas a partir del modelo GPT-2 dentro de la plataforma *Transformer Explainer* (Cho et al., 2024).




Figura 2.13: Distribución de probabilidad de salida del transformador. *Nota.* La figura muestra las probabilidades generadas por la capa final del modelo para predecir el siguiente *token*. Captura de pantalla del software de Cho et al. (2024).

2.2.3. Modelo BERT: Arquitectura y Aplicaciones

Los modelos de lenguaje basados en transformadores han demostrado un desempeño sobresaliente en diversas tareas de NLP. Dentro de esta familia de modelos se encuentra la Representación de Codificador Bidireccional de Transformadores (BERT, por sus siglas en inglés), propuesto por Devlin et al. (2018). Su eficacia radica en su capacidad para analizar el contexto completo de un texto, ya que su bidireccionalidad profunda permite que cada palabra tenga acceso tanto a su contexto anterior como posterior. Esto facilita la captura de matices semánticos complejos, lo que resulta especialmente útil en tareas como el Análisis de Sentimiento en textos especializados.

BERT se basa en la arquitectura de transformadores presentada por Vaswani et al. (2017), y está compuesto por una pila de codificadores, como se muestra en la Fig. 2.14. Existen dos configuraciones principales: BERT-Base, con doce capas de codificadores, y BERT-Large, que amplía la arquitectura a veinticuatro capas. Este incremento en el número de capas permite capturar representaciones contextuales más profundas y mejorar el rendimiento en tareas de Procesamiento del Lenguaje Natural.

La bidireccionalidad en BERT se refiere a su capacidad para analizar simultáneamente el contexto previo y posterior de cada palabra en una oración. Esto se logra mediante una

técnica denominada Modelado del Lenguaje Enmascarado (MLM, por sus siglas en inglés), en la que se ocultan aleatoriamente ciertas palabras de una oración y el modelo debe predecirlas utilizando información de ambos lados del contexto. Además, BERT incorpora una tarea adicional de entrenamiento denominada Predicción de la Siguiente Oración (NSP, por sus siglas en inglés), diseñada para mejorar la comprensión de relaciones entre frases en tareas como la inferencia textual y la búsqueda de información. En esta tarea, el modelo recibe dos oraciones y debe predecir si la segunda oración sigue de manera natural a la primera dentro del texto original.




Figura 2.14: Arquitectura del modelo BERT. *Nota.* La figura muestra la arquitectura general de un modelo BERT. Elaboración propia.

En el desarrollo de modelos de lenguaje, se han explorado dos enfoques principales para modelar el contexto en tareas NLP. El primero corresponde a modelos unidireccionales, los cuales utilizan un modelo autoregresivo, como GPT-1, desarrollado por Radford et al.

(2018), que generaba representaciones de palabras considerando únicamente el contexto previo, es decir, procesando el texto en una única dirección, a esto se conoce como atención causal, donde se restringe el mecanismo de atención para que cada palabra solo pueda conocer las palabras anteriores en la secuencia, evitando el conocimiento de palabras por delante de la misma. Aunque este enfoque es útil en tareas de generación de texto, donde la predicción se necesita de manera secuencial, limita la capacidad del modelo para capturar relaciones de largo alcance dentro de una oración, especialmente en contextos donde el significado depende de información posterior.

El segundo enfoque es la bidireccional superficial, donde el modelo utiliza redes neuronales recurrentes para capturar información del contexto anterior y posterior de cada palabra en la oración. Esto se logra mediante modelos de lenguaje bidireccional (biLM, por sus siglas en inglés), que evalúan cómo se usa una palabra considerando su contexto circundante. Sin embargo, este método no integra simultáneamente ambas direcciones en cada paso del procesamiento, sino que genera representaciones separadas del contexto previo y posterior, combinándolas posteriormente. Un ejemplo de este enfoque es ELMo, propuesto por Peters et al. (2018), el cual generaba *embeddings* contextuales a partir de redes de memoria de corto y largo plazo (LSTM, por sus siglas en inglés) bidireccionales. En este modelo, un LSTM hacia adelante procesaba la oración considerando el contexto anterior, mientras que un LSTM hacia atrás analizaba el contexto posterior. Sin embargo, estas representaciones permanecían separadas durante el procesamiento y solo se combinaban en la salida final, lo que impedía que el modelo integrara simultáneamente toda la información en cada capa. Este enfoque, aunque superior a los modelos unidireccionales, solo logra la integración contextual una vez que ambas direcciones se combinan en la fase final del procesamiento.

Para demostrar la importancia de la bidireccionalidad, consideremos las siguientes oraciones: “El banco de arena está en la playa” y “Voy a depositar dinero en el banco”, donde la palabra “banco” tiene significados completamente distintos. Un modelo unidireccional podría tener dificultades para inferir el significado correcto sin haber procesado la totalidad del contexto. Dado que un modelo bidireccional superficial genera representaciones separadas para el contexto anterior y posterior, la información necesaria para desambiguar el término banco se obtiene solo al combinar ambas direcciones en la salida. Por otro lado, BERT, al tener acceso a toda la información previa y posterior a la palabra “banco”, le permite contextualizar su significado desde el inicio del procesamiento.

La capacidad de BERT para capturar el contexto global de una oración ha demostrado ser altamente efectiva en tareas como el Análisis de Sentimiento. A diferencia de los enfoques tradicionales, BERT interpreta cómo cada término influye en el tono general

del texto, permitiendo una clasificación más precisa de opiniones positivas, negativas o neutrales. Esta ventaja ha sido validada empíricamente por Mann et al. (2023), quienes desarrollaron un modelo mejorado de BERT aplicado al Análisis de Sentimientos en Twitter, logrando una precisión del 96.44 incluso en conjuntos de datos reducidos.

2.2.4. FinBERT: Modelo Especializado para el Análisis de Sentimiento en Finanzas

El análisis contextual de un texto es fundamental, ya que permite determinar si su impacto es positivo, negativo o neutro. Sin embargo, el ámbito financiero presenta desafíos en su interpretación debido a la ambigüedad del lenguaje. Malo et al. (2014) destacan que la orientación semántica general de una oración pueda diferir de la polaridad de las palabras individuales que la componen, lo que implica que el sentimiento expresado en un texto no siempre puede inferirse directamente a partir de sus palabras.

Dado que muchas palabras en finanzas adquieren significados distintos según el contexto, el Análisis de Sentimiento en este campo requiere modelos especializados. Por ejemplo, términos como riesgo o volatilidad no son intrínsecamente negativos, pero su impacto depende de cómo se usen en la oración y del tono general del texto.

BERT es un modelo que generaliza el NLP al capturar las relaciones contextuales entre palabras dentro de un texto, lo que permite interpretar correctamente términos como “riesgo” o “volatilidad” según el contexto en el que aparecen. Esto es útil para el Análisis de Sentimiento financiero, donde la polaridad semántica no puede determinarse mediante el análisis de palabras aisladas. Sin embargo, el lenguaje financiero presenta desafíos adicionales, ya que muchas palabras adquieren significados distintos dependiendo del contexto en el que se utilicen.

A pesar de la capacidad de BERT para comprender el contexto, su entrenamiento de basa en corpus generales de texto como Wikipedia y BookCorpus, lo que representa una limitación cuando se analizan dominios especializados como las finanzas, donde el significado de ciertos términos puede diferir significativamente del uso cotidiano. Para abordar esta limitación, se han desarrollado versiones especializadas de BERT, entrenadas con datos financieros mediante técnicas de aprendizaje transferido (*transfer learning*, término en inglés), lo que permite adaptar el modelo sin modificar su arquitectura.

Uno de estos modelos es FinBERT, propuesto por Araci (2019). FinBERT es una adaptación de BERT diseñada específicamente para la interpretación de textos financieros. A diferencia del modelo base, que se entrena en corpus generales, FinBERT utiliza datos especializados que le permiten capturar con mayor precisión el lenguaje técnico y los matices del sector financiero.

Su entrenamiento se lleva a cabo en un subconjunto del *Reuters TRC2 dataset*, un corpus que incluye 46,143 documentos con más de 29 millones de palabras, lo que permite que FinBERT aprenda patrones lingüísticos propios del sector financiero. Para el Análisis de Sentimientos financiero, FinBERT se entrena con el *Financial PhraseBank*, un corpus de frases extraídas de reportes de mercado y clasificadas por expertos con etiquetas de polaridad positiva, negativa o neutral. Además, se utiliza el *FiQA Sentiment Dataset* que proporciona etiquetas de sentimiento continuo en un rango, permitiendo evaluar no solo la polaridad, sino también la intensidad del sentimiento expresado.

Para mejorar su desempeño, FinBERT no solo se entrena en datos financieros, sino que se somete a un pre-entrenamiento adicional en corpus financieros y un ajuste fino (fine-tuning, término en inglés) en tareas de clasificación de sentimiento. Durante este proceso, se aplican estrategias para evitar el *catastrophic forgetting*, como:

- *Gradual unfreezing*: las capas superiores se ajustan primero, mientras que las inferiores se descongelan progresivamente para retener información semántica previa.
- *Slanted triangular learning rate*: un esquema de tasa de aprendizaje que aumenta inicialmente y luego disminuye gradualmente para optimizar el ajuste fino.
- *Discriminative fine-tuning*: cada capa del modelo se ajusta con una tasa de aprendizaje diferente, permitiendo mayor flexibilidad en la adaptación al dominio financiero.

Gracias a este entrenamiento especializado, FinBERT logra identificar con mayor precisión el tono y la intención de textos financieros, evitando los errores de interpretación que pueden surgir cuando se aplican modelos generales como BERT a este dominio.

2.2.5. LLaMA 3: Generación y Razonamiento

La evolución de los modelos de Procesamiento de Lenguaje Natural ha pasado de una comprensión contextual del texto a modelos de nueva generación enfocados en generación, razonamiento complejo y procesamiento de información en contextos largos. Mientras que modelos basados en BERT han demostrado ser eficientes en tareas de análisis y clasificación de textos, la nueva generación, como LLaMA 3, desarrollado por Meta AI (2024), utiliza una arquitectura de solo decodificación basada en el transformador denso estándar Vaswani et al. (2017), como se ilustra en la Fig. 2.15.

A diferencia de otros modelos recientes que han explorado arquitecturas híbridas, LLaMA 3 mantiene la estructura de sus versiones anteriores LLaMA y LLaMA 2 (Touvron




Figura 2.15: Arquitectura del modelo LLaMA 3. *Nota.* La figura muestra la arquitectura general de un modelo *LLaMA 3*, elaborada por el autor con base en información disponible públicamente.

et al., 2023). Sus mejoras provienen principalmente de una mayor calidad y diversidad en los datos de entrenamiento, así como de una mayor escala de entrenamiento.

El proceso de tokenización utilizado en LLaMA 3 emplea un método basado en codificación de pares de bytes (BPE, por sus siglas en inglés), que segmenta el texto en subpalabras o fragmentos en lugar de utilizar palabras completas o caracteres individuales.

Esto mejora la eficiencia y la representación de palabras raras o compuestas, como se explica en el trabajo de (Sennrich et al., 2015).

Para manejar grandes volúmenes de datos y mantener la estabilidad del modelo, LLaMA 3 utiliza RMSNorm (*Root Mean Square Normalization*, término en inglés), una técnica de normalización propuesta por Zhang y Sennrich (2019). A diferencia de la normalización por capas (LayerNorm, por sus siglas en inglés), que ajusta la media y la escala de los valores de entrada, RMSNorm solo ajusta la escala, haciéndolo más eficiente sin comprometer la estabilidad del modelo.

Asimismo, LLaMA 3 incorpora un mecanismo mejorado de codificación posicional llamado *embeddings* posicionales rotatorios (RoPE, por sus siglas en inglés) método propuesto por Su et al. (2021). A diferencia de los mecanismos trigonométricos tradicionales, donde las posiciones absolutas se suman al *embedding* antes de ingresar al transformador, RoPE introduce rotaciones en un espacio vectorial, preservando la relación entre palabras mediante diferencias angulares. Esto permite que el modelo maneje contextos largos sin perder información sobre las relaciones entre *tokens*, mejorando el razonamiento y la coherencia en secuencias extensas.

Una forma de comprender cómo funciona RoPE es mediante la siguiente analogía: imaginemos un grupo de perros en un parque, cada uno atado a una estaca con una correa larga. Aunque pueden moverse libremente dentro de su radio, mantienen una relación espacial constante entre ellos. No importa si agregamos más perros o cambiamos sus posiciones dentro del área, cada uno sigue reconociendo a sus compañeros según su ángulo y distancia relativa.

Además de la representación eficiente de datos, es clave optimizar el acceso y procesamiento de información durante la inferencia. Para esto, LLaMA 3 implementa un mecanismo optimizado llamado *Multi-Query Attention* (MQA, por sus siglas en inglés), que reduce el costo computacional al compartir claves y valores entre todas las cabezas de atención.

Una analogía para entender este concepto sería imaginar que varias personas necesitan consultar información en una biblioteca. En la atención multi-cabezal (MHA, por sus siglas en inglés), cada persona tiene su propio conjunto de libros para una consulta independiente, lo que requiere más espacio de almacenamiento. En MQA, en cambio, todas las personas comparten una única biblioteca y simplemente hacen diferentes preguntas sobre los mismos libros. Esto hace que el proceso sea más eficiente, ya que se evita la duplicación innecesaria de los libros.

LLaMA 3 mejora MQA con *Grouped Multi-Query Attention* (GQA, por sus siglas en inglés), un mecanismo que combina características de MHA y MQA para lograr equilibrar

calidad y eficiencia en la generación de texto.

Retomando la analogía de la biblioteca, GQA representa un escenario en el que los lectores se organizan en grupos, y cada grupo comparte un conjunto de libros. Esto permite que las consultas sean más precisas que en MQA, sin necesidad de mantener bibliotecas separadas para cada persona, como ocurre en MHA.

Otro desafío en la generación de texto es el procesamiento de secuencias largas, ya que cada nuevo *token* requiere calcular las atenciones sobre todos los *tokens* previos, aumentando exponencialmente el costo computacional.

Para optimizar este proceso, LLaMA 3 emplea un mecanismo denominado KV Cache (*KV Cache*, término en inglés), que almacena en memoria los valores de atención previamente calculados. Gracias a KV Cache, LLaMA 3 puede generar respuestas más rápidamente, evitando cálculos redundantes y permitiendo una inferencia más eficiente, especialmente en diálogos extensos o en modelos con contextos largos.

Adicionalmente, LLaMA 3 incorpora *Swish-Gated Linear Unit* (SwiGLU, por sus siglas en inglés), una variante de las *Gated Linear Units* (GLU, por sus siglas en inglés) exploradas por Shazeer (2020), utilizada como función de activación en sus capas de redes neuronales prealimentadas (*Feed Forward*, término en inglés), una técnica inspirada en el modelo *Pathways Language Model* (PaLM, por sus siglas en inglés) desarrollado por Chowdhery et al. (2022). SwiGLU introduce un mecanismo de compuerta, que filtra y amplifica la información relevante antes de ser procesada.

Para comprender mejor el funcionamiento de SwiGLU, imaginemos una lámpara con un filtro de luz inteligente, donde el filtro ajusta automáticamente la intensidad y la dirección de la luz, enfocándose en las zonas más importantes y atenuando aquellas menos relevantes. En contraste, una lámpara sin este filtro iluminaría todo por igual, sin priorizar ninguna área en particular.

Estas mejoras en la arquitectura de LLaMA 3 permiten que el modelo genere texto de manera más coherente y eficiente, adaptándose mejor a contextos largos y capturando relaciones complejas entre palabras. Un factor a destacar en estos avances ha sido el uso de un conjunto de datos significativamente más amplio y diverso para el entrenamiento, que asciende a aproximadamente 15 billones de *tokens* multilingües, en comparación con los 1.8 billones utilizados en la versión anterior. Para garantizar la calidad del entrenamiento, se han implementado procesos rigurosos de preprocesamiento y curación de datos, así como estrategias de filtrado y aseguramiento de calidad.

Además, las decisiones de diseño han priorizado la estabilidad y escalabilidad del modelo. Se ha optado por una arquitectura estándar basada en el transformador denso con adaptaciones menores, en lugar de modelos más complejos, con el fin de maximizar

la estabilidad durante el entrenamiento.

Gracias a estas mejoras en calidad de datos y estrategias de entrenamiento, LLaMA 3 es capaz de generar texto con mayor precisión, coherencia y adecuación al contexto, convirtiéndose en una herramienta potente para tareas de generación de contenido y resumen automatizado de información en múltiples dominios.

2.3. Modelos de Lenguaje para la Generación de Reportes Financieros

El proceso de análisis en esta investigación combina múltiples fuentes de información con el objetivo de generar reportes detallados sobre el mercado de criptomonedas. Para ello, se integran datos estructurados y no estructurados mediante distintas técnicas de procesamiento.

Estudios han demostrado la capacidad de modelos avanzados como ChatGPT-4o para realizar análisis financieros cuantitativos, incluyendo series temporales, métricas de riesgo-retorno y estimaciones con modelos analíticos como ARMA-GARCH. Los resultados obtenidos han sido comparables a los de herramientas tradicionales como Stata (Feng et al., 2024).

Uno de los principales desafíos en el análisis del entorno financiero, especialmente en los criptomercados, es el manejo eficiente de grandes volúmenes de información textual no estructurada, como noticias y publicaciones en redes sociales. En este contexto, los Modelos Extensos de Lenguaje han demostrado ser herramientas eficaces para resumir información y detectar tendencias emergentes.

