



Pontificia Universidad
JAVERIANA
Cali

PREDICCIÓN DE LA VOLATILIDAD DEL BITCOIN CON MODELOS CLÁSICOS Y DE MACHINE LEARNING

Christian Daniel Escobar Anduquía

Código 8992400

Luis Carlos Ruiz Ramos

Código 8993415

Vladimir Fabian Rivas Cortés

Código 8992535

*Proyecto Aplicado para optar al título de
Magister en Ciencia de Datos*

Directora

Isabel Cristina García Arboleda

**FACULTAD DE INGENIERÍA Y CIENCIAS
MAESTRÍA EN CIENCIA DE DATOS
SANTIAGO DE CALI, JUNIO 27 DE 2025**

TABLA DE CONTENIDO

INTRODUCCIÓN	7
1 DEFINICIÓN DEL PROBLEMA	9
1.1 PLANTEAMIENTO DEL PROBLEMA	9
1.2 FORMULACIÓN DEL PROBLEMA	10
2 OBJETIVOS DEL PROYECTO	11
2.1 OBJETIVO GENERAL	11
2.2 OBJETIVOS ESPECÍFICOS	11
3 MARCO TEÓRICO Y ANTECEDENTES	12
3.1 MARCO TEÓRICO	12
3.1.1 BITCOIN	12
3.1.2 ECONOMÍA Y FINANZAS	12
3.1.3 INVERSIÓN	13
3.1.4 VOLATILIDAD	13
3.1.5 TECNOLOGÍA BLOCKCHAIN	14
3.1.6 EDUCACIÓN FINANCIERA SOBRE CRIPTOMONEDAS	14
3.1.7 PREDICCIÓN MODELOS ESTADÍSTICOS CLÁSICOS	15
3.1.8 PREDICCIÓN MACHINE LEARNING (RED NEURONAL RECURRENTE)	16
3.1.9 PREDICCIÓN MACHINE LEARNING (ÁRBOLES DE DECISIÓN)	17
3.2 ANTECEDENTES	18
4 METODOLOGÍA APLICADA	22
4.1 ANÁLISIS EXPLORATORIO DE DATOS	24
4.1.1 DESCARGA Y DESCRIPCIÓN DE LOS DATOS	24
4.1.2 CÁLCULO DE LA VOLATILIDAD	25
4.1.3 VALIDACIÓN DE DATOS FALTANTES Y ATÍPICOS	26
4.1.4 ESTADÍSTICA DESCRIPTIVA	27
4.1.5 ANÁLISIS DE VOLATILIDAD	29
4.2 ANÁLISIS DE LA SERIE DE TIEMPO	33

4.2.1	DEFINICIÓN Y PREPARACIÓN DE LA SERIE.....	33
4.2.2	SELECCIÓN DEL PERIODO DE ESTUDIO	34
4.2.3	COMPONENTES DE LA SERIE	35
4.2.4	ANÁLISIS ACF Y PACF	38
4.2.5	PRUEBA DE ESTACIONARIEDAD	40
4.2.6	PREPARACIÓN DE DATOS PARA MODELADO PREDICTIVO	43
4.3	FUNDAMENTOS DE LOS MODELOS DE DEPENDENCIA TEMPORAL	44
4.3.1	MODELO ARCH	45
4.3.2	MODELO GARCH	46
4.3.3	MODELO LSTM.....	47
4.3.4	MODELO GRU.....	48
4.3.5	MODELO SRNN	49
4.3.6	MODELO XGBOOST.....	50
4.3.7	MODELO LIGHTGBM.....	51
5	DESARROLLO DE MODELOS	52
5.1	EVALUACIÓN DE LOS MODELOS	52
5.1.1	MODELOS CLÁSICOS DE SERIES DE TIEMPO	54
5.1.2	MODELOS DE REDES NEURONALES RECURRENTES	57
5.1.3	MODELOS DE ÁRBOLES DE DECISIÓN	61
5.2	CONFIGURACIÓN E IDENTIFICACIÓN DE PARÁMETROS	65
5.2.1	OPTIMIZACIÓN EN MODELOS CLÁSICOS	65
5.2.2	OPTIMIZACIÓN EN REDES NEURONALES RECURRENTES	68
5.2.3	OPTIMIZACIÓN EN ÁRBOLES DE DECISIÓN	71
5.3	COMPARACIÓN DE MODELOS	72
5.4	CONSTRUCCIÓN DE TABLERO DINÁMICO	76
6	CONCLUSIONES Y TRABAJOS FUTUROS	82
6.1	CONCLUSIONES.....	83
6.2	TRABAJOS FUTUROS	84
7	REFERENCIAS BIBLIOGRÁFICAS.....	87

LISTA DE FIGURAS

Figura 1. Metodología CRISP-DM para ciencia de datos	22
Figura 2. Estructura de datos importados	24
Figura 3. Ausencia de valores nulos.....	26
Figura 4. Detección de outliers.....	26
Figura 5. Resumen estadístico.....	27
Figura 6. Métricas históricas del Bitcoin	28
Figura 7. Comportamiento de la volatilidad en el tiempo	29
Figura 8. Box plot de la volatilidad	30
Figura 9. Gráfico Q-Q plot de la volatilidad	31
Figura 10. Diagrama de dispersión de volumen y volatilidad del Bitcoin	32
Figura 11. Comportamiento de la volatilidad en serie de tiempo	34
Figura 12. Tendencia de la serie de tiempo	35
Figura 13. Estacionalidad de la serie de tiempo.....	36
Figura 14. Residuales de la serie de tiempo.....	37
Figura 15. Función de autocorrelación de la serie de tiempo	38
Figura 16. Función de autocorrelación parcial de la serie de tiempo	39
Figura 17. Esquema funcional de la celda LSTM.....	47
Figura 18. Esquema funcional de la celda GRU	48
Figura 19. Esquema funcional de la celda SRNN	49
Figura 20. Predicciones ARCH y GARCH	55
Figura 21. Evolución de la función de pérdida MSE y MAE del modelo LSTM.....	58
Figura 22. Evolución de la función de pérdida MSE y MAE del modelo GRU	58
Figura 23. Evolución de la función de pérdida MSE y MAE del modelo SRNN	59
Figura 24. Predicciones iniciales para LSTM, GRU y SRNN	59
Figura 25. Evolución de la función de pérdida MSE y MAE del modelo XGBOOST	62
Figura 26. Evolución de la función de pérdida MSE y MAE del modelo LIGHTGBM	63
Figura 27. Predicciones iniciales para XGBOOST y LIGHTGBM.....	63
Figura 28. Flujo utilizado tipo ETL	76
Figura 29. Página inicial del tablero	77
Figura 30. Sección de cifras del Bitcoin y predicciones de los mejores modelos.....	78
Figura 31. Sección del mejor modelo base en el tablero	79
Figura 32. Sección del mejor modelo optimizado en el tablero	80
Figura 33. Ejemplo de sección de ayudas en modelo base	80
Figura 34. Ejemplo de sección de ayudas en modelo optimizado	81
Figura 35. Sección de información de la serie de tiempo en el tablero	81
Figura 36. Sección de información plana en el tablero	82

LISTA DE TABLAS

Tabla 1. Modelos estadísticos clásicos para predicciones de volatilidades	15
Tabla 2. Modelos de redes neuronales recurrentes para predicciones de volatilidades.	16
Tabla 3. Modelos de árboles de decisión para predicciones de volatilidades.....	17
Tabla 4. Principales estudios acerca de la predicción de la volatilidad del Bitcoin	18
Tabla 5. Adaptación de la metodología CRISP-DM.....	22
Tabla 6. Resultados de la prueba ADF	41
Tabla 7. Línea de tiempo del Bitcoin [60]	42
Tabla 8. Métricas iniciales para ARCH(1) y GARCH(1,1).....	55
Tabla 9. Métricas de validación cruzada para ARCH(1) y GARCH(1,1)	56
Tabla 10. Métricas iniciales para LSTM, GRU y SRNN	59
Tabla 11. Métricas de validación cruzada para LSTM, GRU y SRNN.....	61
Tabla 12. Métricas iniciales para XGBOOST y LIGHTGBM	63
Tabla 13. Métricas de validación cruzada para XGBOOST y LIGHTGBM	64
Tabla 14. Resultados optimización de los modelos clásicos	66
Tabla 15. Métricas finales para los modelos clásicos	67
Tabla 16. Resultados de optimización de modelos de redes neuronales recurrentes	69
Tabla 17. Métricas finales para los modelos de redes neuronales recurrentes.....	70
Tabla 18. Resultados de optimización de modelos de árboles de decisión	71
Tabla 19. Métricas finales para los modelos de árboles de decisión	72
Tabla 20. Validación estadística y robustez de los modelos optimizados.....	73

LISTA DE ANEXOS

Anexo 1. Enlace de acceso al código utilizado para el desarrollo del EDA.....	92
Anexo 2. Enlaces de acceso a los códigos utilizados para el desarrollo de modelos	92
Anexo 3. Enlace de acceso al tablero dinámico.....	92

INTRODUCCIÓN

La globalización ha integrado los mercados internacionales, permitiendo a los inversionistas construir portafolios diversificados con el objetivo de maximizar rentabilidades y mitigar riesgos. Esta integración ha generado un entorno económico dinámico, donde la asignación eficiente de recursos y el acceso a una mayor variedad de instrumentos financieros han incentivado la adopción de nuevas tecnologías y estrategias de inversión [1]. En este contexto, la digitalización del sector financiero propició el auge de activos alternativos como las criptomonedas, cuya adopción creció exponencialmente en los últimos años.

Con la llegada de la Cuarta Revolución Industrial, la implementación de tecnologías innovadoras dio lugar a la aparición de las criptomonedas, que funcionan exclusivamente a través de redes descentralizadas basadas en blockchain [2]. Entre ellas, el Bitcoin, lanzado en 2009, se consolidó como la criptomoneda más representativa, desafiando al sistema financiero tradicional mediante un mecanismo de transacciones más rápidas, económicas y transparentes. Su capacidad para actuar como medio de pago, reserva de valor e instrumento de inversión lo convirtió en un activo atractivo, aunque altamente volátil, lo que generó incertidumbre en los mercados y supuso un reto para los inversionistas [3].

La volatilidad extrema del Bitcoin dificultó su adopción como una alternativa de inversión confiable, dado que su valor experimentó variaciones significativas en cortos periodos de tiempo. Este comportamiento impulsó la necesidad de desarrollar modelos predictivos que permitieran anticipar sus fluctuaciones y proporcionar información clave para la toma de decisiones estratégicas [4]. Tradicionalmente, modelos estadísticos clásicos como ARIMA y sus variantes, fueron utilizados en la predicción de series de tiempo financieras, pero mostraron limitaciones al analizar activos con patrones no lineales y alta volatilidad [5]. En contraste, técnicas de machine learning, particularmente las redes neuronales recurrentes como LSTM y GRU, demostraron mayor capacidad para capturar relaciones complejas en los datos y mejorar la precisión de las predicciones [6].

Por ello, este proyecto tuvo como objetivo desarrollar y comparar modelos clásicos y de machine learning para la predicción de la volatilidad del Bitcoin, evaluando su efectividad y aplicabilidad en contextos de alta incertidumbre [7]. Este análisis no solo permitió comprender mejor el comportamiento del Bitcoin como activo financiero, sino que también puede contribuir al desarrollo de estrategias de inversión más sólidas y al diseño de políticas económicas informadas. Adicionalmente, el estudio buscó generar un marco educativo que facilitara la comprensión de los riesgos y oportunidades asociados a las

criptomonedas, para que inversionistas, analistas y formuladores de políticas puedan tomar decisiones fundamentadas.

La metodología empleada en este estudio se basó en el análisis de datos históricos extraídos de Yahoo Finance [8], una plataforma ampliamente utilizada en el ámbito financiero por su confiabilidad y acceso a información detallada sobre precios, capitalización de mercado y volumen de transacciones, lo que garantiza un acceso constante y fiable a suficientes muestras para entrenar modelos. A través de este conjunto de datos, se construyeron y evaluaron modelos predictivos utilizando técnicas de aprendizaje supervisado, permitiendo una comparación objetiva entre enfoques clásicos y avanzados, y brindando una visión más completa de las tendencias del mercado.

Si bien el análisis predictivo del Bitcoin ha sido abordado desde distintas perspectivas, su naturaleza altamente especulativa plantea desafíos adicionales que requieren enfoques profundos y metodologías más adaptativas. El impacto de factores externos, como regulaciones gubernamentales, cambios en la percepción del mercado y avances tecnológicos, sugiere que el estudio de la volatilidad del Bitcoin debe considerar no solo datos históricos, sino también variables contextuales que influyen en su comportamiento.

En este sentido, los desarrollos futuros en el modelado predictivo podrían beneficiarse de técnicas más avanzadas de procesamiento de lenguaje natural para analizar el sentimiento del mercado, combinando estadística tradicional y aprendizaje profundo [9].

En última instancia, la continua evolución de los mercados financieros digitales resalta la importancia de seguir perfeccionando estos modelos predictivos. La integración de nuevas fuentes de datos y metodologías emergentes permitirá mejorar la precisión de las predicciones y optimizar la gestión del riesgo en mercados financieros altamente volátiles.

1 DEFINICIÓN DEL PROBLEMA

1.1 PLANTEAMIENTO DEL PROBLEMA

El mercado de criptomonedas, con el Bitcoin a la vanguardia, presenta una volatilidad significativa, lo que lo convierte en un terreno fértil para la investigación en ciencia de datos. La predicción precisa de la volatilidad del precio del Bitcoin es crucial para inversores, traders y analistas que buscan tomar decisiones informadas en este entorno altamente dinámico. Sin embargo, la naturaleza compleja y no lineal del comportamiento de los datos del Bitcoin hace que se presenten desafíos para los modelos tradicionales de predicción financiera. Este problema se ve agravado por la falta de consenso sobre un modelo único que pueda capturar eficazmente las fluctuaciones de la volatilidad del precio del Bitcoin.

A pesar de los avances en la aplicación de técnicas de aprendizaje automático, como redes neuronales, en la predicción de precios financieros, la eficacia de estos enfoques para el Bitcoin aún está bajo revisión. Además, la literatura existente sobre este tema presenta una variedad de enfoques y resultados, lo que subraya la necesidad de una evaluación comparativa exhaustiva. Esta disparidad de resultados resalta la necesidad de un estudio que analice de manera integral y comparativa los modelos clásicos de predicción financiera, como ARCH (Autoregressive Conditional Heteroskedasticity) y GARCH (Generalized Autoregressive Conditional Heteroskedasticity), con los enfoques más recientes basados en redes neuronales, como RNN (Redes Neuronales Recurrentes), entre las que se incluye LSTM (Long Short-Term Memory) y GRU (Gated Recurrent Unit) en el contexto específico del Bitcoin.

En consecuencia, el presente trabajo se centró en el desafío de predecir con precisión la volatilidad del precio del Bitcoin utilizando una variedad de técnicas de modelado, con el objetivo de identificar qué modelos son más efectivos en este dominio. Este problema no solo es de interés académico, sino que también tiene implicaciones prácticas significativas para inversores y participantes en el mercado de las criptomonedas.

En vista de lo anterior, el problema que se abordó en este proyecto enmarcó componentes estadísticos clásicos y de machine learning al analizar variaciones y realizar predicciones, financieros al evaluar los riesgos de inversión, y de analítica de datos por detectar patrones y tendencias, que coadyuven al entendimiento de la volatilidad. La construcción se realizó tomando como base los retornos logarítmicos diarios del precio del Bitcoin de cinco años atrás, que, entre otros factores, recoge el

impacto de diversos fenómenos en el precio, permitiendo de paso conocer su variabilidad en el mercado en tiempos de estrés financiero. Cabe señalar que este proyecto se enfocó exclusivamente en información de carácter cuantitativo.

1.2 FORMULACIÓN DEL PROBLEMA

Desde la aparición y fortalecimiento de las criptomonedas, las soluciones y usos de negocio se han expandido constantemente. Hasta ahora, el Bitcoin se ha mantenido como el criptoactivo más popular y con mayor capitalización del mercado [10]. De acuerdo con diversas fuentes, eventos globales de diferente índole, como la condena de Sam Bankman-Fried, la inestabilidad de Wall Street o las tensiones entre Estados Unidos y Rusia por la guerra en Ucrania, no han detenido el crecimiento de Bitcoin, que registró un nuevo máximo en su precio a finales de 2024, cercano a los 109.000 dólares. De esta manera, es importante resaltar que, a pesar de las fluctuaciones que caracterizan el mercado de las criptomonedas, Bitcoin ha mostrado una notable resiliencia [11].

Precisamente, estas variaciones en la volatilidad del precio del Bitcoin generan incertidumbre en los mercados financieros y plantean el menester de identificar el modelo más efectivo para su predicción. En este contexto, surge la necesidad de preguntarse ¿Cuál es el modelo más efectivo para predecir la volatilidad del precio del Bitcoin: modelos estadísticos clásicos o modelos de machine learning?

Esta cuestión se desglosa en una serie de preguntas específicas que permiten un análisis más detallado del fenómeno, a través de la implementación de una serie de modelos clásicos y de machine learning:

- ¿Cómo se desempeñan las técnicas de modelado clásicas, como ARCH y GARCH, en la predicción de la volatilidad del precio del Bitcoin?
- ¿Cómo se desempeñan los modelos de machine learning (LSTM y GRU), en la predicción de la volatilidad del precio del Bitcoin?
- ¿Qué parámetros y configuraciones específicas de cada modelo influyen más en la precisión de las predicciones de la volatilidad del precio del Bitcoin?
- ¿Cuáles son las ventajas y desventajas de los modelos de series temporales clásicos frente a los modelos de redes neuronales recurrentes, en términos de precisión y capacidad de generalización para la predicción de la volatilidad del precio del Bitcoin?

2 OBJETIVOS DEL PROYECTO

2.1 OBJETIVO GENERAL

Desarrollar un cuadro comparativo de modelos para predecir la volatilidad del precio del Bitcoin, utilizando enfoques clásicos y técnicas avanzadas de aprendizaje automático, para identificar los métodos más efectivos y apoyar la toma de decisiones de inversión.

2.2 OBJETIVOS ESPECÍFICOS

- Evaluar la efectividad y alcance de las técnicas de modelado clásicas, como ARCH y GARCH, y de machine learning, como LSTM y GRU, en la predicción de la volatilidad del precio del Bitcoin.
- Determinar los parámetros y configuraciones específicas de cada modelo, que más influyen en la precisión de las predicciones de la volatilidad del precio del Bitcoin.
- Distinguir las principales ventajas y desventajas de los modelos de series temporales clásicos frente a los modelos de redes neuronales recurrentes, en términos de precisión y capacidad de generalización para la predicción de la volatilidad del precio del Bitcoin.
- Construir un tablero dinámico que consolide los resultados de cada modelo, para facilitar su interpretación y comparación.

3 MARCO TEÓRICO Y ANTECEDENTES

3.1 MARCO TEÓRICO

A continuación, se presenta una revisión detallada de la literatura existente con el propósito de establecer los conceptos fundamentales que sustentan este proyecto. Se hará especial énfasis en los pilares financieros, estadísticos y de aprendizaje automático, proporcionando una base teórica que facilite la comprensión y modelado de los datos.

Asimismo, se analizará el papel del Bitcoin en las economías modernas, destacando su impacto en los mercados, su volatilidad y su función como activo digital clave. En este contexto, la predicción de su precio se ha convertido en un área de gran interés, ya que una estimación precisa puede mejorar significativamente las estrategias de inversión y la gestión del riesgo.

3.1.1 BITCOIN

La criptomoneda Bitcoin que inicialmente fue creada en el 2008, con la finalidad de ser un software, que se utilizaría para el envío de dinero, sin necesidad de pasar por intermediarios, lo que representaría un ahorro para las personas, vía disminución de costos de las transacciones [12], ha evolucionado y gracias a su naturaleza, basada en la tecnología blockchain, le permite ser soporte para varias tareas, entre ellas, cumplir funciones de ser; sistema de pago, activo de inversión, dinero digital, depósito de valor, en otras palabras, servir como un facilitador de transacciones, especialmente en las que operan en bloques de grandes volúmenes de datos [13]. Ahora, lo cierto es que sus propiedades representan una competencia para los canales tradicionales del mercado financiero, como el sistema bancario; banco central, banca comercial, banca de inversión y otras entidades intermediadoras, lo que ha generado que algunos países, especialmente los europeos, comiencen a ejercer regulación al respecto, de manera que el activo digital sea aceptado en la economía, pero sin poner en riesgo la estabilidad del sistema financiero [14].

3.1.2 ECONOMÍA Y FINANZAS

La globalización ha transformado la manera en cómo los individuos realizan negocios, haciendo a un lado la moneda física y dando paso al dinero electrónico, que cada día es más común en la sociedad. Esto se ha convertido en el soporte, para que aparezcan las monedas virtuales o criptomonedas, las cuales no dependen de sistemas centralizados para su emisión, registro, compensación y liquidación, caso contrario al dinero físico, que

depende de un banco central [15]. Lo anterior y sumado a la volatilidad inherente a las criptomonedas, ha generado la necesidad de realizar un análisis exhaustivo al rol que desempeñan en la economía y las finanzas de un país, hasta el punto en que, el Comité de Basilea, hace un pronunciamiento de prudencia frente a las criptomonedas, considerando los posibles riesgos que podrían afectar al sistema financiero global [16]. Sin embargo, más allá de estas consideraciones, se encuentran las alternativas de crecimiento económico que pueden generar el uso del Bitcoin y otras monedas digitales, que son ventajosos para los mercados locales, dado que permite aumentar los activos nacionales, producto de la rentabilidad generada por su volatilidad [17].

3.1.3 INVERSIÓN

La significativa variabilidad en el precio de los cryptoactivos se ha convertido en un tema popular, que llama la atención de muchos inversionistas, quienes, a pesar de mostrar una significativa aversión al riesgo, optan por conocer más en detalle el funcionamiento del mercado de las criptomonedas, para saber cómo beneficiarse de las fluctuaciones del precio, que responden a las leyes de la oferta y la demanda. Por esta razón resulta primordial evaluar tanto las ventajas como desventajas de realizar inversiones en este tipo de activos, principalmente el factor de la volatilidad [18]. Los inversionistas tienen con el Bitcoin otros incentivos adicionales, como la aceptación para transacciones comerciales, lo que evita la conversión de los beneficios en dinero físico, dado que naturalmente, se percibe como un medio de pago, así, las criptomonedas se convertirán en dinero fiduciario, consolidándose y perfeccionando su uso [19]. A esto se le suma el atractivo de que su emisión no dependa de ningún ente gubernamental, lo que termina impidiendo la falsificación, así como costos de las transacciones más bajos y que no se ven afectados por la inflación [20], no obstante, las decisiones de inversión dependerán en todo momento de la aversión al riesgo de cada individuo.

3.1.4 VOLATILIDAD

A pesar de no estar reguladas por ninguna autoridad o Banco Central y de su naturaleza altamente volátil y difícil de prever, las criptomonedas se han consolidado como una herramienta financiera y comercial innovadora, utilizadas para el intercambio de bienes y servicios, como también en inversiones a escala global [21]. La volatilidad de las criptomonedas, aunque puede ser vista como insegura y riesgosa, ha generado interés en su posible utilización como instrumentos de cobertura frente a otros activos volátiles dentro de portafolios de inversión, sin embargo, resulta relevante resaltar que, mientras la variación de su precio en el corto plazo sea alta, difícilmente se podrán considerar como refugio de valor o incluso internacionalmente aceptada como moneda real [22].

Realizando un análisis al comportamiento del precio del Bitcoin, se encuentra que en periodos tan cortos como una semana, puede ganar o perder aproximadamente el 30% de su valor de mercado, influenciado por factores como; la especulación, la competencia de otras criptomonedas, el cierre de casas de cambio, y la concentración de mercado, aunque también se podría considerar la presión que genera en los inversionistas, debido a que su oferta total está fijada en 21 millones de Bitcoins [23].

