



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE
HIDALGO

INSTITUTO DE CIENCIAS BÁSICAS E INGENIERÍA

ESTUDIO DE ESTRATEGIAS DE MERCADOS
APLICADAS AL DESEMPEÑO DE CRIPTOMONEDAS

Tesis

QUE PARA OBTENER EL TÍTULO DE:

MAESTRÍA EN CIENCIAS EN COMPUTACIÓN AVANZADA Y
ELECTRÓNICA

P R E S E N T A :

LIC. OMAR DE LA CRUZ VITE

ASESORES

DR. PEDRO AMADO MIRANDA ROMAGNOLI
DR. CARLOS ARTURO SOTO CAMPOS

COMITÉ TUTORIAL

DR. VIRGILIO LÓPEZ MORALES
DRA. ROSA MARÍA ORTEGA MENDOZA
DR. PEDRO AMADO MIRANDA ROMAGNOLI
DR. CARLOS ARTURO SOTO CAMPOS

MINERAL DE LA REFORMA, HIDALGO, FEBRERO DE 2026





Universidad Autónoma del Estado de Hidalgo

Instituto de Ciencias Básicas e Ingeniería

School of Engineering and Basic Sciences

Área Académica de Computación y Electrónica

Department of Electronics and Computer Science

Mineral de la Reforma, Hgo., 24 de febrero del 2026

Número de control: ICBI-AACyE/176/2026

Asunto: Autorización de impresión de tema de tesis.

MTRA. OJUKY DEL ROCÍO ISLAS MALDONADO DIRECTORA DE ADMINISTRACIÓN ESCOLAR DE LA UAEH

El Comité Tutorial de la TESIS del Programa Educativo de Posgrado titulado "Estudio de estrategias de mercados aplicadas al desempeño de criptomonedas", realizado por el sustentante Omar de la Cruz Vite, con número de cuenta 143642, perteneciente al programa de la Maestría en Ciencias en Computación Avanzada y Electrónica, una vez que se ha revisado, analizado y evaluado el documento recepcional de acuerdo a lo estipulado en el Artículo 110 del Reglamento de Estudios de Posgrado, tiene a bien extender la presente: **AUTORIZACIÓN DE IMPRESIÓN**

Por lo que el sustentante deberá cumplir con los requisitos del Reglamento de Estudios de Posgrado y con lo establecido en el proceso de grado vigente.



ÁREA ACADÉMICA DE
COMPUTACIÓN Y ELECTRÓNICA
Dr. Virgilio López Morales

Dra. Rosa María Ortega Mendoza

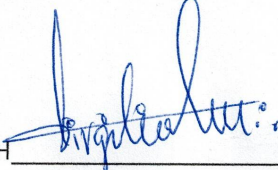
Dr. Pedro Amado Miranda Romagnoli

Dr. Carlos Arturo Soto Campos

Atentamente
"Amor. Orden y Progreso"


Dr. Pedro Amado Miranda Romagnoli
Director de Tesis

Comité Tutorial
Presidente

UAEH 

Secretaria

UAEH 

Vocal


UAEH 

Suplente

UAEH 

Ciudad del Conocimiento, Carretera Pachuca-Tulancingo Km. 4.5 Colonia Carboneras, Mineral de la Reforma, Hidalgo, México. C.P. 42184
Teléfono: 52 (771) 71 720 00 Ext. 40052, 40053
aacye_icbi@uaeh.edu.mx, jesus_ordaz@uaeh.edu.mx

"Amor, Orden y Progreso"



2025



uaeh.edu.mx

Agradecimientos

Agradezco al Posgrado en Computación Avanzada y Electrónica, así como al cuerpo académico que lo conforma, por su constante apoyo y por la transmisión de conocimientos que enriquecieron mi formación profesional y científica.

Reconozco y valoro el respaldo económico proporcionado por la Secretaría de Ciencia, Humanidades, Tecnología e Innovación (SECIHTI), a través del programa de Becas Nacionales para Estudios de Posgrado, el cual hizo posible la realización de esta investigación.

Expreso mi especial agradecimiento a los investigadores Dr. Virgilio López Morales y Dra. Rosa María Ortega Mendoza, quienes integraron el comité tutorial, por sus valiosas aportaciones académicas que contribuyeron significativamente al desarrollo de este trabajo. Asimismo, agradezco profundamente a mis asesores, Dr. Pedro Amado Miranda Romagnoli y Dr. Carlos Arturo Soto Campos, por su compromiso, orientación y apoyo incondicional a lo largo de este proyecto.

Índice general

Agradecimientos	III
Resumen	XII
1. Introducción	1
1.1. Estado del arte	1
1.2. Justificación	2
1.3. Hipótesis	3
1.4. Objetivos	3
1.4.1. Objetivo general	3
1.4.2. Objetivos particulares	3
1.5. Estructura de la Tesis	5
2. Marco teórico	6
2.1. Series de tiempo	6
2.1.1. Componentes de una serie de tiempo	6
2.2. Mercado financiero	8
2.3. Criptomonedas	8
2.3.1. Bitcoin	8
2.4. Medias móviles	9
2.4.1. Media móvil simple	9
2.4.2. Media móvil exponencial	10
2.4.3. Media móvil ponderada	12

2.5. Modelando series de tiempo	13
2.6. Proceso Autorregresivo	15
2.7. Proceso de Medias Móviles	16
2.8. Proceso Autorregresivo y de Promedios Moviles (ARMA)	17
2.9. Diferenciación de una serie de tiempo	18
2.10. Proceso Autorregresivo Integrado de Promedios Moviles (ARIMA)	18
2.10.1. Metodología Box - Jenkins	20
2.10.2. Criterio de Akaike	21
2.11. ARIMA Estacional (SARIMA)	21
2.12. ARCH	22
2.13. GARCH	22
2.14. Bandas de Bollinger	23
2.15. Retorno de la inversión	24
3. Propuesta	26
3.1. Parámetros	26
3.1.1. Algoritmo para usar ARIMA	28
3.1.2. Algoritmo para usar SARIMA	29
3.1.3. Algoritmo para usar GARCH	32
3.1.4. Algoritmo para usar Bandas de Bollinger	33
3.1.5. Algoritmo para usar ROI	33
3.2. Decisiones	34
3.3. Simulación	34
4. Estudio de estrategias	35
4.1. Series de tiempo	35
4.2. ARIMA	37
4.3. SARIMA	40
4.3.1. Corridas lineales vs. paralelo	45

5. Resultados	47
5.1. Análisis exploratorio de datos	47
5.2. Hardware y Software utilizados	48
5.3. Métodos utilizados y desarrollados	48
5.4. Simulaciones	49
5.4.1. Simulaciones utilizando métodos de manera individual	49
5.4.2. Variación en número de días para la compraventa	55
5.5. Simulaciones utilizando la combinación de métodos	57
6. Conclusiones	59
6.1. Trabajo futuro	60
7. Apéndice	65
7.1. Cada un día	65
7.2. Cada cinco días	67
7.3. Cada siete días	69
7.4. Cada 15 días	71
7.5. Cada 30 días	73

Índice de figuras

2.1. Componentes de una serie temporal. Tendencia(T), Ciclicidad (C), Estacionariedad (E), Aleatoriedad (A).	7
2.2. Gráfica de la Tabla 2.1.	10
2.3. Gráfica de la Tabla 2.2.	12
2.4. Gráfica de la Tabla 2.3..	13
2.5. Gráfica de la Tabla 2.4.	19
2.6. Bandas de Bollinger correspondientes a 2022.	24
2.7. Retorno de la inversión a 10 días correspondientes a 2024.	25
3.1. Función en python para buscar el mejor ARIMA.	29
3.2. Función en python para buscar el mejor SARIMA.	31
4.1. Serie de tiempo del Bitcoin de 2014 a 2024.	35
4.2. Series de tiempo del Bitcoin de 2016 a 2019, anualmente.	36
4.3. Series de tiempo del Bitcoin de 2020 a 2024, anualmente.	37
4.4. Usando los 12 meses de 2020.	38
4.5. Predicciones con ARIMA, usando los 12 meses de 2022.	38
4.6. Predicciones de 10 días utilizando ARIMA. Iniciando el 01-01-2020 y terminando el 31-12-2020.	39
4.7. Descomposición aditiva de la serie de tiempo.	41
4.8. Descomposición multiplicativa de la serie de tiempo.	41
4.9. Descomposición STL de la serie de tiempo.	42
4.10. Predicciones con SARIMA, usando los 12 meses de 2022.	43

4.11. Predicciones de 10 días con SARIMA, utilizando una estacionalidad 7 días durante el año 2020.	44
4.12. RMSE del pronóstico de 10 días usando SARIMA.	45
4.13. Corrida lineal utilizando datos del año 2022.	45
4.14. Corrida en paralelo utilizando datos del año 2022.	46

Índice de tablas

2.1. Ejemplo de SMA.	10
2.2. Ejemplo de EMA.	11
2.3. Ejemplo WMA.	13
2.4. Ejemplo de una serie que requiere tres diferenciaciones para ser estacionaria.	18
4.1. Revisión de predicciones de la figura 4.6.	40
4.2. Revisión de predicciones de la figura anterior.	44
5.1. Total de datos y tipo de variables	47
5.2. Estadísticas de la serie de tiempo del Bitcoin.	48
5.3. Método: ARIMA, umbral de compra: 50, capital inicial: 10,000 dólares.	49
5.4. Ganancias promedio del método ARIMA, para tres periodos.	50
5.5. Método: Bollinger, umbral de compra: 50, capital inicial: 10,000 dólares.	50
5.6. Ganancias promedio del método Bandas de Bollinger, para tres periodos.	51
5.7. Método: GARCH, umbral de compra: 50, capital inicial: 10,000 dólares.	51
5.8. Ganancias promedio del método GARCH, para tres periodos.	52
5.9. Método: ROI, umbral de compra: 50, capital inicial: 10,000 dólares.	52
5.10. Ganancias promedio del método ROI, para tres periodos.	53
5.11. Método: SARIMA, umbral de compra: 50, capital inicial: 10,000 dólares.	53
5.12. Ganancias promedio del método SARIMA, para tres periodos.	54
5.13. Métodos con mejor rendimiento por año.	55

5.14. Comparación de estadísticas por método y periodo.	55
5.15. Resultados comparativos por método. Compraventa: 30 días.	56
5.16. Resultados comparativos por método. Compraventa: 15 días.	56
5.17. Resultados comparativos por método. Compraventa: 10 días.	56
5.18. Resultados comparativos por método. Compraventa: 7 días.	56
5.19. Resultados comparativos por método. Compraventa: 1 día.	56
5.20. Método: BGR, umbral de compra: 50, capital inicial: 10,000 dólares. .	57
5.21. Ganancias promedio del método BGR, para tres periodos.	58
7.1. Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD. . .	65
7.2. Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD. . .	66
7.3. Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD. . .	66
7.4. Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.	66
7.5. Comparación de estadísticas por periodo y método (Umbral de compra: 50)	67
7.6. Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD. . .	67
7.7. Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD. . .	68
7.8. Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD. . .	68
7.9. Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.	68
7.10. Comparación de estadísticas por periodo y método (Umbral de compra: 50)	69
7.11. Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD. . .	69
7.12. Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD. . .	70
7.13. Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD. . .	70
7.14. Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.	70
7.15. Comparación de estadísticas por periodo y método (Umbral de compra: 50)	71
7.16. Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD. . .	71
7.17. Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD. . .	72
7.18. Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD. . .	72

7.19. Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.	72
7.20. Comparación de estadísticas por periodo y método (Umbral de compra: 50, fechas hasta 2024-12-11)	73
7.21. Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD. . .	73
7.22. Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD. . .	74
7.23. Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD. . .	74
7.24. Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.	74
7.25. Resumen de rendimiento, compras y ventas promedio (Umbral de compra: 50, fechas hasta 2024-11-26)	75

Resumen

En el presente trabajo se realiza el análisis del rendimiento de la criptomoneda descentralizada Bitcoin usando las bases de datos con los precios históricos actualizados por día, las cuales fueron consultadas en cryptodatadownload.com.

Empezaremos por definir lo que es una media móvil y calculamos tres de ellas: Simple Moving Average (SMA), Exponential Moving Average (EMA) y Weighted Moving Average (WMA). Después se realiza un estudio de los procesos autorregresivos integrados (ARIMA), como posible método para realizar pronósticos de las series de tiempo del Bitcóin. El cual se complementará con un estudio de ARIMA estacional (SARIMA). Para finalizar se realiza un estudio usando un modelo autorregresivo generalizado condicional heterocedástico (GARCH), además de un análisis de rendimiento (ROI) y de las Bandas de Bollinger para analizar el mercado de compraventa.

Usamos los métodos anteriormente descritos para obtener diferentes predicciones en los precios del Bitcoin y el comportamiento del mercado, con los cuales se realiza una simulación de compraventa. Las simulaciones se realizan de manera individual para cada método, además, se realizan simulaciones en donde se conjuntan varios métodos con diferentes criterios de decisión. Se realizan predicciones anuales en el periodo comprendido entre el 01/01/2016 y el 31/12/2024 con diferentes intervalos de predicción. También se realizan predicciones ininterrumpidas entre las mismas fechas. Con los datos recabados se generaron estadísticas que facilitan la comparación entre los distintos hiperparámetros.

Capítulo 1

Introducción

En nuestra vida diaria ocurren tantos fenómenos de manera simultánea que pareciera ser que estos son completamente aleatorios; pero esta afirmación no es del todo cierta. Si contamos con la experiencia y los datos adecuados, podemos predecir cuál será el resultado de algunos de estos fenómenos. Por ejemplo: podemos aproximar de manera bastante certera el tiempo que pasaremos en el tráfico hacia el trabajo, el precio de los productos en el supermercado dependiendo de la temporada del año o incluso el resultado de un partido de fútbol.

1.1. Estado del arte

En años recientes las criptomonedas han alcanzado gran popularidad como forma de pago, las cuales han sido apuntaladas por la tecnología conocida como “cadena de bloques”[1], que utiliza algoritmos criptográficos como forma de seguridad [2]. Pero las criptomonedas también han sido vistas como una posibilidad de inversión, por lo que se han estudiado como un mercado [3, 4, 5], aplicando diferentes formas de predecir su comportamiento, tal como técnicas auto-regresivas [6, 7] o de bandas [8]. Incluso se ha investigado el papel de los “influencers” en el comportamiento de algunas criptomonedas como el Bitcoin [9]. Por otro lado, el estudio presentado en [10] sugiere un comportamiento gregario de las criptomonedas, es decir, como una tendencia de individuos a actuar en grupo, imitando las acciones de otros sin una

dirección centralizada.

En Shahab-Sepahri et al. 2025 [11], se presenta CryptoMamba, una arquitectura basada en Mamba, diseñada específicamente para la predicción de series de tiempo financieras y que se aplica para modelar el precio del Bitcoin. Se hace uso de las propiedades de los modelos de espacios de estados (SSM) mejorados con Mamba. Se usan algoritmos para simular la compraventa de Bitcoin y de esta manera poder medir el rendimiento financiero. Otra investigación es la de Vital-Godinez et al. 2023 [12], donde se realiza un análisis ARIMA de las series de tiempo correspondientes al rendimiento del Bitcoin, utilizando el lenguaje R como software para realizar los cálculos. En este artículo realizan un análisis de bondad de ajuste para determinar cuál es el modelo que reproduce mejor los datos.

Por otro lado, en Pronchakov et al. 2019 [13], se realiza un análisis de tres métodos de media móvil que son usados como indicadores de tendencia: Simple Moving Average, Exponential Moving Average y Weighted Moving Average. En este artículo utilizan la desviación cuadrática media como indicador de rendimiento de los diferentes métodos de media móvil.

Finalmente, en Long et al. 2022 [14], se realiza una comparación entre algoritmos de programación genética y algoritmos de aprendizaje máquina. En este artículo reportan una comparativa de rendimiento utilizando la rentabilidad, la tasa de retorno y riesgo. Usando estos indicadores se concluye que los algoritmos de programación genética tienen un mejor desempeño que los algoritmos de aprendizaje máquina.

