

**Análisis de la volatilidad de un portafolio de criptomonedas mediante modelos de series de tiempo.**

Paula Lisseth Gómez Fonseca, Valentina Rodríguez Córdoba

Facultad de Administración y Economía, Universidad Colegio Mayor de Cundinamarca

Monografía Regular

Tutor: William Gilberto Delgado Munévar

Mayo 15 de 2024

## Resumen

En este estudio se estima la volatilidad de un portafolio compuesto por las 10 criptomonedas con mayor capitalización durante el período comprendido entre el 19 de noviembre de 2017 y el 30 de diciembre de 2023. Se emplean modelos de series temporales como ARIMA, ARCH y GARCH para analizar y evaluar la volatilidad y la rentabilidad en comparación con periodos anteriores. El estudio proporciona bases para estimar, estudiar y analizar estos modelos con el fin de construir un portafolio de inversión diversificado, así como para realizar predicciones fuera de la muestra. La metodología se emplea en un conjunto de 10 criptomonedas, las cuales conforman un portafolio. Los resultados muestran tendencias significativas de volatilidad en el mercado de criptomonedas, indicando que los modelos heterocedásticos ofrecen un mejor rendimiento en términos de estimación normal. Específicamente, el modelo GARCH el cual se destaca al ofrecer un análisis más claro e interpretable de la volatilidad, revelando su comportamiento durante el período analizado.

**Palabras clave:** Criptomonedas, ARCH y GARCH, portafolio de inversión, riesgo, rentabilidad, series temporales, volatilidad.

**Clasificación JEL:** G29, C10, C19, G11, G17, C22, G12.

## Abstract

This study estimates the volatility of a portfolio composed of the 10 cryptocurrencies with the largest capitalization during the period from November 19, 2017 to December 30, 2023. Time series models such as ARIMA, ARCH and GARCH are employed to analyze and evaluate volatility and profitability compared to previous periods. The study provides a basis for estimating, studying and analyzing these models in order to construct a diversified

investment portfolio, as well as to make out-of-sample predictions. The methodology is employed on a set of 10 cryptocurrencies, which make up a portfolio. The results show significant volatility trends in the cryptocurrency market, indicating that hetero-elastic models offer better performance in terms of normal estimation. Specifically, the GARCH model stands out by offering a clearer and more interpretable analysis of volatility, revealing its behavior during the analyzed period.

**Keywords:** Cryptocurrencies, ARCH and GARCH models, investment portfolio, risk, return, time series, volatility.

**JEL classification:** G29, C10, C19, G11, G17, C22, G12.

## Dedicatoria

*"A nuestros mentores y familiares, cuyo apoyo y motivación han sido fundamentales en este camino académico y siendo una fuente constante de inspiración para nosotras".*

## Índice

1	Introducción.....	9
2	Revisión de la Literatura.....	13
3	Marco Teórico .....	18
3.1	<i>Modelos ARCH y GARCH.....</i>	26
3.2	<i>Teoría Clásica de Series Temporales.....</i>	26
3.3	<i>Modelo ARIMA.....</i>	27
4	Metodología.....	29
4.1	<i>Estimación del Modelo .....</i>	30
4.1.1	<i>Modelo ARIMA (p, d, q) .....</i>	30
4.1.2	<i>Modelo ARCH(p) en regresión.....</i>	31
4.1.2.1	<i>Autocorrelación de la volatilidad .....</i>	32
4.1.3	<i>Modelo GARCH (p, q) .....</i>	34
4.1.3.1	<i>La estacionariedad y positividad.....</i>	35
4.1.4	<i>Variables del modelo a emplear.....</i>	36
4.2	<i>Pruebas estacionariedad modelado en Stata .....</i>	39
4.2.1	<i>Correlograma.....</i>	39
4.2.2	<i>Dickey-Fuller (1979,1984).....</i>	40
4.2.3	<i>Phillips y Perron (1988) .....</i>	42
4	Hechos estilizados .....	43
5	Materiales y Métodos Subtitulo.....	46
6	Resultados.....	48
6.1	<i>Análisis Descriptivo.....</i>	48
6.1	<i>Resultados de la Estimación de los modelos .....</i>	50
6.1.1	<i>Resultado de la regresión de ARIMA portafolio (1.1).....</i>	50
6.1.2	<i>Resultados de la regresión de la familia ARCH portafolio (1.2 y 1.3) .....</i>	52
6.1.3	<i>Resultados prueba de Histograma Portafolio .....</i>	53
6.1.4	<i>Resultado final de volatilidad del portafolio .....</i>	55
7	Conclusiones.....	58
8	Referencias .....	60
9	Anexos.....	65