3.1.5 TECNOLOGÍA BLOCKCHAIN

Con la llegada de las criptomonedas, el mundo se enteró de la tecnología blockchain o cadena de bloques, que es la que soporta el funcionamiento de estas. Se puede definir de manera simplificada como unidades descentralizadas que registran un hecho económico y crean un nuevo registro para preservar la cronología de los eventos [24], o en otras palabras más detalladas, consiste en una base de datos descentralizada y estructurada en bloques, que emplea criptografía para asegurar que las transacciones permanezcan inalteradas y ha sido fuente de evolución, siendo cada vez más común observar su implementación en las empresas [25]. En la actualidad se usa en contratos inteligentes, pagos, registro de datos, propiedad intelectual, educación, mercados financieros, entre otros, en todos los campos pensando en la eficiencia y optimización de recursos. Por otra parte, esta tecnología también facilita la interacción con los datos que producen las empresas, creando conexiones con otras regiones del mundo, lo que implica la optimización de recursos económicos y tiempo de descarga de información [26]. En consecuencia, las monedas virtuales traen consigo otra serie de ventajas, que pueden ser apropiadas por el Estado y las empresas, como lo es su tecnología, que es generadora de valor agregado en procesos y en la toma de decisiones, a través de la disminución de costos. Así, no solo los inversionistas se pueden beneficiar de las criptomonedas, sino también la sociedad en general, conociendo más a fondo sobre la tecnología que las pone en marcha.

3.1.6 EDUCACIÓN FINANCIERA SOBRE CRIPTOMONEDAS

Las criptomonedas se han vuelto un tema muy popular en los últimos años, a diario se escuchan algunos términos relacionados con sus usos y aplicabilidad. Los inversionistas, dependiendo de su nivel de aversión al riesgo, previamente investigan sobre la rentabilidad y riesgos asociados por utilizar el Bitcoin y otras criptomonedas como activo de inversión. Para esto es fundamental conocer cómo se está preparando la población, para entender mejor los conceptos relacionados con los criptoactivos. Al respecto, en Colombia, hay una notable falta de entendimiento sobre las criptomonedas tanto en el sector empresarial como en el gubernamental, lo cual podría desencadenar en riesgos

financieros y regulatorios. La ausencia de regulaciones claras y la desconfianza resultante han dificultado su adopción, creando dudas en su implementación [27]. Un caso contrario ocurre en México, en donde las casas de cambio de criptomonedas se encuentran sujetas a la Ley Fintech, por lo que ya existe una parcial regulación, pero, aun así, la adopción de criptomonedas es limitada. A pesar de que existen medios y formas para utilizarlas, gran parte de la población no sabe cómo usarlas, ni cómo integrarlas en sus negocios o como medios de pago, desconociendo que son generadoras de inclusión financiera [28]. De aquí, se destaca la importancia de proporcionar una educación financiera sólida a los inversores interesados en las criptomonedas, partiendo de conceptos básicos hasta análisis técnico, debido a la complejidad y la rápida evolución de este mercado [29].

Cabe precisar que, las criptomonedas, además, han despertado interés académico y de empresas por establecer las variables externas que generan aumentos o descensos en los precios del Bitcoin en el mercado, razón por la cual establecer la predicción de la variabilidad es un tema de amplio estudio, donde se busca tener en cuenta todos los aspectos que generen dichas fluctuaciones. Entre los cuales se han encontrado que tiene una correlación cercana con commodities como el oro o el petróleo [30], eventos geopolíticos como la guerra entre Ucrania y Rusia usados en estudios para generar predicciones sobre su valor [31]. De aquí la importancia de seguir avanzando en estudios sobre su volatilidad.

3.1.7 PREDICCIÓN MODELOS ESTADÍSTICOS CLÁSICOS

La predicción estadística busca a través de experimentos, corroborar un hecho esperado frente a los resultados reales. Históricamente se han utilizado unos modelos denominados clásicos, para proyectar datos en el tiempo. A continuación, la **Tabla 1** agrupa los principales modelos clásicos de pronósticos y su relación con las series de tiempo, puesto que la volatilidad del precio del Bitcoin se presenta continuamente en cualquier intervalo de tiempo:

Tabla 1. Modelos estadísticos clásicos para predicciones de volatilidades

Modelo	Descripción
ARIMA (Modelo Autorregresivo Integrado De Promedio Móvil)	Su propósito es determinar el proceso estocástico que han producido los datos, estimar parámetros que definan ese proceso y validar las hipótesis que han facilitado dicha estimación. Consiste en un modelo econométrico que intenta describir el valor actual de una variable específica, con la particularidad de que la serie analizada ya ha sido sometida a un proceso de diferenciación (I) de orden d. Se encuentran condicionados al cumplimiento de los

	supuestos de; estacionariedad en los datos, el modelo es univariado y sus residuales deben comportarse como ruido blanco [32].
ARCH (Modelo Autorregresivo con Heterocedasticidad Condicional)	Define la volatilidad como la varianza condicional o la varianza de la distribución de rendimientos, que depende de información pasada. La varianza condicional se encarga de capturar las fluctuaciones para estudiar la volatilidad. Deben cumplir el supuesto de no correlación de los residuales y de los residuales al cuadrado [33].
GARCH (Modelo Autorregresivo Generalizado con Heterocedasticidad Condicional)	Representa una extensión de los modelos ARCH, incorporando residuos cuadrados y varianzas condicionales rezagadas, por lo que buscan mejorar la estimación de la heterocedasticidad. Los datos deben tener una distribución de probabilidad asociada. Así, en estos modelos, la volatilidad resulta ser una función lineal de los valores pasados [34].

3.1.8 PREDICCIÓN MACHINE LEARNING (RED NEURONAL RECURRENTE)

La predicción mediante redes neuronales recurrentes (RNN) se presenta como una herramienta poderosa para capturar tendencias y patrones temporales en grandes volúmenes de datos financieros. Gracias a su capacidad para procesar información secuencial, las RNN han demostrado ser efectivas en el pronóstico de series temporales, incluyendo la volatilidad del Bitcoin. A continuación, la **Tabla 2** muestra las principales técnicas basadas en RNN utilizadas para el pronóstico de series financieras.

Tabla 2. Modelos de redes neuronales recurrentes para predicciones de volatilidades

Modelo	Descripción
MLP (Perceptrón Multicapa)	Se le conoce como red neuronal hacia adelante. Se caracteriza porque la información se transfiere de una capa a otra sin conexiones de retroalimentación. Se toma un vector de n variables y se le aproxima una función, para predecir una variable o vector de respuesta, estimando los parámetros que mejor se ajusten. Se usa para tareas de clasificación y regresión, en donde las variables de entrada y salida no son lineales [35].
LSTM (Memoria a Largo Plazo)	Cuenta con una estructura que facilita la calibración de los parámetros de acuerdo con un criterio de ajuste previamente establecido para mejorar la predicción. Las estructuras son especificaciones cuyos valores no se aprenden ni ajustan automáticamente durante el proceso de entrenamiento, pero que influyen de manera significativa en el rendimiento y la capacidad del modelo para identificar patrones en los datos [36].
GRU (Unidades Recurrentes Cerradas)	Es una variante del LSTM, pero con la diferencia de que combina las compuertas de olvidar y de entrada en una sola actualización. Se ha comprobado que GRU supera al LSTM básico en ciertas

	aplicaciones. Además, opera como una optimización del LSTM en términos de cantidad de parámetros, dado que, no cuenta con una unidad de memoria independiente [37].
SRNN (Redes Neuronales Recurrentes Simples)	Permite capturar relaciones temporales inmediatas en series de tiempo como la volatilidad del Bitcoin, pero su simplicidad estructural lo hace menos eficaz para detectar patrones de largo alcance o persistencias prolongadas. Su valor reside en servir como punto de partida para entender el funcionamiento básico de las redes recurrentes y como comparación frente a arquitecturas más avanzadas como LSTM o GRU, que abordan sus limitaciones estructurales mediante mecanismos de memoria y control del flujo de información [38].

3.1.9 PREDICCIÓN MACHINE LEARNING (ÁRBOLES DE DECISIÓN)

En el contexto de la predicción financiera, los árboles de decisión han demostrado ser herramientas eficaces para analizar grandes volúmenes de datos y detectar patrones complejos en mercados volátiles como el de las criptomonedas. Modelos avanzados basados en árboles, optimizan la capacidad predictiva al mejorar la selección de variables y reducir el sobreajuste. A continuación, la **Tabla 3** presenta las principales técnicas basadas en árboles de decisión aplicadas al pronóstico de series financieras.

Tabla 3. Modelos de árboles de decisión para predicciones de volatilidades

Modelo	Descripción
Random Forest	Es un algoritmo que combina múltiples modelos para mejorar la precisión y reducir el sobreajuste. Utiliza la técnica de bagging, donde se generan subconjuntos aleatorios de los datos de entrenamiento y se entrenan árboles de decisión independientes. Sus predicciones se combinan mediante un promedio (en regresión) o votación mayoritaria (en clasificación). En el contexto de la predicción de volatilidad en mercados financieros, Random Forest resulta útil debido a su capacidad para capturar relaciones complejas entre múltiples variables económicas, manejar datos ruidosos y mitigar el impacto de eventos atípicos, lo que lo convierte en una herramienta eficaz para anticipar cambios en la volatilidad del Bitcoin y otros activos financieros [39].
XGBOOST (Aumento de gradiente extremo)	Se trata de un algoritmo que emplea la técnica de boosting para mejorar la precisión y estabilidad de las predicciones. Su enfoque consiste en entrenar secuencialmente múltiples modelos débiles, donde cada nuevo modelo corrige los errores del anterior, logrando un modelo final más robusto. Se distingue por su eficiencia computacional y su capacidad para manejar datos ruidosos, lo que lo hace adecuado para problemas de clasificación y regresión. En la predicción de la volatilidad, permite identificar patrones

	complejos en los datos financieros y capturar relaciones no lineales entre variables económicas. Su precisión y resistencia a valores atípicos lo convierten en una herramienta eficaz para anticipar cambios en la volatilidad de activos financieros [40].
LIGHTGBM (Máquina potenciadora de gradiente de luz)	Corresponde a un algoritmo que también emplea la técnica de boosting, pero que optimiza el crecimiento de los árboles utilizando una estrategia de hoja a hoja en lugar de nivel a nivel, lo que permite una mejor captura de patrones en grandes volúmenes de datos y reduce el tiempo de entrenamiento. En la predicción de rendimientos es capaz de identificar movimientos de mercado con cierto retraso, destacándose por su capacidad para combinar datos técnicos, macroeconómicos y factores del modelo Fama-French. Su capacidad para manejar grandes conjuntos de datos y seleccionar de manera eficiente las características más relevantes lo convierte en una herramienta útil para mejorar la precisión en la estimación de la volatilidad, ofreciendo una mayor similitud entre las predicciones y los índices comparativos en comparación con modelos lineales tradicionales [41].

3.2 ANTECEDENTES

La **Tabla 4** resume las principales investigaciones que tienen relación con el planteamiento del problema, identificando la importancia de la Ciencia de Datos en la construcción de modelos predictivos y toma de decisiones informadas.

Tabla 4. Principales estudios acerca de la predicción de la volatilidad del Bitcoin

Estudio	Contribución
Predicción del precio del Bitcoin utilizando algoritmos de aprendizaje profundo Autor: Emanuelle Alejandro Moreno Quintero Año: 2023	En este estudio se crearon modelos predictivos para el precio de cierre del Bitcoin, utilizando algoritmos de aprendizaje profundo, y se compararon con modelos tradicionales para evaluar su rendimiento. Se descubrió que tanto las redes neuronales convolucionales (CNN) como el modelo ARIMA son inadecuados para este tipo de predicciones, mientras que los modelos de machine learning demostraron un desempeño superior [42].
Análisis de activos financieros en Colombia: cobertura de posiciones con Bitcoin Autores: Christian Daniel Escobar Anduquía Sebastián Darío Avella Jiménez Brayan Ricardo Rojas Ormaza	En este artículo se analizaron las propiedades de cobertura, diversificación y refugio de valor de 10 tipos de activos financieros en relación con las inversiones en Bitcoin, utilizando un modelo de correlaciones condicionales dinámicas (DCC). Se demostró que el Bitcoin ofrece una nueva opción como vehículo de inversión para la economía de

Año: 2023	Colombia, dado que su capacidad de sostenimiento financiero de largo plazo y su volatilidad lo hacen un mecanismo capaz para realizar coberturas frente a otros activos del mercado [43].
Análisis comparativo de redes neuronales profundas para la predicción del precio de mercado de Bitcoin Autor: Aarón López García Año: 2023	En este artículo se desarrollaron tres tipos de modelos de redes neuronales junto con un modelo comparativo para predecir los precios futuros de cierre del Bitcoin. Se descubrió que los modelos temporales, como LSTM, son más representativos que los modelos espaciales para este tipo de pronósticos, dado que los efectos temporales parecen ser determinantes en la estimación del precio de la criptomoneda [12].
Modelos de predicción estocástica para Bitcoin: una evaluación de métodos y desempeño Autores: Caroline Hernández Hernández Juan Sebastián Forero Criollo Año: 2023	En esta investigación se implementaron modelos predictivos para el precio del Bitcoin, destacando; LSTM, GRU, SVR, árboles de decisión, Random Forest y XGBOOST. Se evaluó el desempeño con diferentes métricas de comparación, encontrando a XGBOOST como el modelo más eficaz al incorporar hiperparámetros, optimización bayesiana y validación cruzada anidada [40].
LSTM-GARCH para la predicción de volatilidad en portafolios de criptomonedas Autor: Ester Aguayo Moreno Año: 2021	En este estudio se generaron modelos heterocedásticos de autocorrelación condicional; EGARCH y GJRGARCH, en portafolios compuesto por criptomonedas para pronosticar volatilidad y rendimientos. Se mostró que los modelos univariados GJRGARCH presentan menos errores de estimación, mientras que los modelos EGARCH logran mayores valores en la Razón de Sharpe, es decir, generando un mayor rendimiento esperado por unidad de riesgo [44].
Modelos de predicción del precio de Bitcoin mediante algoritmos de Machine Learning Autor: Eric Jimenez Bujalance Año: 2022	En este trabajo se desarrollaron modelos para predecir el precio del Bitcoin, utilizando algoritmos automáticos de machine learning; random forest, Regresión lineal y series temporales (forecasting), a partir de un conjunto de datos con atributos relacionados con el precio de la criptomoneda. Se valoraron los modelos en función de los errores de regresión, destacándose el modelo de Regresión Lineal por obtener los mejores resultados en comparación con el precio real [45].
Visión actual del Bitcoin desde la perspectiva de los inversionistas Autor: Jonathan Roberto López Marín	En este artículo se analizó el contexto actual del Bitcoin, considerando el papel de inversionistas. Los resultados mostraron que la confianza sobre la criptomoneda ha sido variable, debido a las

Carlos Alberto Paz Gómez Gladys Hernández Romero Año: 2022	caídas significativas en el precio de mercado. Finalmente, se destaca la existencia de múltiples factores que influyen en la volatilidad, por lo que muchos inversionistas no siguen predicciones o gráficos para obtener un grado de satisfacción con respecto a su inversión, sino que se dejan influenciar por otros usuarios [46].
Evolución del precio del Bitcoin. Análisis estadístico de series temporales. Autor: Le Jun Chen Año: 2018	En este estudio se compararon varios modelos para la estimación del precio del Bitcoin, entre ellos; modelo de regresión dinámica y modelo ARIMA. Se concluyó que el modelo ARIMA no es óptimo y que el precio del Bitcoin no muestra tendencias estacionales, es decir, su comportamiento no se repite con periodicidad, adicional, no logra corregir la heterocedasticidad de la varianza. Así se opta por lo que el modelo dinámico, que es más sencillo y explica mejor la variabilidad del precio [11].
Las criptomonedas en el sistema financiero internacional. Un análisis predictivo mediante técnicas de Machine Learning (LSTM) Autor: Arnau Castillo Mur Año: 2020	En esta investigación se diferenciaron los modelos estadísticos de los de machine learning y se demuestra estadísticamente que un modelo perfectamente especificado no siempre produce las mejores predicciones para precios de criptomonedas. Se analizó la capacidad predictiva del precio de cierre mediante modelos de machine learning, como las redes LSTM, y modelos estadísticos, como el modelo ARIMA. Se observó que las redes LSTM son mejores candidatas para la predicción del precio de cierre en comparación con otras alternativas como las redes neuronales recurrentes (RNN) [47].
Factores que influyen en el comportamiento del Bitcoin y su volatilidad Autores: Julieth Andrea Gracia Torres Angie Daniela Hurtado Cuellar Año: 2019	En este trabajo se identificaron los factores políticos, económicos y sociales en las principales economías mundiales, que han impactado en la alta volatilidad del Bitcoin. Asimismo, se destacan aspectos clave para entender su manejo en el mundo digital. Se encontró a través de metodología cualitativa y descriptiva que, la inestabilidad política, regulatoria y la aceptación por parte de pequeñas empresas locales han sido factores clave para que la moneda se mantenga y por tanto presente volatilidad [48].
Prediciendo el precio del Bitcoin, y más Autores: Leidy Catherine Sánchez Ascanio John Alexander Arredondo García2	En este artículo se analizaron los precios del Bitcoin, utilizando los principios básicos de la técnica de las ondas de Elliott, que es una de las herramientas más utilizadas en el campo del

Año: 2020	trading financiero. Se demostró que esta técnica ofrece un margen de efectividad aceptable en la predicción y, debido a su simplicidad, puede ser una herramienta útil para cualquier inversor interesado en el mercado de criptomonedas [49].
Predicción del comportamiento de criptomonedas a partir de métodos de inteligencia artificial Autor: Aldo Ferrando Esteve Año: 2023	En este trabajo se desarrolló un instrumento para la toma de decisiones de inversiones de corto plazo, utilizando datos financieros históricos obtenidos de Yahoo Finance y Prophet de Facebook. Esta última se utilizó para pronosticar las cotizaciones de las criptomonedas mediante un modelo aditivo, arrojando conclusiones gráficas muy intuitivas, para inversionistas con poca experiencia en activos bursátiles [50].
Modelo GARCH para la volatilidad de las criptomonedas Bitcoin y Ether Autor: Antonio Martínez Jenkins Año: 2016	En esta investigación se estimaron modelos GARCH y EGARCH, comparándolos entre sí, encontrando que en ambos modelos, para las series de Bitcoin y Ether, las pruebas del multiplicador de Lagrange (LM TEST) y la prueba de autocorrelación de Ljung-Box sobre los residuos normalizados al cuadrado, muestran que los modelos capturan adecuadamente la varianza condicional, por lo que se procedió a proceder a realizar una predicción a largo plazo de los valores de la serie de rentabilidades y de su volatilidad con el método bootstrap, sin embargo, se observó inestabilidad en los coeficientes estimados [51].
Comparación de algoritmos de Deep Learning para pronósticos en los precios de criptomonedas Autores: Erick Lambis Alandete Miguel Jiménez Gómez Juan D. Velásquez Henao Año: 2023	En este artículo se analizaron cuatro modelos de Deep Learning: RNN, LSTM, GRU y CNN-LSTM, para evaluar su desempeño en la predicción del precio de cierre diario del Bitcoin y Ethereum. Se utilizaron métricas para medir el desempeño: MAE, RMSE, MSE y MAPE y como métrica de ajuste, el R ² . Se encontró que, el algoritmo RNN tuvo un mejor rendimiento en la predicción del precio de Bitcoin, mientras que el algoritmo LSTM lo tuvo en el precio de Ethereum [52].
¿Es factible que el Bitcoin alcance un millón de dólares en 5 años? Autores: Carlos Acevedo Año: 2022	En este artículo se estudiaron los escenarios de viabilidad para que el precio del Bitcoin se incremente considerablemente, pensando en la inversión en bonos de la criptomoneda que realizó el Gobierno de El Salvador. Se aplicaron diferentes métodos de pronósticos como: ARIMA, suavización exponencial simple y doble, promedio móvil simple y doble, función polinómica y función exponencial. Se encontró que con la mayoría de

	los modelos convencionales es poco viable alcanzar el precio de un millón de dólares para el Bitcoin. Si bien el modelo exponencial plantea la posibilidad matemática de llegar al precio, económicamente no es factible lograrlo [53].
--	---

4 METODOLOGÍA APLICADA

Para desarrollar este estudio, se adoptó la metodología CRISP-DM, un enfoque estructurado ampliamente utilizado en proyectos de análisis de datos [54]. Su aplicación permitió abordar el problema de manera sistemática, desde la comprensión del fenómeno financiero hasta la evaluación de modelos predictivos. Se siguieron sus seis fases principales, las cuales se resumen en la **Figura 1** [55]:




Figura 1. Metodología CRISP-DM para ciencia de datos

La **Tabla 5** muestra el ajuste de la metodología CRISP-DM aplicada específicamente a la predicción de la volatilidad del Bitcoin. Este ajuste describe cómo cada fase de la metodología se adaptó para abordar los desafíos específicos asociados con el análisis y la predicción de la volatilidad de un activo tan impredecible como el Bitcoin, utilizando tanto modelos clásicos como de machine learning.

Tabla 5. Adaptación de la metodología CRISP-DM

Fase	Descripción
1. Entendimiento del negocio	Se definió el problema de investigación y su relevancia en el contexto financiero. Dado que la volatilidad del Bitcoin representa un desafío para inversores y analistas, se planteó la necesidad de

	evaluar modelos de predicción, comparando enfoques tradicionales (ARCH, GARCH) con técnicas modernas de machine learning (RNN, LSTM, GRU). También se identificaron los objetivos específicos del proyecto, como la evaluación del desempeño de los modelos y la búsqueda de patrones en la volatilidad del Bitcoin.
2. Entendimiento de los datos	Se realizó un análisis exploratorio de los datos históricos del precio del Bitcoin y su volatilidad, considerando un periodo de al menos cinco años. Además, se estudiaron fuentes de datos complementarias como indicadores macroeconómicos y otras métricas. Se analizaron estadísticas descriptivas, correlaciones y distribuciones para comprender la estructura de los datos y posibles sesgos.
3. Preparación de los datos	Se llevó a cabo la limpieza y transformación de los datos para adecuarlos a los modelos predictivos. Para esto se realizó verificación de valores atípicos y datos faltantes; generación de características derivadas, como retornos logarítmicos y volatilidad histórica; normalización y escalado de variables para mejorar el rendimiento de los modelos de machine learning; creación de conjuntos de entrenamiento y prueba, asegurando que los datos más recientes fueran utilizados para la validación.
4. Modelado	Se implementaron diversos modelos para la predicción de la volatilidad del Bitcoin, incluyendo modelos estadísticos tradicionales (ARCH y GARCH); modelos basados en redes neuronales recurrentes (LSTM y GRU); modelos propios de machine learning (XGBOOST y LIGHTGBM). Para cada modelo, se realizaron ajustes de hiperparámetros y pruebas de diferentes arquitecturas con el objetivo de optimizar su rendimiento.
5. Evaluación	Los modelos fueron evaluados utilizando métricas estándar como el Error Cuadrático Medio (MSE), el Error Absoluto Medio (MAE) y la Raíz del Error Cuadrático Medio (RMSE), entre otras. También se analizaron indicadores específicos para evaluar la precisión en la predicción de cambios en la volatilidad. Se compararon los resultados obtenidos para determinar qué enfoque resultó más efectivo en distintos escenarios de mercado.
6. Despliegue	Los hallazgos del estudio se documentaron de manera detallada para ofrecer conclusiones prácticas y sugerencias sobre su aplicación en estrategias de inversión. Además, se desarrolló un tablero dinámico que presenta los resultados de las predicciones de los modelos de manera comparativa, lo cual facilita la visualización de las distintas predicciones de volatilidad generadas tanto por los enfoques clásicos como por los de machine learning. Este tablero permite a los usuarios tomar decisiones más informadas al ofrecer una representación clara y accesible de los resultados del análisis comparativo, contribuyendo así a mejorar la toma de decisiones en un entorno financiero.