1.2. Justificación

En la actualidad existe un gran interés mundial por el uso de criptomonedas, debido a que permiten hacer transacciones internacionales de bajo costo y de manera casi anónima. Adicionalmente, algunas criptomonedas como el Bitcoin, plantean la no inflación desde su implementación, lo que las hace extremadamente atractivas. Sin embargo, todas las criptomonedas son volátiles, unas más que otras, lo que dificulta su uso para la compraventa de productos de manera cotidiana. Es por esto que

contar con una técnica que pueda predecir el comportamiento en el corto plazo de algunas de las criptomonedas sería de gran utilidad para poder saber cuando hacer compras y ventas, no solo de las monedas en sí, sino de los productos que se ofrecen en el mercado.

1.3. Hipótesis

Es posible predecir el comportamiento del mercado de la criptomoneda Bitcoin, mediante técnicas utilizadas en los mercados financieros. Además, es posible diseñar una estrategia de compraventa ganadora utilizando la información proveniente de las técnicas de mercados financieros, como son: la tendencia, media móvil, retorno de la inversión, etcétera.

1.4. Objetivos

1.4.1. Objetivo general

Estudiar el comportamiento de la criptomoneda descentralizada Bitcoin, utilizando los modelos de autorregresión ARIMA y SARIMA. También se utilizará un modelo GARCH para la predicción de su volatilidad futura en el corto plazo. Además se usarán indicadores como las Bandas de Bollinger y el Retorno de la Inversión.

1.4.2. Objetivos particulares

- Se implementará un programa en **Python 3** para el cálculo de **medias móviles** aplicadas a bases de datos de **criptomonedas**, con el fin de analizar y suavizar la volatilidad de sus precios e identificar tendencias del mercado, utilizando las librerías **Pandas (v2.1.4)**, **NumPy (v1.25.2)** y **Matplotlib (v3.7.2)**.
- Se implementará el modelo **ARIMA** para el análisis y la predicción de series temporales de **criptomonedas**, con el objetivo de modelar su comportamiento

histórico y reproducir resultados estadísticos, utilizando las librerías **Pandas** (v2.1.4) y **Statsmodels** (v0.14.1) para el procesamiento y modelado de los datos.

- Se implementará el modelo **SARIMA** para el análisis y la predicción de series temporales de **criptomonedas**, con el objetivo de modelar patrones estacionales y el comportamiento histórico de los precios, utilizando las librerías **Pandas** (v2.1.4) y **Statsmodels** (v0.14.1), e incorporando **Joblib** (v1.3.2) para la ejecución de cálculos en paralelo y la optimización del tiempo de procesamiento.
- Se implementará el modelo **GARCH** para el análisis de series temporales de **criptomonedas**, con la finalidad de anticipar y modelar la volatilidad de sus precios, utilizando la librería **ARCH** (v6.3.0) para la estimación y análisis del comportamiento heterocedástico de los datos.
- Se implementarán los indicadores financieros de **Retorno de la Inversión (ROI)** y **Bandas de Bollinger**, y se aplicarán al análisis de series de tiempo de **criptomonedas** con el fin de evaluar su desempeño y comportamiento de precios, utilizando la librería **Pandas** (v2.1.4) para el procesamiento y cálculo de los indicadores.
- Se implementará un programa de simulación de **compraventa de criptomonedas**, con la finalidad de evaluar y buscar una **estrategia de inversión ganadora**, integrando los modelos y herramientas desarrollados previamente, incluyendo medias móviles, modelos **ARIMA**, **SARIMA**, **GARCH** e indicadores financieros, para el análisis, predicción y toma de decisiones dentro de la simulación.

1.5. Estructura de la Tesis

Este trabajo está estructurado de la siguiente manera: en el Capítulo 1 se revisan los aspectos generales del proyecto. En el Capítulo 2 se hace una revisión del marco teórico de los temas que se ocupan en esta investigación. En el Capítulo 3 se explica una propuesta para resolver el problema de compraventa de criptomonedas. En el Capítulo 4 se explica a detalle el desarrollo de la propuesta y su evolución durante la construcción de la simulación de compraventa. En el Capítulo 5 se muestran los resultados obtenidos al realizar la simulación utilizando diferentes parámetros y los comparamos entre sí. En el Capítulo 6 se discuten las conclusiones a las que se llega después de analizar los resultados y se comentan también posibles trabajos a futuro. Para finalizar, en el Apéndice se pueden encontrar tablas complementarias que permiten dimensionar la cantidad de hiperparámetros utilizados en el presente trabajo.

Capítulo 2

Marco teórico

2.1. Series de tiempo

En estadística, las series de tiempo son secuencias de datos observados en ciertos intervalos de tiempo y ordenados cronológicamente. Regularmente las series de tiempo se acompañan de una representación gráfica para analizar su evolución temporal.

Las series de tiempo son analizadas para entender el comportamiento pasado y predecir si se presentan tendencias que permitan establecer probabilidades de ocurrencia de eventos futuros, permitiendo al investigador tomar decisiones informadas. El análisis de una serie de tiempo cuantifica las principales características en datos y variaciones aleatorias. Estas razones, combinadas con el avance en la capacidad de cómputo, han logrado que los métodos basados en series de tiempo sean ampliamente aplicables en el gobierno, la industria y el comercio [15] .

2.1.1. Componentes de una serie de tiempo

Tras el estudio en las observaciones de las series temporales podemos determinar que el comportamiento de sus variables puede ser esencialmente de cuatro maneras:

1. Componente tendencia: Se refiere a que los datos demuestran un cambio a largo plazo en la misma dirección, con respecto a la media de los datos.




Figura 2.1: Componentes de una serie temporal. Tendencia(T), Ciclicidad (C), Estacionalidad (E), Aleatoriedad (A).

2. Componente estacional: Muchas de las series temporales demuestran periodicidad, es decir, repiten el comportamiento de sus componentes cada cierto tiempo, puede ser semanal, mensual o en algún intervalo distinto.
3. Componente cíclica: Son fluctuaciones que ocurren en periodos largos e irregulares, no tienen una duración fija como la estacionalidad.
4. Componente aleatoria: Las componentes aleatorias no obedecen ningún patrón de comportamiento, por lo que los datos se encuentran dentro de un intervalo respecto a un valor central.

En la Figura 2.1 se pueden ver gráficamente las componentes de una serie de tiempo anteriormente descritas. Una de las características más importantes para el estudio de series de tiempo es la estacionalidad. Se dice que un proceso es estacionario si la distribución conjunta de las variables $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ es la misma que la distribución de $Y_{t_1-k}, Y_{t_2-k}, \dots, Y_{t_n-k}$ para todas los valores de puntos temporales t_1, t_2, \dots, t_n y todos los valores del parámetro de retraso k [16].

2.2. Mercado financiero

Antes de empezar a estudiar las criptomonedas es conveniente mencionar la estructura de los mercados financieros. Esto se debe a que la estructura de los mercados financieros es similar al comportamiento de las criptomonedas.

Un mercado financiero es un ente que reúne a inversores, compradores e intermediarios financieros; los cuales compran, venden o intercambian activos financieros. La interacción entre la oferta y la demanda en estos mercados es lo que determina el precio de los activos. Los mercados financieros tradicionales son más estables, regulados y predecibles que las criptomonedas, pero en cambio son menos accesibles para el público general. Por otro lado, el mercado de las criptomonedas ofrece mayor libertad, transparencia y acceso, aunque esto hace que se presente un mayor riesgo y volatilidad [17].

2.3. Criptomonedas

Una criptomoneda es una forma de dinero digital que se basa en principios criptográficos para asegurar las transacciones, controlar la creación de nuevas unidades y verificar la transferencia de activos, sin necesidad de una autoridad central [18].

2.3.1. Bitcoin

El término *Bitcoin* fue introducido por primera vez en el año 2008 por un autor bajo el seudónimo de *Satoshi Nakamoto*. Dicho seudónimo hace referencia a una entidad cuya identidad real aún se desconoce, y que podría corresponder tanto a una persona individual como a un grupo de desarrolladores [19]. Bitcoin se plantea como una forma de dinero electrónico que opera sin intermediarios, y presenta cuatro características técnicas destacadas:

- **Alta privacidad:** Las transacciones pueden realizarse de forma seudónima, sin revelar directamente la identidad de los usuarios.

- **Descentralización:** La red funciona sin una autoridad central, sustentándose en una arquitectura de tipo *peer-to-peer* (P2P).
- **Resistencia a la inflación:** Su emisión está limitada a 21 millones de unidades, lo que impide una expansión monetaria arbitraria. Esto se garantiza mediante un método llamado Halving, el cual reduce a la mitad los Bitcoin que reciben los mineros como recompensa por la creación de un bloque, esto sucede cuando se han minado un determinado número de bloques. Ya se han realizado cuatro halvings: el primero fue el 28 de noviembre de 2012, el segundo el 9 de julio de 2016, el tercero el 11 de mayo de 2020 y el cuarto el 20 de abril de 2024.
- **Inalterabilidad:** Gracias a su base criptográfica y al uso de la tecnología de cadena de bloques, es prácticamente imposible falsificar o modificar las transacciones registradas.

2.4. Medias móviles

2.4.1. Media móvil simple

Las medias o promedios son útiles en el análisis de series de tiempo puesto que suavizan las fluctuaciones a corto plazo y ayuda a identificar tendencias [20].

La Media Móvil Simple o *Simple Moving Average* (SMA) [13], es un indicador técnico que calcula el promedio aritmético de los precios de un activo durante un número determinado de periodos, esto es:

$$SMA_t = \frac{P_t + P_{t-1} + P_{t-2} + \dots + P_{t-n+1}}{n} = \frac{\sum_{i=1}^n P_{t-i+1}}{n} \quad (2.1)$$

donde SMA_t es la Media Móvil Simple en el tiempo t , P_t es el precio en el tiempo t y n es el número de períodos considerados. Veamos ahora un ejemplo con un precio de cierre por día, estos datos son hipotéticos y se utilizan únicamente con fines ilustrativos, para después calcular la SMA para 2, 3 y 5 días reportado en la Tabla

2.1. Finalmente, se muestra una gráfica donde podemos observar sus diferencias, ver Figura 2.2.

Día	Precio cierre	SMA 2 días	SMA 3 días	SMA 5 días
1	10	—	—	—
2	12	11.0	—	—
3	11	11.5	11.0	—
4	13	12.0	12.0	—
5	15	14.0	13.0	12.2
6	14	14.5	14.0	13.6
7	13	13.5	14.0	14.0
8	12	12.5	13.0	13.4
9	14	13.0	13.0	13.6
10	10	12.0	12.0	12.6
11	11	10.5	11.7	12.4
12	13	12.0	11.3	12.0
13	16	14.5	13.3	12.8
14	13	14.5	14.0	13.6
15	16	14.5	15.0	14.6

Tabla 2.1: Ejemplo de SMA.




Figura 2.2: Gráfica de la Tabla 2.1.

2.4.2. Media móvil exponencial

La Media Móvil Exponencial o *Exponential Moving Average* (EMA) [13], es un indicador técnico que asigna un mayor peso a los precios más recientes para reflejar mejor las tendencias actuales del mercado. Se calcula mediante la siguiente fórmula recursiva:

$$EMA_t = \alpha \cdot P_t + (1 - \alpha) \cdot EMA_{t-1} \quad (2.2)$$

donde EMA_t es el valor de la EMA en el tiempo t , P_t es el precio en el tiempo t , $\alpha = \frac{2}{n+1}$ es el factor de suavizado, con n siendo el número de períodos, y EMA_{t-1} es el valor de la EMA en el tiempo $t-1$. Ahora revisemos un ejemplo en el cual tenemos un precio de cierre por día, estos datos son hipotéticos y se utilizan únicamente con fines ilustrativos, y calculamos la EMA para 2, 3 y 5 días, estos datos se reportan en la Tabla 2.2. Después hacemos una gráfica donde podemos observar sus diferencias, ver Figura 2.3.

Día	Precio	EMA 2 días	EMA 3 días	EMA 5 días
1	10	10.00	10.00	10.00
2	12	11.33	11.00	10.67
3	11	11.11	11.00	10.78
4	13	12.37	11.67	11.19
5	15	13.79	12.78	12.13
6	14	13.92	13.39	12.75
7	13	13.31	13.13	12.90
8	12	12.44	12.56	12.79
9	14	13.48	13.04	13.12
10	10	11.49	11.69	12.41
11	11	11.17	11.34	12.07
12	13	12.72	12.22	12.38
13	16	14.91	14.08	13.27
14	13	13.64	13.54	13.27
15	16	15.55	14.52	13.95

Tabla 2.2: Ejemplo de EMA.




Figura 2.3: Gráfica de la Tabla 2.2.

2.4.3. Media móvil ponderada

La Media Móvil Ponderada o *Weighted Moving Average* (WMA) [13], es un indicador técnico que asigna diferentes pesos a los precios dentro de un período determinado, generalmente dando mayor importancia a los precios más recientes. La fórmula para calcular la WMA es:

$$WMA_t = \frac{\sum_{i=0}^{n-1} w_i \cdot P_{t-i}}{\sum_{i=0}^{n-1} w_i} \quad (2.3)$$

donde WMA_t es la Media Móvil Ponderada en el tiempo t , P_{t-i} es el precio en el tiempo $t - i$, w_i es el peso asignado al precio P_{t-i} , y n es el número de períodos considerados. Normalmente, los pesos se asignan de forma lineal decreciente, por ejemplo: $w_0 = n$, $w_1 = n - 1$, ..., $w_{n-1} = 1$. Revisemos un ejemplo en el cual tenemos un precio de cierre por día, estos datos son hipotéticos y se utilizan únicamente con fines ilustrativos, y calculamos la WMA para 2, 3 y 5 días como se reporta en la Tabla 2.3, después hacemos una gráfica donde podemos observar sus diferencias, ver Figura 2.4.

Día	Precio	WMA 2 días	WMA 3 días	WMA 5 días
1	10	—	—	—
2	12	11.33	—	—
3	11	11.67	11.33	—
4	13	12.33	11.67	—
5	15	14.33	13.00	12.13
6	14	13.67	14.00	13.00
7	13	13.33	13.33	13.40
8	12	12.33	12.33	13.00
9	14	13.33	12.67	13.27
10	10	11.33	11.33	12.13
11	11	10.67	10.33	11.93
12	13	12.33	11.33	12.33
13	16	15.00	14.00	13.07
14	13	13.33	13.33	13.07
15	16	15.67	15.00	13.93

Tabla 2.3: Ejemplo WMA.




Figura 2.4: Gráfica de la Tabla 2.3..

2.5. Modelando series de tiempo

Las siguientes definiciones se puede encontrar en el libro de Gujarati et al. 2009 [21].

Definición 2.5.1 (Serie de tiempo). Una serie de tiempo es un conjunto de observaciones que una variable toma en diferentes momentos del tiempo. Estas observaciones deben ser registradas siguiendo el mismo intervalo de tiempo, puede ser por ejemplo: cada minuto, cada hora, cada día, cada semana o cada mes, etc.

Definición 2.5.2 (Procesos Estocásticos). Un proceso estocástico es una colección de variables aleatorias ordenadas en el tiempo.

Definición 2.5.3 (Procesos Estocásticos Estacionarios). Se dice que un proceso estocástico es estacionario si su media y su varianza son constantes en el tiempo y si el valor de la covarianza entre dos periodos depende sólo de la distancia o rezago entre estos dos periodos, y no del tiempo en el cual se calculó la covarianza.

En la bibliografía sobre series de tiempo, un proceso estocástico como éste se conoce como *proceso estocástico débilmente estacionario*, *estacionario covariante*, *estacionario de segundo orden* o *proceso estocástico en amplio sentido*. Para efectos de esta investigación y en la mayoría de las situaciones prácticas, basta este tipo de estacionariedad.