Por ejemplo, Lazarev y Sedov (2024) proponen un marco automatizado para la generación de reportes financieros utilizando LLMs como Gemini Pro. Su enfoque combina fuentes académicas, como OpenAlex una base de datos abierta y estructurada de publicaciones científicas, con técnicas de extracción de información y generación automática de resúmenes. Este modelo refuerza el valor de integrar análisis semántico con datos estructurados, permitiendo la entrega oportuna de información relevante para la toma de decisiones en entornos financieros complejos y dinámicos.

Esta investigación implementa un sistema que emplea Modelos Extensos de Lenguaje para la síntesis de noticias financieras, a partir de las cuales se realiza un Análisis de Sentimiento correspondiente a los días previos a cada reporte. Dicho análisis se integra con indicadores técnicos derivados de datos *OHLCV*, con el objetivo de generar reportes automatizados que apoyen la interpretación del comportamiento del mercado de criptomonedas.

Un componente fundamental en el procesamiento de estos datos es el uso del *prompt*,

el cual determina la manera en que se consulta y se extrae información de modelos como LLaMA. Un *prompt* es una instrucción estructurada que guía la generación de respuestas del modelo. Como se explicó en la Sección 2.2, la efectividad de estos modelos depende en gran medida del contexto y la calidad de la información suministrada en el *prompt*. La claridad y especificidad con que se formule esta entrada afecta directamente la relevancia y utilidad del contenido generado.

El diseño y optimización de las instrucciones utilizadas en este sistema se realizó mediante técnicas de ingeniería de *prompt* (*prompt engineering*, término en inglés), consideradas fundamentales para controlar la coherencia factual, reducir alucinaciones analíticas y mejorar la precisión de las respuestas en contextos financieros críticos (P. Liu et al., 2021).

Existen distintos tipos de *prompts*, como los instructivos, de demostración, con ejemplos o mediante plantillas estructuradas. Cada tipo presenta características particulares que se ajustan a tareas específicas dentro del Procesamiento de Lenguaje Natural. Según lo señalado por P. Liu et al. (2021), la elección del tipo de *prompt* influye directamente en la calidad, consistencia y coherencia de las salidas generadas. En esta investigación se empleó un *prompt* estructurado y compuesto, dada su capacidad para tareas orientadas a la generación automatizada de reportes financieros, ya que permite integrar de manera coherente información cuantitativa y textual bajo una lógica de síntesis contextualizada.

En concreto, los *prompts* fueron diseñados para producir resúmenes financieros concisos, facilitando su integración con los datos cuantitativos del Análisis Técnico. Además, se contempla la generación de un *prompt* compuesto que combine la información derivada de noticias financieras con indicadores técnicos, con el propósito de obtener interpretaciones más completas sobre las condiciones del mercado.

En términos de clasificación, el *prompt* utilizado en esta investigación puede describirse como:

- Estructurado manualmente: Elaborado a partir de una plantilla definida explícitamente por el usuario, con una estructura fija que organiza la entrada de forma clara.
- Compuesto: Integra información cuantitativa, como indicadores técnicos del mercado, con datos cualitativos provenientes de noticias financieras, logrando un resumen coherente.
- Orientado a tareas: Diseñado con el propósito específico de ejecutar una función determinada; en este caso, generar reportes técnicos automatizados.

- Few-shot: Se apoya en uno o más ejemplos específicos incluidos en la instrucción para guiar al modelo sobre el formato, tipo de respuesta o patrón esperado, mejorando así su desempeño en tareas particulares.

Esta estrategia de diseño de *prompts* permite explotar las capacidades semánticas y generativas de los Modelos Extensos de Lenguaje, alineándolos con los objetivos específicos del análisis financiero automatizado en criptomercados.

2.4. Limitaciones de los Modelos de Lenguaje: Alucinaciones y Confiabilidad

Los Modelos Extensos de Lenguaje han demostrado una notable capacidad para generar texto coherente y contextualizado. No obstante, una de sus principales limitaciones es su propensión a producir contenido que no refleja hechos verificables, fenómeno conocido como alucinación (*hallucination*, término en inglés). Este problema es particularmente relevante en tareas de resumen abstractivo, como las implementadas en esta investigación, donde el modelo no se limita a extraer fragmentos del texto fuente, sino que construye una versión condensada mediante lenguaje natural generado automáticamente.

Según la taxonomía propuesta por Ji et al. (2022), las alucinaciones pueden clasificarse en dos tipos principales: intrínsecas, cuando el contenido generado contradice directamente la información de entrada, y extrínsecas, cuando el modelo introduce información no respaldada por el texto original o por conocimiento verificable. Estos errores pueden derivarse de deficiencias en la cobertura del corpus de entrenamiento, sesgos estadísticos, ambigüedades semánticas o una priorización excesiva de la fluidez lingüística por encima de la consistencia factual (*factual consistency*, término en inglés).

En el contexto de los resúmenes financieros generados con LLaMA, las alucinaciones extrínsecas pueden manifestarse como afirmaciones sobre movimientos de mercado, sentimiento o desarrollos regulatorios que no están presentes en la noticia original. Este tipo de errores no solo compromete la calidad del contenido generado, sino que también puede distorsionar la percepción del estado del mercado. Por tanto, se vuelve indispensable implementar mecanismos que mitiguen este riesgo y aseguren la utilidad analítica de los reportes producidos.

Además de la generación de afirmaciones textuales incorrectas en tareas de resumen, los Modelos Extensos de Lenguaje presentan riesgos de alucinación en la interpretación de datos estructurados, como indicadores financieros o métricas cuantitativas. Estudios recientes, como el de M. Liu et al. (2025), han evidenciado que estas alucinaciones afectan incluso tareas de razonamiento matemático formal, donde el modelo, a pesar de recibir datos correctos, genera inferencias inconsistentes. De manera similar, también

se ha observado que los modelos tienden a cometer errores de interpretación al evaluar relaciones entre medias móviles o indicadores de *momentum*, afectando la fidelidad de las inferencias técnicas generadas.

Diversas estrategias fueron incorporadas desde el diseño del sistema para mitigar los riesgos de alucinación analítica:

- Validación cruzada de afirmaciones: se contrastan las inferencias generadas con indicadores técnicos derivados de datos *OHLCV*, permitiendo verificar su coherencia cuantitativa.
- Evaluación de la confiabilidad de las fuentes: se utiliza una métrica interna de reputación basada en la frecuencia de publicación, el Análisis de Sentimiento y la cobertura temática de cada fuente.
- Restricción de longitud en los resúmenes: se limita la salida del modelo a un máximo de 512 caracteres, lo que reduce la posibilidad de introducir afirmaciones complejas no verificadas.

Estas medidas, si bien no eliminan por completo el riesgo de alucinación, están alineadas con las recomendaciones actuales de la literatura, que destacan la eficacia de estrategias como la verificación factual, el filtrado de fuentes y la penalización de generación inconsistente. Su implementación dentro del sistema responde a la necesidad de mantener la precisión, trazabilidad y confiabilidad en la generación automatizada de reportes financieros, especialmente en contextos donde las decisiones pueden verse influenciadas por contenido generado de forma automática.

3. Capítulo: Metodología

La presente metodología se basa en la integración de datos estructurados y no estructurados para analizar de forma combinada las condiciones del mercado de criptomonedas. Por un lado, se recopilan noticias financieras relevantes en idioma inglés mediante las herramientas GNews (Abdullah, 2025) y NewsCatcher News API v3 (Newscatcher, 2024), las cuales permiten automatizar la adquisición de contenidos textual desde fuentes reputadas. Por otro lado, se obtienen datos históricos de precios y volumen desde el exchange Binance, empleando la biblioteca *ccxt* (Ccxt, 2025).

Los datos no estructurados se procesan mediante técnicas de Procesamiento de Lenguaje Natural, utilizando modelos avanzados como FinBERT para el Análisis de Sentimiento, y LLaMA para la generación automática de resúmenes y la evaluación temática del contenido. Paralelamente, los datos estructurados se transforman en indicadores técnicos como el Índice de Fuerza Relativa, el MACD, el Rango Promedio Verdadero, las Bandas de Bollinger y la Media Móvil Exponencial, entre otros.

La combinación de estos enfoques permite identificar patrones emergentes, evaluar la volatilidad del mercado y ponderar el impacto de la información financiera según su origen, tono editorial y consistencia temporal. Esta estructura metodológica constituye la base para el desarrollo del sistema automatizado de generación de reportes, descrito en los apartados posteriores.

En lo que sigue, se hará referencia al modelo LLaMA como parte del flujo de Procesamiento de Lenguaje Natural. Salvo que se indique explícitamente lo contrario, todas las menciones a LLaMA corresponden a su versión 3.1.

3.1. Tipo de Investigación

Esta investigación es de tipo cuantitativa y aplicada, ya que busca evaluar el impacto de integrar el Procesamiento de Lenguaje Natural y el Análisis Técnico en la interpretación de tendencias del mercado de criptomonedas. Se adopta un enfoque exploratorio y descriptivo, dado que se analizan patrones presentes en datos financieros y en noticias con el objetivo de generar información procesable para los inversionistas.

Para ello, se emplean técnicas de aprendizaje automático, Análisis de Sentimiento financiero y herramientas de Análisis Técnico basadas en indicadores cuantitativos, con el fin de evaluar la precisión y utilidad de los reportes generados.

3.2. Adquisición y Almacenamiento de Datos

Esta investigación integra dos tipos principales de datos: por un lado, datos no estructurados, correspondientes a noticias financieras en texto libre; y por otro, datos estructurados, relacionados con precios e indicadores técnicos del mercado de criptomonedas. Ambos conjuntos fueron recolectados mediante herramientas especializadas y almacenados en una base de datos relacional utilizando SQLite. En las secciones siguientes se describen las fuentes consultadas, los métodos de adquisición empleados y las variables consideradas, como parte del proceso metodológico necesario para preparar los datos que serán procesados y analizados en función del objetivo de esta investigación.

3.2.1. Noticias Financieras

Para la recopilación de noticias financieras en idioma inglés se emplearon dos herramientas principales: NewsCatcher News API versión 3 y el paquete de Python GNews versión 0.4.0.

NewsCatcher es una solución de nivel empresarial orientada a equipos de ciencia de datos que requieren acceder a noticias relevantes de forma estructurada. Esta API devuelve resultados en formato JSON, con campos como título, resumen, autor, fecha de publicación y URL, lo que facilita su integración en flujos automatizados de análisis de texto.

Por su parte, GNews proporciona acceso al contenido de Google News, permitiendo realizar búsquedas por palabras clave y extraer el contenido completo de los artículos sin necesidad de aplicar técnicas de *web scraping*.

Ambas herramientas permiten ejecutar búsquedas temáticas automatizadas mediante términos como *Bitcoin*, *Ethereum*, regulación cripto y *stablecoins*, programadas para su ejecución diaria. Las respuestas incluyen metadatos relevantes como el título, resumen, autor, fecha de publicación y URL, los cuales posteriormente se almacenan en una base de datos SQLite.

A partir del conjunto inicial de artículos identificados como noticias relevantes del criptomercado, se aplicaron filtros sucesivos con el objetivo de depurar la muestra y asegurar la calidad del análisis. En primer lugar, se excluyeron aquellas noticias provenientes

de sitios considerados poco confiables, como blogs o portales conocidos por difundir desinformación. Esta depuración inicial se realizó de forma empírica mediante una lista manual de dominios excluidos, lo que redujo el conjunto al 47 % del total original.

Posteriormente, se conservaron únicamente aquellas que contenían el texto completo, requisito necesario para aplicar técnicas de NLP, lo que representó el 42 % del total inicial. Finalmente, se seleccionaron las noticias cuyo contenido estaba temáticamente alineado al criptomercado, obteniendo así un subconjunto correspondiente al 39 %. La Fig. 3.1 resume visualmente las etapas aplicadas durante este proceso de filtrado, que incluye criterios de confiabilidad, completitud y relevancia temática.



Figura 3.1: Embudo de filtrado de noticias del criptomercado. *Nota.* Elaboración propia.

De manera complementaria, la Fig. 3.2 presenta el flujo general de extracción, filtrado y almacenamiento de noticias no estructuradas, desde su adquisición hasta su incorporación en la base de datos. Este proceso automatizado recolecta contenido desde GNews y NewsCatcher, aplica filtros temáticos iniciales y almacena los resultados relevantes en la base de datos para su posterior análisis.

3.2.2. Resumen Automático y Evaluación de Relevancia

El sistema implementado realiza un procedimiento automatizado en Python que detecta noticias sin resumen y genera uno nuevo utilizando el modelo de lenguaje LLaMA, descrito en la Sección 2.2.5. Este modelo produce un texto resumido con una longitud máxima de 512 caracteres, con el fin de estandarizar el contenido y asegurar su compatibilidad con los modelos posteriores de Análisis de Sentimiento.



Figura 3.2: Flujo de recopilación de noticias financieras. *Nota.* Elaboración propia.

El contenido del *prompt* utilizado para esta tarea se presenta en el Listado 3.1. Este se genera de forma dinámica para cada noticia detectada e incluye instrucciones precisas sobre el rol del modelo, el tono esperado en la respuesta y los criterios de exclusión temática, con el fin de garantizar la coherencia y relevancia de los resúmenes en el contexto del criptomercado.

```

1      **Task:** Summarize the article below in **<512 characters**.
2      **Role:** You are a crypto market analyst.
3      **Focus on:**
4          - Market impact and price changes
5          - Regulatory updates
6          - Investor sentiment
7          - Tech or industry developments
8      **Tone:** Neutral and professional.
9      **If unrelated to crypto, blockchain, or digital assets, reply:** "Not
      crypto-related news."
10     **Article:**
11     "{content}"
  
```

Listado 3.1: Prompt utilizado para la generación de resúmenes automáticos con validación temática.

Además del resumen, LLaMA aplica razonamiento contextual para determinar si el contenido es temáticamente relevante para el criptomercado. Si la noticia es considerada pertinente, el resumen generado se almacena en la base de datos junto con los metadatos originales. En caso contrario, se asigna la etiqueta *Not crypto-related news* y se descarta

el contenido para las etapas posteriores del análisis.

Este proceso permite optimizar los recursos computacionales al filtrar de forma anticipada contenidos irrelevantes, al mismo tiempo que normaliza los textos de entrada para su uso en el Análisis de Sentimiento con FinBERT y en el cálculo de la reputación de las fuentes.

La Fig. 3.3 representa visualmente este flujo de trabajo automatizado. El sistema identifica los registros sin resumen y emplea LLaMA para generar uno nuevo, aplicando razonamiento contextual para validar si el contenido es relevante para el criptomercado. En función del resultado, la base de datos se actualiza con el resumen generado o con la etiqueta *Not crypto-related news*.




Figura 3.3: Flujo de generación de resúmenes y validación temática con LLaMA. *Nota.* Elaboración propia.

3.2.3. Datos de Mercado

Los datos históricos de precios y volumen fueron obtenidos desde el exchange Binance, a través de la biblioteca *ccxt*. Se descargaron registros *OHLCV* con frecuencia diaria, correspondientes al periodo comprendido entre enero de 2021 y la fecha actual. Cada registro contiene la siguiente información:

- Precio de apertura, cierre, máximo y mínimo del día.
- Volumen total de transacciones realizadas con BTC, expresado en dólares estadounidenses (USDT, por sus siglas en inglés).
- Marca temporal en formato UNIX, posteriormente convertida a fechas legibles.

La biblioteca *ccxt* ofrece una interfaz unificada para acceder a datos de mercado y operar con múltiples plataformas de intercambio de criptomonedas. Está orientada a desarrolladores, analistas financieros y científicos de datos, ya que permite automatizar la adquisición, almacenamiento, análisis y visualización de información, incluyendo el desarrollo, prueba y validación de algoritmos de *trading* personalizados.

Los datos recolectados permiten calcular indicadores técnicos sobre ventanas móviles y sincronizarlos con los Análisis de Sentimiento semanales, generando una representación integrada de las condiciones del mercado. Esta combinación de datos estructurados y no estructurados constituye la base para el desarrollo del Análisis Técnico y de sentimiento que se detalla en los apartados siguientes.

El flujo general de recopilación y almacenamiento de datos estructurados se representa en la Fig. 3.4. Este proceso automatizado obtiene datos de mercado desde Binance, aplica un procesamiento inicial y los almacena en una base de datos estructurada para su posterior Análisis Técnico y generación de reportes.




Figura 3.4: Flujo de recopilación de datos estructurados. *Nota.* Elaboración propia.

3.3. Procesamiento de Datos

Una vez adquiridos y gestionados los datos provenientes de noticias financieras y precios de mercado, se ejecuta una serie de procesos destinados a depurarlos, analizarlos y consolidarlos. Esta sección describe las etapas involucradas en el procesamiento de datos, desde la organización inicial de la base de datos hasta la integración de variables

estructuradas y no estructuradas que serán utilizadas como entrada para la generación automatizada de reportes de mercado.

3.3.1. Estructura y Limpieza de la Base de Datos

La base de datos implementada en SQLite (Hipp, 2023) centraliza los registros de noticias y datos de mercado, con el objetivo de facilitar el acceso y la trazabilidad de la información durante las fases de análisis. Esta estructura contiene tablas separadas donde se almacenan noticias, indicadores técnicos, resultados de Análisis de Sentimiento y métricas de reputación, tal como se muestra en la Fig. 3.5, que presenta el modelo entidad-relación correspondiente al sistema propuesto.