4.1 ANÁLISIS EXPLORATORIO DE DATOS

Antes de aplicar cualquier modelo de predicción, resulta necesario comprender a fondo la estructura y el comportamiento de los datos. Para ello, se recurre al Análisis Exploratorio de Datos (EDA), una fase esencial en todo estudio de ciencia de datos, cuyo objetivo es examinar y resumir las características clave del conjunto de datos. En este apartado se realiza un análisis exploratorio sobre las variables relacionadas con el precio del Bitcoin, enfocándose especialmente en la creación y evaluación de la variable de volatilidad. Este proceso incluye la revisión de distribuciones, la detección de valores atípicos o nulos, y la identificación de relaciones entre variables, con el fin de garantizar la calidad de la información y descubrir patrones relevantes. Así, el EDA permite sentar una base sólida para modelar la dinámica temporal del activo y avanzar con mayor precisión en las etapas posteriores del análisis predictivo.

Para llevar a cabo este análisis, es fundamental contar con datos históricos confiables. A continuación, se describe cómo obtener datos de un activo financiero desde Yahoo Finance utilizando la librería `yfinance` de Python, asegurando su calidad antes del análisis de series de tiempo. Para más información ver **Anexo 1** que contiene el código utilizado para el análisis exploratorio de datos y selección de la serie de tiempo.

4.1.1 DESCARGA Y DESCRIPCIÓN DE LOS DATOS

Se utiliza la librería ***yfinance*** para descargar los datos históricos del par de divisas BTC-USD (Bitcoin frente al dólar estadounidense), desde el 1 de enero de 2014 fecha inicial disponible en la fuente hasta el día anterior a la fecha de ejecución del código. En este caso particular, los datos descargados incluyen información hasta el 31 de diciembre de 2024. Cabe destacar que esta metodología es completamente reproducible para cualquier intervalo de fechas dentro del rango disponible en ***Yahoo Finance***, lo que permite su adaptación a distintos periodos de análisis según las necesidades del estudio. La **Figura 2** muestra un ejemplo de la estructura que se obtiene tras la importación de los datos.

Price	Close	High	Low	Open	Volume
Ticker	BTC-USD	BTC-USD	BTC-USD	BTC-USD	BTC-USD
2024-12-27	94164.859375	97294.843750	93310.742188	95704.976562	52419934565
2024-12-28	95163.929688	95525.898438	94014.289062	94160.187500	24107436185
2024-12-29	93530.226562	95174.875000	92881.789062	95174.054688	29635885267
2024-12-30	92643.210938	94903.320312	91317.132812	93527.195312	56188003691
2024-12-31	93429.203125	96090.601562	91914.031250	92643.250000	43625106843

Figura 2. Estructura de datos importados

A continuación, se describe cada variable:

- **Close:** Precio de cierre al final del día.
- **High:** Precio más alto alcanzado en el día.
- **Low:** Precio más bajo alcanzado en el día.
- **Open:** Precio de apertura del Bitcoin para cada día.
- **Volume:** Volumen total de Bitcoin negociado en el día.

Como la variable de estudio es la volatilidad, la cual no se encuentra suministrada directamente por la fuente, se procede con la creación de esta, a través de la obtención de los rendimientos diarios y su desviación estándar.

4.1.2 CÁLCULO DE LA VOLATILIDAD

Una vez obtenidos y validados los datos históricos del Bitcoin, el siguiente paso consiste en construir la variable objetivo del estudio: la volatilidad. Esta representa la magnitud de las variaciones en el precio del activo a lo largo del tiempo y es fundamental para evaluar su nivel de riesgo e incertidumbre. Para ello, se parte del cálculo de los rendimientos logarítmicos diarios, que permiten estandarizar los cambios porcentuales entre precios consecutivos. A partir de estos rendimientos se obtiene la desviación estándar móvil, que actúa como medida cuantitativa de la volatilidad. A continuación, se describen las fórmulas y procedimientos utilizados para su cálculo.

Rendimientos diarios: son la diferencia en el logaritmo de los precios de cierre de dos días consecutivos. Es decir, si P_t es el precio de cierre en el día t y P_{t-1} es el precio de cierre en el día $t-1$, el rendimiento logarítmico se calcula de la siguiente manera:

$$r_t = \ln \left(\frac{P_t}{P_{t-1}} \right)$$

Desviación estándar: r_t es el rendimiento logarítmico en el día t y n es el número de observaciones (o el tamaño de la ventana de tiempo que se está utilizando). Se toman los rendimientos logarítmicos de cada día, se elevan al cuadrado (para hacerlos positivos), se suman y luego se dividen entre n . Finalmente, se toma la raíz cuadrada de ese promedio para obtener la desviación estándar (volatilidad), la cual se calcula así:

$$\sigma = \sqrt{\frac{1}{n} \sum_{t=1}^n r_t^2}$$

4.1.3 VALIDACIÓN DE DATOS FALTANTES Y ATÍPICOS

En el caso de los valores nulos o **NA**, ninguna de las columnas contiene valores nulos (0 en todas las columnas). La ausencia de valores nulos garantiza que los datos están listos para análisis sin necesidad de imputación o eliminación de registros y se puede comprobar en la **Figura 3**:

Price	
Close	0
High	0
Low	0
Open	0
Volume	0
Log_Returns	0
Volatility	0

dtype: int64

Figura 3. Ausencia de valores nulos

Para los **outliers**, su identificación es una etapa fundamental en el análisis de datos, puesto que estos puntos extremos pueden distorsionar el análisis y los modelos estadísticos. En este caso, se utiliza un enfoque basado en el cálculo del **z_score** modificado, que es robusto frente a valores extremos al emplear la mediana y desviación absoluta media. La **Figura 4** muestra los datos atípicos encontrados, destacando que, Para un umbral de 3 en el cálculo de **z_score** se identificaron 135 **outliers**:




Figura 4. Detección de outliers

4.1.4 ESTADÍSTICA DESCRIPTIVA

Una vez calculada la variable de volatilidad, se hace necesario comprender las características generales del conjunto de datos sobre el cual se realizará el análisis. Esta descripción permite identificar la distribución, el rango y la dispersión de las variables numéricas asociadas al comportamiento del Bitcoin. Para ello, se emplea el comando **describe()** del entorno de programación en **Python**, que genera un resumen estadístico básico pero revelador de las columnas numéricas del dataframe utilizado. La **Figura 5** describe estas propiedades:

	Price	Close	High	Low	Open	Volume	Log_Returns	Volatility
count		3759.000000	3759.000000	3759.000000	3759.000000	3759.000000	3758.000000	3729.000000
mean		19585.858210	20003.126695	19103.286844	19562.390621	18582981195.111465	0.001416	0.033044
std		22126.525737	22584.216017	21597.380679	22097.867872	20343227124.134804	0.036457	0.015193
min		178.102997	211.731003	171.509995	176.897003	5914570.000000	-0.464730	0.007082
25%		1226.309998	1242.800049	1208.440002	1223.955017	410167504.000000	-0.012658	0.022803
50%		9350.529297	9530.518555	9202.353516	9349.161133	14643548444.000000	0.001334	0.030378
75%		30569.386719	31350.405273	30050.850586	30526.150391	29737200552.000000	0.016829	0.040570
max		106140.601562	108268.445312	105291.734375	106147.296875	350967941479.000000	0.225119	0.103649

Figura 5. Resumen estadístico

Las métricas hacen referencia a:

- **Count:** Cantidad total de registros disponibles (3.759 días en este caso).
- **Mean:** Promedio de los valores en la columna.
- **Std:** Desviación estándar, que mide la dispersión de los datos.
- **Min:** Valor mínimo registrado.
- **25% (1er cuartil):** Valor por debajo del cual se encuentra el 25% de los datos.
- **50% (mediana):** Valor central del conjunto de datos.
- **75% (3er cuartil):** Valor por debajo del cual se encuentra el 75% de los datos.
- **Max:** Valor máximo registrado.

El análisis estadístico de las variables numéricas revela una gran dispersión en los precios de Bitcoin, evidenciada por desviaciones estándar elevadas. Esta volatilidad es un reflejo de la naturaleza especulativa del activo, donde las fluctuaciones extremas han sido una constante en su evolución.

Además, la presencia de asimetría positiva en la distribución de los precios sugiere que los valores extremos tienden a estar concentrados hacia la derecha del eje, con episodios

de crecimiento súbito seguidos de correcciones abruptas. Este comportamiento es coherente con los ciclos especulativos que caracterizan al mercado de las criptomonedas.

Por otra parte, la alta desviación estándar en los precios del Bitcoin destaca la magnitud de sus fluctuaciones absolutas. Como complemento, al calcular el coeficiente de variación ($CV = Std/Mean$) se puede evaluar esta dispersión en relación con la media. Para este caso el resultado fue de 1,12, lo que reafirma que la variabilidad en los precios es significativa respecto al promedio, lo que contribuye a su percepción como un activo de alto riesgo.

Estas características son coherentes con un mercado marcado por eventos abruptos, como ciclos especulativos y choques externos. El rango de precios (178 a 106.140 USD) y el volumen negociado (de millones a cientos de miles de millones) destacan la naturaleza volátil y cambiante del mercado. La **Figura 6** refleja la evolución histórica de los precios de apertura, cierre, máximo y mínimo del Bitcoin, lo que permite identificar patrones clave en su comportamiento y analizar la volatilidad del activo.




Figura 6. Métricas históricas del Bitcoin

Se observa una clara tendencia ascendente en el comportamiento del Bitcoin a lo largo del tiempo, con picos pronunciados seguidos de caídas abruptas. Estos movimientos reflejan una alta volatilidad y una dinámica de mercado especulativa. La consistencia entre las series de apertura, cierre, máximo y mínimo refuerza la fiabilidad del conjunto de datos y sugiere que todas reflejan adecuadamente la evolución del precio del activo. Además, los picos extremos suelen coincidir con eventos clave en el mercado, como regulaciones, avances tecnológicos o noticias económicas, lo que subraya la sensibilidad del activo a factores externos. A pesar de las fluctuaciones, la tendencia general ascendente indica una creciente adopción del Bitcoin, impulsada tanto por especulación como por su consolidación como instrumento financiero en mercados globales. Estos patrones destacan la importancia de considerar herramientas de análisis técnico y estrategias de cobertura para gestionar el riesgo asociado a su naturaleza volátil.

4.1.5 ANÁLISIS DE VOLATILIDAD

Si la volatilidad se concentra en valores bajos, significa que Bitcoin generalmente experimenta movimientos estables. Si hay una distribución amplia con valores altos, indica que Bitcoin pasa por periodos de alta inestabilidad, lo cual es importante para traders e inversores. Si la volatilidad de Bitcoin es baja la mayor parte del tiempo, pero tiene picos extremos, significa que es un activo potencialmente rentable, pero con riesgo alto. De aquí la importancia de conocer el histórico de volatilidad. La **Figura 7** refleja un histograma con una curva de densidad que representa la distribución de la volatilidad del Bitcoin a lo largo del tiempo:




Figura 7. Comportamiento de la volatilidad en el tiempo

Se observó que la distribución tiene una asimetría positiva (sesgo a la derecha), lo que significa que la mayoría de los valores de volatilidad son bajos, pero hay algunos días

con valores mucho más altos. Por otro lado, la mayor parte de los datos están concentrados entre 0.01 y 0.05 de volatilidad. Sin embargo, a medida que la volatilidad aumenta (más allá de 0.05), la frecuencia disminuye drásticamente. Este tipo de distribución es típico de los activos financieros, donde los eventos de alta volatilidad son extraños, pero pueden ser muy impactantes.

Como complemento, el gráfico tipo **box plot** permite observar la distribución de la volatilidad del Bitcoin por año. Este tipo de visualización es ideal para identificar tendencias anuales, dispersión de los datos y la presencia de valores atípicos.

La **Figura 8** presenta este análisis visual, a partir del cual se destacan varios comportamientos relevantes.




Figura 8. Box plot de la volatilidad

De la dispersión de la volatilidad a lo largo del tiempo, se observa que:

- **2014-2017:** son los años con mayor dispersión y mayor número de valores atípicos, lo que sugiere alta inestabilidad. Bitcoin tenía una volatilidad más alta y variable.
- **2018-2019:** muestra una volatilidad más controlada, con menos valores extremos. Se estabilizó un poco, pero con episodios de alta volatilidad.
- **2020:** es el año con el mayor valor atípico de todo el gráfico (volatilidad extrema). Probablemente asociado con eventos del mercado como la pandemia del COVID-19. Año con la volatilidad más extrema, coincidiendo con la crisis global.

- **2021-2024:** muestra una tendencia a la baja en la volatilidad, con menor dispersión y menos valores extremos. La volatilidad parece haberse reducido, sugiriendo que Bitcoin ha madurado como activo.

Ahora, como complemento es de relevancia conocer la distribución de la variable, por tanto, se genera un **Q-Q plot** (Quantile-Quantile plot), que es una herramienta gráfica que permite comparar la distribución de los datos observados con una teórica normal. La **Figura 9** muestra la distribución de los datos.




Figura 9. Gráfico Q-Q plot de la volatilidad

De la distribución, se observa que los valores de volatilidad se desvían de la línea roja en los extremos, lo que sugiere colas más pesadas de lo esperado en una distribución normal.

Esto indica que la volatilidad de Bitcoin presenta leptocurtosis, es decir, hay más valores extremos (picos y caídas abruptas) de lo que una normal modelaría. En consecuencia, modelos tradicionales que asumen normalidad como regresión lineal o métodos basados en varianza constante no serían adecuados para describir la volatilidad de Bitcoin. En su lugar, se requieren modelos más avanzados que pueden capturar la heterocedasticidad y las características específicas de los datos financieros.

Finalmente, la información presentada en la sección anterior corresponde a un análisis univariado de la variable volatilidad. Ahora se incluye un gráfico tipo diagrama de dispersión que muestra la relación entre el volumen de transacciones y la volatilidad del Bitcoin. Este análisis ayuda a identificar posibles patrones o correlaciones entre estas dos variables. La **Figura 10** muestra la asociación entre el par de variables.




Figura 10. Diagrama de dispersión de volumen y volatilidad del Bitcoin

Al observar la dispersión, se evidencia que, en la mayoría de los días, el Bitcoin opera en un entorno de volatilidad relativamente baja y volúmenes no extremos. Sin embargo, también se identifican episodios puntuales con alta volatilidad y volúmenes elevados, reflejando la naturaleza dinámica y sensible del activo ante eventos externos, destacando que:

- **Baja volatilidad + Bajo volumen:** indica un mercado estable, con menor actividad.
- **Baja volatilidad + Alto volumen:** establece acumulación de posiciones, posibles movimientos futuros.
- **Alta volatilidad + Alto volumen:** muestra eventos de mercado fuertes (anuncios importantes o crisis).
- **Alta volatilidad + Bajo volumen:** identifica movimientos erráticos sin fuerte respaldo del mercado.

Aunque existe una relación entre la volatilidad y el volumen dado que una mayor volatilidad suele atraer más operaciones, esta no sigue una correlación lineal fuerte. En términos generales, un aumento en la volatilidad suele ir acompañado de un incremento en el volumen de operaciones. Esto se debe a que, cuando el precio de un activo como Bitcoin experimenta movimientos bruscos, los inversores y traders incrementan sus transacciones para aprovechar dichas fluctuaciones, lo que a su vez eleva el volumen [56].

El análisis exploratorio ha permitido identificar que la volatilidad del Bitcoin presenta una distribución asimétrica positiva, con periodos de estabilidad intercalados con picos extremos de alta volatilidad, lo que refleja su naturaleza especulativa y su sensibilidad a eventos del mercado. Además, se ha observado que, aunque el volumen de negociación

tiende a aumentar en momentos de alta volatilidad, la relación entre estas variables no es completamente lineal. Dado que la volatilidad es un componente esencial para evaluar el riesgo y la dinámica del mercado de Bitcoin, surge la necesidad de realizar un análisis de series de tiempo. Este permitirá modelar su comportamiento, identificar patrones, detectar estacionalidad y realizar predicciones que puedan ser útiles para la toma de decisiones estratégicas en inversión y gestión de riesgos.

4.2 ANÁLISIS DE LA SERIE DE TIEMPO

Una vez comprendida la estructura general de los datos y construida la variable de interés, se procede a su análisis como serie de tiempo. Esta etapa permite examinar la evolución temporal de la volatilidad del Bitcoin, identificando patrones, ciclos y comportamientos sistemáticos que no pueden observarse a través de análisis estáticos.

4.2.1 DEFINICIÓN Y PREPARACIÓN DE LA SERIE

Una serie de tiempo es una sucesión de observaciones de una variable registradas en intervalos temporales regulares, donde la dependencia temporal juega un papel clave en su análisis [57]. En este estudio, la serie de tiempo analizada corresponde a la volatilidad diaria del Bitcoin, en lugar de su precio. El objetivo es examinar su comportamiento a lo largo del tiempo, identificando tendencias, posibles patrones estacionales y variaciones en la magnitud de los cambios para comprender mejor su dinámica.

Cabe resaltar que, para trabajar con series de tiempo es menester que el índice del dataframe sea del tipo ***DatetimeIndex***. Esto garantiza que las operaciones y funciones temporales operen de manera correcta.

Con los datos ya transformados y validados, se procede al análisis de la volatilidad como una serie de tiempo. Esta etapa permite descomponer la serie en sus componentes clave: tendencia, estacionalidad y ruido, lo que facilita la comprensión de su comportamiento en el tiempo. Además, se aplican herramientas estadísticas como la autocorrelación y la prueba de estacionariedad para determinar la viabilidad del uso de modelos temporales. Este análisis revela patrones relevantes y confirma las características estructurales de la serie, permitiendo seleccionar los enfoques más adecuados para el modelado predictivo.

Es primordial conocer que las series de tiempo pueden presentar distintos componentes clave. Por un lado, está la tendencia, que indica si los valores crecen, disminuyen o se mantienen estables a largo plazo. También pueden mostrar estacionalidad, es decir, fluctuaciones que se repiten periódicamente. Además, existen ciclos, movimientos que pueden durar años y estar relacionados con factores económicos o estructurales.

Otro aspecto fundamental es la volatilidad, que mide cuánto varían los datos con respecto a su media. Cuando la volatilidad es alta, los valores pueden cambiar bruscamente en cortos periodos de tiempo, mientras que una baja volatilidad indica estabilidad. Sin embargo, toda serie de tiempo contiene un cierto grado de ruido, es decir, variaciones aleatorias que no siguen ningún patrón específico y que pueden dificultar el análisis.

4.2.2 SELECCIÓN DEL PERIODO DE ESTUDIO

En la volatilidad del Bitcoin, el estudio de su serie de tiempo permite entender cómo ha fluctuado en distintos periodos y qué factores podrían estar influyéndola. Al analizar su comportamiento, es posible desarrollar modelos que ayuden a anticipar futuros cambios, lo que resulta clave para la toma de decisiones en los mercados financieros. La **Figura 11** muestra el comportamiento histórico de la variable a través de una serie de tiempo.



Figura 11. Comportamiento de la volatilidad en serie de tiempo

El periodo ideal para desarrollar el análisis de series de tiempo y modelado depende de varios factores, como la estabilidad del comportamiento, la presencia de patrones recurrentes y la cantidad de datos disponibles. Tras una revisión detallada del conjunto de datos, se decidió emplear la porción de datos correspondiente al periodo 2021-2024. Esto debido a que es periodo que contiene información reciente y presenta una volatilidad relativamente estructurada, lo que permite entrenar modelos que capturen patrones más

relevantes para predicciones futuras sin verse excesivamente afectados por eventos atípicos de periodos anteriores.

4.2.3 COMPONENTES DE LA SERIE

Para comprender mejor el comportamiento dinámico de la volatilidad del Bitcoin, se debe descomponer la serie de tiempo en sus elementos estructurales. Este proceso permite aislar las distintas fuentes de variación que influyen en los datos, facilitando una lectura más clara de su evolución. Al analizar estos componentes por separado, se obtiene una visión más detallada del comportamiento temporal, lo que resulta clave para la identificación de patrones relevantes y la posterior selección de modelos de predicción adecuados. A continuación, se describen estos componentes:

Tendencia: representa el patrón general de crecimiento o decrecimiento en la serie. La **Figura 12** refleja el componente de tendencia de la volatilidad del Bitcoin.




Figura 12. Tendencia de la serie de tiempo

De la tendencia se destaca el siguiente comportamiento:

Crecimiento Inicial:

- Desde inicios de 2021 hasta mediados del mismo año, la volatilidad se mantiene en niveles elevados, superando el 0.04.
- Esto sugiere que el mercado experimentó fuertes fluctuaciones en los precios del Bitcoin, posiblemente debido a factores externos como el auge del mercado de criptomonedas en ese periodo.

Declive Sostenido:

- A partir de mediados de 2021, la volatilidad inicia una tendencia descendente constante.

- Este descenso se prolonga hasta mediados de 2023, alcanzando valores mínimos cercanos al 0.02.
- La caída en la volatilidad coincide con un periodo de menor incertidumbre en el mercado, posiblemente debido a la maduración del ecosistema cripto, regulaciones más claras o menor especulación.

Estabilidad y Recuperación:

- Desde mediados de 2023 hasta inicios de 2024, la volatilidad se mantiene relativamente estable, con valores cercanos a los mínimos registrados en el periodo anterior.
- Posteriormente, a partir de inicios de 2024, la volatilidad comienza a mostrar una recuperación gradual, sugiriendo un aumento en la incertidumbre del mercado.

Estacionalidad: muestra patrones repetitivos en la serie de tiempo que ocurren en intervalos regulares, proporcionando información sobre los ciclos inherentes al comportamiento del mercado. La **Figura 13** describe el componente estacional de la serie de tiempo.



Figura 13. Estacionalidad de la serie de tiempo

La estacionalidad indica la presencia de:

Patrón Repetitivo:

- Se observa un ciclo claro y recurrente en la volatilidad del Bitcoin, con picos y valles distribuidos de manera periódica.
- Los picos de volatilidad representan momentos donde las fluctuaciones del precio del Bitcoin han sido más intensas, posiblemente por eventos macroeconómicos, noticias del mercado cripto o movimientos especulativos.
- Los valles de volatilidad coinciden con periodos de relativa calma, donde la variabilidad de los precios ha sido menor.

Amplitud Variable:

- En 2021, la amplitud de los ciclos es mayor, lo que sugiere que la volatilidad estacional era más fuerte y que los precios experimentaban fluctuaciones más pronunciadas en esos periodos.
- Durante 2022 y 2023, la amplitud disminuye, lo que indica una posible estabilización en la volatilidad. Esto podría estar asociado con una menor especulación o con la madurez del mercado.
- En 2024, la amplitud vuelve a incrementarse, lo que sugiere que la volatilidad estacional ha retomado fuerza. Esto puede estar relacionado con eventos recientes del mercado, como cambios regulatorios, nuevos ciclos de inversión o adopción institucional.

Periodicidad:

- Presenta ciclos recurrentes de alta frecuencia.
- Esto indica que el mercado sigue un patrón predecible en ciertos periodos del año, donde la volatilidad tiende a aumentar o disminuir de manera sistemática.

Residuales: reflejan las fluctuaciones aleatorias o el ruido en la serie de tiempo después de eliminar las componentes de tendencia y estacionalidad. Este análisis es fundamental para evaluar qué tan bien las componentes explican la serie original. La **Figura 14** muestra el componente residual en la serie de tiempo.



Figura 14. Residuales de la serie de tiempo

De los residuales se destaca:

Patrones Aleatorios:

- La gráfica de los residuales no muestra una tendencia clara ni ciclos recurrentes, lo que indica que las principales dinámicas de la serie (tendencia y estacionalidad) han sido capturadas correctamente.

- La volatilidad residual parece estar distribuida de manera aleatoria, lo cual es un buen signo de que el modelo de descomposición ha aislado los efectos sistemáticos.

Volatilidad Variable:

- En 2021 y 2022, los valores de los residuales presentan mayor dispersión y fluctuaciones más amplias, lo que sugiere periodos de alta incertidumbre y posibles eventos extraordinarios en el mercado.
- A partir de 2023, los residuales parecen estabilizarse, con fluctuaciones más controladas, lo que podría indicar una menor presencia de eventos inesperados o una reducción en la volatilidad no explicada por los componentes estructurales.