9.1	<i>Anexo A. Análisis correlación: Rendimiento diario del Portafolio de Criptomonedas.....</i>	65
9.2	<i>Anexo B. Resultados prueba Dickey-Fuller .....</i>	67
9.3	<i>Anexo C. Resultados prueba Phillips-Perron.....</i>	68
9.4	<i>Anexo D. Resultados de la Prueba Portmanteau para Ruido Blanco.....</i>	69

### Índice de gráficos

Gráfica 1. Volatilidad .....	46
Gráfica 2 Volatilidad Portafolio .....	49
Gráfica 3 Histograma Portafolio.....	54
Gráfica 4 Resultado gráficos de validación predictiva.....	56

### Índice de tablas

Tabla 1 Criptomonedas empleadas en el análisis. ....	37
Tabla 2 Estadísticas descriptivas SUM .....	39
Tabla 4 Resultado de la regresión de ARIMA portafolio.....	51
Tabla 5 Resultados de la regresión de la familia ARCH portafolio .....	52
Tabla 3 Correlograma Portafolio .....	65
Tabla 6 Resultados de la prueba Dickey-Fuller.....	67
Tabla 7 Resultados Prueba Phillips-Perron .....	68
Tabla 8 Resultados de la Prueba Portmanteau Para Ruido Blanco .....	70





## Introducción

En los últimos años la constante evolución tecnológica y la creciente digitalización de los datos, ha ido transformado significativamente el panorama de las operaciones financieras, lo que ha llevado a la influencia de los activos digitales más relevantes, entre los cuales se destacan las criptomonedas. Por su naturaleza descentralizada, basada en la tecnología blockchain, la cual se popularizó a partir del año 2009 con la creación del Bitcoin y permitió la generación de un sistema monetario alternativo sin el control de las entidades gubernamentales y/o instituciones centrales. Si bien estas representan un atractivo para los inversionistas debido a su potencial de rentabilidad, es crucial destacar que su marcada volatilidad plantea desafíos sustanciales en términos de gestión de riesgos e incertidumbre, lo que constituye un reto significativo en este contexto. Dentro de este marco, la definición del problema que rige esta investigación se fundamenta en la siguiente pregunta problema planteada: ¿Cómo se fundamenta un análisis de volatilidad para un portafolio de inversión compuesto por criptomonedas?, a partir de esta pregunta de investigación se establece el siguiente propósito general: Analizar la volatilidad de un portafolio constituido por criptomonedas con el fin de ofrecer un aporte significativo a la Teoría de la Generación de Carteras Financieras basados en principios de maximización de retornos y minimización de riesgos por medio de modelos estadísticos avanzados de series temporales, como ARCH (Auto-Regresión Condicional Heterocedástica) y GARCH (Heterocedasticidad Condicional Autorregresiva Generalizada), durante el periodo comprendido entre el 19 de noviembre de 2017 hasta el 30 de diciembre de 2023. Los activos objeto de estudio son: Namecoin (NMC-USD), Binance Coin (BNB-USD), Litecoin (LTC-USD), Cardano (ADA-USD), Peercoin (PPC-USD), Ethereum (ETH-USD), Dogecoin (DOGE-USD), Ripple (XRP-USD), Tether (USDt-USD) y Bitcoin (BTC-USD). El período seleccionado para analizar la volatilidad de

las criptomonedas abarca eventos relevantes que justifican su elección. Ofrece un amplio panorama en la variación de sus precios, la adopción institucional y las nuevas formas de financiación a través de las criptomonedas. En noviembre de 2017, Bitcoin superó los \$7,000 USD y posteriormente los \$10,000 USD, alcanzando un máximo histórico cercano a los \$20,000 USD en diciembre del mismo año. Este hito coincidió con un aumento en la adopción de criptomonedas y el auge de las Ofertas Iniciales de Moneda (ICO), brindando nuevas oportunidades de financiación para las empresas. Sin embargo, en 2018, la mayoría de las criptomonedas experimentaron una fuerte caída debido a la incertidumbre regulatoria. En 2019, las tecnologías emergentes como DeFi (Finanzas Descentralizadas) transformaron el panorama financiero, ofreciendo alternativas descentralizadas de inversión y financiamiento basado en la tecnología blockchain. La pandemia de COVID-19 en 2020 inicialmente causó una caída en los precios, seguida de una recuperación hacia finales de año. El 2021 marcó máximos históricos para varias criptomonedas, especialmente Bitcoin, debido al interés de inversión en grandes empresas. En 2022, desafíos regulatorios y la integración con la economía tradicional marcaron el mercado, mientras que en 2023 se observó una mayor aceptación de criptomonedas como forma de pago. Por lo tanto, este período analizado proporciona una visión integral del desarrollo del mercado de criptomonedas, con eventos clave como la adopción institucional, la volatilidad durante la pandemia de COVID-19 y el surgimiento de nuevas tendencias.