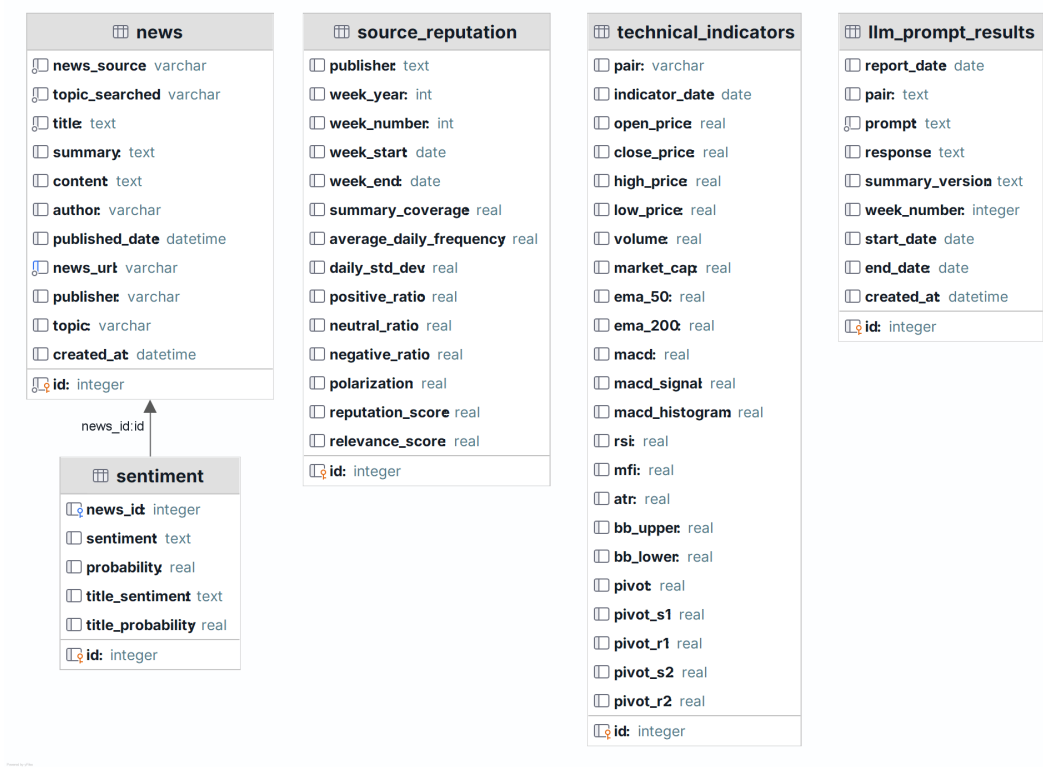


Figura 3.5: Modelo entidad-relación de la base de datos utilizada. *Nota.* Elaboración propia.

Durante la fase de limpieza, se aplican filtros automáticos para eliminar registros duplicados, artículos con campos vacíos como título, contenido o fecha de publicación y aquellos provenientes de fuentes no confiables. También se normalizan los formatos de fecha y texto, y se asegura la coherencia en campos clave como el nombre del proveedor y la estructura temática de los registros.

3.3.2. Clasificación de Sentimiento

Una vez generado el resumen automático de las noticias, se aplica FinBERT, un modelo de Análisis de Sentimiento optimizado para textos del dominio financiero, descrito en la Sección 2.2.4. Este modelo clasifica cada registro en tres categorías: positivo, negativo o neutral, y asigna una probabilidad a cada una. Se conserva únicamente la etiqueta con mayor probabilidad, la cual se almacena en la base de datos junto con el resumen correspondiente. Estas etiquetas se utilizan posteriormente en el cálculo de la polaridad del mercado y en la evaluación de la reputación de las fuentes informativas.

La Fig. 3.6 ilustra este proceso de clasificación automatizada.




Figura 3.6: Clasificación de sentimiento con FinBERT. *Nota.* Elaboración propia.

3.3.3. Evaluación de Reputación y Relevancia de Fuentes

Con el objetivo de identificar medios influyentes y confiables dentro del ecosistema informativo del criptomercado, se implementó un proceso automatizado en Python que calcula semanalmente métricas de reputación y relevancia a nivel de fuente. Este procedimiento se aplica exclusivamente a aquellas noticias cuyo resumen fue generado mediante LLaMA y etiquetado como relevante para el análisis.

En una primera etapa, se consultan los registros almacenados en la base de datos correspondientes a un intervalo semanal específico, mediante una consulta parametrizada por fechas. A partir de esta selección, se calcula un conjunto de indicadores para cada

fuentes informativas, con el fin de caracterizar su línea editorial y su impacto potencial sobre la percepción del mercado. Las variables consideradas son las siguientes:

- El porcentaje de noticias con resumen generado, expresado como la proporción de artículos procesados exitosamente mediante el modelo de resumen automático respecto al total de publicaciones de la fuente durante la semana.
- La frecuencia media de publicaciones diarias, expresada como el número promedio de noticias emitidas por día.
- La desviación estándar de publicaciones diarias, que mide la variabilidad en el número de artículos publicados por día.
- La distribución de sentimientos, calculada como la proporción de noticias clasificadas con polaridad positiva, neutral o negativa. Estas proporciones son valores normalizados entre 0 y 1.
- El grado de polarización, definido como la diferencia relativa entre los porcentajes de noticias positivas y negativas; representa la intensidad de las posturas editoriales.

A partir de estas variables, se calcula un puntaje de reputación semanal mediante una fórmula empírica que pondera la cobertura, regularidad y tono de la fuente. Posteriormente, se deriva un puntaje de relevancia como el producto entre la reputación y la polarización, con el objetivo de identificar fuentes influyentes cuya postura editorial pueda tener mayor impacto analítico. Los resultados se almacenan en la tabla de la base de datos, asociados al año, número de semana, y rango de fechas correspondiente.

$$R_{\text{news}} = \left(\frac{s_r}{100} \right) \cdot f_r \cdot (p_s + 0.3 \cdot n_s - 0.4 \cdot g_s) \quad (3.1)$$

Donde:

- R_{news} representa el puntaje de reputación, una magnitud adimensional que sintetiza el desempeño semanal de una fuente informativa.
- s_r es el porcentaje de noticias con resumen generado, con valores entre 0 y 100.
- f_r corresponde a la frecuencia media de publicaciones diarias, expresada en número de noticias por día.
- p_s , n_s y g_s indican las proporciones relativas de artículos con sentimiento positivo, neutral y negativo, respectivamente; todos son valores entre 0 y 1.

Esta expresión pondera la calidad percibida de cada fuente considerando su regularidad editorial, cobertura informativa y tono general. Adicionalmente, se calcula un índice de relevancia, definido como el producto entre reputación y polarización, con el fin de identificar fuentes que no solo tienen alta actividad y consistencia, sino también una postura editorial marcada respecto al mercado.

Los resultados obtenidos se almacenan semanalmente en una tabla adicional de la base de datos, lo que permite realizar un seguimiento longitudinal, es decir, semana a semana, de la línea editorial adoptada por cada fuente, así como de la estabilidad en sus patrones discursivos a lo largo del tiempo.

Este procedimiento se apoya en pasos previos del sistema, que incluyen:

- Limpieza de noticias: se filtran duplicados y se excluyen artículos sin contenido suficiente o provenientes de dominios poco confiables.
- Generación de resúmenes: se utiliza LLaMA para resumir la información de cada noticia en un máximo de 512 caracteres.
- Clasificación de sentimiento: se emplea FinBERT para etiquetar los resúmenes como positivos, negativos o neutrales. Con base en estos resultados se calcula la polaridad semanal.
- Evaluación de confiabilidad: se pondera la relevancia de cada noticia según la reputación histórica de su fuente, fortaleciendo la interpretación contextual de la información.

La Fig. 3.7 ilustra el flujo general del proceso, desde la consulta semanal de noticias hasta el cálculo de métricas editoriales y su almacenamiento para análisis longitudinal.

3.3.4. *Cálculo de Indicadores Técnicos*

Con base en los datos estructurados obtenidos desde el exchange Binance, mediante la biblioteca *ccxt*, se calcularon diversos indicadores técnicos con el propósito de caracterizar cuantitativamente las condiciones del mercado. Estos indicadores se aplican sobre ventanas móviles construidas a partir de datos OHLCV, y los resultados se almacenan en la base de datos para su análisis conjunto con las variables de sentimiento.

Los indicadores implementados fueron los siguientes:

- Media Móvil Exponencial: se calcularon las EMA de 50 y 200 días para identificar tendencias de mediano y largo plazo.




Figura 3.7: Flujo del cálculo de reputación y relevancia. *Nota.* Elaboración propia.

- Media Móvil de Convergencia/Divergencia: se definió como la diferencia entre las EMA de 12 y 26 días, junto con su línea de señal, correspondiente a una EMA de 9 días del MACD.
- Índice de Fuerza Relativa: se calculó con una ventana de 14 días para evaluar condiciones de sobrecompra o sobreventa en los precios.
- Índice de Flujo de Dinero: incorporó tanto precio como volumen para detectar posibles divergencias entre el movimiento del precio y el flujo de capital.
- Rango Promedio Verdadero: se utilizó como medida de volatilidad, evaluando la amplitud de las variaciones de precio a lo largo de una ventana de 14 días.
- Bandas de Bollinger: se construyeron a partir de una media móvil simple de 20 días y su respectiva desviación estándar, delimitando así rangos de oscilación típicos.
- Punto Pivote Principal: se calculó a partir del promedio del máximo, mínimo y precio de cierre del día anterior, utilizado para definir posibles niveles de soporte y resistencia.

Estos indicadores fueron implementados en Python mediante bibliotecas como `pandas` versión 2.2.3 (McKinney, 2010) y `pandas-ta` versión 0.3.14b para el cálculo de indicadores

técnicos (Johnson, 2024). Sus resultados se almacenaron en la tabla *technical indicators* de la base de datos SQLite. Este almacenamiento permite su integración sistemática con los análisis semanales de sentimiento, contribuyendo a la generación automatizada de reportes descrita en la Sección 3.4.

La Fig. 3.8 ilustra el flujo de procesamiento asociado al cálculo e integración de estos indicadores. El proceso parte de la lectura de registros OHLCV almacenados en la base de datos, sobre los cuales se aplican las transformaciones correspondientes utilizando ventanas móviles predefinidas para obtener métricas como EMA, MACD, RSI, MFI y ATR. Finalmente, los resultados se integran en la tabla *technical indicators*, donde quedan disponibles para su posterior sincronización con el Análisis de Sentimiento.




Figura 3.8: Flujo de cálculo de indicadores técnicos. *Nota.* Elaboración propia.

3.3.5. Integración de Datos

La generación automatizada de reportes parte de la integración de datos estructurados y no estructurados, obtenidos a partir de diferentes fuentes y con distintas frecuencias de actualización. Los datos estructurados incluyen precios históricos, volumen y una serie de indicadores técnicos derivados de registros OHLCV, mientras que los datos no estructurados corresponden a variables obtenidas del procesamiento de noticias financieras, como el Análisis de Sentimiento, la reputación de las fuentes y la polaridad neta semanal.

Para cada día en que se genera un reporte, el sistema consulta los valores más recientes de indicadores técnicos como MACD, EMA o RSI, con el fin de asegurar que

el análisis refleje las condiciones actuales del mercado. De manera complementaria, se incorporan métricas agregadas a nivel semanal derivadas del análisis de noticias, las cuales proporcionan una visión contextual sobre el tono informativo dominante y el comportamiento editorial de las fuentes durante ese periodo.

Ambos conjuntos de variables son integrados en un *prompt* plantilla, en la cual cada sección contiene etiquetas delimitadas entre llaves dobles '{{...}}'. Estas etiquetas son reemplazadas automáticamente por los valores correspondientes, conformando así la entrada estandarizada que se entrega al modelo generador de reportes.

La Fig. 3.9 resume este proceso, mostrando cómo convergen las consultas sobre datos de mercado recientes y métricas semanales provenientes del análisis de noticias. El sistema combina indicadores técnicos actualizados con información de sentimiento y reputación, generando una entrada compuesta que alimenta al modelo de lenguaje LLaMA para la generación automatizada de reportes.

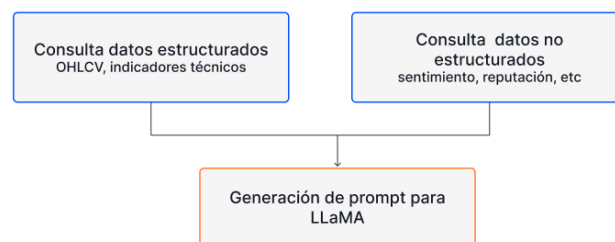


Figura 3.9: Flujo de integración de datos estructurados y no estructurados. *Nota.* Elaboración propia.

A continuación, se presentan los segmentos que componen el *prompt* utilizado por el sistema para generar los reportes financieros. Cada uno de estos fragmentos cumple una función específica dentro de la solicitud enviada al modelo LLaMA, comenzando por la definición de contexto, la incorporación de datos estructurados y no estructurados, y finalizando con una instrucción clara sobre el formato de salida.

El fragmento inicial, mostrado en el Listado 3.2, establece el contexto general de la tarea, definiendo al modelo como un analista financiero especializado en criptomercados. Además, se especifica que su respuesta debe mantener un tono neutral y profesional, y que el objetivo es integrar información técnica, Análisis de Sentimiento y reputación de fuentes en un resumen estructurado.

- 1 You are a financial analyst specialized in cryptocurrency markets. Your task is to generate structured, data-driven reports that integrate technical indicators, sentiment analysis, and, when relevant-economic context.
- 2 Your tone must remain neutral, objective, and professional throughout the report.
- 3 Avoid using technical language, detailed statistics, or direct quotes from data tables. Use plain language summaries that are understandable to a general audience.

Listado 3.2: Fragmento del prompt: contexto del modelo.

El fragmento contenido en el Listado 3.3 proporciona una descripción general de las condiciones actuales del mercado. Incluye métricas como el precio actual, el precio de apertura, los valores máximo y mínimo en 24 horas, el cambio porcentual diario, el volumen de operaciones y la capitalización de mercado. Esta sección cumple una doble función: por un lado, contextualiza el estado reciente del activo analizado; y por otro, proporciona al modelo LLaMA una base numérica clara sobre la cual fundamentar sus observaciones. Las variables incluidas son extraídas directamente desde registros diarios OHLCV y normalizadas para su integración en el *prompt*.

```

1  ## **Overview**
2
3  Summarize the intraday behavior of the asset using the following metrics:
4  - **Date:** {{report_date}}
5  - **Pair:** {{pair}}
6  - **Current Price:** {{current_price}}
7  - **Opening Price:** {{opening_price}}
8  - **24h High/Low:** {{high_24h}} / {{low_24h}}
9  - **Daily Change:** {{daily_change}}%
10 - **Trading Volume:** {{volume}}
11 - **Market Cap:** {{market_cap}}
```

Listado 3.3: Fragmento del prompt: descripción general del mercado.

El fragmento contenido en el Listado 3.4 integra los principales indicadores técnicos derivados de los datos de precios y volumen, cuyas definiciones y métodos de cálculo se detallan en la Sección 2.1.2. Esta sección del *prompt* proporciona al modelo LLaMA una representación cuantitativa del comportamiento técnico del activo, facilitando una interpretación automatizada de tendencias, *momentum*, volatilidad y niveles clave del mercado.

```

1      **Indicator Values:**
2
3      - **EMA 50:** {{ema50}}, **EMA 200:** {{ema200}}
4      - **MACD Line:** {{macd}}, **Signal Line:** {{macd_signal}},
        **Histogram:** {{macd_histogram}}
5      - **RSI:** {{rsi}}
6      - **MFI:** {{mfi}}
7      - **Bollinger Bands:** Upper = {{bb_up}}, Lower = {{bb_lw}}
8      - **ATR (Volatility):** {{atr}}
9      - **Support/Resistance Levels:**
10         - **S1** = {{pivot_s1}}, **R1** = {{pivot_r1}}
11         - **S2** = {{pivot_s2}}, **R2** = {{pivot_r2}}

```

Listado 3.4: Fragmento del prompt: entrada estructurada para Análisis Técnico.

El Listado 3.5 incorpora una versión resumida de las reglas de interpretación técnica que el modelo debe considerar al generar los reportes. Estas instrucciones refuerzan la consistencia analítica del sistema, guiando al modelo en la detección de señales relevantes como cruces de medias móviles, divergencias de MACD o condiciones de sobrecompra según RSI. La fundamentación detallada de estas reglas y su interpretación puede consultarse en la Sección 2.1.2.

- 1 Use the following technical indicators to assess market behavior. Brief
 2 definitions and interpretation rules are provided:
- 3 – **EMA 50 / EMA 200**: If EMA 50 > EMA 200, the trend is bullish. A wide
 4 and growing gap confirms bullish strength. Do not describe the trend
 as weakening or bearish when EMA 50 is above EMA 200, regardless of
 price movement or MACD.
 - 5 – Always assume the EMA 50 and EMA 200 values as given. Do not modify,
 infer, or adjust their magnitude.
 - 6 – Do not suggest a trend reversal unless EMA 50 crosses below EMA 200.
 Weakening \textit{momentum} can suggest corrections, not full
 reversals.
 - 7 – **MACD**: Measures \textit{momentum}. Positive histogram and MACD above
 signal line suggest upward \textit{momentum}.
 - 8 – **RSI**: Oscillator for overbought/oversold signals. Values >= 70 =
 overbought; <= 30 = oversold.
 - 9 – **RSI**: Oscillator for overbought/oversold signals. Values >70 =
 overbought; <30 = oversold. Mid-range values suggest neutrality.
 - 10 – **MFI**: Volume-weighted \textit{momentum}. >80 = strong buying; <20 =
 strong selling.
 - 11 – MFI values between 20 and 80 suggest neutral volume dynamics. Do not
 describe strong buying or selling pressure unless MFI > 80 or < 20.
 - **Bollinger Bands**: Measure volatility. Touching or exceeding a band
 confirms breakout potential; staying inside suggests consolidation or
 trend continuation.
 - **ATR**: Quantifies market volatility. Higher ATR = more volatility.