Valores Extremos:

- Se pueden observar picos significativos, tanto positivos como negativos, que pueden corresponder a eventos inesperados o anomalías en el mercado. Estos valores extremos pueden deberse a anuncios económicos, crisis financieras, liquidaciones masivas o noticias relacionadas con la regulación del Bitcoin.

4.2.4 ANÁLISIS ACF Y PACF

Para analizar la estructura temporal de la serie, se examina la correlación entre observaciones en diferentes rezagos, lo que permite detectar patrones de dependencia útiles para la selección de modelos adecuados. A continuación, se presentan los resultados obtenidos mediante herramientas que exploran estas relaciones.

Función de autocorrelación - ACF: se utiliza para medir la relación entre los valores de una serie temporal con sus propios valores en diferentes rezagos o intervalos de tiempo. En otras palabras, analiza cómo los valores pasados influyen en los valores presentes de la serie. La **Figura 15** muestra el resultado de la ACF en la serie de tiempo.




Figura 15. Función de autocorrelación de la serie de tiempo

De la ACF se observa que:

Alta autocorrelación inicial:

- Los primeros rezagos (lag 1 a lag 5) muestran valores altos de autocorrelación, lo que indica una relación fuerte entre valores consecutivos de la serie en el corto plazo. Sin embargo, esta fuerte relación no persiste por mucho tiempo.

Disminución rápida:

- A medida que aumenta el rezago, la autocorrelación disminuye de manera constante, indicando que la dependencia entre los valores de la serie se debilita rápidamente. Este comportamiento sugiere que la serie presenta una memoria corta, es decir, que los valores pasados influyen poco en los valores futuros conforme avanza el tiempo, acercándose a un patrón menos persistente.

Ausencia de cruces con límites de significancia:

- Aunque los valores de autocorrelación permanecen dentro de los límites de confianza, su magnitud se reduce considerablemente en los rezagos más altos.

La tendencia decreciente de la función de la ACF refleja cómo la volatilidad tiene una memoria limitada. A medida que aumentan los rezagos, la influencia de la volatilidad pasada sobre la volatilidad futura disminuye gradualmente. Esto es indicativo de un comportamiento que tiende hacia la aleatoriedad o un patrón menos persistente en los datos de volatilidad.

Función de autocorrelación parcial - PACF: cuantifica la relación directa entre los valores actuales de una serie temporal y sus rezagos, controlando el efecto de los rezagos intermedios. Así, permite identificar la influencia específica de cada rezago en la serie. La **Figura 16** muestra los resultados obtenidos al aplicar la PACF en la serie.




Figura 16. Función de autocorrelación parcial de la serie de tiempo

De la PACF se observa que:

Rezagos iniciales significativos:

- Los primeros rezagos (lag 1 y lag 2) presentan valores de PACF altos, indicando una fuerte correlación parcial. Esto sugiere que la serie tiene dependencia directa con sus valores recientes.

Disminución general:

- Después de los rezagos iniciales, los valores de la PACF disminuyen rápidamente y se acercan a cero en la mayoría de los rezagos. Esto sugiere que, aunque hay dependencia en los primeros lags, el impacto de los valores pasados se diluye de manera relativamente rápida.

Pico en rezago 30:

- El pico podría señalar la presencia de una estructura compleja en la serie, que no puede ser capturada con modelos más simples como los autoregresivos (AR). Esto motiva el uso de modelos que incluyan rezagos altos para capturar mejor estas relaciones.

Valores fuera de los límites de confianza:

- En general, la mayoría de los valores se mantienen dentro de los límites de confianza, lo que sugiere que no hay patrones inesperados o ruido excesivo.

La serie no parece completamente aleatoria debido a la fuerte correlación inicial y el pico en el lag 30. Sin embargo, el comportamiento general de los valores (tendiendo a cero) sugiere que hay cierta pérdida de memoria en el tiempo.

4.2.5 PRUEBA DE ESTACIONARIEDAD

Luego de identificar posibles patrones de dependencia temporal, se debe evaluar si la serie cumple con el criterio de estacionariedad, condición fundamental para la aplicación de algunos de los modelos de series de tiempo [58]. Para ello, se recurre a pruebas estadísticas específicas que permiten verificar si las propiedades de la serie se mantienen estables a lo largo del tiempo.

Prueba de Dickey-Fuller aumentada (ADF): es una prueba estadística utilizado para verificar si en una serie temporal, sus propiedades estadísticas como la media y la varianza se mantienen constantes en el tiempo. La **Tabla 6** muestra los resultados de esta:

Tabla 6. Resultados de la prueba ADF

Criterio	Resultado
Estadístico ADF	-5.103773
p-value	0.000014
Valor crítico (1%)	-3.434912
Valor crítico (5%)	-2.863555
Valor crítico (10%)	-2.567843
Conclusión	La serie es estacionaria

El valor del estadístico ADF (-5.103773) es menor que los valores críticos en todos los niveles de significancia (1%, 5% y 10%). Asimismo, el **p-value** es menor que el nivel de significancia del 5%, lo que significa que se rechaza la hipótesis nula de que la serie tiene una raíz unitaria. Por lo tanto, la serie es estacionaria. Esto quiere decir que sus propiedades estadísticas, como la media, la varianza y la autocorrelación, se mantienen constantes en el tiempo, lo cual es un requisito clave para muchos modelos de series temporales. En este caso, al trabajar con retornos logarítmicos, ya se ha aplicado una transformación que estabiliza la varianza y elimina tendencias presentes en los precios brutos, haciendo que la serie resultante sea aproximadamente estacionaria, dado que la fórmula de los retornos logarítmicos equivale a la primera diferencia de los logaritmos de los precios y, por lo tanto, actúa como una diferenciación en el contexto de la prueba ADF. En otras palabras, no es necesario realizar transformaciones adicionales a la serie de tiempo.

Aunque la serie temporal de retornos logarítmicos ha sido transformada para garantizar su estacionariedad, es fundamental considerar el contexto histórico que ha influido en la volatilidad del Bitcoin. A lo largo del tiempo, diversos eventos, como crisis financieras, regulaciones gubernamentales, adopción institucional y avances tecnológicos en el ecosistema cripto, han impactado significativamente su precio. La inclusión de una línea de tiempo permite visualizar estos acontecimientos y su efecto en la dinámica del activo, proporcionando un marco de referencia clave para la interpretación de los modelos predictivos.

En este sentido, la **Tabla 7** presenta una línea de tiempo que refleja la evolución del precio del Bitcoin, destacando los principales eventos que han marcado su comportamiento en los mercados financieros. Estos acontecimientos refuerzan la idea de

que es posible desarrollar teoría y política monetaria en torno a las criptomonedas, dado su impacto creciente en la economía global [59].

Tabla 7. Línea de tiempo del Bitcoin [60]

Año	Evento
2024	- La Securities and Exchange Commission (SEC) aprueba los primeros Exchange Traded Fund (ETF) de Bitcoin al contado. - Cuarto halving, reduciendo la recompensa minera de 6,25 a 3,125 BTC por bloque.
2023	Silicon Valley Bank (SVB) y dos bancos pro-cripto (Silvergate y Signature) quiebran.
2022	- La invasión rusa a Ucrania genera conmoción en los mercados globales. - La stablecoin TerraUSD (UST) pierde su paridad con el dólar, provocando el colapso del ecosistema Terra y de su token hermano Luna. - FTX, uno de los mayores exchanges de criptomonedas, se declara en bancarota.
2021	- Tesla anuncia la compra de USD1.500 millones en Bitcoin. - El exchange coinbase debutó en NASDAQ con una valoración de USD85.000 millones. - El Salvador se convierte en el primer país en hacer de Bitcoin moneda de curso legal. - Se lanza el primer ETF de futuros de Bitcoin de ProShares en la Bolsa de Nueva York.
2020	- Colapso por COVID-19: La pandemia de COVID-19 y la declaración de emergencia global causan un desplome de los mercados. - Tercer halving. La recompensa se reduce de 12,5 a 6,25 BTC por bloque. - PayPal anuncia que permitirá a sus 346 millones de usuarios comprar, vender y almacenar Bitcoin y otras criptomonedas.
2019	- Facebook revela su proyecto para lanzar la criptomoneda Libra (posteriormente renombrada a Diem). - El presidente Xi Jinping de China anuncia que el país adoptará la tecnología blockchain, dando señales de apoyo al sector cripto.
2018	- Hackeo de Coincheck, en Japón son robados USD530 millones en NEM. - La SEC rechaza ETFs de Bitcoin, la autoridad estadounidense mantiene su postura contraria, negando varias propuestas.
2017	- Japón reconoce a Bitcoin como medio de pago legal, fortaleciendo su legitimidad. - El gobierno chino ordena el cierre de los principales exchanges de criptomonedas.
2016	- Segundo halving de Bitcoin, la recompensa minera se reduce de 25 a 12,5 BTC por bloque, disminuyendo nuevamente la inflación de la oferta. - Hackeo de Bitfinex, el exchange pierde 120.000 BTC, causando una caída de 20% en el precio de Bitcoin.
2015	- Nueva York introduce la BitLicense, el primer marco regulatorio para empresas de criptomonedas en EE. UU. - Se lanza Ethereum, abriendo nuevas posibilidades para el ecosistema cripto mediante contratos inteligentes y aplicaciones descentralizadas

2014	• Colapso de Mt. Gox, el mayor exchange de Bitcoin en ese momento, tras declarar bancarrota y reportar la pérdida de 850.000 BTC. Esto causó una fuerte caída del precio de Bitcoin debido a la pérdida de confianza en el ecosistema.
2013	• Durante la crisis financiera de Chipre, el control de depósitos impulsa a muchos a refugiarse en Bitcoin. El precio de BTC sube alrededor de 87%, de USD47 a USD88. • El FBI cierra Silk Road, el mayor mercado negro que utilizaba Bitcoin. Aunque inicialmente genera temor y una caída moderada en el precio, Bitcoin demuestra resiliencia. • El Banco Popular de China prohíbe a las instituciones financieras operar con Bitcoin. Tras la medida, BTC cae casi 50% desde sus máximos recientes.
2012	• Se funda Coinbase, uno de los primeros exchanges/custodios importantes en EE. UU., ofreciendo una vía accesible para comprar y vender Bitcoin. • Tiene lugar el primer halving de Bitcoin, reduciendo la recompensa minera de 50 a 25 BTC por bloque. Este evento disminuyó la emisión de nuevos Bitcoins y fortaleció la narrativa de escasez digital.
2011	• Bitcoin alcanza la paridad con el dólar (1 BTC = 1 USD) debido a una mayor adopción. • El precio de BTC se dispara hasta alrededor de USD30 impulsado por la creciente demanda. • Mt. Gox sufre su primer hackeo, causando un desplome relámpago del precio. Tras esto, Bitcoin cae por debajo de USD5.
2010	• Se realiza la primera compra con Bitcoin (10.000 BTC por dos pizzas), iniciando su uso como medio de pago. • Se funda el exchange Mt. Gox en Tokio, el primero de gran escala dedicado a Bitcoin.
2009	• Satoshi mina el primer bloque arrancando la red Bitcoin. Este evento sentó las bases del sistema descentralizado sobre el que se construiría el ecosistema de criptomonedas.
2008	• Satoshi Nakamoto publica el documento técnico de Bitcoin en medio de la crisis financiera global de 2008, lo que generó un creciente interés en monedas alternativas descentralizadas.

4.2.6 PREPARACIÓN DE DATOS PARA MODELADO PREDICTIVO

Una vez validados y transformados los datos, fue necesario estructurar los conjuntos de entrenamiento de acuerdo con las exigencias específicas de cada tipo de modelo. Dado que las arquitecturas utilizadas presentan diferencias fundamentales en la forma en que procesan la información temporal, los datos se organizaron de manera diferenciada para modelos secuenciales (redes neuronales recurrentes) y no secuenciales (modelos de árboles de decisión).

En el caso de los modelos recurrentes, los datos deben ser reorganizados en forma de secuencias temporales para que la red pueda capturar las dependencias a lo largo del tiempo. Para este trabajo, se definió un **time step** de 30 días, por lo que cada muestra

de entrada está compuesta por los valores de volatilidad correspondientes a los 30 días previos. Los datos fueron transformados al formato tridimensional requerido por las redes neuronales recurrentes, siguiendo la estructura (***n_observations***, ***time_steps***, ***n_features***), donde *n_observations* corresponde al número total de secuencias generadas, *time_steps* es 30, y *n_features* es 1, al utilizar únicamente la serie de volatilidad como variable de entrada. Esta estructura permite que las redes LSTM, GRU y SRNN puedan modelar de forma efectiva las dependencias temporales de la serie.

Para los modelos de machine learning basados en árboles de decisión como XGBoost y LightGBM, la serie temporal fue transformada en un conjunto supervisado de variables predictoras mediante la generación de rezagos (lags). En concreto, para cada observación se utilizaron los 30 valores anteriores de la volatilidad como variables independientes (features), mientras que la variable objetivo correspondió al valor de volatilidad del día actual. Esta transformación permite que los algoritmos de aprendizaje automático, que no modelan secuencias de forma nativa, puedan capturar dependencias temporales de corto plazo a partir de los rezagos incluidos. El conjunto final de entrenamiento presenta una estructura bidimensional de tamaño (***n_observations***, ***lags***), siendo *lags* = 30, por lo cual cada muestra de entrada contiene 30 características.

En contraste, los modelos estadísticos clásicos como ARCH y GARCH no requieren estas transformaciones estructurales, dado que están diseñados específicamente para modelar la heterocedasticidad condicional en series temporales financieras. Estos modelos incorporan de forma explícita la dependencia temporal directamente en sus ecuaciones funcionales, utilizando rezagos de la varianza condicional y de los errores pasados para predecir la volatilidad futura. Por esta razón, la serie puede ser utilizada de forma directa, sin necesidad de convertirla en una estructura supervisada o tridimensional.

4.3 FUNDAMENTOS DE LOS MODELOS DE DEPENDENCIA TEMPORAL

Los modelos de dependencia temporal buscan capturar la estructura subyacente de los datos en series de tiempo, aprovechando la relación entre valores pasados y futuros para realizar predicciones. En fenómenos como la volatilidad del Bitcoin, donde los cambios no ocurren de manera aislada, estos modelos permiten identificar patrones recurrentes que reflejan dinámicas propias del activo. Dado que las predicciones se construyen sobre la base de observaciones anteriores, tienden a seguir trayectorias similares a la serie real, ofreciendo una representación más clara de los procesos que influyen en su comportamiento.

Con base en los hallazgos obtenidos durante el análisis exploratorio y el estudio de la serie de tiempo, se fundamenta la elección de los modelos a utilizar en la fase predictiva. En este apartado se describen tanto modelos clásicos (ARCH y GARCH), como modelos avanzados de machine learning, que incluyen redes neuronales recurrentes (LSTM, GRU, SRNN) y modelos basados en árboles de decisión (XGBOOST y LIGHTGBM). La selección responde a su capacidad para capturar comportamientos complejos, como la alta variabilidad, la no linealidad y la presencia de eventos extremos, características propias de la volatilidad del Bitcoin.

A continuación, se presentan los fundamentos teóricos y operativos de cada uno de estos enfoques, como base para su posterior implementación y comparación en términos de desempeño predictivo.

4.3.1 MODELO ARCH

Propuesto por Engle en 1982, se utiliza para modelar series de tiempo con varianza condicional heterocedástica, es decir, cuando la varianza de los errores no es constante, sino que depende de valores pasados [61]. Este modelo es útil en contextos financieros, como el análisis de la volatilidad del Bitcoin, donde los periodos de alta volatilidad tienden a estar seguidos por otros también volátiles.

Su fundamento parte de que la varianza del error en el tiempo t depende de los errores al cuadrado de periodos anteriores. Esta relación se representa en la siguiente ecuación:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2$$

σ_t^2 : es la varianza condicional del error en el instante de tiempo t . "Condicional" significa que depende de la información conocida hasta el tiempo $t - 1$. Representa la volatilidad estimada en ese momento.

α_0 : es un valor constante, positivo. Se interpreta como el nivel base de volatilidad cuando los errores pasados son cero.

α_i : son los coeficientes que multiplican a los errores pasados al cuadrado. Cada uno indica cuánto influye el error en el tiempo $t - i$ sobre la varianza actual.

ε^2_{t-i} : son los errores pasados al cuadrado del modelo de predicción de la serie. Es decir, si en el pasado el modelo se equivocó mucho (error grande), la varianza condicional actual será más alta.

p : es el orden del modelo ARCH, es decir, cuántos rezagos (lags) de los errores se consideran para modelar la varianza.

En vista de lo anterior, ARCH reconoce patrones de agrupación en la variabilidad, permitiendo predicciones más realistas que los modelos tradicionales de regresión que suponen varianza constante.

4.3.2 MODELO GARCH

Desarrollado por Bollerslev en 1986, extiende el ARCH incorporando también la dependencia de la varianza respecto a sus propios valores pasados [62]. Este enfoque mejora la eficiencia del modelo para capturar los periodos de alta o baja volatilidad.

Su fundamento parte de que la varianza condicional actual depende tanto de errores pasados como de varianzas pasadas. La siguiente fórmula representa dicha dependencia.

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

β_j : coeficientes que indican cuánto influye la volatilidad condicional del pasado en la volatilidad actual. A mayor β_j , más persistente es la volatilidad.

ε^2_{t-j} : representa la varianza condicional en el instante $t-j$, es decir, la volatilidad estimada en un momento pasado, específicamente j periodos antes del tiempo actual t). Es parte de la componente autorregresiva de la varianza. Su presencia permite que el modelo recuerde y tenga en cuenta los niveles de volatilidad previos para estimar la volatilidad actual.

p y q : son los órdenes del modelo GARCH. p representa el número de rezagos de la varianza condicional pasada, es decir, el efecto de memoria en la volatilidad, y q el número de rezagos de los errores al cuadrado, es decir, el impacto de los shocks pasados.

Por lo anterior, GARCH mejora la estimación de la volatilidad al incorporar no solo la magnitud de los errores pasados, sino también la persistencia de la propia varianza condicional. Esto permite capturar de manera más efectiva la dinámica temporal de la volatilidad, generando predicciones más estables y realistas frente a las oscilaciones del mercado.

4.3.3 MODELO LSTM

Son una arquitectura de redes neuronales recurrentes especializadas en aprender dependencias a largo plazo. Se fundamentan en la incorporación celdas de memoria que regulan el flujo de información mediante puertas de entrada, olvido y salida, permitiendo retener datos relevantes a lo largo del tiempo. Este mecanismo es clave para la predicción de series con dinámicas complejas, como la volatilidad financiera [63].

Cabe precisar que en los modelos de machine learning, las ecuaciones no modelan directamente la volatilidad como una fórmula explícita tal como ocurre en ARCH y GARCH, pero sí modelan el proceso de aprendizaje secuencial y adaptativo que permite predecirla, capturando dependencias complejas y no lineales en los datos. La **Figura 17** refleja el esquema funcional de la celda LSTM [64].




Figura 17. Esquema funcional de la celda LSTM

Como complemento, las siguientes son las ecuaciones que desarrolla internamente el modelo LSTM.

$$\begin{aligned}
 f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) && \text{(Puerta de olvido)} \\
 i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) && \text{(Puerta de entrada)} \\
 \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) && \text{(Candidata a nueva memoria)} \\
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t && \text{(Actualización de la celda de memoria)} \\
 o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) && \text{(Puerta de salida)} \\
 h_t &= o_t * \tanh(C_t) && \text{(Salida de la celda)}
 \end{aligned}$$

x_t : entrada en el instante t en este caso el valor de la volatilidad.

h_{t-1} : estado oculto de la celda en el instante anterior.

C_t : celda que retiene la información a largo plazo.

σ : función sigma, que da valores entre 0 y 1, controlando el flujo.

$\tanh$: función tangente hiperbólica, que transforma valores entre -1 y 1.

W, b : pesos y sesgos aprendidos durante el entrenamiento

Por lo anterior, LSTM mejora la predicción de la volatilidad al incorporar un mecanismo interno que regula de forma dinámica el flujo de información a lo largo del tiempo. Estas ecuaciones modelan cómo la red decide qué información conservar, actualizar o descartar en cada paso temporal. A través de este proceso, la red retiene información clave del pasado mediante la celda de memoria, filtra eventos irrelevantes con la puerta de olvido, integra nueva información con la puerta de entrada y controla la salida final con la puerta de salida. Esta capacidad permite capturar relaciones no lineales y dependencias de largo plazo en series financieras, generando predicciones más adaptativas y robustas frente a la naturaleza cambiante del mercado.

4.3.4 MODELO GRU

Simplifican las LSTM al combinar las puertas de olvido y entrada en una única puerta de actualización, reduciendo la complejidad computacional sin sacrificar el rendimiento [65].

Así, se fundamenta en que utilizan dos puertas; actualización y reinicio, que permiten al modelo recordar o descartar información de pasos anteriores sin necesidad de una celda de memoria explícita. La **Figura 18** refleja el esquema funcional de la celda GRU [64].




Figura 18. Esquema funcional de la celda GRU

Así, las siguientes corresponden a las ecuaciones fundamentales que desarrolla el modelo GRU.

$$\begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) && \text{(Puerta de actualización)} \\ r_t &= \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) && \text{(Puerta de reinicio)} \\ \tilde{h}_t &= \tanh(W_h \cdot [r_t * h_{t-1}, x_t] + b_h) && \text{(Estado candidato)} \\ h_t &= (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t && \text{(Nuevo estado oculto)} \end{aligned}$$

z_t : controla cuánto del estado anterior se mantiene.

r_t : decide cuánta información del pasado se olvida al generar el nuevo estado.

h_t : posible nuevo contenido de la celda.

En consecuencia, GRU mejora la predicción de la volatilidad al integrar un mecanismo más ligero que conserva la capacidad de capturar relaciones temporales complejas en series financieras. A través de sus ecuaciones, el modelo regula de manera eficiente qué información pasada se conserva o se actualiza mediante la puerta de actualización, y qué información se ignora temporalmente mediante la puerta de reinicio.

4.3.5 MODELO SRNN

Es una arquitectura de redes neuronales recurrentes que permite capturar dependencias temporales de corto plazo en series de tiempo, lo que resulta útil en contextos donde la información reciente tiene un impacto directo en el comportamiento futuro como es el tema de la volatilidad [66].

Su funcionamiento parte de una estructura secuencial, donde cada instante de tiempo t se actualiza a un estado oculto h_t que agrupa la entrada actual x_t y el estado anterior h_{t-1} . La **Figura 19** refleja el esquema funcional de la celda SRNN [64].




Figura 19. Esquema funcional de la celda SRNN

Por tanto, la fórmula principal del modelo SRNN se expresa así:

$$h_t = \tanh(W_h \cdot h_{t-1} + W_x \cdot x_t + b)$$

W_h , W_x : matrices de pesos aprendibles.

Respecto a LSTM y GRU, SRNN no usa puertas, por tanto, no filtran la información. Además, procesa todo el historial reciente, sin decidir que olvidar ni retener. Ahora, esto puede ser útil en secuencias muy cortas donde no hay riesgo de sobreajuste ni de pérdida de gradientes. También, computacionalmente es más ligero.

Este modelo resume la información pasada inmediata para estimar el estado actual. Sin embargo, al no contar con mecanismos que permitan mantener información a largo plazo, su capacidad para capturar patrones más extensos en la volatilidad es limitada.

4.3.6 MODELO XGBOOST

Es un algoritmo de **boosting** basado en árboles de decisión que mejora el rendimiento agregando modelos de forma secuencial para corregir errores anteriores. Adaptado a series de tiempo mediante ingeniería de características, es eficaz en la predicción de valores no lineales [67].

XGBOOST se basa en el principio del gradiente descendente aplicado al conjunto de árboles de decisión. En cada iteración, el algoritmo entrena un nuevo árbol para minimizar la función de pérdida residual, ajustándose a los errores cometidos por el modelo anterior. Esta estrategia, conocida como boosting en gradiente, le permite construir una secuencia de árboles especializados que, en conjunto, forman un modelo altamente preciso. En otras palabras, el crecimiento se da por nivel. La siguiente es la ecuación base del boosting.