Para explicar la estacionariedad débil, sea Y_t una serie de tiempo estocástica con estas propiedades:

- Media: $E(Y_t) = \mu$
- Varianza: $\text{var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$
- Covarianza: $\gamma_k = E[(Y_t - \mu)(Y_{t+k} - \mu)]$

donde γ_k , en el rezago k , es la covarianza entre los valores de Y_t y Y_{t+k} , es decir, entre dos valores Y separados k periodos. Si $k = 0$, obtenemos γ_0 , que es simplemente la varianza de Y (es decir, σ^2); si $k = 1$, γ_1 es la covarianza entre dos valores adyacentes de Y .

En resumen, si una serie de tiempo es estacionaria, su media, su varianza y su autocovarianza (en los diferentes rezagos) permanecen iguales sin importar el momento en el cual se midan; es decir, son invariantes respecto del tiempo.

Tal serie de tiempo tenderá a regresar a su media (llamada *reversión media*) y las fluctuaciones alrededor de esta media (medida por su varianza) tendrán una amplitud constante en términos generales. Para decirlo de otro modo, un proceso estacionario no se desvía demasiado de su valor medio debido a la varianza finita.

Como veremos enseguida, esto no ocurre con los procesos estocásticos no estacionarios.

Debemos señalar que, en un proceso estacionario, la velocidad de la reversión media depende de las autocovarianzas: es rápida si las autocovarianzas son pequeñas y lenta cuando son grandes.

Definición 2.5.4 (Serie de Tiempo No Estacionaria.). Una serie de tiempo no estacionaria tendrá una media que varía con el tiempo o una varianza que cambia con el tiempo, o ambas.

¿Por qué las series de tiempo estacionarias son tan importantes? Porque si una serie de tiempo es no estacionaria, sólo podemos estudiar su comportamiento durante el periodo en consideración. Por tanto, cada conjunto de datos perteneciente a la serie de tiempo corresponderá a un episodio particular. En consecuencia, no es posible generalizar para otros periodos. Así, para propósitos de pronóstico, tales series de tiempo (no estacionarias) tienen poco valor práctico.

2.6. Proceso Autorregresivo

Sea Y_t el logaritmo de la variable que estamos analizando en el periodo t . Si se modela Y_t como:

$$Y_t - \delta = \alpha_1(Y_{t-1} - \delta) + u_t \quad (2.4)$$

donde δ es la media de Y y u_t es un término de error aleatorio no correlacionado, con media cero y varianza constante σ^2 (es decir, ruido blanco), se dice que Y_t sigue un proceso estocástico autorregresivo de primer orden, o **AR(1)**.

Este modelo establece que el valor de Y en el tiempo t depende de su valor en el periodo anterior y de un término aleatorio; los valores de Y están expresados como desviaciones respecto de su media. En otras palabras, este modelo afirma que el valor pronosticado de Y en el periodo t es simplemente alguna proporción (α_1)

de su valor en el periodo $(t - 1)$, más una perturbación aleatoria en el tiempo t . Nuevamente, los valores de Y están expresados alrededor de su media.

Sin embargo, si consideramos el siguiente modelo:

$$Y_t - \delta = \alpha_1(Y_{t-1} - \delta) + \alpha_3(Y_{t-2} - \delta) + u_t, \quad (2.5)$$

entonces el proceso incluye también una dependencia del valor de Y en el tiempo $t - 2$, y por tanto ya no es un $\text{AR}(1)$, sino un proceso autorregresivo de segundo orden, o $\text{AR}(2)$. Es decir, el valor de Y en el tiempo t depende de sus valores en los dos periodos anteriores, con los valores de Y expresados alrededor del valor de su media δ .

En general, tenemos:

$$Y_t - \delta = \alpha_1(Y_{t-1} - \delta) + \alpha_2(Y_{t-2} - \delta) + \dots + \alpha_p(Y_{t-p} - \delta) + u_t \quad (2.6)$$

en cuyo caso Y_t es un proceso autorregresivo de orden p , o $\text{AR}(p)$.

Observe que en todos los modelos anteriores sólo se consideran los valores actuales y pasados de Y ; no hay otros regresores.

2.7. Proceso de Medias Móviles

El proceso autorregresivo (AR) recién expuesto no es el único mecanismo que pudo haber generado a Y . Suponga que modelamos Y de la siguiente manera:

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} \quad (2.7)$$

donde μ es una constante y u_t , al igual que antes, es un término de error estocástico de *ruido blanco*. En este modelo, Y en el periodo t es igual a una constante más un *promedio móvil* de los términos de error presentes y pasados. Por lo tanto, en este caso decimos que Y sigue un proceso de **promedios móviles de primer orden**, o $\text{MA}(1)$.

Si en cambio Y sigue la expresión:

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} \quad (2.8)$$

entonces se dice que Y es un proceso **MA(2)**. De forma más general, si

$$Y_t = \mu + \beta_0 u_t + \beta_1 u_{t-1} + \beta_2 u_{t-2} + \cdots + \beta_q u_{t-q}, \quad (2.9)$$

entonces Y_t es un proceso de **promedios móviles de orden q** , o **MA(q)**.

En resumen, un proceso de promedios móviles no es más que una combinación lineal de términos de error de ruido blanco.

2.8. Proceso Autorregresivo y de Promedios Móviles (ARMA)

Desde luego, es muy probable que Y tenga características tanto de un proceso autorregresivo (AR) como de un proceso de promedios móviles (MA), y, por consiguiente, que siga un proceso **ARMA**.

Así, Y_t sigue un proceso **ARMA(1,1)** si se expresa como:

$$Y_t = \theta + \alpha_1 Y_{t-1} + \beta_0 u_t + \beta_1 u_{t-1} \quad (2.10)$$

porque contiene tanto un término autorregresivo como uno de promedios móviles. En la ecuación (2.10), θ representa un término constante.

En general, en un proceso **ARMA(p, q)**, habrá p términos autorregresivos y q términos de promedios móviles:

$$Y_t = \theta + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{j=0}^q \beta_j u_{t-j} \quad (2.11)$$

2.9. Diferenciación de una serie de tiempo

Una serie temporal $\{Y_t\}$ se dice *diferenciada una vez* cuando se considera la nueva serie definida por

$$\nabla Y_t = Y_t - Y_{t-1},$$

la cual elimina una posible tendencia lineal en la serie original. Si la serie diferenciada no es todavía estacionaria, puede aplicarse nuevamente la operación de diferencia, obteniendo diferencias de segundo o mayor orden hasta lograr la estacionariedad [22]. En la Tabla 2.4 podemos ver un ejemplo de esta propiedad de una serie de tiempo así como en la Figura 2.5 se presenta su gráfico asociado.

t	Y_t	1ª Diferencia	2ª Diferencia	3ª Diferencia
1	0.5	–	–	–
2	4.0	3.5	–	–
3	13.5	9.5	6.0	–
4	32.0	18.5	9.0	3.0
5	62.5	30.5	12.0	3.0
6	108.0	45.5	15.0	3.0
7	170.5	62.5	17.0	2.0
8	252.0	81.5	19.0	2.0
9	354.5	102.5	21.0	2.0
10	480.0	125.5	23.0	2.0
11	630.5	150.5	25.0	2.0
12	808.0	177.5	27.0	2.0
13	1014.5	206.5	29.0	2.0

Tabla 2.4: Ejemplo de una serie que requiere tres diferenciaciones para ser estacionaria.

2.10. Proceso Autorregresivo Integrado de Promedios Mviles (ARIMA)

Los modelos de series de tiempo analizados se basan en el supuesto de que las series consideradas son (*débilmente*) estacionarias.

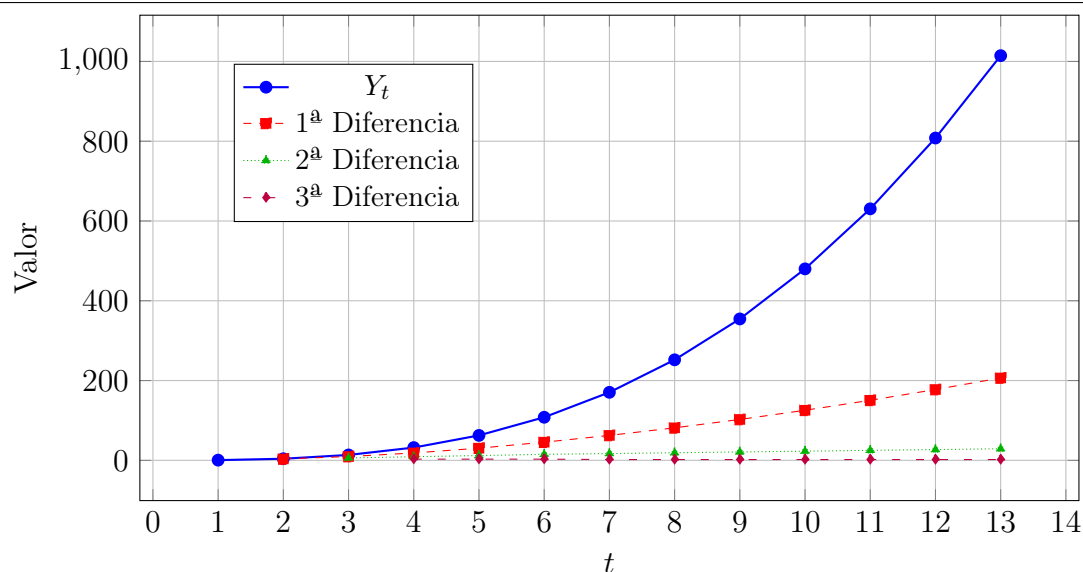


Figura 2.5: Gráfica de la Tabla 2.4.

En pocas palabras, la **media** y la **varianza** de una serie de tiempo débilmente estacionaria son constantes, y su **covarianza** es invariante en el tiempo.

Sin embargo, sabemos que muchas series de tiempo económicas son **no estacionarias**; es decir, son *integradas*. Si una serie de tiempo es integrada de orden 1 —es decir, si es $I(1)$ — entonces sus primeras diferencias son $I(0)$, es decir, estacionarias. De forma similar, si una serie de tiempo es $I(2)$, sus **segundas diferencias** son $I(0)$. En general, si una serie de tiempo es $I(d)$, entonces después de diferenciarla d veces se obtiene una serie $I(0)$.

Por consiguiente, si debemos diferenciar una serie de tiempo d veces para hacerla estacionaria y luego aplicarle el modelo $ARMA(p, q)$, decimos que la serie de tiempo original es $ARIMA(p, d, q)$, es decir, es una serie de tiempo **autorregresiva integrada de promedios móviles**, donde:

- p denota el número de términos autorregresivos (AR),
- d el número de veces que la serie debe diferenciarse para hacerse estacionaria,
- q el número de términos de promedios móviles (MA).

Así, una serie de tiempo $ARIMA(2, 1, 2)$ tiene que diferenciarse una vez ($d = 1$) antes de que se haga estacionaria, y la serie de tiempo estacionaria (en primeras dife-

rencias) puede modelarse como un proceso ARMA(2, 2), es decir, tiene dos términos AR y dos términos MA. Desde luego, si $d = 0$ (es decir, si la serie es estacionaria desde el inicio), entonces ARIMA($p, d = 0, q$) es simplemente un ARMA(p, q). Observe que:

- Un proceso ARIMA($p, 0, 0$) significa un proceso estacionario AR(p) puro.
- Un proceso ARIMA($0, 0, q$) significa un proceso estacionario MA(q) puro.

Con los valores de p , d y q , sabemos qué tipo de proceso está siendo modelado.

2.10.1. Metodología Box - Jenkins

La construcción de un modelo ARIMA adecuado sigue un enfoque sistemático propuesto por Box y Jenkins [23], que consta de cuatro etapas principales:

1. **Identificación.** Esta etapa consiste en encontrar los valores apropiados de p , d y q . Más adelante veremos cómo el *correlograma* y el *correlograma parcial* ayudan en esta labor.
2. **Estimación.** Una vez identificados los valores apropiados de p y q , la siguiente etapa es estimar los parámetros correspondientes a los términos autorregresivos y de promedios móviles incluidos en el modelo. En algunos casos, este cálculo se realiza mediante *mínimos cuadrados ordinarios*, pero en otros se requieren métodos de *estimación no lineal en los parámetros*.
3. **Examen de diagnóstico.** Después de seleccionar un modelo ARIMA particular y de estimar sus parámetros, se debe verificar si dicho modelo se ajusta razonablemente bien a los datos. Esto es importante porque podría existir otro modelo ARIMA que también brinde un buen ajuste.

Por ello, el diseño de modelos ARIMA bajo la metodología de Box-Jenkins es considerado más un *arte* que una *ciencia*; se requiere experiencia y criterio para seleccionar el modelo adecuado. En consecuencia, la metodología Box-Jenkins es un **proceso iterativo**.

4. **Pronóstico.** Una de las razones principales de la popularidad del proceso de construcción de modelos ARIMA es su éxito en el *pronóstico*. En muchos casos, los pronósticos generados mediante esta metodología resultan ser más confiables que los obtenidos a partir de modelos econométricos tradicionales. Por supuesto, la calidad del pronóstico depende del contexto, y cada caso debe verificarse individualmente.

2.10.2. Criterio de Akaike

El criterio de información de Akaike se define como:

$$\text{AIC} = e^{\frac{2k}{n}} \frac{\sum \hat{u}_i^2}{n} = e^{\frac{2k}{n}} \frac{\text{SCR}}{n} \quad (2.12)$$

donde k es el número de regresores y n es el número de observaciones. Además $\frac{2k}{n}$ es el factor de penalización.

Como puede observarse en esta fórmula, el AIC impone una penalización por añadir más regresores. Al comparar dos o más modelos, se prefiere aquel con el valor más bajo de AIC. En la práctica, el AIC nos dice qué modelo logra el mejor equilibrio entre precisión y simplicidad. Cuanto más bajo sea el AIC, mejor es el modelo para predecir y generalizar.

2.11. ARIMA Estacional (SARIMA)

Un modelo ARIMA estacional o *Seasonal* ARIMA (SARIMA) utiliza diferenciación con un rezago igual al número de estaciones (s) para eliminar efectos estacionales aditivos. Al igual que la diferenciación con rezago 1 para eliminar una tendencia, la diferenciación con rezago s introduce un término de promedio móvil.

El modelo ARIMA estacional incluye términos autorregresivos y de promedios móviles en el rezago s . El modelo **ARIMA**(p, d, q)(P, D, Q) $_s$ puede expresarse de forma concisa utilizando el operador de rezago hacia atrás:

$$\Theta_P(B^s) \theta_p(B) (1 - B^s)^D (1 - B)^d x_t = \Phi_Q(B^s) \phi_q(B) w_t \quad (2.13)$$

donde Θ_P , θ_p , Φ_Q y ϕ_q son polinomios de orden P , p , Q y q , respectivamente.

En general, el modelo es **no estacionario**, aunque si $D = d = 0$ y las raíces de la ecuación característica (es decir, de los polinomios en el lado izquierdo de la ecuación (2.13)) son todas mayores que uno en valor absoluto, el modelo resultante será **estacionario** [15].

2.12. ARCH

El Modelo de Heteroscedasticidad Condicional Autorregresivo o *Autoregressive Conditional Heteroscedasticity* (ARCH), propuesto por Engle 1982 [24], permite que la varianza condicional del error en una serie temporal dependa de los errores pasados. Es útil para modelar fenómenos con *volatilidad condicional*, como las series financieras. El modelo ARCH(q) se define como:

$$\begin{aligned} \varepsilon_t &= \sigma_t \cdot z_t, \quad z_t \sim \text{i.i.d.}^1 N(0, 1) \\ \sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \cdots + \alpha_q \varepsilon_{t-q}^2 \\ &= \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 \end{aligned} \quad (2.14)$$

donde $\alpha_0 > 0$, $\alpha_i \geq 0$ para $i = 1, 2, \dots, q$, ε_t es el residuo del modelo en el tiempo t y σ_t^2 es la varianza condicional de ε_t .