Listado 3.5: Fragmento del prompt: reglas de interpretación técnica.

El Listado 3.6 incorpora la entrada no estructurada del *prompt*, correspondiente a variables obtenidas del procesamiento automatizado de noticias financieras. Estas variables incluyen la polaridad semanal del sentimiento, el puntaje de reputación de las fuentes y el índice de polarización informativa. Los valores representados son el resultado del procesamiento previo de Análisis de Sentimiento y evaluación de confiabilidad descrito en las secciones metodológicas anteriores. Su inclusión dentro del *prompt* permite al modelo LLaMA contextualizar el entorno informativo más allá de los datos técnicos, aportando una dimensión cualitativa a la interpretación del mercado.

```

1      **Interpret market sentiment using weekly aggregated data from financial
      publishers.** Each source is evaluated using three core dimensions:
2      – **Polarization**:: Indicates strength of bias. Values >
        {{upper_polarization}} or < {{lower_polarization}} suggest strong
        bias (positive or negative).
3      – **Reputation**:: Reflects consistency, accuracy, and historical
        credibility of the source.
4      – **Relevance**:: Measures how closely the content relates to the current
        market or asset.
5      – **Significant signals** should come from sources with reputation >
        {{reputation_threshold}} and moderate or low polarization.

```

Listado 3.6: Fragmento del *prompt*: entrada no estructurada.

El Listado 3.7 presenta una versión condensada de la instrucción final del *prompt*, en la que se especifica la estructura general, el estilo de redacción y el objetivo de la respuesta esperada. Este diseño busca garantizar reportes breves, consistentes y centrados en el Análisis Técnico y de Sentimiento, alineados con los principios metodológicos del sistema propuesto.

```

1      ## **Observations**
2
3      Write an executive summary for {{report_date}} that synthesizes the key
      insights from the previous sections.
4      Comment on whether technical indicators and sentiment are aligned or
      contradictory. Identify potential shifts in market posture—such as
      indecision, trend exhaustion, breakout pressure, or consolidation. If
      relevant, briefly reference macroeconomic or regulatory events that
      may influence the asset's behavior.
5
6      **Important:** Do not generate any additional sections or headings beyond
      those explicitly listed.

```

Listado 3.7: Fragmento del *prompt*: formato resumido para la respuesta generada.

3.4. Generación Automática de Reportes

Esta sección describe la etapa final del sistema propuesto, en la cual se generan reportes automatizados a partir de los datos previamente procesados. El objetivo de esta fase es producir un resumen conciso y contextualizado de las condiciones del criptomercado, integrando tanto los indicadores técnicos como el Análisis de Sentimiento derivado de noticias financieras.

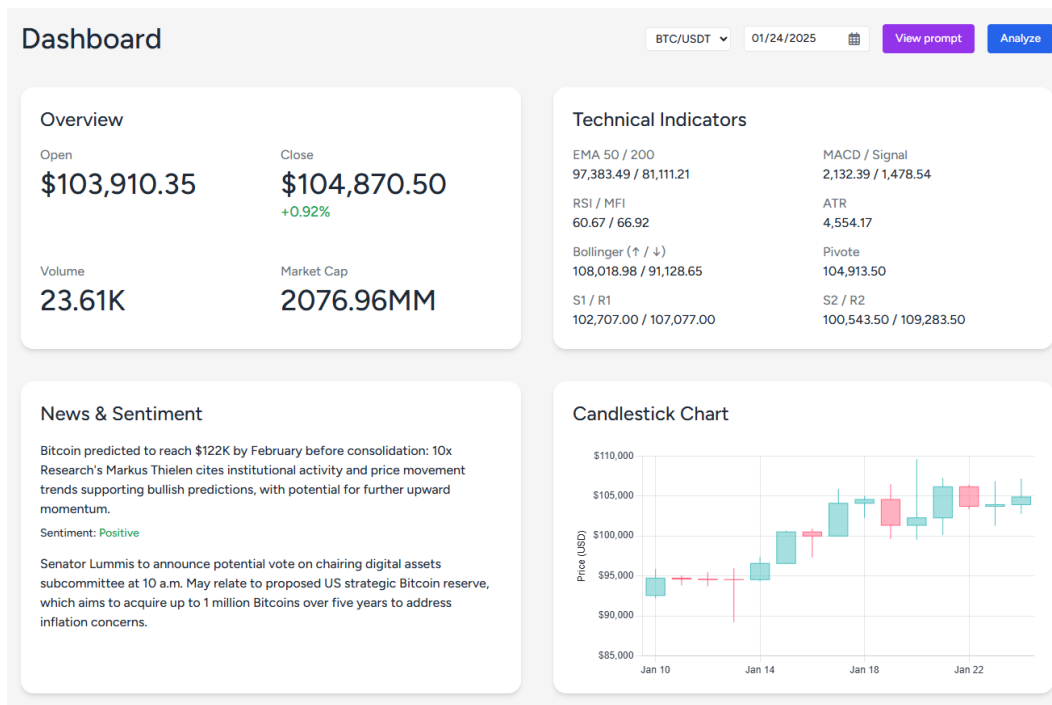


Figura 3.10: Interfaz gráfica para la generación automática de reportes. *Nota.* Se visualizan los datos estructurados y no estructurados, y se activa el modelo de lenguaje mediante el botón *Analyze*. Elaboración propia.

El modelo de lenguaje LLaMA es el encargado de redactar estos reportes, utilizando como base una plantilla estructurada. A partir de esta plantilla, el sistema construye dinámicamente el *prompt*, reemplazando los marcadores con los valores extraídos desde la base de datos. Esta entrada completa define con claridad el rol del modelo, la estructura de salida y las reglas de interpretación que debe seguir.

El resultado es un documento que presenta de forma integrada las tendencias del mercado, la fuerza del movimiento, la polaridad informativa y los posibles escenarios. De este modo, el sistema proporciona una herramienta de apoyo útil para la toma de decisiones en entornos caracterizados por alta volatilidad y carga informativa.

La Fig. 3.10 muestra la interfaz del sistema al momento de generar un reporte automático. Se incluyen indicadores técnicos, resumen de sentimiento y un selector de fecha, junto con el botón de *Analyze*, el cual activa la consulta al modelo de lenguaje para generar un resumen contextualizado del mercado.

3.4.1. Arquitectura del Sistema

La arquitectura del sistema propuesto integra Procesamiento de Lenguaje Natural, Análisis Técnico y Modelos Extensos de Lenguaje para automatizar la generación de

reportes financieros diarios en el contexto del mercado de criptomonedas. Esta se organiza bajo un enfoque de integración tipo Extracción, Carga y Transformación (ELT, por sus siglas en inglés), donde los datos son extraídos desde diversas fuentes, cargados sin transformación previa en una base de datos centralizada, y posteriormente transformados mediante procesos de análisis y generación de contenido.

Como se ilustra en la Fig. 3.11, el sistema se divide en cinco bloques funcionales principales: fuentes externas, recolección de datos, carga a la base de datos, transformación y exposición de resultados.

Fuentes externas. El sistema obtiene datos desde tres fuentes principales: GNews y NewsCatcher para noticias financieras, y Binance para datos históricos del mercado de valores de apertura, máximo, mínimo, cierre y volumen.

Recolección de datos. Esta etapa ejecuta scripts independientes que obtienen noticias desde las APIs de GNews y NewsCatcher, almacenándolas temporalmente en archivos CSV, con filtros para evitar duplicados por título. En paralelo, se descarga información histórica del mercado utilizando la API de Binance y la biblioteca *ccxt*.

Carga a la base de datos. Una vez finalizada la recolección, los datos se cargan en una base de datos SQLite. Las noticias se insertan desde los archivos temporales, mientras que los datos de mercado se almacenan directamente en su tabla correspondiente, sin procesamiento previo.

Transformación. Esta etapa aplica procesamiento sobre los datos almacenados. Los artículos sin resumen son agrupados y enviados al modelo LLaMA junto con un *prompt* específico para generar resúmenes breves. Posteriormente, los resúmenes son clasificados mediante el modelo FinBERT, que determina el sentimiento asociado como positivo, negativo o neutral, y los resultados se almacenan. A partir de estos datos, se calcula un indicador de sentimiento semanal. Paralelamente, los datos históricos se utilizan para calcular indicadores técnicos como EMA, RSI, MACD, entre otros. Con base en la información técnica y de sentimiento, se construye un *prompt* que se emplea para generar el reporte del día mediante LLaMA. Tanto el *prompt* como la respuesta generada se almacenan para su posterior consulta y evaluación.

Exposición de resultados. Los datos transformados son accedidos mediante una API construida con *FastAPI* (Ramírez, 2023), que proporciona *endpoints* para indicadores, reportes, resúmenes y métricas de sentimiento. Esta API alimenta una interfaz gráfica de usuario (UI, por sus siglas en inglés) implementada con *React* (Meta Platforms, Inc., 2013), donde los usuarios pueden explorar el estado del mercado, visualizar indicadores técnicos y descargar los reportes generados.




Figura 3.11: Arquitectura general del sistema propuesto. *Nota.* Elaboración propia.

3.4.2. Contenido de los Reportes

Cada reporte generado automáticamente por el sistema se organiza en cinco secciones principales, diseñadas para ofrecer una visión integrada del comportamiento del mercado para un activo específico en una fecha determinada. Esta estructura tiene como finalidad facilitar la interpretación de los datos por parte de usuarios no especializados, manteniendo un lenguaje técnico moderado y accesible.

La primera sección, *Overview*, resume el estado general del mercado para el par analizado. Incluye información clave como el precio actual, la apertura del día, la variación porcentual diaria, los valores extremos en 24 horas, el volumen negociado y la capitalización de mercado. Esta información se presenta como un párrafo descriptivo que destaca los movimientos relevantes y posibles anomalías en el comportamiento del precio.

En *Technical Analysis*, se interpretan un conjunto de indicadores técnicos calculados a partir de los datos históricos de precios, incluyendo medias móviles exponenciales, el índice de fuerza relativa, el MACD, el índice de flujo monetario, y otros indicadores complementarios como el ATR y las bandas de Bollinger. A diferencia de una tabla numérica, esta sección sintetiza la interpretación de dichos indicadores en un lenguaje narrativo, permitiendo al lector identificar señales de tendencia, cambios de *momentum* o posibles escenarios de reversión.

La sección de *Sentiment Analysis* aborda el tono informativo predominante a partir de un conjunto agregado de noticias financieras previamente clasificadas por sentimiento. Las etiquetas de cada noticia se agrupan en métricas semanales que permiten evaluar la polaridad neta del mercado, el grado de consenso editorial entre fuentes de alta reputación y la posible influencia del entorno informativo sobre el comportamiento del par analizado. El texto generado enfatiza el tono dominante, identifica si existe alineación entre fuentes influyentes y describe posibles señales de cambio en la percepción del mercado.

A continuación, *Observations* presenta una integración de los hallazgos técnicos y del Análisis de Sentimiento, permitiendo una conclusión razonada sobre el estado del mercado. Esta síntesis busca detectar posibles señales mixtas, confirmar hipótesis de cambio de tendencia o advertir sobre contextos de indecisión.

Finalmente, se incluye un *Disclaimer*, que aclara que se trata de un documento generado de forma automatizada con fines meramente informativos, y que no debe considerarse como una recomendación de inversión. Este aviso cumple una función ética y legal, al advertir al lector sobre la naturaleza experimental del sistema y los posibles riesgos asociados al uso de LLM. Específicamente, este tipo de modelos puede incurrir en lo que se conoce como *alucinaciones*, abordada en la sección 2.4, es decir, generar afirmaciones

que aparentan ser verídicas o plausibles, pero que no se derivan directamente de los datos de entrada ni de información validada. Por tanto, se enfatiza la importancia de que los usuarios validen críticamente cualquier interpretación ofrecida por el reporte.

En la Fig. 3.12 se presenta un ejemplo de reporte automático generado por el sistema para el par BTC/USDT.



Report for BTC/USDT - Jan 24, 2025

Overview

On January 24, 2025, the BTC/USDT pair experienced a relatively stable intraday price behavior. The opening price of \$103910.35 rose to a high of \$107120.00 and dipped to a low of \$102750.00 before closing at \$104870.50. This represents a daily change of 0.92%, which is within the normal fluctuation range for this asset. Trading volume was moderate, at 23,609, while market capitalization remained substantial at over \$2 trillion.

Technical Analysis

The technical indicators suggest that BTC/USDT remains in a bullish trend. The EMA 50 (97383.49) is above the EMA 200 (81111.21), indicating upward momentum. However, the MACD Line (2132.39) and Signal Line (1478.54) are not widely separated, suggesting that the upward momentum might be slowing down. Additionally, the RSI value of 60.67 indicates that the asset is neither overbought nor oversold, but rather in a neutral state. Considering these indicators together, it appears that the bullish trend may be losing steam, but there's no clear indication of a reversal.

Sentiment Analysis

The sentiment analysis reveals a mixed picture with reputable sources presenting both optimistic and cautionary views. CoinDesk is cautiously positive, while crypto.news and U.Today are more upbeat about the prospects for BTC/USDT. However, Decrypt expresses concerns over regulatory risks, which slightly dampens overall optimism. Overall, there seems to be no dominant tone in sentiment analysis, suggesting that market participants are currently indecisive about the direction of the asset.

Observations

In summary, technical indicators suggest a slight weakening of the bullish trend for BTC/USDT on January 24, 2025, while sentiment analysis reveals a mixed landscape with both positive and cautious views prevailing among reputable sources. There is no clear indication of a breakout or a sharp drop in price, but rather an indication that market participants are becoming more cautious and indecisive about the future direction of the asset.

Disclaimer

This report was generated automatically using financial data and sentiment analysis. It is provided for informational purposes only and does not constitute financial, investment, or trading advice. Its automated systems do not take responsibility for any investment decisions based on this content. Always consult a qualified financial advisor before making investment decisions.

Figura 3.12: Ejemplo de reporte automático generado para el par BTC/USDT. *Nota.* Elaboración propia.

3.5. Recursos Técnicos Utilizados

Para el desarrollo e implementación del sistema automatizado de análisis del criptomercado, se requieren recursos computacionales, software especializado y acceso a fuentes de datos confiables. A continuación, se detallan los elementos esenciales:

■ Hardware:

- Procesador: Intel Core i7, 2.20 GHz (Turbo Boost hasta 2.21 GHz)
- Memoria RAM: 16 GB
- Unidad de procesamiento gráfico (GPU, por sus siglas en inglés): NVIDIA GeForce GTX 1050 con soporte para CUDA 12.2.2. Se requiere una GPU compatible con CUDA para optimizar el procesamiento de modelos de NLP como LLaMA y FinBERT mediante aceleración por hardware.
- Almacenamiento: Unidad de estado sólido (SSD, por sus siglas en inglés) de alta velocidad, empleada para permitir el acceso rápido a los datos necesarios durante la escritura de los *buffers* de respuesta generados por el modelo LLaMA.

■ Software y herramientas:

- Sistema Operativo: Windows 11 Pro
- Python 3.10: Lenguaje principal para la implementación del sistema.
- *ccxt*: Extracción de datos de precios y volumen de criptomonedas desde exchanges.
- GNews API y NewsatcherAPI: Extracción de artículos de noticias relevantes.
- CoinGecko API: Plataforma para la obtención de datos del mercado cripto, tales como capitalización y métricas de volumen (CoinGecko, 2025).
- FinBERT: Análisis de Sentimiento financiero.
- LLaMA: Modelo de lenguaje utilizado para la generación de texto.
- Ollama: Plataforma para la ejecución local de modelos de lenguaje, utilizada para la implementación de LLaMA (Ollama Team, 2023).
- Docker 4.39: Plataforma de contenedores que facilita la portabilidad, despliegue y replicabilidad del sistema completo en distintos entornos.
- FastAPI: Framework para la creación de servicios web utilizados en la orquestación del sistema.

- React: Biblioteca de JavaScript empleada en el desarrollo de la interfaz de usuario.

■ Acceso a datos:

- Solicitud de acceso a la NewscatcherAPI para investigación.
- Uso de GNews API para recopilación de artículos relevantes sobre criptomercados.
- Conexión a servicios de mercado como Binance para la obtención de precios históricos y métricas económicas.
- Acceso a reportes de CoinMarketCap y fuentes de análisis financiero, que complementarán el procesamiento de datos con contexto adicional.

4. Capítulo: Resultados

Este capítulo presenta los principales resultados obtenidos tras la implementación y validación del sistema automatizado de análisis de criptomercados. Inicialmente, se describe el proceso de optimización del diseño de instrucciones proporcionadas al modelo de lenguaje, así como la definición de los criterios de precisión técnica exigidos. Posteriormente, se presentan los resultados del Análisis Técnico y del Análisis de Sentimiento, evaluando la capacidad del sistema para interpretar tendencias, *momentum* y comportamientos de mercado de manera coherente y profesional.