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x)$$

Esta ecuación expresa que el modelo se construye de manera acumulativa, añadiendo pequeños modelos (árboles) uno a uno. Cada uno corrige los errores del anterior, mejorando así la predicción paso a paso.

$F_m(x)$: es la predicción total del modelo después de agregar el m-ésimo árbol. Es decir, lo que el modelo predice en la iteración **m** .

$F_{m-1}(x)$: es la predicción que tenía el modelo en la iteración anterior $m - 1$

γ_m : es la tasa de aprendizaje que controla cuánto contribuye ese nuevo modelo.

$h_m(x)$: es el nuevo modelo o árbol entrenando en esta iteración, que intenta corregir los errores (residuos) cometidos por $F_{m-1}(x)$

Ahora, la clave de XGBOOST se encuentra en el término de regularización, es decir, en la penalización por la complejidad del árbol; si son muy grandes o con pesos excesivos en sus hojas. La siguiente ecuación indica la forma en cómo se optimiza el modelo.

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2$$

T : número de hojas del árbol.

w_j^2 : peso asignado a la hoja j

γ, λ : hiperparámetros de regularización.

Por lo anterior, XGBOOST representa una alternativa para modelar la volatilidad, especialmente cuando se realiza una adecuada ingeniería de características temporales. Aunque no capta dependencias secuenciales de manera implícita como lo hacen las redes neuronales recurrentes, su capacidad para identificar relaciones no lineales complejas y su eficiencia en el entrenamiento lo hacen eficaz en escenarios donde la volatilidad está influenciada por múltiples factores combinados.

4.3.7 MODELO LIGHTGBM

Es una variante más rápida y ligera de **gradient boosting**, desarrollada para manejar grandes volúmenes de datos con eficiencia [68]. Similar a XGBOOST, puede aplicarse a series temporales mediante ingeniería de características.

Su arquitectura usa un enfoque de crecimiento basado en histogramas y árboles que crecen por hojas, lo que permite una mejor captura de relaciones complejas con menor consumo de memoria y tiempo de entrenamiento. Este modelo se optimiza de la siguiente manera:

$$\Omega(f) = \lambda \sum_{j=1}^T w_j^2$$

A diferencia de XGBOOST, LIGHTGBM no penaliza directamente el número de hojas, dado que no incluye el término $\mathbf{Y y T}$, lo que permite construir árboles más profundos y potencialmente más expresivos, pero con mayor riesgo de sobreajuste si no se controla la profundidad.

Por lo anterior, LIGHTGBM resulta altamente efectivo para la predicción de volatilidad debido a su capacidad para modelar relaciones no lineales complejas a gran velocidad y con bajo consumo de memoria. Su estrategia de crecimiento por hoja con profundidad limitada permite construir árboles más profundos y precisos, mejorando la capacidad de generalización frente a patrones abruptos del mercado.

5 DESARROLLO DE MODELOS

Tras haber abordado los fundamentos teóricos de los modelos de dependencia temporal, esta sección se centra en su aplicación práctica para evaluar qué tan bien predicen la volatilidad del Bitcoin. Se trabajan modelos clásicos como ARCH y GARCH, junto con modelos modernos de aprendizaje automático, como LSTM, GRU, SRNN, XGBOOST y LIGHTGBM, analizando sus características, ventajas y limitaciones. Para más información ver **Anexo 2** que contienen los códigos utilizados para el desarrollo de los modelos.

En esta etapa, se implementan los modelos, se configuran con parámetros básicos y se comparan utilizando métricas comunes de evaluación. Además, se incluye un tablero dinámico que permite visualizar los resultados de forma clara, facilitando su análisis y utilidad en escenarios reales de inversión.

Esta sección sirve como conexión entre la teoría y los resultados prácticos, y proporciona una base sólida para las conclusiones del estudio.

5.1 EVALUACIÓN DE LOS MODELOS

La evaluación del desempeño de los modelos predictivos desarrollados se realizó utilizando un conjunto uniforme de métricas de error, lo que permitió una comparación objetiva en términos de precisión y capacidad de generalización. Para los modelos de aprendizaje automático, se empleó una división cronológica de los datos en conjuntos de entrenamiento (80%) y validación (20%). Adicionalmente, se aplicó una técnica de

validación cruzada adecuada para series temporales, conocida como validación cruzada con ventana expansiva, a todos los modelos, incluidos los enfoques clásicos. No obstante, es importante señalar que, aunque esta técnica también se utilizó en los modelos clásicos, su aplicación presenta ciertas limitaciones inherentes a la naturaleza de dichos métodos. A diferencia de los modelos de aprendizaje automático, los modelos clásicos como ARCH y GARCH no requieren una partición de los datos para entrenamiento y validación en el sentido tradicional. Su enfoque se basa en modelar directamente la volatilidad a partir de su estructura histórica, sin necesidad de un proceso de entrenamiento y validación en el sentido tradicional.

Ahora, con el fin de garantizar condiciones equitativas en la comparación, se utilizaron los mismos conjuntos de datos iniciales en todos los casos. Se adoptó una ventana de observación de 30 días como histórico y se trabajó con una única variable, la volatilidad. El conjunto de prueba, correspondiente al periodo de evaluación de las predicciones, se centró en los meses de enero y febrero de 2025, seleccionados para capturar tanto las tendencias como los factores transitorios presentes en la serie temporal.

Por su parte, la elección de una ventana de dos meses para el análisis de la predicción de la volatilidad del Bitcoin se fundamenta en su alta sensibilidad a fluctuaciones rápidas. Este enfoque permite capturar patrones relevantes sin diluir eventos recientes con información antigua que podría introducir ruido. Asimismo, este horizonte temporal proporciona un equilibrio entre precisión y estabilidad, adaptándose eficazmente a los cambios abruptos del mercado.

Las métricas consideradas fueron las siguientes [69]:

- **MSE (Mean Squared Error):** mide el promedio de los errores al cuadrado entre los valores reales y los predichos. Penaliza con mayor peso los errores grandes. Valores bajos de MSE indican una buena capacidad del modelo para aproximarse al comportamiento real de la volatilidad.
- **RMSE (Root Mean Squared Error):** es la raíz cuadrada del MSE y mantiene la misma unidad de la variable predicha. Representa la desviación estándar de los errores y facilita una interpretación más intuitiva. Cuanto menor sea el RMSE, mayor será la precisión del modelo.
- **MAE (Mean Absolute Error):** calcula el promedio de las diferencias absolutas entre los valores reales y los predichos. Es una métrica robusta ante valores atípicos y permite observar el error promedio sin influencias cuadráticas. Una MAE

baja indica que las predicciones tienden a estar cerca de los valores reales, en promedio.

- **MAPE (%) (Mean Absolute Percentage Error):** expresa el error absoluto medio como un porcentaje, lo que facilita la comparación entre modelos, incluso cuando se aplican a distintas escalas es útil para evaluar la precisión relativa.
- **MdAPE (%) (Median Absolute Percentage Error):** mide el error porcentual mediano en lugar del promedio, lo que lo hace más robusto ante valores extremos o distribuciones sesgadas. Un MdAPE bajo refleja buena consistencia en las predicciones.
- **R² (Coeficiente de Determinación):** indica el grado en que las predicciones explican la varianza de los datos reales. Su valor varía entre 0 y 1 (e incluso puede ser negativo si el modelo es peor que una línea base), siendo 1 el valor ideal. Un R² alto implica que el modelo captura bien la dinámica de la volatilidad.

Cabe resaltar que todos los modelos se implementaron en su configuración inicial, sin procesos de ajuste de parámetros ni técnicas de optimización avanzada. Esto implica que los resultados presentados en esta etapa corresponden a una primera aproximación de su desempeño, permitiendo identificar su potencial base antes de realizar ajustes más complejos en fases posteriores.

5.1.1 MODELOS CLÁSICOS DE SERIES DE TIEMPO

En esta etapa inicial se implementaron los modelos ARCH(1) y GARCH(1,1) como representantes de los enfoques clásicos para la modelación de volatilidad. La elección de estas configuraciones responde tanto a su frecuente uso en aplicaciones financieras como a la comprobación previa de que la serie de tiempo analizada ya presentaba estacionariedad, condición necesaria para su correcta aplicación. Además, estos órdenes son comúnmente utilizados como punto de partida por su balance entre simplicidad y capacidad para capturar heterocedasticidad de corto plazo. La implementación de estos modelos permitió establecer una línea base sobre la cual comparar el desempeño de enfoques más complejos, como los modelos de aprendizaje profundo utilizados en etapas posteriores.

La **Figura 20** muestra el comportamiento de las predicciones frente a la volatilidad observada durante enero y febrero de 2025, lo que permite una primera evaluación cualitativa del ajuste logrado por estos modelos clásicos:




Figura 20. Predicciones ARCH y GARCH

A simple vista, el modelo ARCH pareciera que logra seguir con mayor estabilidad el patrón de la volatilidad real, mientras que GARCH muestra mayores fluctuaciones, especialmente en momentos de cambio abrupto. La **Tabla 8** resume los resultados cuantitativos:

Tabla 8. Métricas iniciales para ARCH(1) y GARCH(1,1)

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
ARCH(1)	0.000007	0.002646	0.001445	2.169913	3.274282	-0.153871
GARCH(1,1)	0.000012	0.003464	0.002517	11.983160	7.810989	-1.070746

Los resultados obtenidos reflejan que el modelo ARCH(1) supera en desempeño al GARCH(1,1) bajo todas las métricas cuantitativas evaluadas. A pesar de que ambos modelos presentan valores negativos en el coeficiente de determinación (R^2), lo que sugiere una baja capacidad explicativa, aunque discutida en su configuración actual, ARCH(1) muestra un error menor y una mayor estabilidad en las predicciones iniciales.

Lo interesante es que, visualmente, ambas series simuladas especialmente ARCH(1) parecen seguir durante la mayor parte del tiempo evaluado, de forma razonable el comportamiento direccional de la volatilidad real, capturando correctamente algunos patrones de alza y baja. Sin embargo, esta aparente coherencia gráfica contrasta con las métricas numéricas, debido a que los modelos no logran replicar con precisión la magnitud de los cambios. En otras palabras, aunque suben o bajan al mismo tiempo que la serie real, lo hacen con una intensidad insuficiente o exagerada, generando errores acumulativos que impactan negativamente en los indicadores como MSE, MAE, MAPE y, en particular, R^2 .

Este contraste pone de manifiesto una de las principales limitaciones de los modelos clásicos como ARCH(1) y GARCH(1,1) al ser aplicados en contextos complejos y altamente no lineales como el mercado de criptomonedas. Aunque pueden ofrecer un

punto de partida razonable, su capacidad para capturar adecuadamente la dinámica completa de la volatilidad financiera es restringida sin un ajuste fino de parámetros, incluyendo la estimación precisa de intervalos de confianza y la correcta cobertura estadística. Estos hallazgos reafirman la necesidad de avanzar hacia modelos más robustos y flexibles, como los que se explorarán en las siguientes secciones mediante técnicas de aprendizaje profundo y algoritmos no lineales.

A diferencia de los modelos de aprendizaje profundo, los modelos ARCH y GARCH son modelos estadísticos clásicos cuyo objetivo principal es modelar la varianza condicional de una serie temporal, particularmente en contextos financieros donde la volatilidad juega un rol central. En teoría, estos modelos no requieren validación cruzada tradicional, dado que su estimación se basa en métodos de máxima verosimilitud sobre un conjunto completo de datos, y su eficacia suele evaluarse mediante información de criterios (AIC, BIC) y análisis residual.

Ahora, para estandarizar la comparación con modelos basados en redes neuronales y evaluar su capacidad de generalización en datos no vistos, se implementó la técnica de validación cruzada con ventana expansiva, la cual consiste en dividir en cuatro bloques (folds) secuenciales de 286 datos cada uno. En cada iteración, el modelo se entrena con todos los datos disponibles hasta ese punto (tamaño de entrenamiento creciente) y se evalúa con el bloque siguiente de 286 datos (tamaño de validación), lo que simula escenarios reales donde los modelos se reentrenan continuamente con nuevos datos y se evalúan sobre los periodos futuros. La métrica objetivo no es el valor del retorno, sino su varianza (volatilidad), que es la salida natural de estos modelos. La **Tabla 9** describe los resultados obtenidos.

Tabla 9. Métricas de validación cruzada para ARCH(1) y GARCH(1,1)

Folds	Tamaño Entreno	Tamaño Validación	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
1 - ARCH	286	286	0.000008	0.002838	0.001702	10.236,848	3.687,647	-0.033557
2 - ARCH	572	286	0.000005	0.002258	0.001441	300.354,464	9.499,127	-0.069538
3 - ARCH	858	286	0.000002	0.001230	0.001031	13.820.558,949	14.483,704	-0.444980
4 - ARCH	1144	286	0.000003	0.001620	0.001054	1.623.325,822	3.921,255	-0.011289
-	ARCH	Promedio	0.000004	0.001986	0.001307	3.938.619,021	7.897,933	-0.139841
1 - GARCH	286	286	0.000008	0.002807	0.001553	87.273,648	2.988,129	-0.011187
2 - GARCH	572	286	0.000005	0.002238	0.001263	2.434.142,701	6.984,784	-0.050591
3 - GARCH	858	286	0.000001	0.001060	0.000713	84.048.725,067	8.356,001	-0.072974
4 - GARCH	1144	286	0.000003	0.001614	0.000959	135.762.628,734	2.880,989	-0.004172
-	GARCH	Promedio	0.000004	0.001930	0.001122	25.045.602,537	5.302,476	-0.034731

Aunque el modelo GARCH(1,1) presenta un rendimiento marginalmente superior al ARCH(1) en todas las métricas evaluadas, ambos modelos muestran un desempeño subóptimo en la predicción de la varianza condicional en este conjunto de datos. Las dificultades se acentúan ante la alta volatilidad, la no linealidad inherente al mercado de criptomonedas y la posible presencia de efectos estructurales que exceden la capacidad de representación de estos modelos lineales y parsimoniosos.

Adicionalmente, las métricas de error porcentual, particularmente MAPE y MdAPE, alcanzan valores anómalamente elevados. Esto se explica tanto por la escala reducida de los datos (producto del preprocesamiento con log-retornos), como por la alta sensibilidad de estas métricas a observaciones extremas o atípicas, las cuales son frecuentes en series de activos digitales. Este comportamiento resalta la necesidad de emplear enfoques más robustos o adaptativos para la estimación de volatilidad en contextos financieros con alta incertidumbre.

Estos resultados refuerzan la hipótesis de que los modelos ARCH/GARCH tradicionales no son adecuados para generalizar en entornos altamente dinámicos, especialmente cuando se los contrasta con arquitecturas más expresivas como LSTM, GRU o SRNN. Si bien la validación cruzada con ventana expansiva no es un procedimiento estándar en estos modelos estadísticos, su aplicación en este contexto ha permitido evidenciar objetivamente sus limitaciones prácticas y destacar el valor de métodos más flexibles para tareas de predicción en series temporales complejas.

5.1.2 MODELOS DE REDES NEURONALES RECURRENTE

En esta segunda fase se evaluaron tres arquitecturas de aprendizaje profundo: LSTM, GRU y SRNN, todas pertenecientes a la familia de redes neuronales recurrentes. Estos modelos fueron seleccionados por su capacidad para capturar relaciones temporales complejas y no lineales en series de tiempo, lo que resulta especialmente relevante en un contexto como el mercado de criptomonedas. Ninguno de ellos fue sometido a procesos de ajuste fino, con el objetivo de explorar su rendimiento base frente a los modelos clásicos previamente presentados. Las arquitecturas implementadas se describen a continuación.

Cabe resaltar que, estas configuraciones fueron seleccionadas como un punto de partida equilibrado, combinando profundidad, mecanismos de control de sobreajuste y capacidad de memoria en cada red, evitando estructuras excesivamente complejas.

El modelo LSTM consta de cuatro capas con 128, 128, 64 y 32 unidades respectivamente, intercaladas con capas **Dropout** para mitigar el sobreajuste, y aplicando regularización

L2 en las dos primeras capas. La salida se genera a través de una capa densa final. La **Figura 21** muestra las gráficas de la función de pérdida durante el entrenamiento del modelo, junto con la gráfica del error MAE, evaluados sobre los conjuntos de entrenamiento y prueba.




Figura 21. Evolución de la función de pérdida MSE y MAE del modelo LSTM

Por su parte, el modelo GRU está compuesto por cuatro capas con 256, 256, 64 y 64 unidades, también intercaladas con **Dropout** y con regularización **L2** en las dos primeras capas, seguido de una capa densa. **Figura 22** muestra las gráficas de la función de pérdida durante el entrenamiento del modelo, junto con la gráfica del error MAE, evaluados sobre los conjuntos de entrenamiento y prueba.




Figura 22. Evolución de la función de pérdida MSE y MAE del modelo GRU

Por otro lado, el modelo SRNN utiliza cuatro capas con 128, 128, 64 y 64 unidades, igualmente acompañadas de **Dropout** y regularización **L2** en las dos primeras capas, culminando con una capa densa final. **Figura 23** muestra las gráficas de la función de pérdida durante el entrenamiento del modelo, junto con la gráfica del error MAE, evaluados sobre los conjuntos de entrenamiento y prueba.




Figura 23. Evolución de la función de pérdida MSE y MAE del modelo SRNN

Luego del análisis del comportamiento de los modelos durante el entrenamiento, se evaluó su capacidad para predecir la volatilidad en un periodo futuro. La **Figura 24** muestra las predicciones generadas frente a la volatilidad observada durante los dos primeros meses de 2025.




Figura 24. Predicciones iniciales para LSTM, GRU y SRNN

Visualmente, se aprecia que los tres modelos logran replicar con bastante fidelidad la forma y dirección de la serie real. Las líneas punteadas correspondientes a cada modelo recurrente (LSTM, GRU y SRNN) siguen de cerca la línea azul de la volatilidad real, con una notable capacidad para anticipar tanto los picos como los valles. Aunque existen ligeras diferencias entre ellos, en general todos muestran un ajuste más coherente que los modelos ARCH y GARCH, especialmente en momentos de mayor variación. Esta percepción se ve respaldada por los resultados cuantitativos de la **Tabla 10**.

Tabla 10. Métricas iniciales para LSTM, GRU y SRNN

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
LSTM	0.000001	0.000801	0.000605	2.811920	2.133066	0.890232
GRU	0.000001	0.000796	0.000600	2.796059	2.039724	0.891602
SRNN	0.000001	0.000784	0.000587	2.709032	2.168942	0.894608

Los valores observados evidencian una mejora significativa en comparación con los modelos clásicos, lo que subraya la efectividad de los enfoques basados en redes neuronales recurrentes para tareas de predicción en series temporales. En particular, el modelo SRNN resalta ligeramente como el mejor en esta etapa, al exhibir el menor error absoluto (MAE) y el mayor coeficiente de determinación (R^2), lo cual sugiere una mayor capacidad explicativa y ajuste a los datos históricos. Esta superioridad se refleja en la habilidad del SRNN para capturar patrones y relaciones complejas a lo largo del tiempo, mejorando la precisión de las predicciones.

Lo que hace aún más notable este resultado es que todos los modelos presentados muestran errores excepcionalmente bajos y errores porcentuales muy acotados (MAPE cercano al 3%), lo que, no solo valida la precisión de los modelos, sino que también demuestra que pueden generalizar de manera efectiva en escenarios de alta volatilidad y dinamismo.

Además, el rendimiento consistente de los modelos de redes neuronales recurrentes, sin necesidad de ajustes avanzados en sus parámetros, refuerza la idea de que estas arquitecturas son muy adaptables y eficientes para la predicción de volatilidad en mercados como el de criptomonedas, que se caracterizan por su naturaleza impredecible y altamente fluctuante. La capacidad de los modelos recurrentes para identificar dependencias a largo plazo en los datos, a través de su estructura interna, permite superar las limitaciones de los modelos clásicos, que en muchos casos no logran capturar completamente las complejidades inherentes a los datos.

En resumen, tanto las métricas cuantitativas como el análisis visual corroboran que los modelos basados en redes neuronales recurrentes no solo superan a los enfoques tradicionales, sino que se posicionan como herramientas poderosas y robustas para predecir volatilidades en mercados financieros tan exigentes como el de criptomonedas, ofreciendo un rendimiento superior en términos de precisión y capacidad de modelado.

Con el fin de evaluar la capacidad de generalización de los modelos, se aplicó un esquema de evaluación secuencial mediante validación cruzada con ventana expansiva con 4 bloques temporales para evaluar rigurosamente el rendimiento de estos modelos. Cada bloque consistió en 286 muestras, respetando la secuencia cronológica de los datos desde marzo de 2021 hasta enero de 2025. Esta metodología permitió observar cómo se comporta cada modelo ante nuevas secuencias temporales, replicando condiciones reales de predicción. Las métricas evaluadas fueron las mismas iniciales. La **Tabla 11** muestra el resumen de la validación cruzada.

Tabla 11. Métricas de validación cruzada para LSTM, GRU y SRNN

Folds	Tamaño Entreno	Tamaño Validación	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²	Épocas
1 - LSTM	286	286	0.000015	0.003835	0.003021	8.900.271	7.793.928	0.706794	100
2 - LSTM	572	286	0.000010	0.003115	0.001871	8.515.609	4.994.380	0.863030	100
3 - LSTM	858	286	0.000002	0.001450	0.000893	4.300.510	2.087.829	0.964443	100
4 - LSTM	1144	286	0.000002	0.001231	0.000712	2.901.906	1.513.673	0.943870	100
-	LSTM	Promedio	0.000029	0.002408	0.001624	6.154574	4.097453	0.869534	100
1 - GRU	286	286	0.000004	0.002064	0.001289	3.781.884	2.239.806	0.915028	100
2 - GRU	572	286	0.000003	0.001861	0.000877	3.813.506	1.463.497	0.951076	100
3 - GRU	858	286	0.000002	0.001291	0.000732	3.460.418	1.586.117	0.971821	89
4 - GRU	1144	286	0.000002	0.001240	0.000690	2.779.672	1.335.602	0.943020	70
-	GRU	Promedio	0.000003	0.001614	0.000897	3.458870	1.656256	0.945236	90
1 - SRNN	286	286	0.000010	0.003090	0.002412	7.129.544	5.956.068	0.809574	79
2 - SRNN	572	286	0.000020	0.004449	0.002802	10.867.940	8.179.572	0.720515	52
3 - SRNN	858	286	0.000002	0.001397	0.000862	4.012.547	2.054.960	0.966988	100
4 - SRNN	1144	286	0.000002	0.001348	0.000899	3.733.663	2.543.744	0.932684	100
-	SRNN	Promedio	0.000009	0.002571	0.001744	6.435924	4.683586	0.857440	83

Los resultados de la validación cruzada con ventana expansiva evidencian una mejora notable en comparación con los enfoques tradicionales, consolidando la eficacia de las redes neuronales recurrentes en tareas de predicción de series temporales. El modelo GRU emerge como el más destacado en esta etapa, no solo por presentar los valores de error más bajos en promedio, sino también por mantener una alta capacidad explicativa a lo largo de los distintos conjuntos de validación. Su rendimiento consistente, sugiere que es especialmente apto para capturar la dinámica compleja de mercados financieros.

Aunque el modelo SRNN exhibe un mayor rango de variación en sus métricas, logra en ciertos escenarios un ajuste comparable al GRU, destacándose en su capacidad para adaptarse rápidamente a nuevos patrones temporales. El modelo LSTM, por su parte, se posiciona como una alternativa intermedia, con buenos resultados generales y un equilibrio entre precisión y estabilidad.

En términos generales, todos los modelos alcanzan niveles de error muy bajo y R² altos, lo cual, valida no solo su precisión, sino también su capacidad de generalización en contextos caracterizados por alta volatilidad.