Para lograr este propósito, se han definido los siguientes objetivos específicos: En primer lugar, seleccionar un conjunto de criptomonedas en función de su capitalización de mercado para identificar y priorizar aquellas con mayor rendimiento. Segundo, asegurar la validez de las series de tiempo de las criptomonedas mediante pruebas de estacionariedad, con el fin de mejorar la precisión de los modelos de análisis de volatilidad. Tercero, crear el

portafolio utilizando las criptomonedas identificadas como series estacionarias. Cuarto, aplicar los modelos ARCH y GARCH para determinar cuál de ellos ofrece una mejor representación del comportamiento de la volatilidad del portafolio. Esto permitirá estimar y predecir la volatilidad, proporcionando información crucial para la gestión de riesgos y la toma de decisiones en las inversiones relacionadas con criptomonedas.

Bajo este contexto, es crucial resaltar que la volatilidad hace posible la medición del riesgo asociado a las fluctuaciones en la rentabilidad de los activos, como consecuencia de cambios en los precios, rendimientos o valores dentro de un período de tiempo determinado. Por lo tanto, la importancia de estimarla radica en que una alta volatilidad puede ofrecer la posibilidad de obtener ganancias significativas en un corto período de tiempo, pero también aumenta la posibilidad de pérdidas considerables si los precios no se comportan como se esperaba. Esto es importante para la gestión del riesgo y la toma de decisiones de inversión.

Las hipótesis que sustentan este estudio con el propósito de obtener conclusiones significativas se establecen en base a la hipótesis nula,  $H_0$ : El portafolio de criptomonedas no exhibe estacionariedad en su serie temporal, y la hipótesis alternativa,  $H_1$ : El portafolio de criptomonedas sí muestra estacionariedad en su serie temporal. Estas hipótesis se someten a pruebas estadísticas para determinar su validez y contribuir a las conclusiones del estudio.

La metodología empleada en este estudio se basa en técnicas avanzadas de series temporales para capturar y explicar las variaciones en los datos. Se utilizan modelos estadísticos y econométricos como ARIMA (Modelos Autorregresivos Integrados de Media Móvil), ARCH (Autorregresión Condicionada Heterocedástica), GARCH (Modelos Autorregresivos Condicionales Heterocedásticos Generalizados) y otros modelos de volatilidad para analizar la autocorrelación y la heterocedasticidad en los precios de las criptomonedas.

En cuanto a los resultados obtenidos, el estudio confirma la Hipótesis Alternativa (HA), que postula que el portafolio de criptomonedas sí exhibe estacionariedad en su serie temporal. Esto establece una base sólida para el análisis de la volatilidad y la formulación de estrategias de inversión centradas en estas criptomonedas.

La estructura de esta investigación se organiza de la siguiente manera: en primer lugar, se presenta una revisión de la literatura, donde se destacan los hallazgos más relevantes relacionados con el tema. Luego, en el marco teórico, se exponen las propuestas que han brindado aporte al desarrollo de modelos de series de tiempo y su aplicación tales como: los modelos ARCH de Engle en 1982 y GARCH de Box & Jenkins, 1976. La metodología se describe detalladamente en el cuarto capítulo, donde se analiza el comportamiento del portafolio compuesto por criptomonedas, iniciando con pruebas de estacionariedad que permiten aplicar los modelos de series temporales para comprender y justificar las fluctuaciones en los datos. Finalmente, en las conclusiones, se resumen los hallazgos clave y se discuten las implicaciones de estos resultados, lo que permite ofrecer una perspectiva diferente al momento de analizar la volatilidad de un portafolio y considerar su inclusión en la toma de decisiones de inversión, teniendo en cuenta el riesgo.