Cada sección incluye ejemplos reales de reportes generados para el par BTC/USDT, los cuales sintetizan variables cuantitativas, como precios e indicadores técnicos, y variables cualitativas, como el tono de las noticias financieras, en un formato estructurado, accesible y técnicamente fundamentado.

4.1. Proceso de Optimización del Diseño de Instrucciones

Esta sección describe el proceso de optimización llevado a cabo en el sistema de generación automática de reportes. En una primera etapa de validación, se identificaron errores recurrentes en la interpretación de indicadores técnicos por parte del modelo de lenguaje, lo que evidenció la necesidad de reforzar las instrucciones proporcionadas en el diseño del *prompt*.

El objetivo principal de esta optimización fue fortalecer la coherencia técnica de las respuestas generadas, garantizando que el modelo interpretara adecuadamente los patrones de tendencia, *momentum* y volatilidad basados en los valores reales de los indicadores calculados. Para lograrlo, se implementaron mejoras progresivas en el diseño de instrucciones y se definieron criterios explícitos de precisión técnica que sirvieron como base para evaluar la validez de las interpretaciones producidas.

4.1.1. Identificación de Errores de Interpretación Técnica

Durante la validación inicial del sistema, se observaron errores recurrentes en la forma en que el modelo de lenguaje interpretaba los indicadores técnicos, particularmente en la relación entre la media móvil exponencial de 50 días (EMA 50) y la de 200 días (EMA 200). Aunque los valores proporcionados eran claros, por ejemplo, cuando la EMA 50 era superior a la EMA 200, el modelo generaba descripciones que contradecían esta información, sugiriendo de forma incorrecta una tendencia bajista o una debilidad estructural.

Los principales tipos de errores identificados fueron:

- Interpretaciones equivocadas del ensanchamiento entre las medias móviles exponenciales, donde un aumento en la separación entre la EMA 50 (94,441.73) y la EMA 200 (77,813.57) debía interpretarse como un fortalecimiento de la tendencia, y no como su debilitamiento.
- Contradicciones explícitas con los valores reales, afirmando erróneamente que la EMA 50 estaba por debajo de la EMA 200.
- Sobreinterpretaciones del RSI, asignando condiciones de sobrecompra a valores neutrales (como un RSI de 46.17, dentro del rango normal).

La Tabla 4.1 sintetiza estos errores representativos detectados durante la fase inicial de validación.

Tabla 4.1: Errores comunes en la interpretación técnica del modelo

Tipo de error	Texto generado por el modelo
Interpretación incorrecta de EMAs	<i>The EMA 50 and EMA 200 lines indicate a widening gap, which is often seen as a sign of weakening upward pressure.</i>
Contradicción con valores reales	<i>The short-term trend is bearish due to the EMA 50 being below the EMA 200.</i>
Sobreinterpretación del RSI	<i>The RSI indicates the asset is approaching overbought conditions.</i>

Nota. La tabla muestra ejemplos de errores generados por el modelo antes de la implementación de ajustes en las instrucciones de *prompt*.

Con base en los errores detectados, se procedió a optimizar el diseño de instrucciones proporcionadas al modelo, mediante el establecimiento de reglas más explícitas que

evitaran inferencias incorrectas en la interpretación de los indicadores técnicos. Las acciones correctivas implementadas para atender estas deficiencias se describen en las secciones siguientes.

4.1.2. Optimización del Diseño de Instrucciones del Prompt

Con el objetivo de corregir los errores detectados durante la fase de validación, se implementaron diversas mejoras en el diseño de las instrucciones proporcionadas al modelo de lenguaje. Estas modificaciones se centraron en establecer reglas explícitas que guiaran de manera precisa la interpretación de los indicadores técnicos. Las acciones más relevantes incluyeron:

- Establecer que, si la EMA 50 se encuentra por encima de la EMA 200, la tendencia debe interpretarse inequívocamente como alcista, salvo en caso de un cruce confirmado en sentido contrario.
- Definir que un valor de RSI entre 30 y 70 corresponde a una condición neutral, descartando interpretaciones de sobrecompra o sobreventa dentro de este rango.
- Determinar que un MFI situado entre 20 y 80 representa una dinámica de volumen neutral, evitando inferencias sobre presiones de compra o venta si no se superan estos umbrales.
- Prohibir la inferencia de cambios de tendencia basados únicamente en el acercamiento o ensanchamiento de las EMAs, salvo cruce confirmado.
- Restringir la afirmación de *breakouts* exclusivamente a situaciones en las que el precio toque o supere los límites de las Bandas de Bollinger.
- Asegurar un tono de redacción neutral, objetivo y profesional en todos los reportes generados, evitando expresiones especulativas o emotivas.

La incorporación de estas instrucciones permitió controlar inferencias no deseadas y redujo significativamente errores de interpretación técnica en las salidas del modelo, fortaleciendo así la coherencia y fiabilidad de los reportes automatizados.

Cabe señalar que, en la mayoría de los casos, las modificaciones no implicaron la adición de nuevos criterios técnicos, sino ajustes semánticos y de formulación destinados a reforzar el cumplimiento de reglas ya definidas. El objetivo principal fue mejorar la claridad y especificidad de las instrucciones, reduciendo ambigüedades que pudieran permitir interpretaciones erróneas por parte del modelo.

Por ejemplo, el diseño original del *prompt* indicaba:

EMA 50 / EMA 200: Short- and long-term trend indicators. A crossover (EMA 50 > EMA 200) may indicate a bullish trend.

Esta formulación fue reemplazada por una versión más precisa:

EMA 50 / EMA 200: If EMA 50 > EMA 200, the trend is bullish. A wide and growing gap confirms bullish strength. Do not describe the trend as weakening or bearish when EMA 50 is above EMA 200, regardless of price movement or MACD.

Este ajuste no introdujo un nuevo criterio técnico, sino que eliminó ambigüedades en la interpretación: se reforzó que una configuración en la que EMA 50 supere a EMA 200 debe interpretarse inequívocamente como una tendencia alcista, sin sugerir debilitamiento salvo en presencia de un cruce confirmado. Esta precisión evitó inferencias erróneas basadas en fluctuaciones menores de precio o indicadores de *momentum*.

En síntesis, la optimización de las instrucciones permitió fortalecer sustancialmente la capacidad del modelo para interpretar correctamente los indicadores técnicos, minimizando errores de inferencia y elevando la coherencia de los reportes generados.

4.1.3. Precisión Técnica Exigida al Modelo

Para evaluar la calidad técnica de los reportes generados por el sistema, se definieron criterios explícitos de interpretación tanto para los indicadores técnicos como para el Análisis de Sentimiento de mercado. Estas reglas establecieron un marco objetivo de validación, evitando interpretaciones ambiguas o inconsistentes.

Interpretación de Indicadores Técnicos

La interpretación de los indicadores técnicos se basó en principios fundamentales del Análisis Técnico financiero. Se establecieron parámetros objetivos para identificar tendencias, dinámicas de *momentum*, condiciones de sobrecompra o sobreventa, y fases de consolidación o volatilidad. Los criterios exigidos al modelo fueron los siguientes:

- Tendencia por EMAs: Si $EMA\ 50 > EMA\ 200$, debe interpretarse como tendencia alcista; si $EMA\ 50 < EMA\ 200$, como tendencia bajista. No debe sugerirse debilitamiento de la tendencia mientras la EMA 50 permanezca por encima de la EMA 200.

- Condición de RSI: Valores de RSI mayores a 70 indican sobrecompra; valores menores a 30 indican sobreventa; valores entre 30 y 70 deben interpretarse como zona neutral.
- Dinámica de volumen por MFI: Valores de MFI superiores a 80 sugieren fuerte presión compradora; valores inferiores a 20, fuerte presión vendedora; valores entre 20 y 80 indican una dinámica de volumen neutral.
- Interpretación de MACD: Un MACD positivo y por encima de su señal sugiere *momentum* alcista; un MACD negativo y por debajo de su señal indica *momentum* bajista. Un histograma cercano a cero sugiere debilitamiento del impulso, pero no necesariamente un cambio de tendencia.
- Breakouts en Bandas de Bollinger: Solo puede afirmarse la ocurrencia de un breakout si el precio toca o supera los límites superior o inferior de las bandas. La permanencia dentro de las bandas sugiere consolidación o continuación de tendencia.
- Consideración de ATR: Un valor elevado de ATR refleja mayor volatilidad, pero no define la dirección de la tendencia; únicamente mide la intensidad de los movimientos.

Estos criterios se utilizaron como marco de referencia durante la validación de los reportes generados. Cualquier interpretación que se apartara de estos parámetros fue considerada incorrecta, permitiendo así una evaluación sistemática y consistente de la calidad de las respuestas del modelo.

Interpretación de Sentimiento de Mercado

El Análisis de Sentimiento se basó en la evaluación de noticias financieras agregadas semanalmente a partir de fuentes seleccionadas. Para garantizar una interpretación precisa y neutral, se exigió al modelo cumplir las siguientes reglas:

- Polarización: Se considera que existe un fuerte sesgo positivo o negativo si el valor de polarización es mayor a 1.25 o menor a 0.35. Valores dentro de este rango se interpretan como postura neutral o equilibrada.
- Reputación: Solo deben considerarse señales provenientes de fuentes con reputación superior a 0.31, entendida como una medida de consistencia histórica y credibilidad verificada.
- Relevancia: Debe priorizarse la evaluación del tono de las fuentes cuya relevancia temática respecto al mercado o activo analizado sea alta o moderada.

- Interpretación: El modelo debe interpretar el sentimiento general basándose en la tendencia de las fuentes más reputadas. En caso de una divergencia significativa, debe señalarse de forma explícita la falta de consenso y sugerirse posibles causas, como la incertidumbre macroeconómica o la presencia de noticias contradictorias.
- Restricciones de redacción: No se deben citar directamente valores numéricos de polarización o reputación, sino sintetizar la interpretación en términos cualitativos.

El cumplimiento de estas reglas garantizó una evaluación sistemática, permitiendo validar la capacidad del sistema para interpretar correctamente el tono de mercado de manera objetiva y profesional.

4.2. Resultados del Análisis Técnico

Esta sección presenta una selección de casos representativos generados por el sistema automatizado, correspondientes a distintas condiciones de mercado observadas en el par BTC/USDT. Los ejemplos incluyen situaciones de tendencia alcista, tendencia bajista y fases de consolidación, permitiendo evaluar la capacidad del modelo para interpretar correctamente los principales indicadores técnicos, tales como las medias móviles exponenciales (EMA), el índice de fuerza relativa (RSI) y el MACD.

Cada fragmento mostrado refleja la salida generada después de la optimización del diseño de instrucciones, asegurando una interpretación consistente y alineada con los datos técnicos reales.

La Tabla 4.2 resume tres escenarios seleccionados que ilustran distintas configuraciones de mercado y la respuesta del sistema ante cada una. Uno de los casos corresponde a diciembre de 2022, seleccionado intencionalmente por representar una configuración bajista relevante en la que la EMA 50 se ubicaba por debajo de la EMA 200.

Tabla 4.2: *Resumen comparativo de condiciones de mercado en tres reportes generados por el sistema*

Fecha	Tendencia	Sentimiento	Interpretación
Enero 29, 2025	Alcista (EMA 50 > EMA 200)	Moderado optimismo	Tendencia positiva con señales de cautela
Diciembre 21, 2022	Bajista (EMA 50 < EMA 200)	Sin datos	Tendencia bajista débil con señales de incertidumbre
Abril 5, 2025	Consolidación (EMA 50 $\approx$ EMA 200)	Moderado optimismo	Consolidación con <i>momentum</i> débil

Nota. Esta tabla presenta una selección de reportes generados automáticamente por el sistema bajo diferentes condiciones de mercado. Se evidencia la capacidad del modelo para resumir señales técnicas y sentimentales de forma coherente y profesional.

Una vez definido el conjunto de reportes seleccionados, es importante destacar que la validación de las interpretaciones generadas por el sistema se basó en criterios derivados directamente de las reglas técnicas definidas en el diseño de instrucciones del *prompt*. Estos criterios consideraron específicamente:

- Las relaciones entre las medias móviles exponenciales.
- Los niveles observados en los osciladores RSI y MFI.
- El comportamiento del MACD.
- La posición relativa del precio respecto a las Bandas de Bollinger.

Esta metodología permitió evaluar de manera estructurada y consistente la precisión de las interpretaciones generadas bajo distintas condiciones de mercado.

4.2.1. Caso de Análisis Técnico: Tendencia Alcista

Se presenta a continuación un caso representativo de tendencia alcista detectado por el sistema. El análisis corresponde al 29 de enero de 2025, fecha en la que se observa una configuración técnica caracterizada por medias móviles ascendentes (EMA 50 > EMA 200) y un *momentum* positivo moderado reflejado en el MACD. Este escenario permite

evaluar la capacidad del modelo para interpretar correctamente condiciones de mercado con sesgo claramente alcista.

La Tabla 4.3 presenta los valores de los principales indicadores técnicos considerados en este análisis.

Tabla 4.3: Valores de indicadores técnicos para BTC/USDT en tendencia alcista (29 de enero de 2025)

Indicador	Valor	Indicador	Valor
Precio de cierre	103,733.24	EMA 50	98,379.71
EMA 200	82,173.73	MACD Line	1,600.50
Signal Line	1,682.35	Histograma MACD	-81.85
RSI	56.92	MFI	61.06
ATR (Volatilidad)	4,195.47		
Banda Bollinger Superior	108,672.77	Banda Bollinger Inferior	93,410.01
Soporte 1 (S1)	101,779.94	Resistencia 1 (R1)	105,234.61

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

A partir de estos indicadores, el sistema generó el siguiente Análisis Técnico:

Technical Analysis

The technical indicators suggest a continuation of the bullish trend. The EMA 50 is above the EMA 200, indicating a strong upward *momentum*. However, the MACD histogram shows a slight decrease in *momentum*, which could be a sign of caution. The RSI is at 56.92, suggesting that the price is not overbought or oversold. The Bollinger Bands are wide and the price is above the middle band, indicating volatility. Overall, the indicators suggest a bullish trend with potential for further growth.

La validación de este análisis muestra que el modelo interpretó correctamente la configuración técnica observada, reconociendo:

- La relación $EMA\ 50 > EMA\ 200$, interpretada adecuadamente como tendencia alcista.
- La ausencia de cruce de medias móviles, evitando inferencias de reversión de tendencia.

- El valor del RSI (56.92) dentro del rango neutral, correctamente asociado a una condición de no sobrecompra ni sobreventa.
- La ligera disminución en el histograma del MACD, señalada apropiadamente como un indicio de precaución, sin sugerir cambio de tendencia.
- La amplitud moderada de las Bandas de Bollinger, interpretada como indicativa de volatilidad presente en el mercado.

Estos resultados validan la capacidad del modelo para interpretar con precisión escenarios de tendencia alcista, respetando los criterios técnicos establecidos en el diseño de instrucciones del *prompt*.

4.2.2. Caso de Análisis Técnico: Tendencia Bajista

Tal como se anticipó en la Tabla 4.2, se presenta a continuación un caso concreto que valida la capacidad del sistema para interpretar condiciones de mercado con sesgo descendente. El análisis corresponde al 21 de diciembre de 2022, fecha en la que se observa una disposición técnica de medias móviles descendente ($EMA\ 50 < EMA\ 200$) y un *momentum* bajista moderado reflejado en el MACD. Este caso permite evaluar la precisión del modelo para identificar correctamente escenarios de debilidad en el mercado.

Cabe señalar que este ejemplo fue seleccionado de un periodo histórico distinto, debido a la ausencia de ciclos bajistas significativos durante 2025 en el par BTC/USDT. Se recurrió a un evento de 2022 con el fin de representar adecuadamente condiciones descendentes en la validación.

La Tabla 4.4 presenta los valores de los principales indicadores técnicos considerados en este análisis.

El sistema generó el siguiente Análisis Técnico:

Technical Analysis

The technical indicators suggest a mix of signals indicating uncertainty rather than clear trend continuation or reversal. The EMA 50 and EMA 200 are aligned in a bearish configuration, with EMA 50 below EMA 200, which could indicate a weakening trend. However, the distance between these two lines is relatively small, suggesting a potential for consolidation rather than a strong bearish *momentum*. Additionally, the MACD histogram shows a negative value, indicating downward *momentum*, while the RSI value of 46.60 suggests neutrality rather than overbought or oversold conditions. Overall, the technical indicators point towards market hesitation and uncertainty.

Tabla 4.4: Valores de indicadores técnicos para BTC/USDT en tendencia bajista (21 de diciembre de 2022).

Indicador	Valor	Indicador	Valor
Precio de cierre	16,672.87	EMA 50	17,455.51
EMA 200	21,987.83	MACD Line	-115.17
Signal Line	-95.70	Histograma MACD	-19.47
RSI	46.60	MFI	54.19
ATR (Volatilidad)	503.29		
Banda Bollinger Superior	17,703.20	Banda Bollinger Inferior	16,395.88
Soporte 1 (S1)	16,723.45	Resistencia 1 (R1)	16,925.45

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

La validación de esta interpretación se realizó considerando los siguientes criterios:

- La EMA 50 se encontraba por debajo de la EMA 200, lo que correspondía a una configuración bajista.
- No se observó cruce de la EMA 50 sobre la EMA 200, por lo que no debía interpretarse reversión de tendencia.
- El RSI (46.60) se mantenía dentro del rango neutral, sin indicar condiciones extremas de sobreventa.
- El MACD mostraba un histograma negativo y valores por debajo de la señal, correctamente interpretados como debilidad de impulso.
- El precio permanecía dentro de las Bandas de Bollinger, sugiriendo consolidación sin ruptura, de acuerdo con los demás indicadores.