5.1.3 MODELOS DE ÁRBOLES DE DECISIÓN

En esta etapa se evaluaron dos modelos de aprendizaje automático basados en árboles de decisión: XGBOOST y LIGHTGBM, reconocidos por su eficiencia y alto rendimiento en tareas de regresión. Ambos fueron aplicados bajo un enfoque autorregresivo, utilizando como predictores los valores rezagados (lags) de la propia serie, lo que permitió

adaptar modelos originalmente no secuenciales al análisis de series temporales. Para este caso, se utilizaron 30 lags o rezagos, equivalentes a una ventana de observación de 30 días sobre la volatilidad. Este enfoque permite aplicar técnicas de machine learning sobre datos secuenciales sin recurrir a arquitecturas recurrentes, lo que los convierte en alternativas livianas en términos de procesamiento. Las configuraciones iniciales se basaron en parámetros comunes de uso general.

Se utilizó un modelo XGBOOST con 70 árboles secuenciales, permitiendo corregir errores progresivamente sin sobreajustar. La tasa de aprendizaje fue de 0.1, valor equilibrado entre velocidad y precisión. Cada árbol tuvo una profundidad máxima de 6, ayudando a evitar que el modelo aprendiera ruido o patrones poco relevantes. Además, se aplicaron estrategias de muestreo: el 80% de las filas y el 80% de las columnas se usaron en cada iteración, reduciendo la varianza y mejorando la generalización. La **Figura 25** muestra las curvas de la función de pérdida durante el entrenamiento del modelo XGBoost, junto con la evolución del error MAE, evaluados sobre los conjuntos de entrenamiento y prueba.




Figura 25. Evolución de la función de pérdida MSE y MAE del modelo XGBOOST

En el caso de LIGHTGBM, el modelo fue configurado para equilibrar precisión y velocidad de entrenamiento. Se usaron 70 árboles, capturando patrones generales sin ser costoso computacionalmente. La tasa de aprendizaje fue de 0.1, permitiendo avances estables en el ajuste. No se limitó la profundidad, lo que permitió capturar estructuras complejas. Se establecieron 31 hojas por árbol, con buena capacidad de aprendizaje sin hacerlos demasiado grandes. El modelo exigió al menos 20 observaciones por hoja, reduciendo la complejidad excesiva. También se aplicó submuestreo de filas y columnas al 80%. La **Figura 26** muestra las curvas de la función de pérdida durante el entrenamiento del modelo LightGBM, junto con la evolución del error MAE, evaluados sobre los conjuntos de entrenamiento y prueba.




Figura 26. Evolución de la función de pérdida MSE y MAE del modelo LIGHTGBM

Tras examinar el desempeño de los modelos durante el entrenamiento, se procedió a evaluar su efectividad en la predicción de la volatilidad sobre un periodo no utilizado previamente. La **Figura 27** presenta los resultados obtenidos frente a los valores reales de volatilidad registrados durante los dos primeros meses de 2025



Figura 27. Predicciones iniciales para XGBOOST y LIGHTGBM

A nivel visual, ambas predicciones resultan conectadas al comportamiento real de la volatilidad. En particular, los modelos muestran trayectorias con bastante coherencia direccional, no tan precisas como en los modelos de redes neuronales, pero capaces de capturar de forma sostenida las fases de incremento o descenso que caracterizan al fenómeno observado. Este comportamiento está respaldado por las métricas que se presentan en la **Tabla 12**.

Tabla 12. Métricas iniciales para XGBOOST y LIGHTGBM

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
XGBOOST	0.000001	0.000818	0.000664	3.027736	2.823703	0.885293
LIGHTGBM	0.000001	0.000873	0.000707	3.232299	2.898877	0.869403

Ambos modelos presentan valores altos en el coeficiente de determinación R^2 , lo cual implica que sus predicciones son explicativas para la volatilidad. Además, errores como el MAE y MAPE son similares a los registrados por los modelos basados en redes neuronales recurrentes, sugiriendo una adecuada precisión y robustez.

Estos resultados reafirman que, si bien los árboles de decisión potenciados son herramientas poderosas para tareas de regresión estándar, su uso en contextos de series temporales con alta no linealidad, como la volatilidad del Bitcoin, requiere un diseño más avanzado. Alternativas como el uso de variables exógenas o ingeniería de características temporales podrían mejorar sustancialmente estos resultados.

En conclusión, XGBOOST y LIGHTGBM, en su configuración actual autorregresiva, logran capturar de forma adecuada las dinámicas temporales de la volatilidad, tanto por su alto ajuste cuantitativo como por su coherencia visual. Esto contrasta se alinea con los modelos secuenciales, que mostraron mejor capacidad para interpretar la estructura interna de la serie temporal.

Ahora, dado el bajo desempeño observado en las métricas iniciales y la conexión visual entre las predicciones y la serie real, se procedió a aplicar una validación cruzada con ventana expansiva de forma más robusta la capacidad de generalización de los modelos XGBOOST y LIGHTGBM. Este procedimiento permitió evaluar el desempeño de los modelos a lo largo de distintas etapas de la serie temporal, reduciendo el riesgo de obtener estimaciones optimistas asociadas a una única partición fija de entrenamiento y prueba. Al emplear la validación cruzada con ventana expansiva con múltiples pliegues (folds), se obtuvo una visión más completa de cómo se comportan los modelos frente a distintas distribuciones de datos, revelando su estabilidad y consistencia ante posibles variaciones en la serie temporal. La **Tabla 13** muestra los resultados de la validación.

Tabla 13. Métricas de validación cruzada para XGBOOST y LIGHTGBM

Folds	Tamaño Entreno	Tamaño Validación	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
1 - XGBOOST	286	286	0.000009	0.003062	0.002267	7.211255	4.640220	0.813033
2 - XGBOOST	572	286	0.000066	0.008099	0.006520	34.435157	28.342468	0.073787
3 - XGBOOST	858	286	0.000014	0.003716	0.002241	13.359625	5.421883	0.766339
4 - XGBOOST	1144	286	0.000002	0.001519	0.001039	4.243706	2.868906	0.914532
-	XGBOOST	Promedio	0.000023	0.004099	0.003017	14.812436	10.318369	0.641923
1 - LIGHTGBM	286	286	0.000008	0.002879	0.002193	6.831224	4.801731	0.834695
2 - LIGHTGBM	572	286	0.000030	0.005501	0.004238	22.631680	13.845302	0.572655
3 - LIGHTGBM	858	286	0.000007	0.002554	0.001654	9.612041	4.262188	0.889629
4 - LIGHTGBM	1144	286	0.000002	0.001526	0.001085	4.410864	3.399772	0.913723
-	LIGHTGBM	Promedio	0.000012	0.003115	0.002292	10.871452	6.577248	0.802676

Los resultados de la validación cruzada con ventana expansiva confirman un sostenimiento en el ajuste de ambos modelos respecto a las métricas iniciales. En particular, los valores promedio del coeficiente R^2 continúan positivos en ambos casos, indicando que las predicciones superaron a una línea base constante. Esto sugiere que, en promedio los modelos logran captar cierta estructura en los datos cuando se les expone a múltiples subconjuntos de entrenamiento.

Sin embargo, las métricas de error como el MAPE y el MAE muestran una dispersión considerable entre pliegues, especialmente en los primeros folds, lo cual evidencia cierta inestabilidad en el rendimiento de los modelos dependiendo del tramo de la serie que les toca predecir. Este comportamiento es particularmente visible en el segundo pliegue de cada modelo, donde se observa un incremento abrupto de los errores y una caída del R^2 . Estos hallazgos refuerzan la idea de que las configuraciones actuales carecen de mecanismos que les permitan adaptarse dinámicamente a cambios estructurales en la volatilidad.

En suma, estos resultados resaltan la importancia de evaluar modelos de forma extensiva antes de descartar su utilidad. Aunque el desempeño global aún está por debajo de lo esperado, la validación cruzada revela que los modelos tienen un nivel de adaptabilidad que podría aprovecharse mejor con ajustes específicos. Este tipo de análisis es fundamental para tomar decisiones informadas sobre mejoras futuras o combinaciones de enfoques que aumenten la precisión y robustez en entornos de alta variabilidad.

5.2 CONFIGURACIÓN E IDENTIFICACIÓN DE PARÁMETROS

La configuración e identificación de parámetros resulta crucial para optimizar el desempeño de los modelos predictivos de volatilidad, maximizando su capacidad de capturar las dinámicas complejas del mercado de criptomonedas. En este contexto, los hallazgos de la sección anterior resaltan la relevancia de los modelos modernos, particularmente los basados en aprendizaje profundo, por su adaptabilidad, precisión y flexibilidad en escenarios donde la incertidumbre y la volatilidad predominan. Estas cualidades abren nuevas oportunidades para su aplicación práctica, potenciando la toma de decisiones informadas y contribuyendo al diseño de estrategias efectivas en mercados financieros tan desafiantes

5.2.1 OPTIMIZACIÓN EN MODELOS CLÁSICOS

En el caso de los modelos clásicos, se utilizaron los criterios **AIC** (Criterio de Información de Akaike) y **BIC** (Criterio de Información Bayesiano) como herramientas principales de configuración para determinar el modelo óptimo. La regla básica para seleccionar el mejor

modelo bajo ambos criterios se fundamenta en elegir aquel con los valores más bajos de AIC y BIC, respectivamente. El AIC busca equilibrar el ajuste del modelo a los datos con su complejidad, favoreciendo modelos que logren alta verosimilitud, pero penalizando la inclusión de parámetros innecesarios. Por su parte, el BIC introduce una penalización aún más estricta por la complejidad del modelo, privilegiando soluciones más parsimoniosas cuando el tamaño de la muestra es grande [70].

Ambos criterios actúan como mecanismos robustos para identificar modelos que expliquen adecuadamente los datos sin incurrir en sobreajuste o en una complejidad excesiva. Mientras el AIC puede preferir modelos ligeramente más complejos, el BIC tiende a ser más conservador, seleccionando modelos más simples cuando hay dudas.

La optimización de los modelos se llevó a cabo mediante una búsqueda exhaustiva (**grid search**) de los parámetros **p y q**, evaluando sistemáticamente todas las combinaciones posibles en un rango de uno a cinco. Esta estrategia permitió identificar de forma precisa las configuraciones que minimizaban los valores de AIC y BIC. La **Tabla 14** resume los resultados de AIC y BIC de las mejores combinaciones de los parámetros p para los modelos ARCH y p y q para los modelos GARCH.

Tabla 14. Resultados optimización de los modelos clásicos

p	q	ARCH (AIC)	GARCH (AIC)	ARCH (BIC)	GARCH (BIC)
1	-	-595.774497	-	-589.541885	-
2	1	-	-559.563012	-	-549.175325

En este análisis, se evaluaron distintas combinaciones de los parámetros p y q en un rango de uno a cinco. Al comparar los resultados, se observa que tanto el criterio AIC como el BIC coinciden en identificar los mismos modelos como los óptimos en sus respectivas categorías.

Cabe resaltar que, además de los parámetros **p y q**, los modelos ARCH y GARCH contemplan otras configuraciones que pueden influir en su rendimiento. Entre ellas se encuentra la distribución de los errores, que comúnmente se asume normal, aunque en ciertos contextos puede sustituirse por distribuciones como la **t-student** para capturar colas más pesadas. También está el método de estimación de parámetros, usualmente basado en máxima verosimilitud, que puede tener variantes dependiendo del entorno de implementación. Otro aspecto para considerar son las restricciones de no negatividad en los coeficientes, necesarias para asegurar que la varianza estimada sea siempre positiva. Finalmente, es posible definir distintas estrategias para la inicialización de la varianza, como el uso de la varianza muestral o un valor condicional inicial.

Aunque estos elementos ofrecen oportunidades para afinar el modelo, es habitual mantenerlos en sus valores por defecto cuando el objetivo es realizar una comparación clara y replicable. Por esta razón, dichas configuraciones no fueron incluidas en el proceso de optimización, principalmente por tres motivos: primero, el enfoque del estudio se centró en la comparación estructural de modelos a través de sus órdenes p y q , considerados los hiperparámetros más influyentes y controlables. Segundo, incorporar múltiples configuraciones simultáneamente como la distribución de errores o métodos alternativos de estimación habría incrementado considerablemente la complejidad computacional del análisis. Y tercero, hacerlo habría comprometido la claridad y la replicabilidad del estudio, al introducir una gran cantidad de combinaciones de parámetros que dificultarían una evaluación comparativa transparente entre modelos.

En consecuencia, de acuerdo con las variables optimizadas, para el modelo ARCH, el modelo con $p=1$ mostró el AIC y el BIC más bajos, confirmando que el modelo inicial propuesto es el más adecuado, es decir, el ARCH(1). El valor de p en este modelo establece que solo se utiliza el cuadrado del residuo anterior para estimar la volatilidad de hoy.

Para el modelo GARCH, la mejor combinación encontrada fue $p=2$ y $q = 1$, tanto por el criterio AIC como por el criterio BIC, sugiriendo que el modelo GARCH(2,1) ofrece el mejor compromiso entre ajuste y complejidad. El valor q en este modelo introduce persistencia en la volatilidad, es decir, si el día anterior fue muy volátil, hoy también se asume que lo será. Para corroborar lo anterior, la **Tabla 15** muestra las métricas de desempeño.

Tabla 15. Métricas finales para los modelos clásicos

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
ARCH(1)	0.000007	0.002646	0.001445	2.169913	3.274282	-0.153871
GARCH(2,1)	0.000016	0.004000	0.003212	15.124356	11.192693	-1.697979

La consistencia observada entre los criterios AIC y BIC en la selección de los modelos ARCH(1) y GARCH(2,1) respalda la robustez y confiabilidad de la especificación adoptada, asegurando un equilibrio entre ajuste y parsimonia en la modelación de la volatilidad. Sin embargo, se evidencia que el coeficiente de determinación (R²) continúa negativo en ambas configuraciones, lo cual es un comportamiento común en la modelación de volatilidad. Esto ocurre porque en modelos de heterocedasticidad condicional, como ARCH y GARCH el R² tradicional no captura de manera adecuada la calidad del ajuste, dado que su estructura no se basa en explicar el nivel de la variable, sino su varianza condicional.

Por tanto, la validación de la capacidad de predicción y generalización de estos modelos no debe basarse exclusivamente en métricas tradicionales de bondad de ajuste como el R^2 , que resultan inadecuadas en el contexto de modelado de volatilidad condicional. En cambio, debe enfocarse en un riguroso diagnóstico de los residuos estandarizados generados por los modelos. La calidad de un modelo GARCH o ARCH no depende únicamente de su ajuste dentro de la muestra observada, sino de su habilidad para capturar adecuadamente la dinámica de la varianza condicional y de producir residuos que se comporten como un ruido blanco, es decir, que no presenten autocorrelación, heterocedasticidad remanente ni patrones sistemáticos.

En este sentido, para evaluar la capacidad de generalización de modelos como ARCH y GARCH es fundamental analizar tanto los residuos como las predicciones para asegurar la robustez del modelo. Los residuos deben mostrar independencia, homocedasticidad y una distribución aproximadamente normal, lo que indica que no queda estructura no explicada en el modelo.

Por otro lado, las predicciones deben ser evaluadas en términos de su capacidad para seguir de manera consistente la dinámica de la volatilidad real fuera de muestra. Solo mediante una revisión integral del comportamiento de los residuos y de la calidad de las predicciones se puede determinar de forma confiable si el modelo tiene una verdadera capacidad de generalizar y de anticipar adecuadamente la evolución futura de la volatilidad. Estas pruebas se desarrollan en la sección 5.3.

5.2.2 OPTIMIZACIÓN EN REDES NEURONALES RECURRENTE

En el caso de las redes neuronales recurrentes (RNN), cuya estructura está especialmente diseñada para capturar dependencias temporales y contextuales en datos secuenciales, se llevó a cabo un proceso de optimización de hiperparámetros orientado a maximizar su desempeño. Este procedimiento permitió afinar las configuraciones arquitectónicas de sus distintas variantes, ajustando elementos clave para mejorar su capacidad predictiva y estabilidad durante el entrenamiento.

La optimización se enfocó en minimizar dos métricas clave: el error cuadrático medio (MSE) y el error absoluto medio (MAE). Estas métricas fueron empleadas como función objetivo durante el proceso de validación, y reflejan la capacidad del modelo para reducir desviaciones respecto al valor real de la volatilidad. El MSE penaliza errores grandes con mayor severidad, favoreciendo ajustes más conservadores, mientras que el MAE proporciona una medida directa y robusta del error promedio, útil en contextos con alta variabilidad como el de los activos digitales.

A diferencia de los algoritmos tradicionales, donde la búsqueda de hiperparámetros puede realizarse mediante métodos exhaustivos como **grid search**, en el caso de redes neuronales el alto costo computacional hace más adecuado adoptar estrategias de exploración más acotadas y eficientes. Para este estudio, se implementó un esquema de optimización automática de hiperparámetros mediante búsqueda aleatoria (**random search**), utilizando la herramienta **Keras Tuner**, la cual permite explorar de forma eficiente el espacio de configuraciones posibles. Este procedimiento fue complementado con la técnica de **early stopping**, que consiste en monitorear el desempeño del modelo sobre un conjunto de validación durante el entrenamiento y detener el ajuste de parámetros cuando la pérdida deja de mejorar durante un número determinado de épocas consecutivas. Con ello se evita el sobreajuste, se reduce el tiempo de entrenamiento y se favorece la selección de modelos con mejor capacidad de generalización.

La **Tabla 16** presenta los hiperparámetros clave ajustados para cada tipo de red, junto con una breve descripción de la relevancia de estos.

Tabla 16. Resultados de optimización de modelos de redes neuronales recurrentes

Hiperparámetro	Valor óptimo LSTM	Valor óptimo GRU	Valor óptimo SRNN	Descripción
Unidades por capa	[128, 128, 64, 64]	[256, 128, 64, 128]	[128, 128, 64, 32]	Cantidad de unidades por capa, define la profundidad y capacidad de memoria del modelo
Función de activación	tanh	tanh	tanh	Activa las neuronas de cada capa, permitiendo capturar relaciones no lineales
Dropout por capa	[0.1, 0.1, 0.3, 0.3]	[0.1, 0.2, 0.1, 0.2]	[0.2, 0.1, 0.3, 0.2]	Técnica de regularización que apaga aleatoriamente neuronas durante el entrenamiento para prevenir sobreajuste
Regularización L2	1e-5 en capas 1 y 2	1e-5 en capas 1 y 2	1e-4 y 1e-3 en capas 1 y 2	Penaliza pesos excesivos en la red, promoviendo soluciones más simples y generalizables
Learning rate	0.001	0.001	0.001	Tasa de aprendizaje del optimizador Adam, regula la magnitud de los ajustes en los pesos durante la retro propagación

Aunque no se incluyen en la tabla anterior, todos los modelos fueron entrenados utilizando el optimizador Adam, ampliamente reconocido por su capacidad para adaptarse dinámicamente al ritmo de aprendizaje de cada parámetro, lo que lo hace particularmente eficaz en escenarios con funciones de pérdida ruidosas o no estacionarias.

También se utilizó un tamaño de lote de 32, un valor que ofrece un buen equilibrio entre la estabilidad del gradiente y la eficiencia computacional. El entrenamiento se limitó a un máximo de 200 épocas, con el objetivo de brindar tiempo suficiente para la convergencia sin prolongar innecesariamente los recursos computacionales. Además, se implementó la técnica de **early stopping**, la cual detiene el entrenamiento cuando la pérdida de validación no mejora durante 20 épocas consecutivas.

Esta estrategia no solo reduce el riesgo de sobre entrenamiento, sino que también asegura que se conserve la mejor versión del modelo en términos de capacidad de generalización. Durante el proceso de ajuste, se exploraron de forma dirigida distintos rangos para los hiperparámetros clave: unidades por capa entre 32 y 256, tasas de **dropout** entre 0.1 y 0.3 y coeficientes de regularización **L2** entre 1e-5 y 1e-3. La **Tabla 17** muestra los resultados de evaluación final.

Tabla 17. Métricas finales para los modelos de redes neuronales recurrentes

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
LSTM	0.000001	0.000798	0.000596	2.739799	1.721257	0.890433
GRU	0.000001	0.000806	0.000606	2.797543	1.911435	0.888396
SRNN	0.000001	0.000773	0.000575	2.641988	1.983764	0.897557

En términos generales, la optimización de los hiperparámetros logró mantener resultados estables y competitivos, aunque no siempre mejoró todas las métricas frente a las versiones iniciales. Comparando con los modelos originales (previos a la optimización), se observa que todos los modelos optimizados presentaron una leve disminución en el R² y un ligero aumento en RMSE y MAE. Sin embargo, los valores siguen siendo sobresaliente en todas las métricas sin comprometer precisión.

Esto sugiere que, si bien la optimización aportó mejoras en regularización y estabilidad del entrenamiento, los modelos originales ya se encontraban cercanos a un óptimo local. En particular, el rendimiento del SRNN resalta por su solidez, superando a las arquitecturas más complejas incluso antes de ser optimizado, y manteniendo esta ventaja tras los ajustes. Este resultado refuerza la importancia de evaluar la complejidad del modelo frente al desempeño real, especialmente en tareas donde la sobrerrepresentación de parámetros puede no traducirse en beneficios tangibles.

Aun así, el proceso de optimización resultó esencial para validar la consistencia de las arquitecturas propuestas y descubrir configuraciones de hiperparámetros que equilibraran mejor la capacidad predictiva con la robustez del modelo. Además de ajustar parámetros como la regularización o el dropout, se obtuvo evidencia de que los modelos eran estables ante distintas combinaciones, lo cual fortalece su aplicabilidad en

escenarios reales. En este sentido, la optimización no solo refinó la generalización de los modelos, sino que proporcionó un marco empírico para justificar su desempeño y robustez en la predicción de series financieras volátiles como el Bitcoin.

5.2.3 OPTIMIZACIÓN EN ÁRBOLES DE DECISIÓN

Para la optimización de modelos de tipo boosting basados en árboles de decisión, se implementó el **framework Optuna**, una biblioteca de optimización hiperbólica orientada por algoritmos de búsqueda bayesiana. Se eligió esta herramienta debido a su capacidad para explorar de manera eficiente espacios de hiperparámetros de alta dimensión utilizando el método **TPE** (Tree-structured Parzen Estimator), el cual modela la función de pérdida como una distribución de probabilidad y dirige las evaluaciones hacia regiones del espacio que presentan mayor probabilidad de mejora. Esta metodología supera en eficiencia y rendimiento a enfoques tradicionales como **grid search** o **random search**, especialmente en contextos computacionalmente costosos y donde el número de combinaciones posibles es elevado.

Los hiperparámetros seleccionados para optimización corresponden a aquellos que ejercen un control directo sobre la capacidad de aprendizaje, la complejidad del modelo, la regularización contra el sobreajuste y la diversificación entre árboles. Estos factores son críticos en tareas de predicción temporal, particularmente en el modelado de volatilidad, donde el riesgo de sobreajuste y la necesidad de generalización robusta son especialmente elevados.

En el caso de ambos modelos, la función objetivo empleada en **Optuna** buscó minimizar el error cuadrático medio (RMSE) y el error absoluto medio (MAE) sobre el conjunto de prueba. Se realizaron 50 iteraciones, cada una con una combinación diferente de hiperparámetros seleccionados dentro de los siguientes rangos de búsqueda. La **Tabla 18** muestra los resultados de la optimización.

Tabla 18. Resultados de optimización de modelos de árboles de decisión

Hiperparámetro	Rango búsqueda	Valor óptimo (XGBOOST)	Valor óptimo (LIGHTGBM)	Descripción
n_estimators	50–300	240	170	Número total de árboles del modelo ensamblado
learning_rate	0.01–0.3	0.0171	0.0337	Tasa de aprendizaje que regula el ajuste de cada árbol
max_depth	3–12	3	3	Profundidad máxima permitida para cada árbol
subsample	0.5–1.0	0.5023	0.7727	Fracción de observaciones

				utilizadas por árbol
colsample_bytree	0.5–1.0	0.9788	0.8997	Fracción de características seleccionadas por árbol
num_leaves	20–150	-	111	Número máximo de hojas por árbol
min_child_samples	5–50	-	47	Mínimo de observaciones requeridas en una hoja

Los valores óptimos alcanzados por **Optuna** reflejan una estrategia conservadora y altamente regularizada. En ambos modelos se priorizó una baja profundidad, lo cual limita la complejidad estructural de los árboles para evitar sobreajuste. La baja tasa de aprendizaje indica una preferencia por actualizaciones suaves y progresivas, mientras que los altos valores en **subsample** y **colsample_bytree** introducen aleatoriedad que mejora la generalización. En LIGHTGBM, el alto número de hojas permite compensar la baja profundidad con divisiones más finas. Esto sugiere que el optimizador identificó configuraciones que, aunque simples en estructura, permiten captar patrones relevantes sin sobreentrenar. Esta configuración, si bien conservadora, apuntó a maximizar la robustez fuera de muestra. La **Tabla 19** evalúa si dicha estrategia logró traducirse en una mejora sustancial del desempeño predictivo.