2.13. GARCH

El Modelo Condicional Autorregresivo Generalizado con Heteroscedasticidad o en inglés *Generalized Autoregressive Conditional Heteroscedasticity* (GARCH), propuesto

¹Independiente e idénticamente distribuida.

por Bollerslev 1986 [25], generaliza el modelo ARCH al permitir que la varianza condicional dependa también de sus propios rezagos. El modelo GARCH(p, q) se define como:

$$\begin{aligned}\varepsilon_t &= \sigma_t \cdot z_t, & z_t &\sim \text{i.i.d. } N(0, 1) \\ \sigma_t^2 &= \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2\end{aligned}\tag{2.15}$$

donde $\omega > 0$, $\alpha_i \geq 0$ y $\beta_j \geq 0$.

2.14. Bandas de Bollinger

Las Bandas de Bollinger [8] son uno de los indicadores de compraventa más empleados para comparar los cambios en el valor de la cotización de cualquier activo y el valor relativo de su precio a lo largo de un periodo de tiempo. Este indicador fue creado en la década de los años 80 por John Bollinger y consiste en tres bandas que se dibujan superpuestas al gráfico de evolución del precio.

- La banda central es una media móvil. Comúnmente se emplea una media móvil simple con un lag de 20 periodos.
- La banda superior se calcula sumando al valor de la media móvil simple 2 veces la desviación estándar de la media móvil.
- La banda inferior se calcula restando a la media móvil simple 2 veces la desviación estándar de la media móvil.

Las bandas de Bollinger son usadas para:

- Identificar periodos de alta o baja volatilidad.
- Identificar cambios de tendencia en el precio.
- Identificar fortaleza o debilidad en la tendencia del precio.

Si notamos un estrechamiento sostenido de las bandas podemos suponer que ocurrirá lo siguiente:

- Si el precio se ubica entre la media móvil y la banda superior, el movimiento repentino se dará en forma de alza.
- Si el precio se ubica entre la media móvil y la banda inferior, el movimiento repentino se dará en forma de baja.




Figura 2.6: Bandas de Bollinger correspondientes a 2022.

En la Figura 2.6 tenemos un ejemplo de las bandas de Bollinger para 2022, en donde podemos notar un estrechamiento en las bandas en el mes de diciembre.

2.15. Retorno de la inversión

El retorno de la inversión o ROI por sus siglas en inglés *Return of Investment* es una razón financiera que compara el beneficio o la utilidad obtenida y su relación con la inversión realizada. Para su cálculo se utiliza la siguiente fórmula:

$$ROI = \frac{\text{ingresos} - \text{inversión}}{\text{inversión}} \times 100. \quad (2.16)$$

En la Figura 2.7 tenemos un ejemplo del retorno de la inversión a 10 días para 2024, el cual nos permite visualizar el comportamiento tipo onda que este presenta.

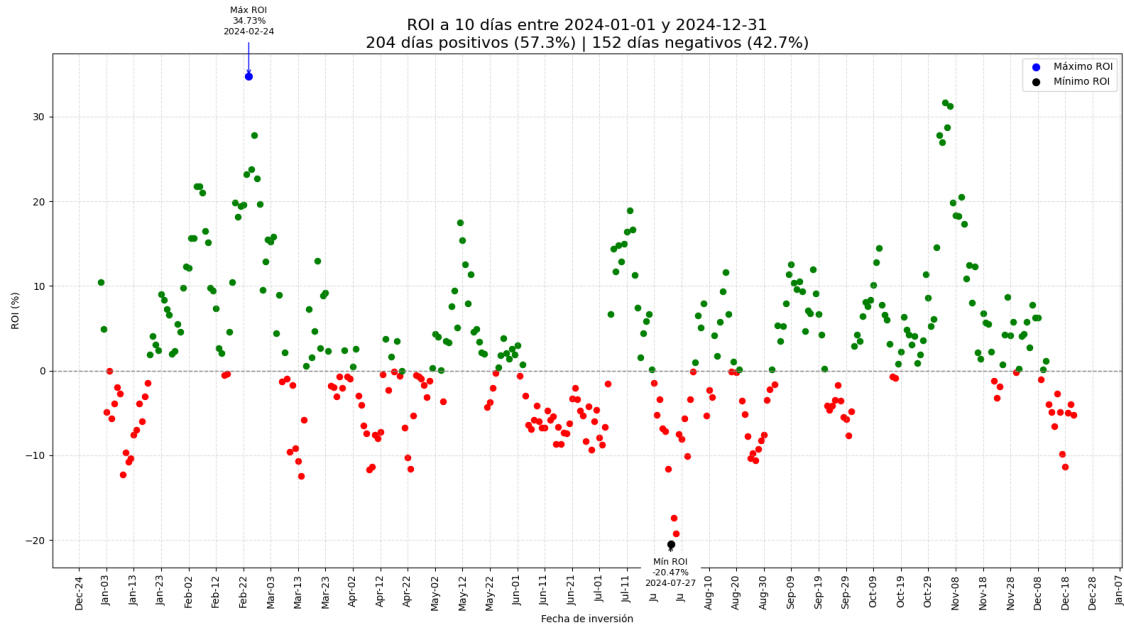


Figura 2.7: Retorno de la inversión a 10 días correspondientes a 2024.

Capítulo 3

Propuesta

En este Capítulo se explica como se aborda el problema de la compraventa de criptomonedas.

3.1. Parámetros

Utilizaremos la base de datos `Bitstamp_BTCUSD_d` [26] que obtuvimos de la página <https://www.cryptodatadownload.com/data/bitstamp/> que contiene la siguiente información:

- **Unix Timestamp** – Esta es la marca de tiempo Unix, también conocida como “Tiempo Epoch”.
- **Date** – Esta marca de tiempo está convertida a la hora estándar de Nueva York (EST).
- **Symbol** – El símbolo al que se refiere esta serie temporal de datos.
- **Open** – El precio de apertura del período de tiempo.
- **High** – El precio más alto durante el período de tiempo.
- **Low** – El precio más bajo durante el período de tiempo.
- **Close** – El precio de cierre del período de tiempo.

- **Volumen (Cripto)** – El volumen en la criptomoneda negociada. Por ejemplo, para BTC/USDT, donde BTC significa Bitcoin y USDT significa Tether (una *stablecoin* cuyo valor está anclado al dólar estadounidense), este volumen está expresado en BTC.
- **Volumen en Moneda Base** – El volumen en la moneda base o de conversión. Por ejemplo, para BTC/USDT, este volumen está expresado en USDT.

En la base de datos encontraremos un compendio de los datos antes mencionados, los cuales comprenden los años de 2016 a 2023, con los cuales se realizó la simulación de compraventa de Bitcoin:

- individualmente por año,
- y continuamente por la totalidad de los años.

Ademas de también hacerlo por cantidad de métodos utilizados para la toma de decisión con:

- un método,
- y tres métodos simultáneamente.

Para realizar la simulaciones anteriores los posibles criterios a tomar en cuenta son:

1. Capital Inicial = 10,000 USD.
2. BTC Inicial = 0.
3. Peso ARIMA $\in [0, 100]$.
4. Peso SARIMA $\in [0, 100]$.
5. Peso GARCH $\in [0, 100]$.
6. Peso ROI $\in [0, 100]$.

7. Peso Bandas de Bollinger $\in [0, 100]$.
8. Umbral de compra $\in [0, 100]$.

A continuación, listamos los algoritmos que usaremos para realizar la simulación de compraventa.

3.1.1. Algoritmo para usar ARIMA

Algoritmo 1 Flujo de generación de decisión con modelo ARIMA.

- 1: **Load Bitstamp_BTCUSD_d.csv**: Carga la base de datos con los precios históricos del Bitcoin por día.
 - 2: **Initialize parameters**:
 - ventana*: Intervalo de tiempo para entrenamiento del modelo.
 - days_of_prediction*: Número de días a predecir.
 - umbral_comprar*: Umbral a alcanzar para realizar una compra.
 - umbral_vender*: Umbral a alcanzar para realizar una venta.
 - 3: **buscar_mejor_arima()**: Buscar (p, d, q) del modelo ARIMA usando el *criterio de Akaike (AIC)*.
 - 4: **model.fit()**: Entrenar el modelo ARIMA con los parámetros obtenidos en el paso anterior.
 - 5: **model.predict()**: Predice los siguientes *days_of_prediction*.
 - 6: **evaluar_pct_y_recomendar()**: Calcula el cambio porcentual de *days_of_prediction* y compara con los umbrales para regresar una decisión:
 - if** $\text{pct} \geq \text{umbral_comprar} \Rightarrow$ **COMPRAR**.
 - elif** $\text{pct} \leq \text{umbral_vender} \Rightarrow$ **VENDER**.
 - else** **ESPERAR**.
 - 7: **Return** Regresa la decisión, los parámetros del modelo y los valores de predicción.
-

En el Algoritmo 1 podemos apreciar los pasos que se siguen para obtener una decisión de compraventa. Se utilizó la librería Pandas (v2.1.4) para la manipulación de la base de datos. De la librería Statsmodels (v0.14.1) se utilizó la función ARIMA, la cual se entrenó usando la base de datos de precios históricos de apertura del Bitcoin. La función *buscar_mejor_arima()*, mostrada en la Fig. 3.1, es parte de la paquetería propia y utiliza el criterio de Akaike para encontrar la mejor combinación de p , d y q ; con estos valores se obtuvo una predicción de 10 días y usando estos datos

```
1 def buscar_mejor_arima(timeSeries: pd.DataFrame):
2     p = d = q = range(0, 3)
3     best_aic = float('inf')
4     best_params_arima = None
5
6     for param in itertools.product(p, d, q):
7         try:
8             model = ARIMA(timeSeries['Precio'], order=param)
9             model_fit = model.fit()
10            if model_fit.aic < best_aic:
11                best_aic = model_fit.aic
12                best_params_arima = param
13        except Exception:
14            continue
15
16    model = ARIMA(timeSeries['Precio'], order=best_params_arima)
17    model_fit = model.fit()
18    return model_fit, best_params_arima, best_aic
```

Figura 3.1: Función en python para buscar el mejor ARIMA.

la función *evaluar_pct_y_recomendar()*, que también forma parte de la paquetería propia, toma la decisión de compraventa.

3.1.2. Algoritmo para usar SARIMA

En el Algoritmo 2 podemos apreciar los pasos que se siguen para obtener una decisión de compraventa. Se utilizó la librería Pandas (v2.1.4) para la manipulación de la base de datos. De la librería Statsmodels (v0.14.1) se utilizó la función SARI-MAX, la cual se entrenó usando la base de datos de precios históricos de apertura del Bitcoin. La función *buscar_mejor_sarima()* se muestra en la Fig. 3.2, ésta es parte de la paquetería propia que utiliza el criterio de Akaike para encontrar la mejor combinación de p, d y q. Se utiliza la librería Joblib (v1.3.2), de python, para la realización de los cálculos en paralelo y optimizar el tiempo de procesamiento.

Algoritmo 2 Flujo de generación de decisión con modelo SARIMA.

- 1: **Load Bitstamp_BTCUSD_d.csv**: Carga la base de datos con los precios históricos del Bitcoin por día.
 - 2: **Initialize parameters**:
 - ventana*: Intervalo de tiempo para entrenamiento del modelo.
 - n_pred*: Número de días a predecir.
 - umbral_comprar*: Umbral a alcanzar para realizar una compra.
 - umbral_vender*: Umbral a alcanzar para realizar una venta.
 - seasonal_interval*: Intervalo estacional, definido como 7 días.
 - totalIterations*: Número total de iteraciones a realizar, definido como 20.
 - 3: **buscar_mejor_arima()**: Buscar $(p, d, q) \times (P, D, Q)$ del modelo SARIMA usando el *criterio de Akaike (AIC)* usando la biblioteca *joblib* para explorar el espacio muestra en paralelo.
 - 4: **model.fit()**: Entrenar el modelo SARIMA con los parámetros obtenidos en el paso anterior.
 - 5: **model.predict()**: Predice los siguientes *n_pred*.
 - 6: **evaluar_pct_y_recomendar()**: Calcula el cambio porcentual de *n_pred* y comparar con los umbrales para regresar una decisión:
 - 7: **if** $\text{pct} \geq \text{umbral_compra}$ **then COMPRAR**.
 - 8: **else if** $\text{pct} \leq \text{umbral_venta}$ **then VENDER**.
 - 9: **else ESPERAR**.
 - 10: **end if**
 - 11: **Return** Regresa la decisión, los parámetros del modelo y los valores de predicción.
-

Con estos valores se obtuvo una predicción de 10 días y usando estos datos la función *evaluar_pct_y_recomendar()*, que también forma parte de la paquetería propia, toma la decisión de compraventa.

```

1  def buscar_mejor_sarima(
2  timeSeries: pd.DataFrame,
3  seasonal_interval: int = 7,
4  totalIterations: int = 20,
5  n_jobs: Optional[int] = None):
6
7  p = d = q = range(0, 3)
8  order_combinations = list(itertools.product(p, d, q))
9  seasonal_combinations = list(itertools.product(p, d, q))
10 seasonal_pdq = [(x[0], x[1], x[2], seasonal_interval) for x in
    ↪ seasonal_combinations]
11 param_combinations = list(itertools.product(order_combinations,
    ↪ seasonal_pdq))
12
13 if n_jobs is None:
14     n_jobs = multiprocessing.cpu_count()
15 results = Parallel(n_jobs=n_jobs, backend="loky")(
16     delayed(_evaluate_sarima)(params, timeSeries, totalIterations) for
    ↪ params in param_combinations)
17
18 valid_results = [res for res in results if res[0] != float('inf')]
19 if not valid_results:
20     raise RuntimeError("No se pudo ajustar ningún modelo SARIMA
    ↪ válido.")
21
22 valid_results.sort(key=lambda x: x[0])
23 best_aic, best_order, best_seasonal_order = valid_results[0]
24
25 model = sm.tsa.statespace.SARIMAX(
26     timeSeries['Precio'],
27     order=best_order,
28     seasonal_order=best_seasonal_order,
29     enforce_stationarity=False,
30     enforce_invertibility=False)
31 model_fit = model.fit(maxiter=totalIterations, disp=False)
32
33 return model_fit, best_order, best_seasonal_order, best_aic

```

Figura 3.2: Función en python para buscar el mejor SARIMA.

3.1.3. Algoritmo para usar GARCH

Algoritmo 3 Flujo de generación de decisión con modelo GARCH(1,1).

- 1: **Load Bitstamp_BTCUSD_d.csv**: Carga la base de datos con los precios históricos del Bitcoin por día.
 - 2: **Initialize parameters**:
 - ventana*: Intervalo de tiempo para entrenamiento del modelo.
 - n_obs*: Número de elementos a considerar, definido como 100.
 - 3: **Compute returns**: Calcula los los retornos logarítmicos en porcentaje.
 - 4: **model.fit()**: Entrena el modelo GARCH(1,1) con *returns* y *n_obs*.
 - 5: **model.forecast**: Pronostica la varianza para el siguiente elemento.
 - vol_pred*: Volatilidad pronosticada.
 - 6: **Compute current_vol**: Calcula el cuadrado de la última varianza condicional.
 - 7: **Comparar** la volatilidad pronosticada con la actual:
 - 8: **if** *vol_pred* < *current_vol* **then** COMPRAR
 - 9: **else if** *vol_pred* > *current_vol* **then** VENDER
 - 10: **else** ESPERAR
 - 11: **end if**
 - 12: **return** Regresa la decisión y los parámetros del modelo.
-

En el Algoritmo 3 podemos apreciar los pasos que se siguen para obtener una decisión de compraventa. Se utilizó la librería Pandas (v2.1.4) para la manipulación de la base de datos. De la librería ARCH (v6.3.0) se utilizó la función *arch_model* y se entrenó usando los precios históricos de apertura del Bitcoin. Con lo anterior se obtuvo una predicción de un día para la volatilidad la cual se utilizó para comparar con la volatilidad actual y tomar la decisión de compraventa.