La validación demuestra que el modelo interpretó correctamente la estructura bajista predominante, basada en la disposición de las medias móviles y el comportamiento del MACD. No obstante, se observó que el lenguaje empleado suavizó la caracterización de la tendencia bajista, enfatizando la incertidumbre en lugar de la dirección descendente, a pesar de que los indicadores técnicos presentados en la Tabla 4.4 confirmaban una tendencia claramente negativa.

4.2.3. Caso de Análisis Técnico: Consolidación

Se presenta a continuación un caso representativo de condición de mercado en lateralidad detectado por el sistema. El análisis corresponde al 5 de abril de 2025, fecha en la que se observa una disposición técnica caracterizada por la convergencia de las medias móviles ($EMA\ 50 \approx EMA\ 200$) y un comportamiento de indicadores que sugiere consolidación dentro de un rango definido. Este escenario permite evaluar la capacidad del modelo para interpretar correctamente situaciones de mercado sin una tendencia predominante.

La selección de esta fecha se basó en criterios técnicos predefinidos, considerando periodos en los que:

- El cambio porcentual diario fuera inferior al 3 %.
- El RSI se mantuviera entre 45 y 55.
- El valor absoluto del histograma del MACD fuera menor o igual a 100.

Estas condiciones fueron consideradas indicativas de un mercado sin dirección clara, caracterizado por baja volatilidad direccional y ausencia de impulso marcado, lo cual es consistente con una fase de consolidación técnica.

La Tabla 4.5 presenta los valores de los principales indicadores técnicos utilizados para la validación de este análisis.

Tabla 4.5: Valores de indicadores técnicos para BTC/USDT en condición de lateralidad (5 de abril de 2025)

Indicador	Valor	Indicador	Valor
Precio de cierre	83,537.99	EMA 50	87,183.82
EMA 200	85,380.07	MACD Line	-962.77
Signal Line	-1052.44	Histograma MACD	89.66
RSI	46.12	MFI	59.21
ATR (Volatilidad)	3,286.87		
Banda Bollinger Superior	88,070.68	Banda Bollinger Inferior	81,046.01
Soporte 1 (S1)	82,523.29	Resistencia 1 (R1)	84,409.34

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

El sistema generó el siguiente Análisis Técnico:

Technical Analysis

The technical indicators suggest a cautiously optimistic trend for Bitcoin on April 05, 2025. The EMA 50 and EMA 200 lines show a bullish orientation, with a gap of approximately 18 points. This alignment supports the notion of a continued upward *momentum*. However, the RSI value of 46.12 indicates neutrality, neither overbought nor oversold conditions. MACD also shows a positive histogram, suggesting upward *momentum* but at a slower pace than the previous days. The MFI value is around 59.21, indicating neutral volume dynamics. Considering these indicators, it appears that Bitcoin's price movement might be entering a phase of consolidation or trend exhaustion.

La validación de esta interpretación muestra que el modelo reconoció adecuadamente una condición de consolidación, observando:

- La convergencia de las medias móviles EMA 50 y EMA 200, interpretada correctamente como ausencia de tendencia definida.
- La inexistencia de cruce de medias móviles o señales de impulso significativo.
- Los valores del RSI (46.12) y del MFI (59.21) dentro de rangos neutrales, reflejando estabilidad sin condiciones extremas.
- Un MACD con *momentum* débil, interpretado correctamente como indicativo de consolidación.
- La oscilación del precio dentro de las Bandas de Bollinger, sin ruptura hacia nuevos rangos.

Estos resultados validan que el sistema interpretó correctamente un escenario de mercado lateral, siguiendo los parámetros técnicos definidos en el diseño de instrucciones del *prompt*.

Cabe señalar que en la evaluación de sentimiento correspondiente a esta fecha, las fuentes más influyentes mostraban niveles elevados de polarización, con valores cercanos a uno, y puntuaciones de reputación relativamente bajas, próximas a 0.25, como se muestra en la Tabla 4.10. Si bien esta combinación podría reducir la confiabilidad del análisis desde el punto de vista informativo, la consistencia observada con los indicadores técnicos, en particular la convergencia de las medias móviles y la presencia de un impulso débil, refuerza la validez general de la interpretación generada. Esta situación demuestra

la capacidad del sistema para elaborar una síntesis crítica incluso cuando la calidad de las señales disponibles es limitada.

4.2.4. Comparación de Escenarios Técnicos

La evaluación conjunta de los casos analizados permite observar cómo varían los principales indicadores técnicos bajo distintas condiciones de mercado.

La Tabla 4.6 ofrece una visión comparativa de los elementos técnicos más relevantes identificados en cada caso, facilitando el análisis de los resultados generados por el sistema.

Tabla 4.6: Comparación de escenarios técnicos interpretados por el sistema

Elemento	Alcista	Bajista	Consolidación
Fecha del análisis	29-ene-2025	21-dic-2022	05-abr-2025
Relación EMA	EMA 50 > EMA 200	EMA 50 < EMA 200	EMA 50 $\approx$ EMA 200
MACD	Histograma levemente negativo, <i>momentum</i> decreciente	MACD negativo, señal clara de debilidad	Histograma cercano a cero, sin impulso claro
RSI	RSI en zona neutral-alcista	RSI en zona media	RSI neutral, sin presión
MFI	MFI > 60	MFI en zona media	MFI neutral
Bandas de Bollinger	Amplias; precio en zona superior	Precio dentro del canal, sin ruptura	Canal estrecho; precio oscilando en el centro
Interpretación	Optimismo moderado con advertencia de precaución	Tendencia débil con lenguaje matizado e incertidumbre	Lectura equilibrada de lateralidad y baja volatilidad

Nota. La tabla resume los indicadores clave y la respuesta generada por el sistema en tres configuraciones distintas del mercado. Se observa una interpretación consistente y adaptativa según el contexto técnico de cada caso.

4.3. Resultados del Análisis de Sentimiento

Esta sección presenta los resultados de la evaluación del Análisis de Sentimiento realizado por el sistema automatizado, considerando las reglas de precisión establecidas previamente para la interpretación de fuentes de noticias financieras. Se analizan distintos

escenarios de mercado para validar la coherencia entre las señales de sentimiento detectadas y las condiciones técnicas observadas.

La Tabla 4.7 resume una selección de escenarios representativos, destacando la tendencia técnica predominante y la interpretación de sentimiento correspondiente.

Tabla 4.7: *Resumen de tendencias de sentimiento en diferentes escenarios de mercado*

Fecha	Contexto técnico	Tendencia de sentimiento
Enero 12, 2025	Consolidación neutral	Sentimiento cauteloso con señales de estabilización
Enero 29, 2025	Tendencia alcista moderada	Ligero optimismo entre fuentes principales
Abril 5, 2025	Consolidación técnica	Moderado optimismo con neutralidad predominante

Nota. Esta tabla presenta una selección de reportes donde se evaluó la consistencia entre el Análisis de Sentimiento generado por el modelo y las condiciones reales observadas en las fuentes.

Una vez resumidos los escenarios seleccionados, a continuación se presentan tres casos que ilustran el desempeño del sistema en la interpretación de sentimiento bajo distintas condiciones de mercado. Cada análisis se acompaña de los valores de reputación, polarización y relevancia de las fuentes consideradas, así como de una evaluación de la coherencia entre la interpretación generada y las condiciones reales observadas.

4.3.1. *Caso de Análisis de Sentimiento: Consolidación Neutral*

Se presenta un caso representativo de interpretación de sentimiento para un escenario de consolidación neutral en el par BTC/USDT. El análisis corresponde al 12 de enero de 2025, fecha caracterizada por estabilidad en el precio y señales técnicas de bajo impulso.

La Tabla 4.8 muestra la evaluación de las principales fuentes de noticias utilizadas para el Análisis de Sentimiento en esa fecha.

El sistema generó el siguiente fragmento para el Análisis de Sentimiento:

Tabla 4.8: Evaluación de fuentes de noticias para el Análisis de Sentimiento (12 de enero de 2025)

Fuente	Polarización	Reputación	Relevancia
Bitcoinist	0.29	2.85	0.83
CoinDesk	0.33	2.28	0.76
Yahoo Finance	0.00	2.20	0.00
Investopedia	0.00	0.20	0.00

Nota. Las métricas corresponden a los valores de polarización, reputación y relevancia utilizados para ponderar el Análisis de Sentimiento para la fecha indicada.

Sentiment Analysis

Market sentiment for January 12, 2025, as reflected by reputable sources, leans towards caution and uncertainty rather than optimism or pessimism. Bitcoinist’s analysis suggests a cautiously optimistic stance while also acknowledging potential risks. CoinDesk’s perspective is more cautious, highlighting the complexities of market dynamics. These views are consistent with the technical indicators’ portrayal of stabilization rather than strong trend continuation or reversal. There’s no clear dominant tone among top sources, suggesting that the market remains in a state of indecision or adjustment.

La evaluación de esta interpretación muestra que el modelo captó adecuadamente el tono general de cautela y estabilidad, reflejando:

- Un predominio de perspectivas neutrales o ligeramente optimistas entre las fuentes más reputadas (Bitcoinist y CoinDesk).
- Ausencia de sesgos extremos de polarización, consistente con los valores de las fuentes (polarización < 0.35).
- Coherencia entre el Análisis de Sentimiento y la interpretación técnica de un mercado en consolidación.

Estos resultados validan la capacidad del sistema para sintetizar correctamente las señales de sentimiento en escenarios de baja dirección de mercado.

4.3.2. Caso de Análisis de Sentimiento: Mercado Moderadamente Optimista

Se presenta a continuación el Análisis de Sentimiento generado para el par BTC/USDT en la fecha del 29 de enero de 2025. Este caso evalúa la capacidad del sistema para interpretar correctamente el tono general del mercado a partir de múltiples fuentes financieras, aplicando las reglas de precisión establecidas.

La Tabla 4.9 resume las métricas de polarización, reputación y relevancia de las principales fuentes consideradas en este análisis.

Tabla 4.9: Evaluación de fuentes de noticias para el Análisis de Sentimiento (29 de enero de 2025)

Fuente	Polarización	Reputación	Relevancia
u.today	0.29	2.85	0.83
yahoo.com	0.33	2.28	0.76
dailyhodl.com	0.00	2.20	0.70
globenewswire.com	0.00	2.10	0.68
aol.com	0.40	0.20	0.15
tynmagazine.com	0.45	0.18	0.10

Nota. Los valores presentados corresponden a las métricas de polarización, reputación y relevancia utilizadas por el sistema para interpretar el sentimiento general del mercado en la fecha especificada.

El sistema generó el siguiente fragmento de Análisis de Sentimiento:

Sentiment Analysis

The sentiment analysis reveals a mixed tone among reputable sources. u.today has a neutral tone with low polarization, suggesting that they see the market as stable. Yahoo.com also reports a neutral tone but with moderate polarization, indicating some caution. Dailyhodl.com and globenewswire.com report more bullish tones with lower polarization, suggesting optimism about future growth. However, aol.com and tynmagazine.com have weaker reputations and report mixed or bearish sentiments. Overall, the sentiment analysis suggests that there is a slight leaning towards a bullish tone among top sources.

La evaluación de esta interpretación muestra que el modelo logró captar adecuadamente la dispersión de señales presentes, reflejando:

- Una tendencia moderadamente optimista entre las fuentes de mayor reputación, como u.today, Yahoo Finance y Dailyhodl.
- La presencia de tonos neutrales a levemente positivos, coherentes con los valores de polarización observados (< 0.35).
- La correcta mitigación del impacto de fuentes de baja reputación, como aol.com y tynmagazine.com, que presentaban señales más negativas pero con baja influencia relativa.

Estos resultados validan la capacidad del sistema para sintetizar adecuadamente el sentimiento general del mercado, priorizando las señales más confiables y evitando sesgos derivados de fuentes menos relevantes o de baja calidad.

4.3.3. *Caso de Análisis de Sentimiento: Tendencia Positiva con Señales de Consolidación*

Se presenta a continuación un caso representativo de interpretación de sentimiento generado por el sistema para un escenario de tendencia positiva con señales de consolidación en el par BTC/USDT. El análisis corresponde al 5 de abril de 2025, fecha caracterizada por un leve retroceso de precio y señales técnicas de estabilización moderada.

La Tabla 4.10 muestra la evaluación de las principales fuentes de noticias utilizadas para este análisis.

Tabla 4.10: Evaluación de fuentes de noticias para el Análisis de Sentimiento (5 de abril de 2025)

Fuente	Polarización	Reputación	Relevancia
FXStreet	1.00	0.25	0.25
Cointelegraph.com	1.00	0.25	0.25
Investopedia	1.00	0.25	0.25
Benzinga.com	0.00	0.15	0.00

Nota. Las métricas corresponden al puntaje de polarización, reputación y relevancia utilizado para ponderar el sentimiento general del mercado en la fecha analizada.

El sistema generó el siguiente fragmento de Análisis de Sentimiento:

Sentiment Analysis

The sentiment analysis reveals a moderate optimism bias among top sources, with most publishers exhibiting a polarization score slightly above the threshold for strong bias. FXStreet, Cointelegraph.com, and Investopedia are all reporting positive sentiments towards Bitcoin, while Benzinga.com remains neutral. This alignment suggests that market participants share a cautious optimism about the future prospects of Bitcoin, which aligns with the technical indicators suggesting a continued upward trend.

La evaluación de esta interpretación muestra que el modelo reconoció correctamente el sesgo optimista moderado predominante en el entorno informativo, observando:

- La presencia de sentimiento positivo en las fuentes principales (FXStreet, Cointelegraph y Investopedia), con valores de polarización elevados pero consistentes.
- Una correcta ponderación de la neutralidad reportada por Benzinga.com, evitando distorsionar la interpretación general.
- Coherencia entre el Análisis de Sentimiento y las señales técnicas observadas, caracterizadas por $EMA\ 50 > EMA\ 200$, MACD positivo y RSI en zona neutral (según la Tabla 4.5).

Estos resultados validan la capacidad del sistema para integrar información de diversas fuentes de manera crítica y construir interpretaciones de sentimiento acordes con la realidad técnica del mercado.

4.3.4. Comparación de Escenarios de Sentimiento

La evaluación de los escenarios presentados permite observar cómo varía la interpretación del sentimiento según el contexto técnico y las características de las fuentes informativas. A diferencia de los indicadores numéricos, el Análisis de Sentimiento implica una síntesis cualitativa sensible a la polarización, reputación y relevancia de cada medio. La Tabla 4.11 presenta una síntesis de estos tres casos, destacando las condiciones del mercado, el tono predominante detectado y la calidad informativa subyacente.

4.4. Errores Residuales tras la Optimización

A pesar de las mejoras implementadas en el diseño de instrucciones del *prompt*, se identificaron casos en los que el modelo continuó generando interpretaciones inconsis-

Tabla 4.11: Comparación de escenarios de sentimiento interpretados por el sistema

Elemento	12-ene-2025	29-ene-2025	05-abr-2025
Contexto técnico	Consolidación neutral	Tendencia alcista moderada	Tendencia positiva con señales de consolidación
Tono general	Cautela e incertidumbre	Optimismo moderado entre fuentes confiables	Optimismo con sesgo leve, dominado por fuentes reputadas
Polarización media	Baja (< 0.35)	Baja (< 0.35)	Alta pero concentrada en fuentes con buena reputación
Fuentes influyentes	CoinDesk, Bitcoinist	u.today, Dailyhodl	FXStreet, Cointelegraph, Investopedia
Consistencia técnica	Alta	Alta	Alta

Nota. La tabla resume las características técnicas y sentimentales en tres fechas representativas. Se observa que el sistema ajusta su interpretación del sentimiento considerando tanto el contexto del mercado como la calidad de las fuentes disponibles.

tentes. En particular, se observaron errores residuales en la valoración de escenarios de consolidación, donde el modelo tendió a sobreestimar el impulso alcista basándose en un MACD levemente positivo, a pesar de que otros indicadores, como el RSI y el MFI, se mantenían en rangos de neutralidad.

Estos resultados evidencian que, si bien la optimización redujo significativamente las alucinaciones analíticas, persisten ciertos desafíos inherentes a la inferencia automática en contextos de baja direccionalidad de mercado.

La Tabla 4.12 resume algunos ejemplos representativos de errores detectados tras la optimización.

Estos ejemplos subrayan la importancia de interpretar los reportes generados como elementos auxiliares, sujetos a verificación experta antes de su utilización en decisiones de inversión.

4.4.1. Ejemplo 1: Interpretación Incorrecta de Consolidación

El reporte generado para el 7 de febrero de 2025 presenta una interpretación técnica inconsistente. A pesar de que la EMA 50 se mantenía claramente por encima de la EMA 200, indicando una estructura de tendencia alcista, el modelo describió el entorno como “incierto”. Aunque el MACD mostraba valores negativos y el RSI se encontraba en un

Tabla 4.12: Errores residuales detectados tras la optimización del sistema

Fecha	Contexto técnico	Descripción del error residual
Febrero 7, 2025	Tendencia alcista débil (EMA 50 > EMA 200, MACD débil)	Interpretación incorrecta: calificó el entorno como incierto en vez de alcista moderado
Marzo 11, 2025	Tendencia alcista con <i>momentum</i> débil (EMA 50 > EMA 200, MACD/RSI neutrales)	Contradicción entre tendencia y <i>momentum</i> ; enfatizó indecisión total en lugar de tendencia débil
Marzo 16, 2025	Consolidación técnica con baja volatilidad	Exageración de incertidumbre y volatilidad, sugiriendo reversión sin base suficiente

Nota. La tabla presenta ejemplos de errores residuales en la interpretación técnica tras la optimización de instrucciones. Se evidencian principalmente errores de matiz y sobreinterpretación en escenarios de consolidación o debilitamiento de tendencia.

rango neutral (42.19), el contexto técnico general correspondía a una fase de tendencia alcista debilitada, no a una consolidación o fase de indecisión.