Tabla 19. Métricas finales para los modelos de árboles de decisión

Modelo	MSE	RMSE	MAE	MAPE (%)	MdAPE (%)	R ²
XGBOOST	0.000001	0.000807	0.000631	2.916731	2.304301	0.888515
LIGHTGBM	0.000001	0.000835	0.000680	3.129121	2.320797	0.880687

La configuración final de hiperparámetros en ambos modelos reflejó una estrategia orientada a la generalización y al control del sobreajuste, sin embargo, los resultados obtenidos tras la optimización evidenciaron solo mejoras marginales en precisión. El modelo XGBOOST mostró una leve ventaja en casi todas las métricas frente a LIGHTGBM, con mejoras en MAE y MAPE, pero ninguna transformación significativa en términos de capacidad explicativa (R²). Estos resultados sugieren que, si bien el ajuste de hiperparámetros es esencial para afinar modelos de boosting, existen límites estructurales en su capacidad para modelar fenómenos altamente estocásticos como la volatilidad del Bitcoin.

5.3 COMPARACIÓN DE MODELOS

La volatilidad del precio del Bitcoin representa uno de los mayores desafíos en la modelación financiera contemporánea. Su comportamiento altamente cambiante, no lineal y propenso a rupturas estructurales exige enfoques analíticos que trasciendan las

métricas tradicionales de evaluación. Comprender sus patrones de variabilidad y estabilidad requiere pruebas estadísticas y métricas especializadas que permitan una caracterización más profunda de su dinámica.

En consecuencia, la evaluación de la capacidad de estos modelos no puede limitarse únicamente a métricas tradicionales como el error cuadrático medio (MSE), el error absoluto medio (MAE) o el coeficiente de determinación (R^2). Aunque útiles para medir el ajuste, estos indicadores no capturan de forma integral aspectos cruciales como la robustez frente a nuevos datos, el comportamiento de los residuos o la estabilidad de las predicciones. Por ello, en una fase avanzada del análisis se recurrió a un conjunto de siete indicadores complementarios, capaces de proporcionar una evaluación más completa tanto de la precisión como de la capacidad de generalización de los modelos.

Estos indicadores incluyen pruebas estadísticas como **Ljung-Box**, **Jarque-Bera**, **Kolmogorov-Smirnov**, **ADF** y **Engle**, que permiten analizar la independencia, normalidad, estacionariedad y heterocedasticidad de los residuos [71]. Además, se incorporaron métricas cuantitativas como la **correlación de Pearson** y el **Ratio de Estabilidad del Error** (REE), útiles para medir la fuerza de asociación lineal entre las series y la consistencia del desempeño predictivo. Su uso no solo enriquece la evaluación técnica, sino que fortalece las conclusiones al trascender el marco limitado de las métricas de error puntuales.

Así, la **Tabla 20** concentra una batería de indicadores estadísticos e inferenciales que evalúan el desempeño de los modelos optimizados desde una perspectiva robusta.

Tabla 20. Validación estadística y robustez de los modelos optimizados

Indicador	ARCH(1)	GARCH(2,1)	LSTM	GRU	SRNN	XGBOOST	LIGHTGBM
Ljung-Box	0.303397	0.070818	0.516816	0.576969	0.354554	0.286803	0.327213
Jarque-Bera	0.000000	0.014191	0.721980	0.704122	0.514448	0.536871	0.569600
Kolmogorov-Smirnov	0.000039	0.000039	0.000000	0.000000	0.000000	0.000000	0.000000
ADF	0.000819	0.000051	0.000000	0.000108	0.000000	0.000000	0.061681
Engle	0.000000	0.238610	0.016869	0.028176	0.009453	0.195361	0.461747
Pearson Correlation	0.696004	0.602297	0.946413	0.946020	0.947913	0.953404	0.948683
Ratio de Estabilidad del Error	0.163951	0.224359	0.324771	0.325674	0.319255	0.304872	0.320887

Desde la perspectiva de la precisión, uno de los elementos más importantes es la relación entre las predicciones y los valores reales. En este sentido, el modelo ARCH(1) muestra

una capacidad limitada para seguir la dinámica del mercado, con una relación lineal moderada entre las series. GARCH(2,1), aunque ligeramente mejor, sigue evidenciando una debilidad estructural para capturar patrones complejos. Por el contrario, los modelos basados en redes neuronales, como LSTM, GRU y SRNN, presentan una correlación mucho más fuerte con los valores reales, lo que indica que logran modelar con mayor fidelidad los movimientos de la serie temporal. XGBOOST y LIGHTGBM, por su parte, también ofrecen correlaciones elevadas, demostrando que incluso los modelos no secuenciales pueden capturar eficazmente la estructura de volatilidad del Bitcoin.

La estabilidad de los errores a lo largo del tiempo es otro indicador relevante de precisión. Aquí, ARCH(1) y GARCH(2,1) muestran comportamientos menos consistentes, con errores que varían significativamente entre ciclos. En cambio, los modelos LSTM, GRU y SRNN mantienen una notable regularidad en su desempeño, reflejando un comportamiento más estable y confiable en contextos cambiantes. Este mismo patrón se observa en XGBOOST y LIGHTGBM, que presentan también un buen control de la variabilidad del error, lo que refuerza su utilidad para escenarios de alta incertidumbre como los que caracterizan al mercado de criptomonedas.

Cuando se evalúa la capacidad de generalización de los modelos, uno de los primeros aspectos a considerar es la independencia de los residuos. En el caso de ARCH(1), los residuos presentan signos de autocorrelación, lo cual indica que el modelo no logra capturar completamente la estructura temporal subyacente. GARCH(2,1) mejora ligeramente, pero sigue mostrando dependencia en los errores. Por el contrario, los modelos LSTM, GRU, SRNN, XGBOOST y LIGHTGBM logran residuos más independientes, señal de una mayor capacidad para capturar patrones relevantes sin dejar estructura sin modelar.

La distribución de los residuos también aporta información importante sobre la robustez de los modelos. Mientras que ARCH(1) y GARCH(2,1) presentan residuos alejados de la normalidad lo que puede generar inferencias poco confiables, los modelos LSTM, GRU y SRNN generan residuos mucho más cercanos a una distribución normal. De igual manera, los residuos de XGBOOST y LIGHTGBM muestran un comportamiento estadísticamente más adecuado, lo que contribuye a una mejor generalización en diferentes muestras temporales.

Sin embargo, al comparar la forma completa de la distribución empírica de los residuos con una distribución teórica, todos los modelos incluidos ARCH(1), GARCH(2,1), LSTM, GRU, SRNN, XGBOOST y LIGHTGBM enfrentan limitaciones. Sus residuos se desvían significativamente de la forma esperada, lo que refleja la complejidad extrema del

comportamiento del mercado del Bitcoin. Este hallazgo no anula las ventajas previamente mencionadas, pero sí subraya que ningún modelo logra una reproducción perfecta de la distribución empírica.

La estacionariedad de los residuos es otra condición deseable, dado que permite que los modelos mantengan estabilidad frente a nuevos datos. ARCH(1) y GARCH(2,1) cumplen con este criterio, aunque en un contexto de bajo rendimiento general. En cambio, LSTM, GRU y SRNN muestran una clara tendencia a producir residuos estacionarios, consolidando su capacidad para adaptarse a distintas fases del mercado. XGBOOST también cumple con esta condición, mientras que LIGHTGBM se encuentra en el límite, lo que podría implicar cierta vulnerabilidad bajo ciertas condiciones.

Asimismo, en cuanto a la capacidad de los modelos para capturar la heterocedasticidad de la serie, es decir, la variabilidad cambiante en la varianza, ARCH(1) muestra una clara deficiencia, con efectos de volatilidad no resueltos en los residuos. GARCH(2,1) mejora este aspecto, pero no logra eliminarlo por completo. Entre los modelos modernos, LSTM se destaca como el único dentro de las redes neuronales que logra controlar en parte esta condición, mientras que GRU y SRNN aún muestran rezagos. En contraste, XGBOOST y especialmente LIGHTGBM sobresalen al eliminar casi por completo estos efectos residuales, confirmando su solidez para capturar la dinámica de la varianza en la serie.

Finalmente, al comparar estos resultados con los obtenidos previamente en la optimización a través de las métricas de error y el coeficiente de determinación, se observa una fuerte correspondencia entre los modelos que muestran un mejor ajuste cuantitativo y aquellos que evidencian mayor solidez estadística. XGBOOST se posiciona como el modelo más robusto de forma integral, al combinar una alta precisión con residuos estables, independientes y sin efectos de heterocedasticidad remanente. Le siguen muy de cerca LSTM y GRU, que destacan tanto por su capacidad predictiva como por su estructura residual favorable, aunque con leves limitaciones en la captura total de la heterocedasticidad. En tercer lugar, LIGHTGBM muestra también un desempeño competitivo, con buen equilibrio entre precisión y generalización, aunque con señales de menor estacionariedad en los residuos. SRNN, si bien presenta buenos indicadores de correlación y estabilidad, queda ligeramente por debajo de sus contrapartes por su menor capacidad para capturar ciertos aspectos dinámicos de la varianza. Por último, ARCH(1) y GARCH(2,1) confirman su rezago frente a los enfoques modernos, con errores mayores, residuos no normales y efectos de autocorrelación y heterocedasticidad no explicados. Así, los indicadores analizados no solo enriquecen el diagnóstico, sino que validan de manera transversal que los modelos modernos, en especial XGBOOST, LSTM

y GRU, ofrecen la combinación más sólida entre precisión y generalización para la predicción de la volatilidad del Bitcoin.

5.4 CONSTRUCCIÓN DE TABLERO DINÁMICO

Para consolidar y facilitar la interpretación comparativa de los modelos de predicción desarrollados, se implementó un tablero dinámico en **Power BI**. Este tablero actúa como una herramienta visual y analítica que permite al usuario especialmente inversionistas y analistas de riesgo navegar intuitivamente entre resultados, métricas, validaciones estadísticas y comparaciones modelo a modelo.

Power BI fue seleccionado como herramienta de visualización debido a su integración nativa con el ecosistema Microsoft, su capacidad para construir modelos semánticos en estrella optimiza los cálculos complejos. A esto se suma su solidez en entornos corporativos gracias a funciones avanzadas de gobernanza como seguridad a nivel de fila y control de versiones, así como su licenciamiento competitivo y alta escalabilidad. El tablero desarrollado en este proyecto se conecta a un flujo automatizado de tipo **ETL**, donde un **script** en **Python** entrena y evalúa modelos predictivos (ARCH, GARCH, LSTM, GRU, SRNN, XGBOOST y LIGHTGBM), exporta los resultados a **Google Sheets** mediante una **API**, y permite que **Power BI** consuma esta información en tiempo real a través de un conector nativo, manteniendo desacoplada la lógica de modelado respecto a la capa de visualización. La **Figura 28** muestra el flujo implementado para la construcción del tablero.




Figura 28. Flujo utilizado tipo ETL

Adicionalmente, la medición realizada por la empresa Gartner para el año 2024, sitúa a **Power BI** dentro del cuadrante de líderes del mercado [72]. Dicho cuadrante incluye empresas que obtienen una puntuación alta tanto en la visión a largo plazo como en la capacidad de ejecución y tienen un peso importante en la dirección general que tendrá el mercado en los próximos años. Esta medición contempla elementos que generan una puntuación en características como seguridad, gobierno de datos, capacidades **cloud**, conectividad de datos, preparación de datos, visibilidad del contenido, capacidades de inteligencia artificial, visualización de datos, consultas en lenguaje natural, narración de historias con datos y capacidades para informes.

Así, el tablero se organiza en cuatro páginas principales, cada una con objetivos analíticos específicos y componentes visuales que responden a preguntas de negocio relevantes. Para más información ver **Anexo 3** que contiene el acceso al tablero dinámico.

Página de Introducción y Navegación:

Esta primera página ofrece al usuario una visión general del propósito del tablero, presentando botones de navegación que permiten acceder rápidamente a las secciones clave del informe: comparación de modelos, métricas por indicador, validación estadística y vistas tabulares. Su diseño cumple una función introductoria y estructural, guiando la exploración del tablero bajo un enfoque de análisis cuantitativo riguroso y accesible. La **Figura 29** muestra el diseño de esta página.




Figura 29. Página inicial del tablero

Esta visualización inicial, permite responder al interrogante de ¿Cómo puedo navegar de manera eficiente por el tablero para acceder a las secciones clave del informe y entender su propósito general?

Página “Panel General” Cifras relevantes y predicciones:

Este panel general ofrece una visualización clara y estructurada del comportamiento reciente del Bitcoin, integrando tanto indicadores actuales como proyecciones futuras. En la parte superior, se presentan los cambios diarios en la volatilidad, el precio y el volumen de transacciones, junto con las predicciones de volatilidad generadas por modelos de inteligencia artificial. Los dos gráficos que componen el cuerpo del panel muestran, por un lado, la evolución de la volatilidad del precio y, por otro, la trayectoria del valor del Bitcoin durante los últimos dos meses. Adicional, se muestra la predicción del día de mañana bajo los tres modelos más precisos, XGBOOST, GRU Y LSTM. La **Figura 30** refleja las cifras más relevantes.




Figura 30. Sección de cifras del Bitcoin y predicciones de los mejores modelos

Esta visualización responde al interrogante: ¿cómo ha evolucionado recientemente el precio y la volatilidad del Bitcoin, y qué estimaciones de volatilidad proyectan distintos modelos predictivos para el corto plazo? Al integrar datos históricos, variaciones diarias y predicciones, el panel permite evaluar el estado actual del mercado y anticipar posibles escenarios futuros, apoyando así la toma de decisiones estratégicas en contextos financieros o de inversión.

Página “Mejor Modelo” Base y Optimizado:

Esta sección se divide en dos partes, en la primera se presenta una evaluación comparativa del rendimiento de distintos modelos de predicción de la volatilidad del Bitcoin, en su versión base. En la parte superior se muestran las métricas de error del modelo optimizado seleccionado, incluyendo el error cuadrático medio, el error absoluto medio, el porcentaje de error medio absoluto y el coeficiente de determinación (R^2). Además, un recuadro indica que, según el modelamiento realizado, el mejor modelo base ha sido GRU.

En la segunda parte se presenta la versión optimizada de cada modelo, enfocándose en la evaluación estadística de la calidad de las predicciones, con énfasis en pruebas de normalidad, estacionariedad y correlación. En la parte superior se reportan los resultados de pruebas estadísticas aplicadas al modelo optimizado seleccionado: Ljung-Box, Jarque-Bera, Kolmogorov-Smirnov, ADF, Engle y el coeficiente de correlación de Pearson, junto con el REE (Error Relativo Esperado). Se indica que el mejor modelo es XGBOOST.

Las **Figuras 31 y 32** reflejan el diseño de esta sección.




Figura 31. Sección del mejor modelo base en el tablero




Figura 32. Sección del mejor modelo optimizado en el tablero

Estas visualizaciones permiten responder a la pregunta ¿Cuál es el modelo predictivo más efectivo para predecir la volatilidad del Bitcoin, considerando tanto su configuración base como optimizada?

Adicionalmente, en todas las páginas hay botones de ayudas, que permiten conocer la definición de cada una de las métricas e indicadores evaluados. A modo de ejemplo, en esta sección, las **Figuras 33** y **34** muestra estas ayudas.




Figura 33. Ejemplo de sección de ayudas en modelo base




Figura 34. Ejemplo de sección de ayudas en modelo optimizado

Página “Información de la Serie” Validación de Supuestos:

Esta vista del tablero se compone de cuatro gráficos y adicional, valida los supuestos estadísticos necesarios para una modelación predictiva confiable de la volatilidad del Bitcoin. Mediante pruebas como Dickey-Fuller Aumentada (ADF), se confirma que la serie es estacionaria, lo cual es clave para aplicar modelos autorregresivos. Las visualizaciones incluidas permiten identificar tendencias prolongadas, patrones estacionales y residuos con comportamiento de ruido blanco. En conjunto, estos análisis demuestran que la serie cumple con las condiciones estadísticas requeridas para ser modelada eficazmente con enfoques tanto clásicos como avanzados. La **Figura 35** muestra una de las visualizaciones correspondientes a esta sección.




Figura 35. Sección de información de la serie de tiempo en el tablero

Se observa entonces que las visualizaciones permiten responder a las siguientes cuestiones: ¿Cumple la serie de volatilidad del Bitcoin con los requisitos estadísticos necesarios para una modelación predictiva confiable y efectiva? ¿Es estacionaria y cuáles son sus características de tendencia, estacionalidad y residuos?

Página “Información Plana” Auditoría de Resultados:

En esta sección se despliegan tablas comparativas que detallan las predicciones diarias de cada modelo frente a los valores reales, tanto en su versión base como optimizada. Además de permitir un análisis fino de los errores observacionales, esta vista aporta transparencia al proceso, facilitando auditorías, backtesting y la generación de reportes técnicos para entes reguladores o stakeholders. La **Figura 36** refleja la información de esta sección.

←

Información Plana

Predicción Modelo Base									Predicción Modelo Optimizado								
Fecha	Real	SRNN	LSTM	GRU	ARCH	GARCH	LightGBM	XGBoost	Fecha	Real	SRNN	LSTM	GRU	ARCH	GARCH	LightGBM	XGBoost
2025	0,022189	0,022335	0,022279	0,022346	0,021873	0,021032	0,022483	0,022428	2025	0,016336	0,016446	0,016466	0,016483	0,010974	0,010973	0,016735	0,016942
enero	0,023667	0,023748	0,023648	0,023679	0,023187	0,022531	0,024089	0,024060	enero	0,022523	0,022511	0,022452	0,022488	0,021561	0,017607	0,022828	0,022704
1	0,023737	0,023936	0,023741	0,023757	0,023379	0,023378	0,024900	0,024374	1	0,023737	0,023950	0,023771	0,023844	0,023379	0,022125	0,024323	0,024165
2	0,024218	0,024127	0,023711	0,023724	0,023335	0,023338	0,024288	0,024459	2	0,024218	0,023846	0,023777	0,023753	0,023335	0,020731	0,023926	0,024165
3	0,023751	0,023983	0,024129	0,024199	0,023810	0,020954	0,025072	0,024431	3	0,023751	0,023885	0,024237	0,024241	0,023810	0,021109	0,024839	0,024694
4	0,023384	0,023355	0,023756	0,023742	0,023352	0,020398	0,024066	0,024090	4	0,023384	0,023318	0,023710	0,023736	0,023352	0,022412	0,024238	0,024131
5	0,022523	0,023153	0,023374	0,023360	0,022991	0,018689	0,024718	0,023719	5	0,022523	0,023092	0,023294	0,023303	0,022991	0,018697	0,023842	0,023859
6	0,023574	0,022857	0,022603	0,022542	0,022144	0,017820	0,023679	0,022637	6	0,023574	0,022702	0,022452	0,022488	0,022144	0,021880	0,022861	0,022754
7	0,025314	0,023516	0,023447	0,023584	0,023177	0,019725	0,024959	0,024499	7	0,025314	0,023427	0,023612	0,023673	0,023177	0,022907	0,023859	0,023965
8	0,024595	0,025135	0,025076	0,025330	0,024889	0,024033	0,025252	0,024665	8	0,024595	0,025002	0,025419	0,025513	0,024889	0,024034	0,025163	0,025102
9	0,025040	0,024802	0,024540	0,024565	0,024184	0,024182	0,023834	0,024333	9	0,025040	0,024711	0,024404	0,024408	0,024184	0,024181	0,024741	0,024738
10	0,023922	0,024949	0,024839	0,024948	0,024620	0,023898	0,024895	0,025025	10	0,023922	0,024957	0,025073	0,025104	0,024620	0,023778	0,025163	0,025032
11	0,023862	0,024432	0,023940	0,023901	0,023520	0,023989	0,024754	0,024845	11	0,023862	0,024219	0,023905	0,023825	0,023520	0,023986	0,024806	0,024642
12	0,023673	0,023876	0,023780	0,023801	0,023460	0,023656	0,025295	0,024997	12	0,023673	0,023928	0,023559	0,023604	0,023460	0,023648	0,024806	0,024642
13	0,023676	0,023933	0,023636	0,023661	0,023275	0,023275	0,024301	0,024810	13	0,023676	0,023678	0,023634	0,023741	0,023275	0,023275	0,023872	0,024013
14	0,023384	0,023513	0,023619	0,023653	0,023281	0,020819	0,024115	0,024183	14	0,023384	0,023446	0,023437	0,023461	0,023281	0,020766	0,023872	0,024007
15	0,024435	0,023410	0,023375	0,023375	0,022990	0,022990	0,024187	0,024278	15	0,024435	0,023351	0,023228	0,023328	0,022990	0,022990	0,023914	0,023894
16	0,024450	0,024367	0,024286	0,024413	0,024025	0,024024	0,025168	0,024916	16	0,024450	0,024255	0,024504	0,024507	0,024025	0,024024	0,024781	0,024708
17	0,023507	0,024589	0,024402	0,024444	0,023136	0,022483	0,024544	0,024759	17	0,023507	0,024381	0,024429	0,024401	0,023136	0,022482	0,024448	0,024789
Total	0,022189	0,022335	0,022279	0,022346	0,021873	0,021032	0,022483	0,022428	Total	0,016336	0,016446	0,016466	0,016483	0,010974	0,010973	0,016735	0,016942

Figura 36. Sección de información plana en el tablero

Así, esta visualización responder a las preguntas sobre ¿Qué valores de volatilidad diaria ha generado cada modelo predictivo, tanto en su versión base como optimizada, y cómo se comparan con los valores reales observados?

6 CONCLUSIONES Y TRABAJOS FUTUROS

El análisis realizado sobre la predicción de la volatilidad del Bitcoin ha permitido comparar enfoques clásicos y modernos, destacando la relevancia de técnicas de machine learning en contextos financieros altamente dinámicos. A partir de los resultados obtenidos, se

identificaron fortalezas y limitaciones en cada metodología, brindando un marco sólido para futuras investigaciones. En esta sección, se presentan las conclusiones principales del estudio y se proponen líneas de trabajo futuras que pueden mejorar la precisión y estabilidad de los modelos predictivos.

6.1 CONCLUSIONES

El presente estudio permitió realizar una comparación exhaustiva entre enfoques clásicos y modernos para la predicción de la volatilidad del Bitcoin, un activo caracterizado por su comportamiento altamente dinámico y no lineal. En este análisis, los modelos de machine learning en particular las redes neuronales recurrentes como LSTM y GRU, junto con el algoritmo de boosting XGBOOST demostraron un rendimiento notable frente a los modelos tradicionales de series temporales como ARCH y GARCH. Esta superioridad se evidenció especialmente en su capacidad para capturar patrones complejos en los datos y adaptarse a cambios abruptos en la volatilidad, una característica esencial en contextos marcados por alta incertidumbre.

Las métricas de evaluación utilizadas, tales como el error cuadrático medio (MSE), el error absoluto medio (MAE) y el análisis de residuos, confirmaron que los modelos de aprendizaje automático no solo lograron predicciones más precisas, sino también una mayor estabilidad estadística. En el caso de las redes neuronales, este desempeño puede atribuirse a sus mecanismos de memoria interna y puertas de control, que permiten modelar relaciones temporales no lineales con mayor eficacia. Por su parte, XGBOOST se destacó por su eficiencia en el procesamiento de grandes volúmenes de datos y su capacidad para detectar interacciones complejas entre variables, ofreciendo una alternativa sólida con menor demanda computacional.