3.1.4. Algoritmo para usar Bandas de Bollinger

Algoritmo 4 Flujo de generación de decisión utilizando Bandas de Bollinger

- 1: **Load Bitstamp_BTCUSD_d.csv**: Carga la base de datos con los precios históricos del Bitcoin por día.
 - 2: **Initialize parameters**:
 - ventana*: Intervalo de tiempo para entrenamiento del modelo.
 - window*: Número de elementos a considerar, definido como 20.
 - num_std*: Número de desviaciones estándar, definido como 2.
 - precio_actual*: Obtiene el ultimo elemento de *ventana*.
 - 3: **Compute ma**: Calcula la media móvil simple de longitud *window*.
 - 4: **Compute std**: Calcula la desviación estándar móvil de longitud *window*.
 - 5: **Compute upper**: Calcula la banda superior: $ma + num_std \times std$
 - 6: **Compute lower**: Calcula la banda inferior: $ma - num_std \times std$
 - 7: **Evaluate decision**:
 - 8: **if** *precio_actual* < *banda_inferior* **then** COMPRAR
 - 9: **else if** *precio_actual* > *banda_superior* **then** VENDER
 - 10: **else** ESPERAR
 - 11: **end if**
 - 12: **Return**: Regresa la decisión y los parámetros del modelo.
-

En el Algoritmo 4 podemos apreciar como se automatiza el proceso de la toma de decisión usando el modelo de las bandas de Bollinger, con el objetivo de comparar estrategias de compraventa para Bitcoin. Se utilizo la librería Pandas (v2.1.4) para la manipulación de la base de datos.

3.1.5. Algoritmo para usar ROI

Algoritmo 5 Generación de señal utilizando pendiente del ROI

- 1: **Compute rois**: Calcula el retorno de la inversión de los últimos 10 días.
 - 2: **Compute ave_roi**: Calcula el promedio de rois.
 - 3: **Evaluate decision**:
 - 4: **if** *ave_roi* > *umbral_vender* **then** VENDER
 - 5: **else if** *ave_roi* < *umbral_comprar* **then** COMPRAR
 - 6: **else** ESPERAR
 - 7: **end if**
 - 8: **Return**: Regresa la decisión y los parámetros del modelo.
-

En el Algoritmo 5 podemos apreciar como se automatiza el proceso de la toma de decisión usando el modelo de retorno de la inversión, con el objetivo de comparar estrategias de compraventa para Bitcoin. Se utilizo la librería Pandas (v2.1.4) para la manipulación de la base de datos.

3.2. Decisiones

Cada uno de los 5 métodos anteriores cuenta con un algoritmo sencillo que le permite decidir entre una de las tres opciones siguientes: COMPRAR, VENDER o ESPERAR. Cuando tenemos más de un método evaluado simultáneamente, la decisión se toma por una votación ponderada donde a cada método se le asigna una cantidad de votos y existe un umbral mínimo de estos para que tome una de las tres opciones.

3.3. Simulación

La simulación de compraventa se llevará a cabo entre los años de 2016 a 2024, de manera individual por año y luego de manera continua. El intervalo para la predicción será de 10 días.

Empezaremos la etapa de simulación haciendo compraventa de Bitcoin con cada uno de los métodos de manera individual, para después pasar a tres métodos de manera simultánea.

Capítulo 4

Estudio de estrategias

A continuación, se muestran algunos resultados preliminares de los métodos mencionados en el Capítulo 3, con los cuales se pudieron determinar de manera experimental cuales son los hiperparámetros que nos otorgan los mejores resultados.

4.1. Series de tiempo

Se muestran los precios del Bitcoin desde 2014-11-28 hasta 2025-03-03.





Figura 4.1: Serie de tiempo del Bitcoin de 2014 a 2024.

Se observa en la Figura 4.1 varias cosas:


1. El precio del Bitcoin ha subido notablemente con el paso del tiempo, denotando una tendencia alcista a largo plazo.
2. El precio se mantuvo estable y muy cercano a cero durante un periodo de tiempo considerable.
3. El precio ha tenido subidas y caídas, tanto grandes como pequeñas.

Veamos ahora con más detalle, las series de tiempo del Bitcoin de manera anual en las Figuras 4.2 y 4.3. De las cuales podemos observar:


1. El precio del Bitcoin termina por lo general mas alto de como empezó el año, salvo en 2018 y 2022.
2. El aumento de precio del Bitcoin por lo regular ocurre en el segundo semestre del año.




(a) 2017



(b) 2018



(c) 2019



(d) 2020

Figura 4.2: Series de tiempo del Bitcoin de 2016 a 2019, anualmente.

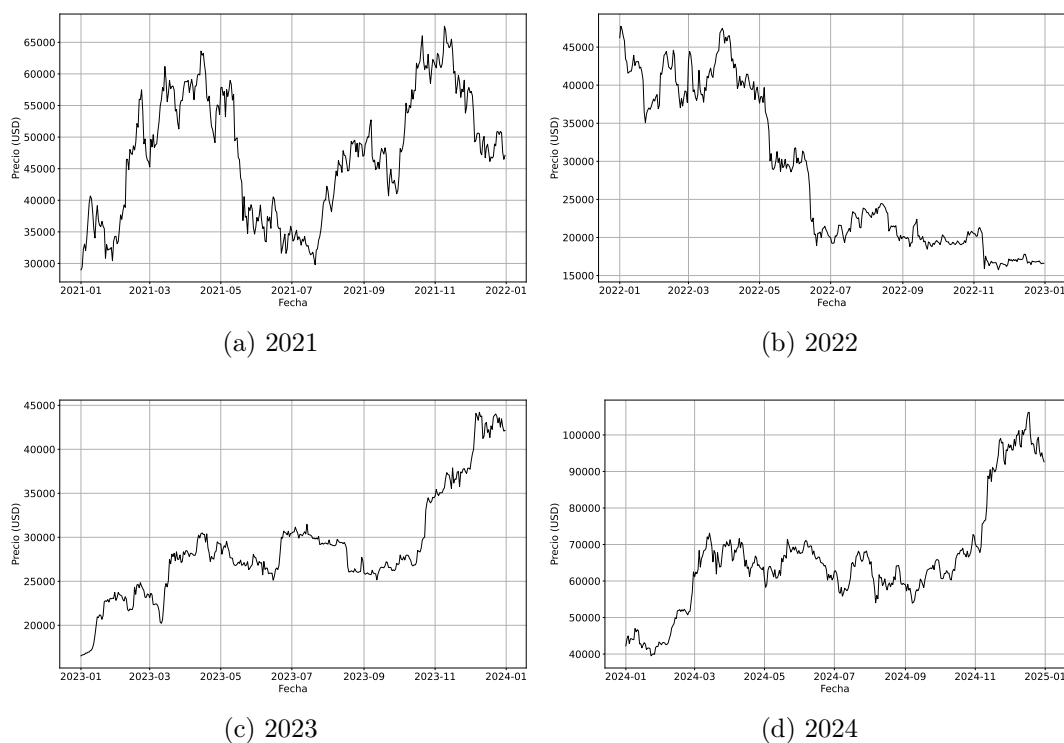



Figura 4.3: Series de tiempo del Bitcoin de 2020 a 2024, anualmente.

4.2. ARIMA


Cuando trabajamos con el método ARIMA, nuestro principal objetivo es determinar el valor de las variables p , d y q . Para esto nos apoyamos de la metodología de Box-Jenkins, explicada en el Capítulo 3.

En el ejemplo de la Figura 4.4, mostramos el correlograma y el correlograma parcial, en el inciso (a) de estas gráficas nosotros debemos interpretar cuales son los posibles candidatos para p y q . También analizando la gráfica del inciso (b) debemos poder determinar el valor de d . En consecuencia automatizar un programa que realice una simulación de compraventa representa una complicación en su desarrollo. Para solventar el problema anterior es que usamos el criterio de Akaike.



(a) ACF y PACF.


(b) Primera diferenciación.



(c) Serie de tiempo y predicción de 20 días con ARIMA.

Figura 4.4: Usando los 12 meses de 2020.

Ahora usando el AIC como parámetro, realizamos varias ejecuciones de nuestro código ARIMA y de entre estas escogemos p , d y q , los cuales corresponden a la ejecución que tenga menor AIC y los usamos para realizar la predicción y las gráficas respectivas.



(a) Predicción de 30 días generada automáticamente.

Figura 4.5: Predicciones con ARIMA, usando los 12 meses de 2022.

Una vez que nuestro programa ya funciona de manera automatizada, procedemos a realizar múltiples ejecuciones secuenciales y realizamos una tabla para contabilizar el porcentaje de éxitos en las predicciones.

Revisamos el caso en que tomamos el periodo de predicción igual a 10 días y con el intervalo de tiempo comprendido entre 01-01-2020 y 31-12-2020. La Fig. 4.6 muestra 30 gráficas, correspondientes a predicciones comprendidas en el periodo estudiado.

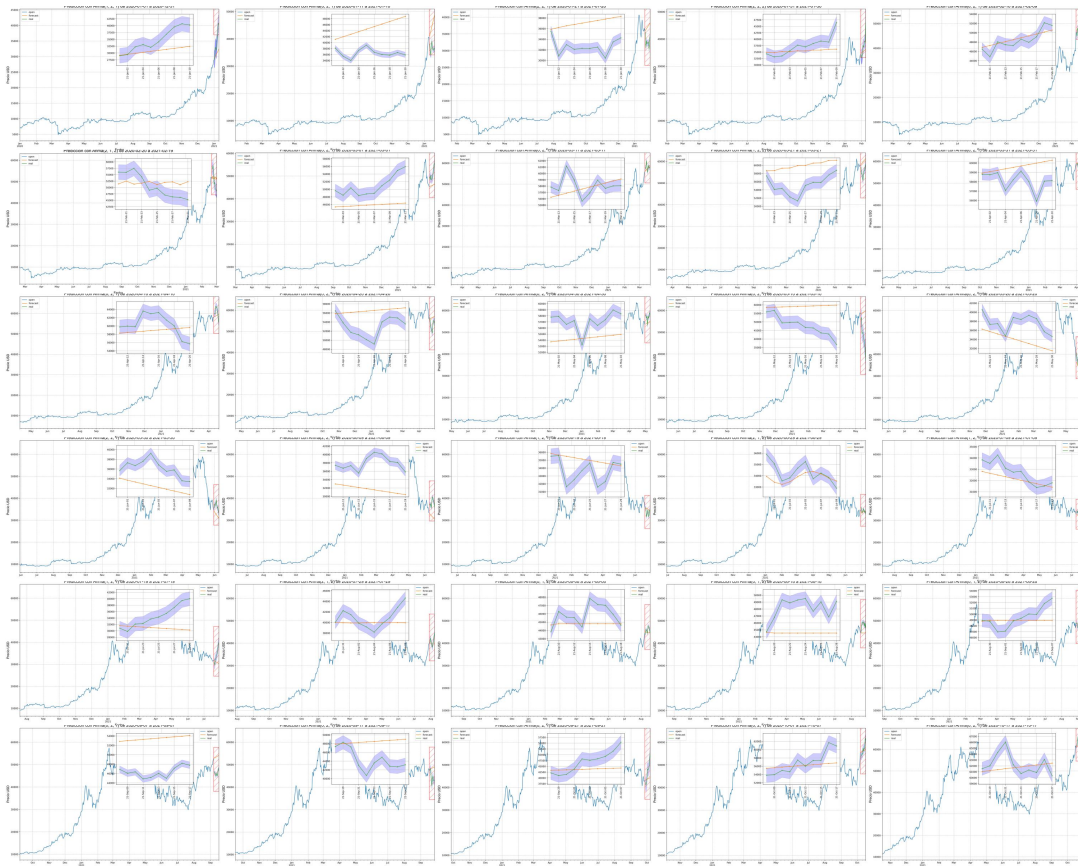


Figura 4.6: Predicciones de 10 días utilizando ARIMA. Iniciando el 01-01-2020 y terminando el 31-12-2020.

✓	x	x	✓	✓
x	x	x	✓	x
x	x	✓	x	✓
✓	x	✓	✓	✓
x	x	x	✓	x
✓	x	x	✓	x

Tabla 4.1: Revisión de predicciones de la figura 4.6.

En la Tabla 4.1 podemos ver que el total de aciertos en las predicciones fue de 13, de un total de 30 casos, lo que corresponde a un 43.3% de predicciones correctas.

4.3. SARIMA

En el caso de SARIMA, no solo se debe de encontrar los valores de p , d y q asociados a la parte de ARIMA, sino también se deben encontrar P , D , Q y s que corresponden a la parte estacional del modelo. Dado que SARIMA es uno de los métodos que más consume tiempo de cómputo, pues en la primera versión del método tomaba alrededor de 15 horas en su ejecución, se decidió paralelizar el método lo cual redujo el tiempo de ejecución significativamente, con un tiempo de ejecución de 1 a 2 horas. Cabe aclarar que esto era para p , d , q , P , D , Q dentro de los parámetros de búsqueda acotados y solo para un valor de s ; por lo que para determinar el valor óptimo de s tomaría un tiempo bastante considerable, aún con la paralelización. Por lo anterior se buscó una alternativa y se utilizó la descomposición de la serie del tiempo que nos brinda la biblioteca Statsmodel, la cual nos permite calcular 3 tipos diferentes: descomposición Aditiva, descomposición Multiplicativa y descomposición STL. Es así como encontramos de manera automática el parámetro de estacionalidad de la serie.

Las Figuras 4.7, 4.8 y 4.9 muestran las descomposiciones aditiva, multiplicativa y STL respectivamente. Vemos que proporcionan resultados similares para el parámetro de estacionalidad, por lo cual decidimos utilizar la descomposición multiplicativa basándonos en los residuales de cada una.




Figura 4.7: Descomposición aditiva de la serie de tiempo.

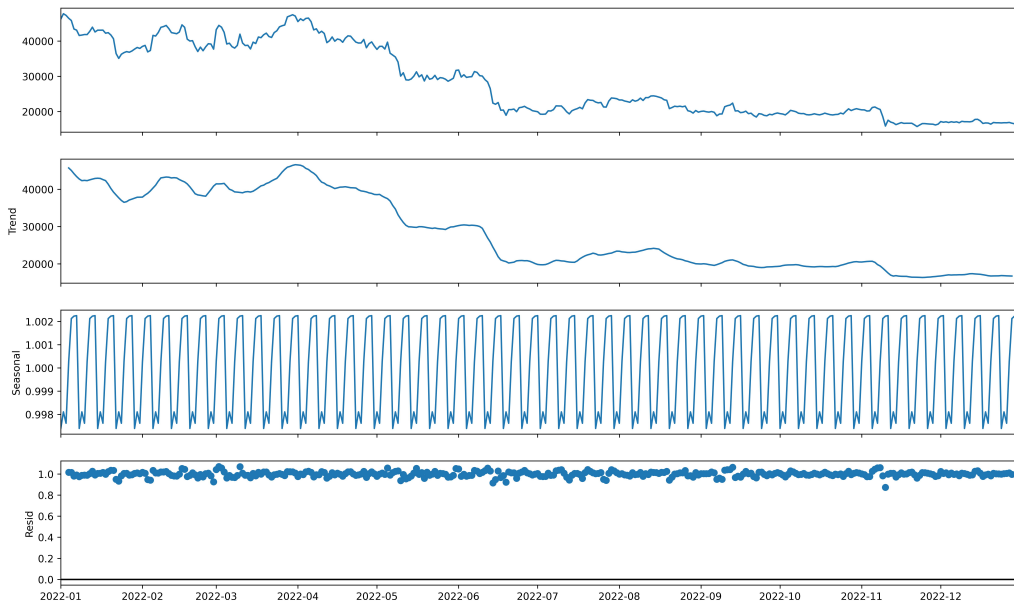


Figura 4.8: Descomposición multiplicativa de la serie de tiempo.






Figura 4.9: Descomposición STL de la serie de tiempo.


De la descomposición multiplicativa obtenemos que el valor de s es 8. Se realizaron pruebas con los valores 7, 8 y 9, las cuales pueden verse en la Figura 4.10. Podemos constatar que el comportamiento en las tres estacionalidades es aproximadamente el mismo para cualquier valor de s . Por lo cual se eligió el valor de s igual a 7, dado que corresponde a los días que tiene una semana.