## Revisión de la Literatura

La creciente popularidad del mercado de las criptomonedas y el volumen masivo de transacciones que se llevan a cabo han generado un notable interés en entender el comportamiento de estos activos y su relación con los mercados financieros. Según (Fang, y otros, 2022), el interés en las criptomonedas ha experimentado un crecimiento exponencial, especialmente a partir del año 2018, lo que ha llevado al ámbito del comercio financiero a centrar una parte significativa de su estudio e investigación en este mercado, representando un 85% de interés. Este aumento en la atención investigativa coincide de manera destacada con el crecimiento en la capitalización de mercado de las criptomonedas y su amplia aceptación en los últimos años.

Por ende, en la literatura se pueden encontrar diversas metodologías empleadas para analizar la volatilidad de las criptomonedas y su relación con otros mercados.

En primer lugar, en relación con los modelos de series temporales ARCH y GARCH, (Borda, 2000) lleva a cabo una modelización ARCH para estimar la volatilidad del índice bursátil de referencia de la Bolsa de Madrid, el IBEX-35. Utiliza los datos diarios correspondientes al periodo comprendido entre el 2 de enero de 1992 y el 5 de junio de 1999. Siguiendo la metodología propuesta por Engle. Comienza con un contraste en la definición del modelo ARCH a partir del residuo generado por la aplicación de un modelo MA (1) a la serie de estudio. Posteriormente, verifica la presencia de una estructura tipo ARCH contrastando las funciones de autocorrelación para diversas transformaciones de la serie de datos. Observa una correlación significativa, especialmente al examinar los valores al cuadrado y otras potencias asimétricas. Para confirmar esta estructura, analiza la autocorrelación de los residuos mediante el modelo de medias móviles de orden uno,

mostrando un patrón similar al encontrado en los datos originales, lo que refuerza la evidencia de la presencia de una estructura ARCH.

Luego, realiza un análisis comparativo que incluye las variantes de los modelos autorregresivos heterocedásticos condicionales, como el Modelo IGARCH, E-GARCH, GJR-ARCH, el Modelo de cadenas de Markov y SW-ARCH, así como un modelo alternativo GJR-ARCH + ARCH. Verifica si existen diferencias notables en los valores estimados al aplicar cada uno de ellos. Los resultados resaltan que la volatilidad estimada confirma diversos planteamientos teóricos según la aplicación realizada con cada variante, es decir por medio del desarrollo modelizador ARCH. Por ende, la varianza condicional está presente en el proceso de formación de la rentabilidad del activo bursátil, como el IBEX 35, y es un factor a considerar para medir la prima de riesgo, la cual es directamente proporcional a la volatilidad. Es decir, cuando aumenta la varianza condicional, también aumenta la rentabilidad exigida al IBEX 35. Sin embargo, señala que existe un retraso en la aplicación de resultados complejos a las necesidades diarias, ya que la varianza condicional utilizada para calcular la rentabilidad actual es la calculada el día anterior. En conclusión, se destaca que, a pesar de su complejidad, la varianza condicional funciona como una señal de alerta y/o prevención de riesgo bajo la aplicación específica de Modelos ARCH.

En el caso de (Casas Monsegny & Cepeda Cuervo, 2008), comienzan con una descripción detallada de los modelos ARCH, GARCH y EGARCH, con el propósito de establecer una estimación adicional mediante un modelo alternativo para el análisis de series financieras, específicamente estudiando las series de precios y de retornos de las acciones de Gillette. Inicialmente, identifican una variabilidad en la varianza de los retornos de las acciones de Gillette durante el periodo comprendido entre el 4 de enero de 1999 y el 13 de mayo de 2003, junto con variaciones significativas de la volatilidad a lo largo del tiempo. La