Desde una perspectiva estadística, los modelos propuestos fueron validados rigurosamente mediante pruebas como la de Dickey-Fuller Aumentada, que confirmó la estacionariedad de la serie de tiempo, y análisis de residuos que evidenciaron la ausencia de heterocedasticidad remanente. Estas validaciones fortalecen la confianza en la capacidad de generalización de los modelos, asegurando que sus predicciones se sustentan en una estructura temporal sólida y coherente con los principios fundamentales del análisis cuantitativo.

Adicionalmente, se desarrolló un tablero dinámico en Power BI para la visualización de resultados, que facilitó la interpretación de los modelos y consolidó una plataforma interactiva para el análisis de volatilidad. Esta integración entre modelos predictivos y herramientas de visualización demostró ser altamente efectiva para comunicar los

hallazgos tanto a públicos técnicos como no especializados, reforzando el valor práctico del enfoque adoptado.

En síntesis, el estudio puso de manifiesto la capacidad transformadora de los modelos de machine learning en el análisis de series temporales financieras altamente volátiles como el Bitcoin. Más allá de su rendimiento superior frente a los métodos tradicionales, estas técnicas demostraron ser particularmente eficaces para abordar fenómenos marcados por la no linealidad, la estacionalidad cambiante y la ocurrencia de eventos abruptos. El uso de arquitecturas avanzadas, como redes neuronales recurrentes (LSTM, GRU) y modelos de boosting (XGBOOST), permitió no solo mejorar la precisión de las predicciones, sino también ofrecer interpretaciones más completas sobre las dinámicas internas de la volatilidad, posicionándolos como recursos esenciales para la modelación cuantitativa en finanzas.

Asimismo, el análisis evidenció que la diversidad metodológica entre los modelos implementados representa una fortaleza en sí misma, ya que permite abordar el problema desde distintos enfoques teóricos y computacionales. Esta pluralidad facilita una mayor adaptabilidad al tipo de datos, a los objetivos específicos del análisis y a los contextos operativos en los que estos modelos serán aplicados. En conjunto, los hallazgos no solo validan el uso de enfoques modernos como componentes clave del análisis financiero contemporáneo, sino que también consolidan su papel como herramientas fundamentales para enfrentar los retos que plantea la creciente complejidad de los mercados digitales.

6.2 TRABAJOS FUTUROS

A partir de los resultados obtenidos, se identifican diversas oportunidades para continuar fortaleciendo la predicción de la volatilidad del Bitcoin. Una primera línea de trabajo consiste en profundizar en el ajuste de los hiperparámetros y arquitecturas de los modelos analizados. Si bien se realizó un proceso riguroso de optimización, futuras investigaciones podrían explorar métodos más exhaustivos de validación cruzada, estrategias de búsqueda más eficientes o combinaciones de ventanas temporales y funciones de activación que permitan mejorar el rendimiento de las predicciones.

En paralelo, las investigaciones futuras también podrían centrarse en la optimización de estrategias de inversión basadas en las predicciones de volatilidad. Esto incluiría el desarrollo de herramientas que conviertan los pronósticos en decisiones financieras efectivas, tales como algoritmos de trading algorítmico, o la evaluación de la rentabilidad de estrategias que integren la predicción de la volatilidad en la gestión de riesgos.

Además, la creación de sistemas automatizados que ajusten sus estrategias en función de la volatilidad pronosticada podría representar un avance relevante en la gestión de portafolios de criptomonedas.

Otro aspecto clave para trabajos futuros es la integración de nuevas fuentes de datos que puedan enriquecer el desempeño de los modelos. Actualmente, la mayoría de los estudios se centran en series temporales basadas en precios históricos, pero la inclusión de variables externas, como indicadores macroeconómicos, métricas on-chain (datos extraídos directamente de la blockchain), índices de miedo y codicia, y análisis de sentimiento en redes sociales, podría mejorar la capacidad predictiva de los modelos. También, sería relevante evaluar la influencia de factores regulatorios, cambios en la adopción institucional del Bitcoin y su relación con otros activos financieros tradicionales.

Asimismo, resulta pertinente considerar el volumen de transacciones como una fuente de información complementaria en la predicción de la volatilidad. Incorporar variables relacionadas con el volumen, como el volumen negociado diario o indicadores técnicos como el OBV (On-Balance Volume), podría aportar señales útiles sobre las dinámicas de oferta y demanda. Futuras investigaciones podrían explorar cómo la inclusión de estas características influye en el desempeño de los modelos, especialmente en contextos de alta especulación o variaciones en la liquidez del mercado.

También se podría profundizar en la capacidad de los modelos para predecir cambios de régimen en la volatilidad. Eventos extremos como crisis financieras, caídas repentinas del mercado o anuncios regulatorios suelen afectar de manera significativa el comportamiento del Bitcoin. Investigar la adaptabilidad de los modelos ante escenarios de alta incertidumbre permitiría desarrollar sistemas más robustos y resilientes a cambios drásticos en el mercado.

Por otra parte, las limitaciones en recursos computacionales y la sensibilidad de los modelos a cambios en la estructura de los datos abren la posibilidad de explorar técnicas que optimicen su eficiencia y estabilidad. Métodos como el aprendizaje federado podrían permitir el entrenamiento de modelos descentralizados sin comprometer la privacidad de los datos, mientras que la selección de características ayudaría a reducir la dimensionalidad de los datos sin perder información relevante.

Finalmente, otra línea de investigación interesante consiste en enfatizar la importancia de la interpretación probabilística de los pronósticos en el contexto de la predicción de la volatilidad del Bitcoin. Aunque los modelos avanzados han demostrado su precisión superior, la naturaleza especulativa del mercado crypto sugiere que ninguna predicción

es completamente determinista.

Por lo tanto, se recomienda la adopción de enfoques basados en distribuciones de probabilidad para representar la incertidumbre en las predicciones, en lugar de valores puntuales. Esta metodología podría mejorar la toma de decisiones al permitir que inversionistas y analistas evalúen escenarios de riesgo con mayor profundidad.

Estas líneas de trabajo permitirán seguir fortaleciendo el conocimiento sobre la predicción de la volatilidad del Bitcoin y su aplicación en contextos financieros dinámicos, contribuyendo al desarrollo de herramientas más precisas y adaptables en el análisis de criptomonedas.

7 REFERENCIAS BIBLIOGRÁFICAS

- [1] M. V. Flores, "La globalización como fenómeno político, económico y social", *Orbis. Revista Científica Ciencias Humanas*, vol. 12, n.º 34, pp. 26-41, 2016.
- [2] L. E. . Paz Quintanilla, J. G. . Márquez Romero, y J. E. . Calles Ramos, "Uso del Bitcoin como moneda de curso legal en El Salvador", *Revista Jiboa*, vol. 1, n.º 1, pp. 45–52, oct. 2023.
- [3] D. Rey Miró, D. A. Berlanga y R. Palomo Zurdo, "Análisis de la volatilidad de Bitcoin en comparación con otros activos financieros", *Revista de Economía y Finanzas*, Vol. 1, n.º 3, feb 2024.
- [4] N. Quirós Aguilar y E. Corea Zúñiga, "BITCOIN YA EXISTE. UNA EVOLUCIÓN EN LA NATURALEZA DEL DINERO", *Logos*, vol. 4, n.º 1, pp. 48-79, ene. 2023.
- [5] L. J. Chen, "Evolución del precio del Bitcoin: Análisis estadístico de series temporales", Tesis de Pregrado, Universidad Complutense de Madrid, Facultad de Estudios Estadísticos, Madrid, España, 2019.
- [6] A. López García, "Análisis comparativo de redes neuronales profundas para la predicción del precio de mercado de Bitcoin", *Rect@*, vol. 24, n.º 1, pp. 1–16, jun. 2023.
- [7] M. H. Díaz López, A. King-Domínguez, y L. Améstica-Rivas, "Estimación de Precios de Bitcoin mediante Regresión Lineal Múltiple y Redes Neuronales", *Podium*, n.º 44, pp. 119–132, dic. 2023.
- [8] Yahoo Finance, "Yahoo Finance – Stock Market Live, Quotes, Business & Finance News." [En línea]. Disponible en: <https://finance.yahoo.com/>.
- [9] P. A. Pauli, Análisis de sentimiento: Comparación de algoritmos predictivos y métodos utilizando un lexicon español, Tesis de Pregrado, Instituto Tecnológico de Buenos Aires, 2019, Buenos Aires, Argentina.
- [10] J. W. Goodell, S. B. Jabeur, F. Saâdaoui y M. A. Nasir, "Explainable artificial intelligence modeling to forecast Bitcoin prices," *International Review of Financial Analysis*, vol. 88, no. 102702, 2023.
- [11] R. Fernandez. (2024, abr 3). "Criptomonedas - Datos estadísticos". Statista, [Online]. Available: <https://es.statista.com/temas/8092/criptomonedas/#topicOverview>. [Accessed: Jun. 10, 2024].
- [12] J. Ruocco, "Bitcoin y la naturaleza política del dinero," *CEC*, vol. 9, n.º 17, pp. 143-151, mar. 2023.
- [13] J. A. Higuera, C. A. Quintero González y M. Sepulveda Castillo, "El Bitcoin como dinero y su mercado," *Área de Inversiones Alternativas, Unidad de Análisis del Mercado Financiero (UAMF)*, Boletín de Coyuntura, no. 10.
- [14] R. Anguren, J. García Alcorta, L. García Calvo, D. Hernández García, and E. Valdeolivas, "La regulación de los criptoactivos en el marco internacional y europeo en curso," *Revista de Estabilidad Financiera*, no. 44, pp. 121-147, Primavera 2023.

- [15] A. V. Morales Cortés and L. N. Perea Mosquera, "El Bitcoin en el sistema financiero," Repositorio Institucional Unilibre, Universidad Libre, no. 8, pp. 62-72, 2018, Pereira, Colombia.
- [16] L. D. Salas Ocampo Y M. Alfaro Salas, "Criptomonedas y su efecto en la estabilidad del sistema financiero internacional: Apuntes para Centroamérica," Revista Relaciones Internacionales, vol. 95, no. 1, pp. 33-78, 2022.
- [17] J. A. Castañeda Giraldo y L. Correa Morales, "Criptomonedas: Una revolución a la banca tradicional," Tesis de Pregrado, Universidad Libre, 2022, Pereira, Colombia.
- [18] M. Ángel Vázquez-Gutiérrez, "Inversiones globales en entornos inciertos: El Bitcoin", VinculaTégica, vol. 4, n.º 1, pp. 221–225, sep. 2018.
- [19] L. J. Blanco Encinosa, "Criptomonedas. Breve análisis desde la perspectiva económica y financiera," Cofin Habana, vol. 15, no. 2, Jul. 2021.
- [20] W. Maldonado de la Cruz y L. Viteri-Rade, "Criptomonedas en la actualidad: ¿es una inversión rentable?," 593 Digital Publisher CEIT, vol. 8, no. 2, pp. 27-39, 2023.
- [21] A. Cárdenas-Pérez, L. Lascano-Pérez, G. Proaño-Altamirano, G. Mácas-Sánchez Y S. Chango-Galarza, "El mundo de las criptomonedas y su importancia en el comercio virtual," Revista Publicando, vol. 9, no. 36, pp. 44-58, 2022.
- [22] M. Cabrera Soto y C. Lage Codorniu, "Criptomonedas: ¿qué son y qué pretenden ser?," Economía y Desarrollo, vol. 166, no. 1, ene. 2022.
- [23] R. Romero Aguilar y K. Jiménez Elizondo, "Vulnerabilidades del Bitcoin," Notas Económicas Regionales, Secretaría Ejecutiva del Consejo Monetario Centroamericano, no. 107, Nov. 2019.
- [24] G. Noriega C., "¿Blockchain es más que criptomonedas?, presente y futuro," Facultad de Contaduría Pública, no. 29, pp. 2022, Jan.-Jun. 2021.
- [25] P. Lozano y D. David, "Criptomonedas y Blockchain en el ámbito financiero: Un análisis de correlación," Revista de Métodos Cuantitativos para la Economía y la Empresa, vol. 34, pp. 328-358, 2022.
- [26] D. V. Cuadrado-Avilés, D. A. Ponce-Molina, A. P. Valdivieso-Bonilla y G. E. Proaño-Altamirano, "Revisión literaria de la implementación de Criptomonedas y Blockchain dentro de las Fintech en América Latina," REVISTA DE INVESTIGACIÓN SIGMA, vol. 8, no. 02, pp. 64-73, 2021.
- [27] J. A. Paredes Castaño, C. C. Baquero Flórez, N. D. González Niño Y D. I. Parra Rodríguez, "Medición del conocimiento del uso de criptomonedas desde una perspectiva empresarial y gubernamental en Colombia," Tesis de especialización, Universidad EAN, 2024.
- [28] J. M. Mata Hernández, "Panorama de inclusión financiera y del uso de criptomonedas en México," Interconectando Saberes, no. 13, pp. 37-45, 2022.
- [29] A. Gordon Muñoz, "Evaluación del rendimiento de inversiones en criptomonedas: Riesgos y oportunidades," Revista Ingenio Global, vol. 2, no. 1, pp. 13-23, Jan.-Jun. 2023.
- [30] A. Bouteska, M. Z. Abedin, P. Hajek y K. Yuan, "Cryptocurrency price forecasting – A

- comparative analysis of ensemble learning and deep learning methods," *International Review of Financial Analysis*, vol. 92, no. 103055, 2024.
- [31] A. Bouteska, M. K. Hassan, M. Rashid y M. H. Bilgin, "The dynamics of bonds, commodities and bitcoin based on NARDL approach," *The Quarterly Review of Economics and Finance*, vol. 94, pp. 58–70, 2024.
 - [32] A. Cortés Mojica, "Construcción, comparación y selección de modelos predictivos econométricos y de machine learning para la proyección de la Tasa Representativa de Mercado (TRM) y su impacto en compañías del sector real," Tesis de maestría, Universidad de los Andes, 2023.
 - [33] P. A. Mora Adán, "Comparación de modelos clásicos en series de tiempo y modelos bayesianos para pronosticar tres acciones colombianas en el último año," Tesis de pregrado, Universidad Santo Tomás, Nov. 2020.
 - [34] C. A. Murillo Morales, "Implementación de un modelo GARCH-M al modelo CAPM para mejorar el ajuste de los rendimientos de los activos financieros," Tesis de Licenciatura, Universidad Autónoma del Estado de México, 2023.
 - [35] J. Mariño Villalba, "Una comparación entre modelos estadísticos y de Machine Learning para la predicción de series de tiempo multivariadas," Tesis de maestría, Universidad Nacional de Colombia, 2023.
 - [36] M. Palou Miceli, "Evaluación del poder predictivo del modelo LSTM en el análisis de series de tiempo financieras," Tesis de Licenciatura, Universidad de San Andrés, Escuela de Administración y Negocios, Argentina, 2024.
 - [37] F. J. Nanclares Rodríguez, "Redes Neuronales Recurrentes para la Predicción de Series Temporales," Trabajo de Fin de Grado, Grado en Ingeniería Informática, Universidad Autónoma de Madrid, Escuela Politécnica Superior, 2021
 - [38] S. Ranjit, S. Shrestha, S. Subedi, y S. Shakya, "Comparison of Algorithms in Foreign Exchange Rate Prediction," 3rd International Conference on Computing, Communication and Security (ICCCS), pp. 9-13, 2018.
 - [39] F. Orte Bénédict, "Modelo de predicción para mercados de futuros de cripto-activos basado en Random Forests," Tesis doctoral, Univ. Politécnica de Madrid, Escuela Técnica Superior de Ingenieros Industriales, España, 2022.
 - [40] C. Hernández Hernández y J. S. Forero Criollo, "modelos de predicción estocástica para Bitcoin: una evaluación de métodos y desempeño", Tesis de maestría, Escuela de Economía y Finanzas, Universidad EAFIT , Bogotá, Colombia, 2023.
 - [41] S. G. Marsol, "Uso de algoritmos data driven para superar al S&P500," Tesis de maestría, Universitat Oberta de Catalunya, Barcelona, España, 2024.
 - [42] E. A. Moreno Quintero, "Predicción del precio del Bitcoin utilizando algoritmos de aprendizaje profundo", Tesis de Maestría, Escuela de Ingeniería, Ciencia y Tecnología, Universidad del Rosario, Bogotá, Colombia, 2023.
 - [43] C. D. Escobar Anduquia, S. D. Avella Jiménez, y B. R. Rojas Ormaza, "Análisis de activos financieros en Colombia: cobertura de posiciones con Bitcoin", *Rev. CEA*, vol. 9, n.º 21, p. e2481, ago. 2023.

- [44] E. Aguayo Moreno, "LSTM-GARCH para la predicción de volatilidad en portafolios de criptomonedas", Tesis de Maestría, Centro de Investigación en Matemáticas, A.C., Monterrey, México, 2021.
- [45] E. Jimenez Bujalance, "Modelos de predicción del precio de Bitcoin mediante algoritmos de Machine Learning," Treball Final de Grau, UPC, Escola d'Enginyeria de Telecomunicació i Aeroespacial de Castelldefels, Departament d'Enginyeria Telemàtica, 2022.
- [46] J. R. . Lopez Marin, C. A. . Paz Gómez y G. . Hernández Romero, "Visión actual del Bitcoin desde la perspectiva de los inversionistas ", Publ. investig., vol. 17, no. 1, ene. 2023,
- [47] A. Castillo Mur, "Las criptomonedas en el sistema financiero internacional. Un análisis predictivo mediante técnicas de Machine Learning (LSTM)," Treball Final de Grau, UPC, Facultat de Matemàtiques i Estadística, Universitat de Barcelona. Departament d'Econometria, Estadística i Economia Aplicada, 2020.
- [48] J. A. Gracia Torres y A. D. Hurtado Cuellar, "Factores que influyen en el comportamiento del Bitcoin y su volatilidad," Tesis de Pregrado, Programa de Negocios Internacionales, Facultad de Ciencias Económicas y Administrativas, Universitaria Agustiniiana, Bogotá, D.C., Colombia, 2019.
- [49] L. C. Sanchez Ascanio y J. A. Arredondo Garcia, "Prediciendo el precio del Bitcoin, y más," Suma Negocios, vol. 11, no. 24, pp. 42-52, 2020
- [50] A. F. Esteve, "Predicción del comportamiento de criptomonedas a partir de métodos de inteligencia artificial," M.S. thesis, Universitat Politècnica de València, Departamento de Matemática Aplicada, Valencia, España, 2023
- [51] A. M. Jenkins, "Modelo GARCH para la volatilidad de las criptomonedas Bitcoin y Ether," M.S. thesis, Predicción en Economía – Máster de Investigación, UNED, 2016.
- [52] E. Lambis-Alandete, M. Jiménez-Gómez y J. D. Velázquez-Henao, "Comparación de algoritmos de Deep Learning para pronósticos en los precios de criptomonedas," Ingeniería y Competitividad, vol. 25, no. 3, 2023.
- [53] C. Acevedo, "¿Es factible que el Bitcoin alcance un millón de dólares en 5 años?," Realidad Empresarial, N° 13, pp. 8-21, 2022.
- [54] L. López Vázquez y R. Cadena Martínez, "Modelo de Ciencia de Datos para predecir ventas en una Empresa", Ciencia Latina, vol. 7, n.º 4, pp. 9374-9393, sep. 2023.
- [55] P. Haya, "La metodología CRISP-DM en ciencia de datos," Instituto de Ingeniería del Conocimiento, 29 de noviembre de 2021.
- [56] N. Yamak, R. Yamak, y S. Samut, "Causal Relationship Between Bitcoin Price Volatility and Trading Volume: Rolling Window Approach," Financial Studies, vol. 23, no. 3, pp. 6–20, 2019
- [57] J. C. Abril y M. de las M. Abril, «Modelado y estimación de la volatilidad estocástica: aplicación a la inflación», South American Research Journal, vol. 4, n.º 1, pp. 35-51, 2024.
- [58] A. J. Cangrejo Esquivel, J. R. Tovar Cuevas, I. C. Garcia Arboleda y D. F. Manotas

- Duque, "Estimación clásica y bayesiana de la volatilidad en el modelo de Black-Scholes," *Revista. Métodos Cuantitativos para la Economía. y la Empresa*, vol. 34, pp. 237-262, 2022.
- [59] A. J. Urdaneta Montiel, Y. E. Carvallo Monsalve, y E. V. Borgucci García, "Bitcoin y la teoría monetaria de Friedman y Mises. Evidencias estadísticas," *Revista de Ciencias Sociales*, vol. 26, no. 4, pp. 246–259, 2020.
 - [60] C. Mulcahy, "Bitcoin price history: 2009 — 2025," *Bitcoin Magazine*, 2-mar-2023. [Online]. [<https://Bitcoinmagazine.com/guides/Bitcoin-price-history>].
 - [61] R. F. Engle, "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation," *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982.
 - [62] T. Bollerslev, "Generalized Autoregressive Conditional Heteroskedasticity," *Journal of Econometrics*, vol. 31, no. 3, pp. 307–327, 1986.
 - [63] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Computation*, vol. 9, no. 8, pp. 1735–1780, 1997.
 - [64] T. Toharudin, R. S. Pontoh, R. E. Caraka, S. Zahroh, Y. Lee, and R. C. Chen, "Employing long short-term memory and Facebook Prophet model in air temperature forecasting," *Commun. Stat. Simul. Comput.*, vol. 52, no. 2, pp. 279–290, 2021
 - [65] K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, "Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation," in *Proc. of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, Doha, Qatar, pp. 1724–1734, 2014.
 - [66] Y. Bengio, P. Simard, and P. Frasconi, "Learning long-term dependencies with gradient descent is difficult," *IEEE Transactions on Neural Networks*, vol. 5, no. 2, pp. 157–166, 1994.
 - [67] T. Chen and C. Guestrin, "XGBOOST: A Scalable Tree Boosting System," in *Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785–794, 2016.
 - [68] G. Ke et al., "LIGHTGBM: A Highly Efficient Gradient Boosting Decision Tree," in *Proc. of NIPS*, 2017.
 - [69] D. Chicco, M. J. Warrens y G. Jurman, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation," *PeerJ Computer Science*, vol. 7, art. e623, 2021.
 - [70] Lai, H., & Gao, X., "Modified BIC Criterion for Model Selection in Linear Mixed Models," *Mathematics*, vol. 11, no. 9, p. 2130, 2023.
 - [71] T. E. Pratas, F. R. Ramos, y L. Rubio, "Forecasting Bitcoin volatility: exploring the potential of deep learning," *Eurasian Economic Review*, vol. 13, pp. 285–305, 2023.
 - [72] Microsoft Corporation, "Microsoft is named a Leader in 2024 Gartner® Magic Quadrant™ for CRM Customer Engagement Center," *Microsoft Dynamics 365 Blog*, Dec. 17, 2024. [Online].

ANEXOS

Anexo 1. Enlace de acceso al código utilizado para el desarrollo del EDA

https://colab.research.google.com/drive/1odCZKwICFUszEyjmu4Ig_WAbMaWKxzDF

Anexo 2. Enlaces de acceso a los códigos utilizados para el desarrollo de modelos

https://colab.research.google.com/drive/1_aLP6jHPZTZ_vQLTqpxbrYKc2DayR_WB

<https://colab.research.google.com/drive/1ao3s3TsyzaMUE26uX64IfEjUdsICwqMq>

<https://colab.research.google.com/drive/1wFR6NnxpRgBAvSJPK2Hj6EqqyRwZEBi>

<https://colab.research.google.com/drive/1O5SqnMqfvOLQowC9VRbKJPnHCTjARcY>

https://colab.research.google.com/drive/1mQCVgK1wTP_NqipWkUqZJcYRzITLuOs-

Anexo 3. Enlace de acceso al tablero dinámico

<https://app.powerbi.com/view?r=eyJrIjoiaWwOTRIYjltNmQ0Zi00MjNlWJjYzUtNmVhMjI0MmI0ODg1IiwidCI6IjE2YWY2YjQ1LTAwYzUtNGJhMy05ZDRjLThtZmExNmU0MzYwMyIsImMiOiR9>