(a) Predicción de 30 días con estacionalidad de 7 días.



(b) Predicción de 30 días con estacionalidad de 8 días.



(c) Predicción de 30 días con estacionalidad de 9 días.

Figura 4.10: Predicciones con SARIMA, usando los 12 meses de 2022.

Revisamos el caso en que tomamos el parámetro de estacionalidad igual a 7 días, con el periodo de predicción igual a 10 días y con el intervalo de tiempo comprendido entre 01-01-2020 y 31-12-2020. Las predicciones obtenidas con estos valores de parámetros se muestran en la Fig. 4.11.

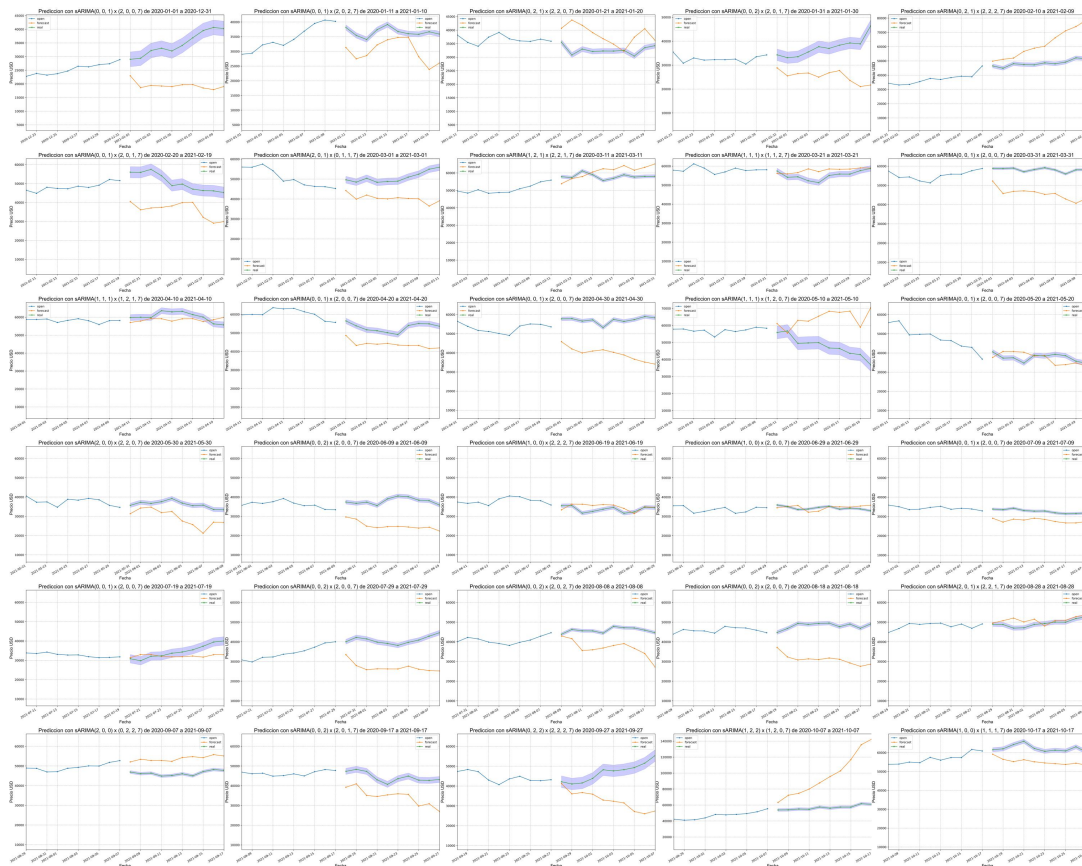


Figura 4.11: Predicciones de 10 días con SARIMA, utilizando una estacionalidad 7 días durante el año 2020.

✓	x	x	✓	✓
x	✓	✓	✓	x
x	x	✓	x	✓
✓	✓	x	✓	✓
x	x	x	✓	x
✓	x	x	✓	x

Tabla 4.2: Revisión de predicciones de la figura anterior.

En la Tabla 4.2 podemos ver que el total de aciertos en las predicciones fue de 15, de un total de 30 casos, lo que corresponde a un 50% de predicciones correctas.

Veamos el comportamiento de RMSE en las predicciones usando SARIMA para diferentes valores del parámetro de estacionalidad con periodo de predicción de 10 días.




Figura 4.12: RMSE del pronóstico de 10 días usando SARIMA.

Como podemos notar en la Figura 4.12, los Errores Cuadráticos Medios (RMSE por sus siglas en inglés) para los parámetros de estacionalidad igual a 6, 7 y 8, se encuentran bastante cercanos entre sí; esto se constató, además, realizando numerosas ejecuciones sobre diferentes periodos de tiempo.

4.3.1. Corridas lineales vs. paralelo

Se realizaron pruebas donde se compararon los RMSE obtenidos al realizar la ejecución del programa usando las dos implementaciones: lineal y paralelo. Se usó un intervalo de predicción de 30 días y para el parámetro de estacionalidad se usaron los valores 6, 7 y 8.




Figura 4.13: Corrida lineal utilizando datos del año 2022.




Figura 4.14: Corrida en paralelo utilizando datos del año 2022.

En las Figuras 4.13 y 4.14, se observa que los errores de la ejecución en paralelo son un poco mayores a los de la ejecución lineal, pero tomando en cuenta que el tiempo de ejecución es sustancialmente mayor para el caso lineal, usaremos el método que trabaja en paralelo, para de esta manera minimizar el tiempo de cómputo.

Capítulo 5

Resultados

5.1. Análisis exploratorio de datos

Como parte inicial del proceso de estudio de una serie de tiempo, el primer punto a tomar en cuenta es realizar el análisis exploratorio de los datos. Además de que nos sirve para constatar que nuestra base de datos tenga los datos completos y correctos, también nos ayuda a entender un poco mejor el problema que estamos enfrentando.

Como primer punto revisamos el total de datos y que éste coincida con el intervalo de tiempo que queremos estudiar. En nuestro caso debe coincidir la cantidad de días que existen entre 2014-11-28 y 2025-03-03, que son 3750 días, con el número de entradas en nuestra base de datos.

#	Columna	Non-Null	Tipo de Dato
0	date	3750 non-null	datetime64[ns]
1	open	3750 non-null	float64
2	close	3750 non-null	float64
3	high	3750 non-null	float64
4	low	3750 non-null	float64

Tabla 5.1: Total de datos y tipo de variables

Podemos ver, en la Tabla 5.1, que nuestra base de datos cuenta con la cantidad de datos correcta y que además no presenta valores nulos.

Como segundo punto podemos revisar en la Tabla 5.2, estadísticas básicas de

nuestra serie de tiempo que nos permiten ir construyendo una idea de con qué estamos trabajando.

Estadístico	open	close	high	low
conteo	3750.00	3750.00	3750.00	3750.00
media	21221.84	21244.83	21725.94	20678.24
desviación estándar	24117.37	24138.65	24642.09	23556.25
mínimo	162.00	162.00	212.84	152.40
25 %	2502.80	2507.52	2593.45	2423.40
50 %	9733.50	9741.24	9970.73	9454.22
75 %	34442.22	34493.03	35285.75	33334.89
máximo	106214.00	106187.00	109356.00	105363.00

Tabla 5.2: Estadísticas de la serie de tiempo del Bitcoin.

5.2. Hardware y Software utilizados

Se utilizó una computadora con un procesador Intel Core I5 modelo 13600K de 3.50 GHz con 14 núcleos, 32 GB en RAM DDR5 a 4800 Mhz, con un disco duro SSD NVMe de 932 GB y una tarjeta de video NVIDIA RTX 3060 de 12 GB.

Como lenguaje de programación utilizamos Python 3, y las librerías utilizadas fueron principalmente: Pandas, Matplotlib, Statsmodels y Joblib.

5.3. Métodos utilizados y desarrollados

Utilizamos los métodos ARIMA y SARIMA que nos proporciona la librería Statsmodels y el método GARCH que nos proporciona la librería ARCH, ambas librerías pertenecen a Python. Los métodos de Bandas de Bollinger y Retorno de la inversión fueron programados dentro del desarrollo de la paquetería propia.

Cada uno de los métodos anteriores funciona como una función independiente de las demás, lo que nos permite ejecutarlos de manera individual o en cualquier combinación que necesitemos.

5.4. Simulaciones

Para determinar el desempeño de los métodos estudiados se realizaron simulaciones de compraventa durante diferentes periodos y con la utilización de métodos de manera individual y combinada. Si bien los métodos ARIMA y SARIMA utilizan el criterio de Akaike para distinguir entre su mejor combinación de parámetros, la única métrica que se utilizará para evaluar el desempeño de cada método será el Rendimiento de la inversión, medido en porcentaje. A continuación se presentan los resultados obtenidos para las simulaciones individuales y algunas combinaciones de métodos.

5.4.1. Simulaciones utilizando métodos de manera individual

ARIMA

Empezamos por mostrar los resultados cuando usamos el método ARIMA para la compraventa y con un umbral de compra de 50. Tomando los siguientes parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 100, Peso Bandas de Bollinger = 0, Peso GARCH = 0, Peso ROI = 0, Peso SARIMA = 0. Los pesos 0 indican que el método en cuestión no es utilizado, aunque se debe asignar un valor ya que de esa manera el programa descarta el método con valor 0.

Tabla 5.3: Método: ARIMA, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9722.22	0.41	10044.22	0.44	1	0
2017	9872.29	0.06	10992.71	9.93	1	8
2018	10000.00	0.00	10000.00	0.00	0	0
2019	9015.90	0.32	11191.31	18.50	6	8
2020	9811.07	0.04	10576.36	5.76	1	4
2021	8738.64	0.04	10625.67	6.26	6	6
2022	9722.22	0.01	9944.75	-0.55	1	0
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 5.4: Ganancias promedio del método ARIMA, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	4.15	1.78	2.89
2020–2024	2.29	1.60	2.00
2022–2024	-0.18	0.33	0.00

En la Tabla 5.3 se muestra el desempeño de ARIMA para nueve años, del 2016 al 2024. Podemos notar que el mejor año para este método fue 2019, donde se realizaron 6 de 36 compras posibles y 8 de 36 ventas posibles, para un rendimiento del 18.50 %. En la misma tabla vemos que en los años 2023 y 2024 se realizaron 0 compras y ventas, para un rendimiento del 0 % durante el año. También podemos ver que 2022 fue un mal año para el método, pues se obtuvo un rendimiento negativo.

La Tabla 5.4 muestra el rendimiento de ARIMA en tres periodos de operación, 2016-2024, 2020-2024 y 2022-2024. El mejor rendimiento se obtuvo en el primer y más largo periodo, con un 4.15 %, mientras que el peor desempeño lo obtuvo en el último y más corto periodo, con un rendimiento negativo.

Bandas de Bollinger

Veamos ahora los resultados cuando usamos el método de las Bandas de Bollinger para la compraventa, utilizando un umbral de compra de 50. Se utilizaron los siguientes parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 0, Peso Bandas de Bollinger = 100, Peso GARCH = 0, Peso ROI = 0, Peso SARIMA = 0.

Tabla 5.5: Método: Bollinger, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9753.44	0.58	10201.97	2.02	1	3
2017	10000.00	0.00	10000.00	0.00	0	0
2018	9452.72	0.09	9747.79	-2.52	2	1
2019	9453.00	0.07	9952.64	-0.47	2	1
2020	9764.48	0.03	10321.74	3.22	1	4
2021	10000.00	0.00	10000.00	0.00	0	0
2022	9444.44	0.02	9713.54	-2.86	2	0
2023	9482.70	0.02	10419.22	4.19	2	2
2024	9736.87	0.00	10254.65	2.55	1	1

Tabla 5.6: Ganancias promedio del método Bandas de Bollinger, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	0.90	1.23	1.24
2020–2024	1.82	1.20	1.40
2022–2024	1.29	1.67	1.00

En la Tabla 5.5 podemos notar que el mejor año para este método fue 2023, realiza 2 de 36 compras y 2 de 36 ventas posibles, para un porcentaje de 4.19 % de rendimiento durante el año. Además, en los años de 2017 y 2021 realiza 0 de 36, compras y ventas posibles, para un rendimiento del 0 % durante el año. Tiene tres años con rendimiento negativo, que son 2018, 2019 y 2022.

La Tabla 5.6 nos muestra el desempeño de las Bandas de Bollinger en tres periodos diferentes. Notamos que en este caso el mejor desempeño lo tiene en el periodo 2020-2024 con un rendimiento del 1.89 %. En los otros dos periodos, este método, obtiene ganancias marginales aunque positivas.

GARCH

Veamos ahora los resultados cuando usamos el método GARCH para la compraventa, también utilizando un umbral de compra de 50. Utilizamos los siguientes valores para los parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 0, Peso Bandas de Bollinger = 0, Peso GARCH = 100, Peso ROI = 0, Peso SARIMA = 0.

Tabla 5.7: Método: GARCH, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	2620.16	13.87	13388.64	41.76	29	5
2017	10052.18	2.99	67485.77	636.21	25	11
2018	2777.78	1.03	6065.46	-35.78	26	0
2019	4102.31	0.88	10163.38	4.54	23	8
2020	5166.54	0.47	14347.98	51.78	21	10
2021	7120.31	0.07	10343.72	6.18	15	17
2022	4452.13	0.24	8492.29	-15.08	20	1
2023	5166.55	0.17	12369.66	23.70	20	7
2024	5320.76	0.08	13747.31	41.40	21	10

Tabla 5.8: Ganancias promedio del método GARCH, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	84.96	22.22	7.67
2020–2024	21.20	19.40	9.00
2022–2024	16.67	20.33	6.00

En la Tabla 5.7 podemos notar que el mejor año para este método fue 2017, realiza 25 de 36 compras y 11 de 36 ventas posibles, para un rendimiento del 636.21 % durante el año. Además de que no existe ningún año donde no realice compras. Este método tiene dos años con rendimiento negativo que son 2018 y 2022.

La Tabla 5.8 se muestra el desempeño de GARCH en tres periodos distintos. El mejor rendimiento lo obtiene en el primer periodo 2016-2024, con un 84.96 % de rendimiento. En los dos periodos restantes 2020-2024 y 2022-2024 obtiene un rendimiento del 21.20 % y 16.67 % respectivamente. Notamos una mejora significativa de este método con respecto a los dos anteriores.

ROI

Veamos ahora los resultados cuando usamos el método ROI para la compraventa, utilizando un umbral de compra de 50. Tomando los siguientes parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 0, Peso Bandas de Bollinger = 0, Peso GARCH = 0, Peso ROI = 100, Peso SARIMA = 0.

Tabla 5.9: Método: ROI, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5463.10	7.89	11589.68	19.21	17	3
2017	3172.11	3.17	64038.68	578.06	27	7
2018	6666.67	0.39	7924.17	-18.49	12	0
2019	6664.12	0.65	11143.22	17.99	19	11
2020	4081.26	0.55	14732.24	60.72	23	7
2021	4704.44	0.11	10136.43	10.58	22	7
2022	5291.14	0.18	8313.38	-14.49	17	1
2023	5347.00	0.16	12015.41	27.22	18	7
2024	4882.92	0.08	12781.90	31.47	19	4

Tabla 5.10: Ganancias promedio del método ROI, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	79.14	19.33	5.22
2020–2024	23.10	19.80	5.20
2022–2024	14.73	18.00	4.00

En la Tabla 5.10 notamos que el mejor año para este método fue 2017, realiza 27 de 36 compras y 7 de 36 ventas posibles, para un rendimiento del 578.06 % durante el año. Este método mantiene una gran actividad de compraventa durante todos los años. Tiene, sin embargo, un rendimiento negativo en 2018 y 2022.

La Tabla 5.10 nos muestra el desempeño del método ROI en tres periodos distintos. Vemos que en el primer periodo 2016-2024 tiene su mejor rendimiento, con el 79.14 %. En los periodos 2020-2024 y 2022-2024 obtiene rendimientos del 23.10 % y 14.73 % respectivamente.