selección de cada modelo se basa en el criterio de información de Akaike (AIC) y el criterio de información bayesiana (BIC), con el fin de evitar sobreajustes durante su desarrollo, optando por el modelo con el menor resultado en cada uno de ellos. Tras aplicar cada modelo, observan que los modelos ARCH no cumplen con todos los supuestos, mientras que los modelos GARCH y EGARCH, en general, resultan adecuados para modelar los retornos. Los residuales y sus cuadrados satisfacen el supuesto de no autocorrelación, y los parámetros de la varianza son significativos según los criterios de información AIC y BIC. Como resultado, concluyen que el mejor modelo para explicar el comportamiento de los precios de las acciones es el GARCH, y el modelo EGARCH es el que mejor explica la serie de los retornos. (Gutiérrez Urzúa & Salgado, 2012) en su investigación denominada *Construcción de una cartera de inversión usando modelos GARCH*, procede al análisis de carteras de inversión compuestas por títulos accionarios representado por el índice general de precios de acciones (IGPA) de la Bolsa de Comercio de Santiago de Chile, durante el periodo comprendido entre el 2 de enero de 1995 y el 29 de diciembre de 2000, empleando el modelo de media varianza desarrollado por Harry Markowitz, y usando los modelos GARCH propuestos por Nelson (1991) para estimar las volatilidades de los activos que integrarán cada uno de los portafolios. Posteriormente, comparan el rendimiento de estos portafolios con aquellos conformados utilizando el mismo modelo, pero sin la incorporación de los modelos GARCH en la estimación de la volatilidad, según lo propuesto por Fernández (2006). Dentro de los resultados obtenidos, una observación relevante es que los modelos de cartera que incorporaron matrices de varianza-covarianza condicionales tendieron a mostrar, en su mayoría, retornos promedio superiores en comparación con las carteras que no utilizaron esta información condicional. Esto sugiere que la inclusión de los modelos GARCH en la estimación de la volatilidad condicional podría capturar de manera efectiva la información

del mercado y transferirla al modelo de media varianza. Como resultado, las ponderaciones asignadas a cada activo dentro de la cartera son diferentes cuando se utiliza varianza-covarianza condicional en contraposición a la no condicional.

Continuando con (Jenkins, 2016), en su planteamiento del Modelo GARCH, donde introducen 2 criptomonedas con mayor capitalización como el Bitcoin durante el periodo comprendido entre 18 de Julio de 2010 hasta el 7 de Junio de 2016 y el Ether durante el periodo comprendido entre a 8 de Agosto de 2015 hasta el 7 de Junio de 2016, se enfoca principalmente en la construcción de un modelo predictivo de su rentabilidad y volatilidad, estudiando las propiedades de las series temporales desde la génesis de dichas criptomonedas y estimando un modelo autorregresivo de heterocedasticidad condicionada, en base al cual, presenta una predicción a largo plazo. Basándose en las estimaciones de los modelos GARCH aplicados a las series de Bitcoin y Ether, se realizó una predicción a largo plazo de 100 días utilizando una técnica de remuestreo. Sin embargo, los resultados obtenidos se recomiendan ser interpretados meticulosamente debido a la inestabilidad de los coeficientes estimados y al tamaño reducido de la muestra de las series. Se destaca como una extensión práctica significativa del modelo GARCH su capacidad para calcular y prever la métrica de riesgo VaR (Valor en Riesgo). Esta aplicación del modelo GARCH resalta su utilidad en la evaluación y gestión del riesgo en contextos financieros, ofreciendo una herramienta valiosa para los inversores y analistas del mercado.

El estudio de (Mauricio & Andrés, 2022) se enfoca en analizar el efecto spillover del mercado de criptomonedas, los mercados financieros y commodities durante el período comprendido entre el 26 de enero de 2018 hasta el 31 de diciembre de 2020. Se utilizaron índices de volatilidad de las diez criptomonedas con mayor capitalización de mercado, incluyendo Bitcoin, Ethereum, Binance Coin, Tether, XRP-Ripple, Cardano, Dogecoin,



Litecoin, ChainLink y Stellar. También se consideraron las volatilidades de las cotizaciones del Oro (GVZ) y el Petróleo (OVX), así como los índices de volatilidad del mercado financiero norteamericano (VIX) y europeo (VSTOXX).

El efecto spillover se cuantificó utilizando la metodología propuesta por Diebold y Yilmaz, la cual se basa en técnicas de vectores autorregresivos (VAR) y se conoce como el Spillover Index. Los resultados revelaron que Ethereum es la criptomoneda que más contribuye a la volatilidad del mercado, con un índice de spillover del 100,35%, seguido por Cardano con un 95,14%. Este hallazgo permite identificar que el Bitcoin no domina el mercado, a pesar de su alta capitalización.

Además, se observó que los índices de volatilidad implícita, como VIX y VSTOXX, contribuyen en menos del 3% a la volatilidad de las criptomonedas. Por otro lado, los índices asociados con materias primas como OVX y GVZ no representan una contribución importante a la volatilidad de las criptomonedas. Estos hallazgos proporcionan una visión valiosa sobre la dinámica de los mercados financieros y criptomonedas, destacando la importancia de considerar múltiples factores en el análisis de la volatilidad.