La Tabla 4.13 presenta los valores de los principales indicadores en esta fecha.

Tabla 4.13: Valores de indicadores técnicos para BTC/USDT en tendencia alcista débil (7 de febrero de 2025)

Indicador	Valor	Indicador	Valor
Precio de cierre	96,506.80	EMA 50	98,599.04
EMA 200	83,647.50	MACD Line	-615.42
Signal Line	346.26	Histograma MACD	-961.68
RSI	42.19	MFI	34.34
ATR (Volatilidad)	4,497.67		
Banda Bollinger Superior	107,466.16	Banda Bollinger Inferior	95,633.37
Soporte 1 (S1)	94,705.43	Resistencia 1 (R1)	99,223.08

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

El sistema generó el siguiente fragmento:

Technical Analysis

The technical indicators suggest that the current trend is uncertain, with conflicting signals from both short-term (EMA 50) and long-term (EMA 200) indicators. While the EMA 50 remains above the EMA 200, indicating a bullish trend, the MACD line has dropped below its signal line, suggesting weakening *momentum*. The RSI value of 42.19 is near neutrality, and the MFI value of 34.34 indicates weak buying pressure. However, the Bollinger Bands show that the price is still within a relatively narrow range, indicating potential consolidation or trend continuation.

Esta alucinación analítica evidencia una comprensión incorrecta de la prioridad interpretativa establecida en el diseño de instrucciones del *prompt*. Aunque el MACD reflejaba una ligera pérdida de *momentum*, la estructura principal de mercado, representada por una EMA 50 superior a la EMA 200, debía prevalecer como indicativo de tendencia alcista. Sin embargo, el modelo otorgó un peso desproporcionado al debilitamiento del MACD, clasificando erróneamente el entorno como “incierto”.

Este tipo de error, aunque reducido tras la optimización, revela que persiste un riesgo residual de inferencias inconsistentes, especialmente en escenarios donde los indicadores de impulso presentan fluctuaciones dentro de tendencias estructuralmente estables.

4.4.2. Ejemplo 2: Contradicción entre Momentum y Tendencia

El reporte generado para el 11 de marzo de 2025 presenta una interpretación técnica inconsistente. Aunque la EMA 50 se encontraba por encima de la EMA 200, configurando una señal estructural alcista, el modelo enfatizó indecisión debido a señales de debilidad observadas en el MACD, el RSI y el MFI.

La Tabla 4.14 presenta los valores de los principales indicadores para esta fecha.

El sistema generó el siguiente fragmento de análisis:

Technical Analysis

The technical picture reveals a mixed signal. While the EMA 50 is above the EMA 200, indicating a bullish trend, the RSI and MFI suggest neutrality with values around 40 and 32 respectively. The MACD histogram shows downward *momentum*, contradicting the bullish trend suggested by EMA 50's superiority over EMA 200. Bollinger Bands are wide, suggesting high volatility. However, ATR indicates moderate volatility during this period.

Tabla 4.14: Valores de indicadores técnicos para BTC/USDT en contradicción entre tendencia y *momentum* (11 de marzo de 2025)

Indicador	Valor	Indicador	Valor
Precio de cierre	82,932.99	EMA 50	92,215.81
EMA 200	85,693.62	MACD Line	-3518.12
Signal Line	-2964.24	Histograma MACD	-553.88
RSI	40.31	MFI	32.03
ATR (Volatilidad)	5,141.05		
Banda Bollinger Superior	99,378.63	Banda Bollinger Inferior	77,671.40
Soporte 1 (S1)	78,486.86	Resistencia 1 (R1)	85,498.26

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

En este caso, la alucinación analítica ocurrió porque el modelo no priorizó adecuadamente la señal estructural de tendencia proporcionada por la relación $EMA\ 50 > EMA\ 200$. Aunque algunos indicadores de *momentum*, como el MACD y el RSI, mostraban señales de debilitamiento, estas no eran lo suficientemente pronunciadas como para invalidar la estructura de tendencia alcista.

La interpretación correcta debió reconocer una tendencia alcista en desarrollo, aunque con menor impulso. Sin embargo, el modelo otorgó un peso desproporcionado a las señales de debilidad momentánea, describiendo erróneamente el entorno como de “indecisión total”, en lugar de caracterizarlo como una continuación moderada de la tendencia existente.

Este tipo de error ilustra las dificultades inherentes a la inferencia automática en contextos donde existen señales técnicas mixtas, resaltando la importancia de priorizar los indicadores estructurales en la interpretación de tendencias.

4.4.3. Ejemplo 3: Exageración de Incertidumbre y Volatilidad

El reporte generado para el 16 de marzo de 2025 presenta una interpretación técnica que exagera la incertidumbre del mercado. Aunque la EMA 50 permanecía claramente por encima de la EMA 200, configurando un contexto de tendencia alcista debilitada, el modelo interpretó la situación como un posible cambio de tendencia debido a señales de volatilidad moderada y a una ligera debilidad de *momentum* reflejada en el MACD y el RSI.

La Tabla 4.15 presenta los valores de los principales indicadores técnicos para esta fecha.

Tabla 4.15: Valores de indicadores técnicos para BTC/USDT en fase de consolidación con volatilidad moderada (16 de marzo de 2025)

Indicador	Valor	Indicador	Valor
Precio de cierre	82,574.53	EMA 50	90,571.60
EMA 200	85,569.10	MACD Line	-3015.54
Signal Line	-3130.40	Histograma MACD	114.86
RSI	41.76	MFI	38.64
ATR (Volatilidad)	4,580.21		
Banda Bollinger Superior	92,492.32	Banda Bollinger Inferior	78,242.03
Soporte 1 (S1)	81,331.42	Resistencia 1 (R1)	84,467.34

Nota. Los valores presentados fueron extraídos directamente del conjunto de indicadores calculados para el par BTC/USDT en la fecha especificada.

El sistema generó el siguiente fragmento de análisis:

Technical Analysis

The technical picture reveals increased uncertainty for Bitcoin on March 16, 2025. Although the EMA 50 remains above the EMA 200, indicating a longer-term bullish trend, the MACD histogram shows a slight positive *momentum* while both RSI and MFI remain in neutral territory. The widening of the Bollinger Bands suggests growing volatility, and the ATR also indicates heightened market swings. Together, these mixed signals point toward increased uncertainty and potential consolidation or reversal risk.

En este caso, la alucinación analítica surgió de una sobreinterpretación del incremento en la volatilidad. Aunque tanto el ATR como la expansión de las Bandas de Bollinger indicaban un aumento moderado en la amplitud de los movimientos de precio, no existían señales técnicas que justificaran una reversión de tendencia.

La estructura principal del mercado, definida por una EMA 50 superior a la EMA 200, permanecía intacta, indicando una tendencia alcista debilitada pero aún vigente. Sin embargo, el modelo sobredimensionó el efecto de la volatilidad, interpretando erróneamente un escenario de consolidación como un contexto de alta incertidumbre.

Este tipo de error evidencia que, incluso bajo instrucciones optimizadas, persiste un riesgo residual de magnificar riesgos percibidos en situaciones donde los indicadores técnicos sostienen la continuidad de tendencia. Esta observación subraya la importancia de integrar de manera crítica señales de volatilidad dentro del análisis estructural de tendencias.

5. Capítulo: Discusión

Este capítulo discute la validez de la hipótesis planteada, analiza el grado de cumplimiento de los objetivos de investigación y examina las limitaciones observadas en la implementación del sistema propuesto.

5.1. Evaluación de la Hipótesis

La hipótesis plantea que la combinación de técnicas de Procesamiento de Lenguaje Natural y Análisis Técnico, a través de modelos avanzados como LLaMA y herramientas de análisis de mercado, mejoraría consistentemente la precisión en la predicción de tendencias y la interpretación del sentimiento en los criptomercados.

Los resultados obtenidos permiten corroborar parcialmente esta hipótesis, validando las mejoras en la interpretación de tendencias y sentimiento, aunque persisten desafíos en escenarios de consolidación:

- El Análisis Técnico automatizado, basado en el cálculo diario de indicadores como EMA, MACD, RSI, MFI, ATR y Bandas de Bollinger, proporcionó interpretaciones consistentes de la tendencia y volatilidad del mercado.
- El Análisis de Sentimiento, integrado a partir de fuentes reputadas mediante modelos NLP, complementó la evaluación técnica, especialmente en fases de consolidación o incertidumbre.
- Sin embargo, se detectaron errores residuales o alucinaciones en escenarios de baja direccionalidad, indicando que la integración mejora la interpretación general, pero aún presenta retos metodológicos en contextos ambiguos.

Un resultado ilustrativo corresponde al 29 de enero de 2025, fecha en la que se mantenía una estructura de tendencia alcista, confirmada por la relación $EMA\ 50 > EMA\ 200$, como se muestra en la Tabla 4.3. Como se muestra en la Fig. 5.1, la línea MACD había cruzado ligeramente por debajo de su línea de señal, lo que sugiere una pérdida de *momentum* en una fase aún favorable. Este debilitamiento técnico fue contrastado con

un sentimiento moderadamente optimista derivado del análisis de noticias, lo que indica que, a pesar del enfriamiento en el impulso de mercado, persistía una percepción positiva general. Esta combinación refuerza la utilidad del sistema para detectar escenarios mixtos, en los que la integración de ambas perspectivas permite matizar el análisis y clasificar el entorno como una tendencia positiva con señales de cautela.




Figura 5.1: Indicador MACD y línea de señal en BTC/USDT durante enero de 2025. *Nota.* Se observa un cruce bajista del MACD por debajo de la línea de señal ocurrió entre el 27 y 28 de enero, lo que sugiere pérdida de *momentum* en una fase aún alcista (EMA 50 > EMA 200). Esta señal refuerza una lectura de cautela en el análisis integrado.

5.2. Respuesta a las Preguntas de Investigación

A continuación, se presentan las respuestas a las preguntas de investigación planteadas en el desarrollo de esta investigación. Estas respuestas sintetizan los resultados obtenidos a partir de la implementación y validación del sistema, evaluando tanto su desempeño técnico como su capacidad interpretativa en el contexto de análisis de criptomercados.

5.2.1. Precisión al Combinar NLP y Análisis Técnico

¿En qué medida la combinación de Procesamiento de Lenguaje Natural y Análisis Técnico mejora la precisión en la predicción de tendencias y la interpretación del sentimiento en los criptomercados?

Esta integración permitió al sistema identificar patrones numéricos mediante indicadores técnicos e incorporar señales cualitativas obtenidas del Análisis de Sentimiento a partir de fuentes informativas. Si bien no garantiza una precisión absoluta, la combinación de NLP y análisis técnico permitió generar reportes más contextualizados y consistentes, especialmente cuando las condiciones del mercado eran claramente direccionales o acompañadas de señales informativas coherentes.

5.2.2. *Modelos de NLP Más Efectivos*

¿Qué técnicas y modelos de NLP son más efectivos para analizar datos textuales en criptomercados y mejorar la identificación de tendencias?

El sistema integró dos enfoques complementarios. FinBERT se utilizó para la clasificación automática del sentimiento financiero, asignando etiquetas positivas, negativas o neutras a noticias previamente filtradas. Por su parte, LLaMA se empleó tanto para la generación de resúmenes breves como para la redacción de reportes estructurados que contextualizan la información agregada. En ambos casos, su efectividad dependió del uso de *prompts* altamente específicos. Ambos modelos demostraron ser útiles en distintas etapas del procesamiento, contribuyendo al análisis interpretativo de señales de mercado y a la coherencia narrativa de los reportes generados.

5.2.3. *Integración de Sentimiento y Análisis Técnico*

¿Cómo puede la integración del Análisis de Sentimiento con indicadores técnicos como RSI y MACD mejorar la predicción de tendencias en criptomercados?

La integración permitió reforzar las señales de confirmación o advertencia generadas por el Análisis Técnico. En escenarios donde indicadores como el RSI o el MACD presentaban lecturas ambiguas o neutras, las evaluaciones de sentimiento ofrecieron una perspectiva adicional que facilitó una interpretación más matizada del entorno. Esta complementariedad mejoró la capacidad del sistema para interpretar transiciones de fase y movimientos potenciales de consolidación o ruptura.

5.2.4. *Integración de Datos Estructurados y No Estructurados*

¿Cómo pueden integrarse datos estructurados, como los indicadores técnicos, y datos no estructurados, como las noticias y el Análisis de Sentimiento, para generar reportes dinámicos y efectivos en el análisis de criptomercados?

Los datos estructurados, como los indicadores técnicos calculados diariamente, se integraron con datos no estructurados provenientes de noticias financieras, cuyos resúmenes y métricas de sentimiento fueron agregados a nivel semanal. Ambos tipos de información fueron consolidados en reportes automatizados que combinaron señales cuantitativas con interpretaciones del contexto informativo. Esta integración permitió generar descripciones más completas del comportamiento del mercado, facilitando la identificación de patrones y condiciones relevantes mediante una síntesis coherente de datos heterogéneos.

5.2.5. *Impacto de LLaMA en la Precisión de los Reportes*

¿En qué medida el uso de NLP y modelos de lenguaje como LLaMA mejora la precisión de los reportes analíticos en criptomercados?

LLaMA contribuyó a mejorar la precisión narrativa de los reportes, al contextualizar de forma coherente las señales derivadas tanto de los indicadores técnicos como del análisis de sentimiento. Su desempeño fue especialmente útil para sintetizar información compleja en descripciones estructuradas y comprensibles. Sin embargo, su efectividad dependió de manera significativa del diseño del *prompt*, ya que instrucciones poco específicas tendían a generar inferencias no verificadas, particularmente en contextos ambiguos. En conjunto, el uso de LLaMA fortaleció la calidad interpretativa del sistema, siempre que se aplicaran restricciones adecuadas en la generación textual.

5.3. Consideraciones sobre Errores Residuales

A pesar de las optimizaciones implementadas, se identificaron errores residuales, particularmente en escenarios de baja volatilidad y consolidación. El modelo tendió a sobreinterpretar leves señales de *momentum* como cambios de tendencia, aunque la estructura técnica principal permanecía intacta.

Estos resultados resaltan la necesidad de controles adicionales en aplicaciones donde el análisis erróneo puede tener consecuencias críticas. En particular, sería recomendable explorar mecanismos de verificación secundaria, aplicar calibraciones dinámicas basadas en volatilidad observada o integrar ponderaciones explícitas que prioricen indicadores de tendencia estructural sobre señales momentáneas de impulso.

Estas estrategias podrían fortalecer la robustez del sistema en contextos de mercado caracterizados por alta incertidumbre o baja direccionalidad.

6. Capítulo: Conclusiones

La presente investigación abordó el desarrollo de un sistema automatizado para el análisis de tendencias y sentimiento en criptomercados, integrando técnicas de Procesamiento de Lenguaje Natural y Análisis Técnico. El objetivo general fue diseñar y validar una herramienta capaz de sintetizar información estructurada y no estructurada para apoyar la interpretación del contexto de mercado y facilitar la toma de decisiones informadas en entornos volátiles.

La integración de NLP y Análisis Técnico proporciona una mejora observable en la generación de reportes analíticos de criptomercados. El sistema demostró ser capaz de interpretar de forma coherente escenarios de con direccionalidad clara, integrando además señales de sentimiento provenientes de fuentes informativas reputadas. Esta capacidad de síntesis multidimensional representa una aportación relevante en el campo de la automatización del análisis de mercados digitales.

Sin embargo, persisten algunas limitaciones que deben ser consideradas. En primer lugar, la precisión alcanzada depende críticamente de la calidad del diseño de instrucciones y de los mecanismos de validación implementados para controlar posibles alucinaciones. Además, se identificaron restricciones inherentes al razonamiento cuantitativo: aunque los Modelos Extensos de Lenguaje son altamente competentes en el reconocimiento de patrones textuales y relacionales, presentan dificultades al interpretar magnitudes numéricas en contextos técnicos. En particular, tienden a interpretar los valores numéricos sin evaluar su proporción o impacto relativo, o a priorizar patrones narrativos sobre comparaciones cuantitativas estrictas, lo que puede derivar en interpretaciones incorrectas respecto a la relevancia o distancia entre diferentes indicadores.

Asimismo, se observaron dificultades en la interpretación de escenarios de baja volatilidad o direccionalidad ambigua, donde el modelo tendió a sobreinterpretar señales de volatilidad como cambios de tendencia. Este fenómeno evidencia la necesidad de mecanismos adicionales de calibración y de verificación secundaria en la inferencia automática de reportes.