SARIMA

Veamos ahora los resultados cuando usamos el método SARIMA para la compraventa, utilizando un umbral de compra de 50. Tomando los siguientes parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 0, Peso Bandas de Bollinger = 0, Peso GARCH = 0, Peso ROI = 0, Peso SARIMA = 100.

Tabla 5.11: Método: SARIMA, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9748.01	0.43	10078.31	0.78	1	3
2017	11346.78	0.17	14534.65	49.50	3	28
2018	4722.22	0.82	7340.53	-22.28	19	0
2019	6664.05	0.53	10289.29	5.83	15	16
2020	8655.02	0.21	12822.74	28.23	10	14
2021	6811.00	0.08	10446.34	7.45	14	12
2022	5060.97	0.19	8155.96	-11.03	18	3
2023	6948.32	0.12	11828.54	18.29	14	13
2024	7915.78	0.04	11794.73	21.21	11	19

Tabla 5.12: Ganancias promedio del método SARIMA, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	10.55	11.67	12.89
2020–2024	12.03	13.40	12.20
2022–2024	9.49	14.33	11.67

En la Tabla 5.11 vemos que el mejor año para este método fue 2017, realiza 3 de 36 compras y 28 de 36 ventas posibles, para un rendimiento del 49.50 % durante el año. este método mantiene bastante actividad durante todos los años. En los años 2018 y 2022 obtiene un rendimiento negativo.

En la Tabla 5.12 vemos el desempeño del método en tres periodos distintos, siendo el de 2020-2024 el mejor, con un rendimiento del 12.03 %. En los periodos 2016-2024 y 2022-2024 obtiene un rendimiento del 10.55 % y 9.49 % respectivamente.

Resumen

En la Tabla 5.13 se muestra los métodos ganadores en cada año en términos del rendimiento, también se muestra la cantidad final de Bitcoin y el capital total con lo que el inversor terminaría. Vemos que el método de ROI es mejor en cuatro años, mientras que GARCH es mejor en tres. El método ARIMA gana en dos años pero es porque en realidad no hace operaciones. Otros datos importantes que muestra la Tabla 5.13 son las compras y ventas que hace cada método. Se puede concluir que los métodos que son más activos, es decir hacen mas compraventas, son en general los que obtienen mejores rendimientos, aunque hay excepciones o años malos, en que los métodos no funcionan adecuadamente. Una posibilidad para tener años malos o con malas predicciones puede ser que existen años alcistas y años bajistas, por lo que el estudio de estos ciclos es tema de un trabajo futuro.

A manera de resumen, la tabla 5.14 muestra el desempeño de cada método por periodo estudiado. Vemos que GARCH gana en dos periodos 2016-2024 y 2022-2024, con un rendimiento del 84.96 % y 16.67 % respectivamente. Le sigue el método ROI, ganando en el periodo 2020-2024, con un rendimiento del 23.10 %. El siguiente

Tabla 5.13: Métodos con mejor rendimiento por año.

Año	Método ganador	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	GARCH	13.87	13388	41.76	29	5
2017	GARCH	2.99	67485	636.21	25	11
2018	ARIMA	0	10000	0	0	0
2019	ROI	0.65	11143	17.99	19	11
2020	ROI	0.55	14732	60.72	23	7
2021	ROI	0.11	10136	10.58	22	7
2022	ARIMA	0.01	9945	-0.55	1	0
2023	ROI	0.16	12015	27.22	18	7
2024	GARCH	0.08	13747	41.40	21	19

método con rendimientos mejores es SARIMA, sin embargo, hay que decir que su tiempo de ejecución es demasiado en comparación con los demás métodos por lo que su uso no se justifica.

Tabla 5.14: Comparación de estadísticas por método y periodo.

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	4.15	1.78	2.89
	2020–2024	2.29	1.60	2.00
	2022–2024	-0.18	0.33	0.00
Bollinger	2016–2024	0.90	1.23	1.24
	2020–2024	1.42	1.20	1.40
	2022–2024	1.29	1.67	1.00
GARCH	2016–2024	84.96	22.22	7.67
	2020–2024	21.80	19.40	9.00
	2022–2024	16.67	20.33	6.00
ROI	2016–2024	79.14	19.33	5.22
	2020–2024	23.10	19.80	5.20
	2022–2024	14.73	18.00	4
SARIMA	2016–2024	10.55	11.67	12.89
	2020–2024	12.03	13.40	12.20
	2022–2024	9.49	14.33	11.67

5.4.2. Variación en número de días para la compraventa

Nos interesa ahora cambiar el número de días, que los métodos utilizan, para hacer las operaciones de compraventa, con la finalidad de ajustar este parámetro a su valor

óptimo. Para este estudio hemos seleccionado a los método con el mejor desempeño en la sección anterior: Bandas de Bollinger, GARCH y ROI. Esto tiene un doble propósito, por un lado desechar los métodos con poco rendimiento y por el otro ahorrar tiempo de cómputo. Los valores escogidos para la ejecución de compraventas es 1, 7, 10, 15 y 30 días. A continuación mostramos los resultados obtenidos en el periodo comprendido del 01/01/2016 al 31/12/2024.

Método	Rendimiento (%)	Capital Final (\$)	Compras	Ventas
Bollinger	20.84	12084.84	3	7
GARCH	1484.89	158489.34	65	41
ROI	293.39	39339.41	50	43

Tabla 5.15: Resultados comparativos por método. Compraventa: 30 días.

Método	Rendimiento (%)	Capital Final (\$)	Compras	Ventas
Bollinger	153.72	25372.48	11	23
GARCH	1772.73	187273.41	135	79
ROI	2449.13	254913.93	108	75

Tabla 5.16: Resultados comparativos por método. Compraventa: 15 días.

Método	Rendimiento (%)	Capital Final (\$)	Compras	Ventas
Bollinger	85.94	18594.68	11	33
GARCH	1960.60	206060.54	206	116
ROI	1232.23	143155.50	108	108

Tabla 5.17: Resultados comparativos por método. Compraventa: 10 días.

Método	Rendimiento (%)	Capital Final (\$)	Compras	Ventas
Bollinger	84.61	18461.95	24	38
GARCH	1768.32	186832.98	281	181
ROI	1195.65	129565.04	108	108

Tabla 5.18: Resultados comparativos por método. Compraventa: 7 días.

Método	Rendimiento (%)	Capital Final (\$)	Compras	Ventas
Bollinger	88.20	18820.48	145	298
GARCH	1662.46	176246.31	1961	1283
ROI	1144.56	124456.87	1709	1118

Tabla 5.19: Resultados comparativos por método. Compraventa: 1 día.

Notamos que el método GARCH es el mejor cuando las compraventas se realizan en 1, 7, 10 y 30 días, como se ve en las Tablas 5.19, 5.18, 5.17 y 5.15, con rendimientos del 1662.46 %, 1768.32 %, 1960.60 % y 1484.89 % respectivamente. Por otro lado, el método ROI tiene un mejor desempeño para compraventas a 15 días, con un rendimiento del 2449.13 % en el periodo, como puede verse en la Tabla 5.16. Un compartamiento interesante a notar es que el rendimiento de GARCH parece seguir una distribución normal y alcanza un máximo al realizarse la compraventa cada 10 días.

5.5. Simulaciones utilizando la combinación de métodos

Combinación BGR

Ahora mostramos los resultados de las simulaciones cuando usamos la combinación BGR (Bollinger, GARCH y ROI) para la compraventa, siendo el umbral de compra = 50. Se utilizaron los siguientes parámetros iniciales: Capital Inicial = 10,000 dólares, BTC Inicial = 0, Peso ARIMA = 0, Peso SARIMA = 33.3, Peso GARCH = 33.3, Peso ROI = 33.3, Peso Bandas de Bollinger = 0. Los valores 0 para ARIMA y Bandas de Bollinger indican que estos métodos no son utilizados, pero requieren una entrada en nuestro programa general.

Tabla 5.20: Método: BGR, umbral de compra: 50, capital inicial: 10,000 dólares.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5741.90	7.52	11578.59	19.09	16	2
2017	6958.31	2.39	52723.68	458.25	18	4
2018	7500.00	0.31	8505.22	-12.52	9	0
2019	6825.98	0.50	10281.01	5.75	13	6
2020	6326.45	0.33	12809.89	35.51	14	4
2021	8017.92	0.04	10022.81	3.09	8	6
2022	7233.92	0.12	9168.87	-8.31	10	2
2023	7506.14	0.08	10932.21	9.32	9	1
2024	7897.05	0.03	11186.34	11.86	8	3

Tabla 5.21: Ganancias promedio del método BGR, para tres periodos.

Periodo	Rendimiento (%)	Compras	Ventas
2016–2024	57.56	11.67	3.11
2020–2024	10.29	9.80	3.20
2022–2024	4.29	9.00	2.00

La Tabla 5.20 muestra el desempeño del método combinado BGR en varios años, siendo el mejor en 2017 con un 458.25 %. Hay que notar que en otros años se obtienen resultados mixtos, teniendo pérdidas en 2018 y 2022, mientras que se obtienen ganancias marginales en 2019 y 2021. En la Tabla 5.21 se muestra el desempeño para el método BGR en periodos de varios años, en este caso siempre se obtiene un rendimiento positivo, siendo el periodo 2016-2024 el mejor, con un 57.56 %.

Vemos que esta combinación de métodos no demuestra ser mejor que los métodos GARCH o ROI, esto se debe muy probablemente a que la combinación requiere que al menos dos métodos aprueben una compraventa, derivado en menos operaciones.

Capítulo 6

Conclusiones

Se empleó una base de datos que contiene los precios diarios de apertura del Bitcoin correspondientes al período comprendido entre los años 2014 y 2024. A partir de dicha base, se entrenaron los modelos ARIMA y SARIMA con el objetivo de generar pronósticos de precios. También se entrenó el modelo GARCH para predecir la volatilidad a corto plazo. Los modelos ARIMA y SARIMA se utilizaron para realizar predicciones con un horizonte de 10 días, mientras que el modelo GARCH se aplicó para una predicción de un día.

Con la misma serie temporal se calcularon las Bandas de Bollinger y el Retorno de la Inversión. Posteriormente, se implementaron los algoritmos correspondientes a cada método con el fin de determinar una acción de inversión, clasificada en tres posibles decisiones: compra, venta o espera.

El capital inicial, equivalente a \$10,000 dólares, se dividió en 36 partes iguales, asignando una fracción a cada iteración experimental. En cada iteración, se ejecutó la decisión generada por cada modelo y se registraron los resultados obtenidos en una base de datos. Este procedimiento se repitió 36 veces a lo largo de 360 días con el propósito de evaluar la consistencia y el desempeño de las estrategias analizadas.

El desempeño de los cinco métodos utilizados se puede sintetizar de la siguiente manera:

- GARCH es el método que mejor rendimiento genera.

- ROI es el método que genera el segundo mejor rendimiento.
- Los métodos ARIMA y Bandas de Bollinger presentan un rendimiento bajo.
- SARIMA es el método que se descarta por la cantidad de tiempo computacional que se requiere en cada ejecución del mismo y que además presenta un rendimiento bajo.

Adicionalmente se puede observar que los métodos que mejor rendimiento otorgan, son también aquellos que más operaciones realizan durante un periodo dado. Por otro lado, usar más de un método para tomar la decisión de compraventa disminuye el número de operaciones realizadas, y por ende se obtienen menores rendimientos durante el periodo.

Cabe señalar que cuando se analiza la simulación de compraventa en el periodo 2016-2024, el método GARCH obtiene un rendimiento del 84.96 %, mientras que en el periodo 2022-2024 obtiene un rendimiento del 16.67 %. Estos resultados son prometedores, especialmente para el caso de que se quiera hacer un ejercicio real de compraventa.

6.1. Trabajo futuro

Los puntos a desarrollar en una siguiente etapa son los siguientes:

- Cambio de la base de datos de Bitcoin por alguna otra criptomoneda o activo financiero.
- Cambio en los umbrales de decisión de compraventa de los métodos actuales.
- Cambio de los métodos para la toma de decisión de compraventa.
- Cambio en los periodos de tiempo tanto de entrenamiento como de simulación.
- Agregar el estudio de variables exógenas.

Además, buscando una aproximación aún más precisa del modelo se podrían aplicar métodos de optimización a los hiperparámetros con el afán de encontrar mejores valores de estos.

Bibliografía

- [1] C. Yu, W. Yang, F. Xie, and J. He, “Technology and security analysis of cryptocurrency based on blockchain,” *Complexity*, 2022.
- [2] M. S. Ferdous, M. J. M. Chowdhury, and M. A. Hoque, “A survey of consensus algorithms in public blockchain systems for crypto-currencies,” *Journal of Network and Computer Applications*, vol. 182, p. 103035, 2021.
- [3] V. L. Tran and T. Leirvik, “Efficiency in the markets of crypto-currencies,” *Finance Research Letters*, vol. 35, p. 101382, 2020.
- [4] F. Fang, C. Ventre, M. Basios, L. Kanthan, F. Martinez-Rego, David adn Wu, and L. Li, “Cryptocurrency trading: a comprehensive survey,” *Financial Innovation*, vol. 8, no. 13, 2022.
- [5] J. Chiu and T. V. Koepl, “The economics of cryptocurrency: Bitcoin and beyond,” *Canadian Journal of Economics*, vol. 55, no. 4, 2022.
- [6] R. Shumway and D. Stoffer, “Arima models,” in *Time Series Analysis and Its Applications*, Springer Texts in Statistics, 2017.
- [7] A. Kumar Dubey, A. Kumar, V. García-Díaz, A. Kumar Sharma, and K. Kanhaiya, “Study and analysis of sarima and lstm in forecasting time series data,” *Sustainable Energy Technologies and Assessments*, vol. 47, p. 101474, 2021.
- [8] S. Chen1, B. Zhang, G. Zhou, and Q. Qin, “Bollinger bands trading strategy based on wavelet analysis,” *Applied Economics and Finance*, vol. 5, no. 3, 2018.

-
- [9] E. A. Meyer, I. M. Welpé, and P. Sandner, “Testing the credibility of crypto influencers: An event study on bitcoin,” *Finance Research Letters*, vol. 60, p. 104864, 2024.
- [10] E. Bouri, R. Gupta, and D. Roubaud, “Herding behaviour in cryptocurrencies,” *Finance Research Letters*, vol. 29, pp. 216–221, 2019.
- [11] M. S. Sepehri, A. Mehradfar, M. Soltanolkotabi, and S. Avestimehr, “Cryptomamba: Leveraging state space models for accurate bitcoin price prediction,” *arXiv preprint arXiv:2501.01010*, 2025.
- [12] G. Vital-Godinez, J. Quiterio-Romero, P. Miranda-Romagnoli, and C. A. Soto-Campos, “Modelos arima para el análisis sistematizado de criptomonedas,” *Pädi Boletín Científico*, vol. 11, no. 21, pp. 1–7, 2023.
- [13] Y. Pronchakov and O. Bugaienko, “Methods of forecasting the prices of cryptocurrency on the financial markets,” *Technology transfer: innovative solutions in Social Sciences and Humanities*, vol. 2, pp. 13–16, 03 2019.
- [14] X. Long, M. Kampouridis, and D. Jarchi, “An in-depth investigation of genetic programming and nine other machine learning algorithms in a financial forecasting problem,” in *Congress on Evolutionary Computation*, (Wivenhoe Park, United Kingdom), 2022.
- [15] P. S. Cowpertwait and A. W. Metcalfe, *Introductory Time Series with R*. Nueva York, USA: Springer, 2009.
- [16] J. D. Cryer and K. S. Chan, *Time series analysis: with applications in R*. Nueva York, USA: Springer-Verlag, 2008.
- [17] J. Madura, *Mercados e Instituciones Financieras*. Ciudad de México, México: Cengage Learning Editores, 11 ed., 2015.

-
- [18] A. Narayanan, J. Bonneau, E. Felten, A. Miller, and S. Goldfeder, *Bitcoin and Cryptocurrency Technologies: A Comprehensive Introduction*. Princeton University Press, 2016.
- [19] S. Nakamoto, “Bitcoin: A peer-to-peer electronic cash system.” <https://bitcoin.org/bitcoin.pdf>, 2008. Consultado el 7 de enero de 2026.
- [20] J. J. Murphy, *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York, NY, USA: New York Institute of Finance, 1 ed., 1999.
- [21] Damodar and D. C. Porter, *Basic Econometrics*. McGraw-Hill Education, 2009.
- [22] D. Peña, *Análisis de series temporales*. Madrid: Alianza Editorial, 2005.
- [23] G. E. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- [24] R. F. Engle, “Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation,” *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982.
- [25] T. Bollerslev, “Generalized autoregressive conditional heteroskedasticity,” *Journal of Econometrics*, vol. 31, no. 3, pp. 307–327, 1986.
- [26] B. E. Data, “Cryptodatadownload.” <https://www.cryptodatadownload.com/data/bitstamp/>. consultado el 4 de Marzo de 2025.

Capítulo 7

Apéndice

A continuación, encontramos ejecuciones adicionales para los métodos: ARIMA, Bandas de Bollinger, GARCH y ROI. En los cuales se usan diferentes intervalos de compraventa.

7.1. Cada un día

Tabla 7.1: Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	10000.00	0.00	10000.00	0.00	0	0
2017	10000.00	0.00	10000.00	0.00	0	0
2018	10000.00	0.00	10000.00	0.00	0	0
2019	10000.00	0.00	10000.00	0.00	0	0
2020	10000.00	0.00	10000.00	0.00	0	0
2021	10000.00	0.00	10000.00	0.00	0	0
2022	10000.00	0.00	10000.00	0.00	0	0
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.2: Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9814.72	0.41	10215.22	2.15	8	53
2017	9799.07	0.17	12299.98	23.00	11	50
2018	9235.56	0.12	9683.57	-3.16	28	3
2019	9540.92	0.06	9995.59	-0.04	17	32
2020	9690.63	0.04	10817.72	8.18	13	33
2021	9596.15	0.01	10037.58	0.38	15	6
2022	9290.09	0.02	9700.64	-2.99	26	5
2023	9723.74	0.01	10208.35	2.08	11	29
2024	9585.50	0.01	10247.09	2.47	16	17

Tabla 7.3: Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	3213.52	13.07	15893.59	60.25	280	74
2017	6770.74	2.74	46056.80	363.10	246	113
2018	3447.75	0.98	7085.19	-28.56	240	19
2019	5043.67	0.86	11398.85	14.93	229	121
2020	5872.86	0.40	16889.58	69.83	193	119
2021	6431.43	0.08	10206.02	2.62	164	137
2022	4401.16	0.24	8358.13	-15.96	206	38
2023	6367.30	0.14	12377.64	24.46	192	160
2024	5410.74	0.07	12316.58	23.17	206	108

Tabla 7.4: Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5167.93	8.10	13023.56	30.24	185	48
2017	3718.37	3.13	48630.04	390.33	272	61
2018	6767.12	0.42	8329.97	-16.70	118	0
2019	6821.97	0.58	11120.12	12.12	178	111
2020	3823.08	0.56	19261.18	94.21	237	55
2021	5615.92	0.09	9873.71	-0.44	184	68
2022	6250.49	0.15	8714.80	-12.13	137	4
2023	5162.66	0.16	11990.34	19.90	188	72
2024	4847.20	0.08	12046.29	20.46	204	77

Tabla 7.5: Comparación de estadísticas por periodo y método (Umbral de compra: 50)

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	0.00	0.00	0.00
	2020–2024	0.00	0.00	0.00
	2022–2024	0.00	0.00	0.00
Bollinger	2016–2024	3.12	15.00	19.78
	2020–2024	1.22	16.20	18.00
	2022–2024	0.52	17.67	17.00
GARCH	2016–2024	56.32	219.56	94.33
	2020–2024	20.82	192.20	108.40
	2022–2024	10.56	201.33	102.00
ROI	2016–2024	59.78	189.22	55.11
	2020–2024	24.40	190.00	55.20
	2022–2024	9.41	176.33	51.00

7.2. Cada cinco días

Tabla 7.6: Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9735.19	0.52	10194.04	1.94	2	3
2017	9909.36	0.06	10904.80	9.05	2	21
2018	10000.00	0.00	10000.00	0.00	0	0
2019	9236.73	0.21	10743.42	8.93	8	12
2020	9905.78	0.02	10480.43	4.80	1	6
2021	8778.79	0.03	10415.93	4.16	9	6
2022	9727.93	0.01	9930.69	-0.69	2	1
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.7: Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9648.28	0.84	10397.99	3.98	3	10
2017	9907.38	0.06	10771.56	7.72	1	7
2018	9320.50	0.11	9757.94	-2.42	5	3
2019	9591.12	0.05	9975.95	-0.24	3	1
2020	9884.61	0.01	10234.68	2.35	1	8
2021	9863.01	0.00	10004.88	0.05	1	0
2022	9315.07	0.02	9667.59	-1.98	5	0
2023	9487.07	0.02	10386.39	3.86	4	4
2024	9737.87	0.00	10194.17	1.94	2	2

Tabla 7.8: Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	3690.46	12.26	14607.95	52.34	54	15
2017	9169.31	2.80	52795.86	442.73	48	24
2018	3885.34	0.90	7328.76	-24.67	45	3
2019	5180.27	0.84	11174.42	14.89	44	23
2020	5597.25	0.42	16071.26	65.17	40	23
2021	6172.00	0.09	10379.80	6.67	35	30
2022	3990.28	0.26	8398.74	-14.85	44	5
2023	5921.91	0.16	12732.44	29.07	39	30
2024	5466.21	0.07	12664.40	26.64	40	22

Tabla 7.9: Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5287.25	8.00	12415.81	25.88	36	11
2017	3095.44	3.21	53133.08	454.10	55	13
2018	6986.30	0.36	8377.02	-15.07	22	0
2019	6971.07	0.59	11188.70	15.02	36	24
2020	3910.06	0.55	17479.06	79.71	47	13
2021	5588.08	0.09	10111.61	5.45	37	12
2022	6032.22	0.15	8599.37	-12.81	29	1
2023	5248.19	0.16	12322.47	24.94	37	15
2024	4930.32	0.08	12509.09	26.83	40	14

Tabla 7.10: Comparación de estadísticas por periodo y método (Umbral de compra: 50)

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	3.52	2.44	4.67
	2020–2024	1.25	2.40	2.60
	2022–2024	-0.23	0.67	0.33
Bollinger	2016–2024	1.47	2.33	3.89
	2020–2024	1.24	2.60	2.80
	2022–2024	1.94	3.67	2.00
GARCH	2016–2024	66.67	49.89	19.44
	2020–2024	22.94	39.60	22.60
	2022–2024	13.62	41.00	19.00
ROI	2016–2024	67.12	37.67	11.44
	2020–2024	24.82	38.00	11.00
	2022–2024	12.99	35.33	10.00

7.3. Cada siete días

Tabla 7.11: Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9815.05	0.49	10239.37	2.39	1	1
2017	10411.19	0.12	12211.90	24.51	2	30
2018	10000.00	0.00	10000.00	0.00	0	0
2019	9268.37	0.23	10968.55	9.69	6	9
2020	9874.80	0.03	10642.22	6.42	1	5
2021	8872.63	0.03	10568.62	5.69	6	1
2022	10000.00	0.00	10000.00	0.00	0	0
2023	9812.07	0.01	10177.46	1.77	1	1
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.12: Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9837.37	0.39	10176.14	1.76	1	5
2017	9728.68	0.27	13682.71	36.83	2	4
2018	9619.01	0.05	9819.88	-1.80	2	1
2019	9423.08	0.07	9939.71	-0.60	3	0
2020	9632.22	0.04	10493.42	4.93	2	2
2021	9615.38	0.01	9972.73	-0.27	2	0
2022	9230.77	0.02	9637.22	-1.74	4	0
2023	9822.49	0.01	10123.11	1.23	1	3
2024	9638.91	0.01	10250.07	2.50	2	2

Tabla 7.13: Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	2567.37	14.43	14964.44	55.57	42	9
2017	4915.00	3.49	55990.70	494.19	40	11
2018	2885.85	1.06	7080.87	-27.83	37	1
2019	6331.88	0.71	11550.69	20.13	29	20
2020	7585.48	0.28	14255.50	45.22	21	22
2021	6373.48	0.08	10591.81	10.06	24	19
2022	4872.37	0.22	8585.94	-10.71	27	7
2023	3104.39	0.26	14323.51	48.96	40	10
2024	3607.66	0.10	13021.01	30.21	36	9

Tabla 7.14: Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5280.90	8.08	12216.91	24.56	26	8
2017	3038.10	3.24	50367.42	423.82	39	8
2018	6538.46	0.45	8313.62	-15.23	18	0
2019	6506.75	0.62	11040.21	12.57	27	15
2020	3947.68	0.56	17361.13	84.24	33	7
2021	5418.67	0.10	10320.98	9.53	27	8
2022	5961.54	0.16	8640.77	-11.90	21	0
2023	5072.97	0.16	12276.20	25.17	27	9
2024	4921.25	0.07	12028.95	22.65	28	11

Tabla 7.15: Comparación de estadísticas por periodo y método (Umbral de compra: 50)

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	5.83	1.22	5.22
	2020–2024	3.62	1.60	1.40
	2022–2024	0.59	0.33	0.33
Bollinger	2016–2024	4.42	2.11	1.89
	2020–2024	1.33	1.80	1.40
	2022–2024	0.66	2.33	1.67
GARCH	2016–2024	73.20	33.33	12.00
	2020–2024	24.75	29.60	13.40
	2022–2024	22.82	34.33	8.67
ROI	2016–2024	63.93	27.33	7.33
	2020–2024	25.94	27.20	7.00
	2022–2024	11.97	25.33	6.67

7.4. Cada 15 días

Tabla 7.16: Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	10000.00	0.00	10000.00	0.00	0	0
2017	10000.00	0.00	10000.00	0.00	0	0
2018	10000.00	0.00	10000.00	0.00	0	0
2019	8634.52	0.36	11223.87	17.12	5	5
2020	9728.81	0.07	10959.37	9.59	1	3
2021	9074.63	0.03	10511.23	5.11	3	5
2022	10000.00	0.00	10000.00	0.00	0	0
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.17: Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	9722.29	0.91	10422.84	8.76	1	5
2017	9727.63	0.16	12413.42	24.13	1	3
2018	9583.33	0.07	9806.53	-1.93	1	0
2019	9603.14	0.05	9950.68	-0.49	1	1
2020	9645.40	0.04	10418.09	4.18	1	3
2021	9583.33	0.01	10019.36	0.19	1	0
2022	9166.67	0.03	9673.24	-3.27	2	0
2023	9608.48	0.02	10257.22	2.57	1	1
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.18: Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	3959.04	11.51	12850.74	34.09	17	5
2017	10211.61	2.70	54734.02	525.53	15	9
2018	3333.33	1.00	6688.12	-27.04	16	0
2019	6190.53	0.78	11841.13	29.18	13	9
2020	2130.98	0.73	15496.31	77.10	19	2
2021	4966.28	0.11	10641.70	10.56	14	9
2022	3346.29	0.29	8365.99	-16.34	16	1
2023	6121.94	0.15	12458.68	29.75	13	10
2024	5783.11	0.07	12112.54	26.39	12	8

Tabla 7.19: Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	5623.33	7.57	11471.46	19.48	11	4
2017	3946.15	2.99	53217.30	480.55	17	6
2018	7083.33	0.37	8314.34	-16.86	7	0
2019	6237.00	0.76	11721.64	22.31	13	6
2020	2887.02	0.69	15497.96	77.12	18	4
2021	5768.87	0.09	10167.95	10.49	12	6
2022	6273.27	0.15	8796.38	-8.21	9	1
2023	5471.75	0.15	11758.28	28.27	12	8
2024	4851.01	0.08	12282.64	27.94	13	4

Tabla 7.20: Comparación de estadísticas por periodo y método (Umbral de compra: 50, fechas hasta 2024-12-11)

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	3.97	1.00	1.11
	2020–2024	2.54	0.80	1.60
	2022–2024	0.00	0.00	0.00
Bollinger	2016–2024	3.25	1.11	1.11
	2020–2024	0.70	1.20	1.20
	2022–2024	-0.23	1.00	0.33
GARCH	2016–2024	69.33	14.44	6.56
	2020–2024	33.58	14.80	5.40
	2022–2024	13.93	13.67	6.33
ROI	2016–2024	71.23	12.44	4.33
	2020–2024	27.12	12.80	4.60
	2022–2024	16.00	11.33	4.33

7.5. Cada 30 días

Tabla 7.21: Tipo: ARIMA, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	10000.00	0.00	10000.00	0.00	0	0
2017	10000.00	0.00	10000.00	0.00	0	0
2018	9166.67	0.13	9646.57	-3.53	1	0
2019	9799.81	0.13	10763.34	7.63	1	4
2020	10000.00	0.00	10000.00	0.00	0	0
2021	8716.09	0.04	10782.94	7.83	2	2
2022	10000.00	0.00	10000.00	0.00	0	0
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.22: Tipo: Bollinger, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	10000.00	0.00	10000.00	0.00	0	0
2017	10000.00	0.00	10000.00	0.00	0	0
2018	10000.00	0.00	10000.00	0.00	0	0
2019	9245.91	0.09	9907.06	-0.93	1	1
2020	9324.12	0.08	10834.38	18.19	1	2
2021	10000.00	0.00	10000.00	0.00	0	0
2022	9166.67	0.02	9527.25	-4.73	1	0
2023	10000.00	0.00	10000.00	0.00	0	0
2024	10000.00	0.00	10000.00	0.00	0	0

Tabla 7.23: Tipo: GARCH, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	4765.78	10.40	12433.78	49.21	8	3
2017	7485.70	3.66	41410.85	386.59	9	3
2018	2540.85	1.11	6693.96	-26.97	9	1
2019	4040.33	1.00	11220.69	34.65	8	3
2020	1714.81	0.80	16675.90	122.35	10	1
2021	5110.92	0.12	11510.81	22.93	7	4
2022	4198.35	0.25	8369.40	-8.70	7	1
2023	4786.16	0.18	11669.46	16.69	7	1
2024	5410.31	0.08	12715.30	37.26	7	3

Tabla 7.24: Tipo: ROI, umbral de compra: 50, capital inicial: 10000 USD.

Fecha	Capital Final (\$)	BTC Final	Capital Total (\$)	Rendimiento (%)	Compras	Ventas
2016	6039.27	7.27	11400.05	24.36	5	1
2017	3764.95	3.51	36323.13	384.31	9	3
2018	5833.33	0.51	7716.31	-15.82	5	0
2019	7761.70	0.65	12385.86	48.63	6	4
2020	4033.64	0.60	15216.89	79.54	8	4
2021	7050.64	0.07	10923.13	29.94	5	5
2022	6666.67	0.11	8497.91	-7.30	4	0
2023	4674.06	0.19	11605.60	39.27	7	3
2024	4166.67	0.09	12119.73	32.22	7	0

Tabla 7.25: Resumen de rendimiento, compras y ventas promedio (Umbral de compra: 50, fechas hasta 2024-11-26)

Método	Periodo	Rendimiento (%)	Compras	Ventas
ARIMA	2016–2024	1.20	0.44	0.67
	2020–2024	3.13	0.80	0.80
	2022–2024	0.00	0.00	0.00
Bollinger	2016–2024	0.94	0.33	0.22
	2020–2024	2.29	0.60	0.60
	2022–2024	-1.58	0.33	0.00
GARCH	2016–2024	57.57	7.78	2.22
	2020–2024	68.27	7.60	2.00
	2022–2024	15.41	7.00	1.67
ROI	2016–2024	68.35	6.22	2.22
	2020–2024	34.73	6.20	2.40
	2022–2024	21.40	6.00	1.00