Como líneas futuras de investigación, se propone, en primer lugar, explorar modelos de lenguaje entrenados específicamente para el dominio financiero, con el fin de mejorar

la precisión contextual en el análisis. En segundo lugar, se sugiere incorporar validadores estadísticos que ponderen la relevancia de los indicadores técnicos y de sentimiento en función de la volatilidad observada. También sería pertinente estudiar la automatización de portafolios de inversión mediante señales combinadas provenientes de datos de mercado y análisis de sentimiento. Finalmente, una línea potencialmente útil consiste en integrar mecanismos de explicabilidad (*explainable AI*, término en inglés), que permitan a los usuarios no solo recibir predicciones, sino también comprender de forma clara las razones detrás de cada recomendación, fortaleciendo así la transparencia y la confianza en el sistema.

Cabe destacar que el potencial de los Modelos Extensos de Lenguaje trasciende el ámbito financiero. Un ejemplo reciente es la presentación en LlamaCon 2025 de su integración en el Laboratorio Nacional de la Estación Espacial Internacional, donde se aprovechará LLaMA como herramienta de investigación, asistencia en decisiones rápidas y acceso a datos en entornos con conectividad limitada (Meta, 2025).

Más allá de este caso, estos modelos pueden emplearse en la detección temprana de riesgos sistémicos, facilitando la anticipación de crisis o contagios entre mercados. También tienen aplicaciones en el cumplimiento regulatorio, automatizando la verificación de normativas como la Ley Sarbanes-Oxley (SOX) y ayudando a reducir riesgos legales y financieros.

Finalmente, su uso en asistentes personalizados para pequeños inversionistas representa una vía para democratizar el acceso a herramientas analíticas avanzadas, tradicionalmente reservadas a grandes instituciones.

Estos desarrollos refuerzan la relevancia de seguir explorando y adaptando los modelos de lenguaje a dominios especializados, avanzando hacia soluciones más robustas, precisas y adaptativas. Aunque centrado en criptomercados, el sistema propuesto demuestra que es posible integrar datos estructurados y no estructurados para generar reportes automatizados con valor analítico real.

Esta investigación no solo aporta un marco funcional para combinar Análisis Técnico y Sentimiento mediante inteligencia artificial, sino que también abre nuevas posibilidades para la automatización del análisis financiero en entornos volátiles. Con ello, se espera que este trabajo contribuya de forma concreta al esfuerzo colectivo por desarrollar herramientas más accesibles, interpretables y eficaces para la toma de decisiones informadas en los mercados del futuro.

Referencias

- Abdullah, M. (2025). *GNews* (Ver. 0.4.0) [Provide an API to search for articles on Google News and returns a usable JSON response.]. <https://github.com/ranahaani/GNews>
- Aggarwal, V., Arora, A., & Kumar, P. (2023). Predicting the Movement of Index (Bank Nifty) Using Day's First Support & Resistance with Pivot Points Standard Indicator. *2023 IEEE 8th International Conference on Big Data, Cloud Computing, and Data Science (BCD)*, 98-101. <https://doi.org/10.1109/BCD57833.2023.10466353>
- Anand, H., & Arya, A. (2024). An Empirical Study of Financial BERT Models for Sentiment Analysis and Cryptocurrency Price Correlation. *2024 IEEE 9th International Conference for Convergence in Technology, I2CT 2024*. <https://doi.org/10.1109/I2CT61223.2024.10543560>
- Anghel, G. D. I. (2015). Stock Market Efficiency and the MACD: Evidence from Countries around the World. *Procedia Economics and Finance*, 32, 1414-1431. [https://doi.org/10.1016/S2212-5671\(15\)01518-X](https://doi.org/10.1016/S2212-5671(15)01518-X)
- Araci, D. (2019). FinBERT: A Pretrained Language Model for Financial Communications. *arXiv preprint arXiv:1908.10063*. <https://doi.org/10.48550/arXiv.1908.10063>
- Billade, K. K., Patel, J., Karthik, N., & Vani, V. (2024). Sentiment Analysis for Stock Prediction Using Mass Media Sources. En M. L. Owoc, F. E. Varghese Sicily, K. Rajaram & P. alasundaram (Eds.), *Computational Intelligence in Data Science* (pp. 179-189). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-69982-5_14
- Ccxt. (2025). CryptoCurrency eXchange Trading Library [4.4.78]. <https://github.com/ccxt/ccxt>
- Cho, A., Kim, G. C., Karpekov, A., Helbling, A., Wang, Z. J., Lee, S., Hoover, B., & Chau, D. H. (2024). Transformer Explainer: Interactive Learning of Text-Generative Models. *IEEE VIS*. <https://doi.org/10.48550/arXiv.2408.04619>
- Chomsky, N. (1957). *Syntactic Structures*. Mouton. <https://www.ling.upenn.edu/courses/ling5700/Chomsky1957.pdf>
- Chowdhery, A., Narang, S., Devlin, J., Bosma, M., Mishra, G., Roberts, A., Barham, P., Chung, H. W., Sutton, C., Gehrmann, S., Schuh, P., Shi, K., Tsvyashchenko, S.,

- Maynez, J., Rao, A., Barnes, P., Tay, Y., Shazeer, N., Prabhakaran, V., . . . Fiedel, N. (2022). PaLM: Scaling Language Modeling with Pathways. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2204.02311>
- CoinGecko. (2025). CoinGecko Cryptocurrency API [Consultado en abril de 2025]. <https://www.coingecko.com/en/api>
- Cong, L. W., Li, Y., & Wang, N. (2020). *Tokenomics: Dynamic Adoption and Valuation* (Working Paper N.º 2018-49, 2018-03-015, 2018-15, 18-62). Becker Friedman Institute; Fisher College of Business; Charles A. Dice Center; Columbia Business School. <https://doi.org/10.2139/ssrn.3222802>
- de Oliveira Carosia, A. E., da Silva, A. E. A., & Coelho, G. P. (2024). Predicting the Brazilian Stock Market with Sentiment Analysis, Technical Indicators and Stock Prices: A Deep Learning Approach. *Computational Economics*, 65, 2351-2378. <https://doi.org/10.1007/S10614-024-10636-Y/TABLES/14>
- Deb, S., Sankhe, A., Dalvi, I., & Vartak, P. (2024). Cryptocurrency Forecasting using Financial Indicators. *2024 15th International Conference on Computing Communication and Networking Technologies, ICCCNT 2024*. <https://doi.org/10.1109/ICCCNT61001.2024.10724096>
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *NAACL HLT 2019 - 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies - Proceedings of the Conference*, 1, 4171-4186. <https://doi.org/10.48550/arXiv.1810.04805>
- Dhokane, R. M., & Agarwal, S. (2024). Enhancing Stock Price Prediction with MACD and EMA Features Using LSTM Algorithm. *2024 International Conference on Emerging Smart Computing and Informatics (ESCI)*, 1-6. <https://doi.org/10.1109/ESCI59607.2024.10497295>
- Du, K., Xing, F., Mao, R., & Cambria, E. (2024). Financial Sentiment Analysis: Techniques and Applications. *ACM Computing Surveys*, 56, 220. <https://doi.org/10.1145/3649451>
- Fang, F., Vargas, J. P., & Mahmood, A. (2024). Cryptocurrency Trading: A Comprehensive Survey. En *Blockchain and Cryptocurrency: Applications and Outlook* (pp. 65-89). Springer. https://doi.org/10.1007/978-981-96-6839-7_4
- Feng, Z., Li, B., & Liu, F. (2024). *A First Look at Financial Data Analysis Using ChatGPT-4o* (inf. téc.). SSRN. <https://doi.org/10.2139/ssrn.4849578>
- Firza, Y., Dirgantoro, B., & Setianingsih, C. (2021). Bollinger Bands and Single Exponential Smoothing Methods in the Decision System of Selling and Buying Stock. *2021 3rd*

- International Conference on Electronics Representation and Algorithm (ICERA)*, 173-178. <https://doi.org/10.1109/ICERA53111.2021.9538632>
- Flores, C. D. (2023). Criptoactivos: Conceptos Básicos, posibles Beneficios y Riesgos Potenciales [Accessed: 2025-01-27]. https://www.gob.mx/cms/uploads/attachment/file/846231/8._Criptoactivos_-_Estudios_Econ_micos_CNBV_-_Vol._5.pdf
- Fu, Z., Zheng, Y., & Lin, J. (2025). Adaptive Volatility Analysis: An Integrated ATR Model for Dynamic Market Conditions. *Optimizations in Applied Machine Learning*, 2(2), 1-13. <https://doi.org/10.5281/zenodo.10842058>
- Hafid, A., Ebrahim, M., Rahouti, M., & Oliveira, D. (2024). Cryptocurrency Price Forecasting Using XGBoost Regressor and Technical Indicators. *2024 IEEE International Performance, Computing, and Communications Conference (IPCCC)*. <https://doi.org/10.1109/IPCCC59868.2024.10850357>
- Hamilton, W. P. (1922). *The Stock Market Barometer*. Harper & Brothers.
- Hipp, D. R. (2023). *SQLite* [Versión 3. Base de datos embebida]. <https://sqlite.org>
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y., Chen, D., Dai, W., Chan, H. S., Madotto, A., & Fung, P. (2022). Survey of Hallucination in Natural Language Generation. *ACM Computing Surveys*, 55. <https://doi.org/10.1145/3571730>
- Johnson, K. (2024). pandas-ta: A Technical Analysis Library in Python 3.6+ [GitHub repository]. <https://github.com/twopirllc/pandas-ta>
- Kensuke, I. T. (2024). Cryptoeconomics and Tokenomics as Economics: A Survey with Opinions. *2024 IEEE International Conference on Blockchain and Cryptocurrency, ICBC 2024*, 729-746. <https://doi.org/10.1109/ICBC59979.2024.10634383>
- Kirkpatrick, C. D., & Dahlquist, J. R. (2006). *Technical Analysis: The Complete Resource for Financial Market Technicians*. FT Press.
- Kirkpatrick, C. D., & Dahlquist, J. R. (2010). *Technical Analysis: The Complete Resource for Financial Market Technicians* (2nd). FT Press.
- Kudo, T., & Richardson, J. (2018). SentencePiece: A simple and language independent subword tokenizer and detokenizer for Neural Text Processing. *EMNLP 2018 - Conference on Empirical Methods in Natural Language Processing: System Demonstrations, Proceedings*, 66-71. <https://doi.org/10.18653/v1/d18-2012>
- Kumlungmak, K., & Vateekul, P. (2023). Multi-Agent Deep Reinforcement Learning With Progressive Negative Reward for Cryptocurrency Trading. *IEEE Access*, 11, 66440-66455. <https://doi.org/10.1109/ACCESS.2023.3289844>
- Lafferty, J. D., McCallum, A., & Pereira, F. C. N. (2001). Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. *Proceedings*

- of the 18th International Conference on Machine Learning (ICML)*, 282-289. <https://www.cs.columbia.edu/~jebara/6772/papers/crf.pdf>
- Lazarev, A., & Sedov, D. (2024). Utilizing Modern Large Language Models (LLM) for Financial Trend Analysis and Digest Creation. *2024 6th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA)*, 317-321. <https://doi.org/10.1109/SUMMA64428.2024.10803746>
- Liu, J., Makarov, I., & Schoar, A. (2023, abril). *Anatomy of a Run: The Terra Luna Crash* (Working Paper N.º 6847-23). MIT Sloan School of Management. Cambridge, MA. <https://doi.org/10.3386/w31160>
- Liu, M., Bo, S., & Fang, J. (2025). Enhancing Mathematical Reasoning in Large Language Models with Self-Consistency-Based Hallucination Detection. <https://doi.org/10.48550/arXiv.2504.09440>
- Liu, P., Yuan, W., Fu, J., Jiang, Z., Hayashi, H., & Neubig, G. (2021). Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural Language Processing. *ACM Computing Surveys*, 55. <https://doi.org/10.48550/arXiv.2107.13586>
- Malo, P., Sinha, A., Takala, P., Korhonen, P., & Wallenius, J. (2014). Good Debt or Bad Debt: Detecting Semantic Orientations in Economic Texts. *Journal of the American Society for Information Science and Technology*, 65(4), 782-796. <https://doi.org/10.1002/asi.23062>
- Mann, S., Arora, J., Bhatia, M., Sharma, R., & Taragi, R. (2023). Twitter Sentiment Analysis Using Enhanced BERT. *Lecture Notes in Electrical Engineering*, 959, 263-271. https://doi.org/10.1007/978-981-19-6581-4_21
- McKinney, W. (2010). Data Structures for Statistical Computing in Python. En S. van der Walt & J. Millman (Eds.), *Proceedings of the 9th Python in Science Conference* (pp. 51-56). SciPy. <https://doi.org/10.25080/Majora-92bf1922-00a>
- Meta. (2025). *Llama, our open source AI model, is going to space!* [Accessed: 2025-04-28]. <https://about.fb.com/news/2025/04/space-llama-metas-open-source-ai-model-heading-into-orbit/>
- Meta AI. (2024). *The LLaMA 3 Herd of Models* (inf. téc.) (Accesado: 2025-01-20). Meta Platforms Inc.
- Meta Platforms, Inc. (2013). React – A JavaScript library for building user interfaces. <https://reactjs.org>
- Mikolov, T., Chen, K., Corrado, G., & Dean, J. (2013). Efficient Estimation of Word Representations in Vector Space. *1st International Conference on Learning Representations, ICLR 2013 - Workshop Track Proceedings*. <https://doi.org/10.48550/arXiv.1301.3781>

- Murphy, J. J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications* (2nd). New York Institute of Finance.
- Nakamoto, S. (2008). Bitcoin: A Peer-to-Peer Electronic Cash System [Accesado: 2025-01-20]. <https://bitcoin.org/bitcoin.pdf>
- Newscatcher. (2024). *Newscatcher API* (Ver. 0.7.3) [NewsCatcher News API V2 SDK for Python]. <https://www.newscatcherapi.com/>
- Ollama Team. (2023). Ollama: Run Large Language Models Locally. <https://ollama.com>
- Otabek, S., & Choi, J. (2024). From Prediction to Profit: A Comprehensive Review of Cryptocurrency Trading Strategies and Price Forecasting Techniques. *IEEE Access*, 12, 87039-87064. <https://doi.org/10.1109/ACCESS.2024.3417449>
- Pennington, J., Socher, R., & Manning, C. D. (2014). GloVe: Global Vectors for Word Representation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1532-1543. <https://doi.org/10.3115/v1/D14-1162>
- Peters, M. E., Neumann, M., Iyyer, M., Gardner, M., Clark, C., Lee, K., & Zettlemoyer, L. (2018). Deep contextualized word representations. *arXiv preprint arXiv:1802.05365*. <https://doi.org/10.48550/arXiv.1802.05365>
- Radford, A., Narasimhan, K., Salimans, T., & Sutskever, I. (2018). Improving Language Understanding by Generative Pre-Training. *OpenAI*. https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf
- Ramírez, S. (2023). FastAPI framework, high performance, easy to learn, fast to code, ready for production. <https://github.com/fastapi/fastapi>
- Rees-Evans, A. (2024). How to Launch a Token. Springer. <https://doi.org/10.1007/979-8-8688-0533-2>
- Rhea, R. (1932). *The Dow Theory: An Explanation of Its Development and an Attempt to Define Its Usefulness as an Aid in Speculation*. Barron's.
- Sasmaz, E., & Tek, F. B. (2021). Tweet Sentiment Analysis for Cryptocurrencies. *6th International Conference on Computer Science and Engineering (UBMK)*. <https://doi.org/10.1109/UBMK52708.2021.9558914>
- Sennrich, R., Haddow, B., & Birch, A. (2015). Neural Machine Translation of Rare Words with Subword Units. *54th Annual Meeting of the Association for Computational Linguistics, ACL 2016 - Long Papers*, 3, 1715-1725. <https://doi.org/10.18653/v1/p16-1162>
- Shazeer, N. (2020). GLU Variants Improve Transformer. *arXiv preprint, arXiv:2002.05202*. <https://doi.org/10.48550/arXiv.2002.05202>

- Su, J., Ahmed, M., Lu, Y., Pan, S., Bo, W., & Liu, Y. (2021). RoFormer: Enhanced Transformer with Rotary Position Embedding. *Neurocomputing*, 568. <https://doi.org/10.1016/j.neucom.2023.127063>
- Tahmasbi, E. (2024). Evaluating the Effectiveness of Technical Analysis in the Cryptocurrency Market [ResearchGate]. <https://doi.org/10.13140/RG.2.2.29037.40164>
- Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M.-A., Lacroix, T., Rozière, B., Goyal, N., Hambro, E., Azhar, F., Rodriguez, A., Joulin, A., Grave, E., & Lample, G. (2023). LLaMA: Open and Efficient Foundation Language Models. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2302.13971>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention Is All You Need. *Advances in Neural Information Processing Systems, 2017-December*, 5999-6009. <https://doi.org/10.48550/arXiv.1706.03762>
- Wu, Y., Schuster, M., Chen, Z., Le, Q. V., Norouzi, M., Macherey, W., Krikun, M., Cao, Y., Gao, Q., Macherey, K., Klingner, J., Shah, A., Johnson, M., Liu, X., Kaiser, Ł., Gouws, S., Kato, Y., Kudo, T., Kazawa, H., ... Dean, J. (2016). Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation. <https://doi.org/10.48550/arXiv.1609.08144>
- Yamamoto, M. (2023). Evolution of Natural Language fProcessing Technology: Not Just Language Processing Towards General Purpose AI. <https://doi.org/10.48550/arXiv.2310.06228>
- Zhang, B., & Sennrich, R. (2019). Root Mean Square Layer Normalization. *Advances in Neural Information Processing Systems*, 32. <https://doi.org/10.48550/arXiv.1910.07467>