## Marco Teórico

La evolución de las tecnologías de la información ha generado un impacto significativo sobre los sistemas de seguridad empleados en procesos alternativos de emisión monetaria privada y sin intermediación a través de un medio digital, transformando los sistemas con los que se lleva cualquier registro de transacciones y datos, y generando gran influencia sobre los mercados e instituciones (Böhme et al, 2015), dando paso a la creación de nuevos medios de intercambio electrónicos como una nueva alternativa de control para el sistema financiero, siendo uno de estos medios un activo digital denominado criptomoneda.

A pesar de los cambios existentes relacionados con nuevas alternativas de emisión monetaria y la influencia de la tecnología sobre la creación de una moneda digital, es necesario partir del concepto general de dinero de acuerdo con la teoría para evidenciar cuáles son las características y funciones que se incluyen dentro del uso y manejo de las criptomonedas desde su creación e implementación.

A través de la historia se puede evidenciar que el dinero nace como un proceso evolutivo de intercambio de acuerdo con el valor derivado de su origen. Su definición parte de diferentes concepciones según las características relacionadas con la función que cumplía en la sociedad primitiva y actual. En primer lugar, se destaca a uno de los fundadores de la escuela austriaca de economía Carl Menger (1840 - 1921), por sentar las bases para comprender la naturaleza y el origen del dinero, definiéndolo como un medio de intercambio indirecto que surge de una elección voluntaria e individual y sin ninguna planificación social. En consecuencia, el economista austriaco y discípulo de Menger, Ludwig Von Mises (1881 - 1973), argumentó que el dinero no debía definirse por las características físicas de cualquier bien, ya que dicho bien debía considerarse como una mercancía utilizada en los intercambios indirectos para poder desarrollar una actividad.

De acuerdo con cada una de las posturas planteadas por los autores mencionados, para garantizar la empleabilidad del dinero, en términos de intercambio y valor, debe cumplir 3 funciones principales: dinero como medio de cambio, partiendo de su aceptabilidad universal para facilitar el intercambio de bienes y servicios; dinero como unidad de cuenta, constituyendo una medida de valor de los b/s, expresado en unidades monetarias y el dinero como reserva de valor, debido a su función como medio de pago, considerándose un activo líquido que permite mantener un poder adquisitivo estable y constante en el tiempo. Dichas funciones se relacionan y complementan entre sí al momento de ser demostradas, permitiendo que el dinero cumpla su papel en la economía. Como medio de intercambio y unidad de cuenta, facilita el comercio y las transacciones económicas, y su función como reserva de valor proporciona una forma de almacenar valor a lo largo del tiempo, respaldando su aceptación como medio de intercambio. Es importante destacar que históricamente se ha considerado al dinero como un medio de cambio, función que la teoría clásica considera como la más relevante. Adam Smith, uno de sus principales exponentes, concibe al dinero como una parte esencial en la transición de una economía de subsistencia a una economía de intercambio (McLea et al, 2015).

En cuanto a su naturaleza, existen diversos tipos de dinero que varían según el régimen monetario inicial y actual, relacionados con su evolución a lo largo del tiempo. Entre ellos, uno de los más utilizados desde su concepción es el dinero fiduciario, conocido como la moneda convencional. Este tipo de dinero comparte características con las monedas digitales y es el resultado de la evolución histórica de los sistemas monetarios. Es importante señalar que el dinero fiduciario no es una invención moderna, sino que ha existido a lo largo de la historia.

El dinero fiduciario es una moneda emitida por los bancos nacionales y respaldada por los gobiernos. Se considera de curso legal y no está respaldada por un producto físico. Este modelo monetario es centralizado, con la oferta controlada por un banco central gubernamental. Uno de los primeros sistemas de dinero fiduciario moderno fue implementado por el economista británico John Law en el siglo XVIII, quien estableció un banco emisor y promovió el uso de papel moneda respaldado por la confianza en el gobierno y activos reales (Sáez, 2012). Posteriormente, en 1971, en Estados Unidos se llevaron a cabo una serie de cambios en las políticas económicas y de relaciones exteriores por parte del presidente Richard Nixon, lo que resultó en la transición del patrón oro a un sistema fiduciario.

Pese a que el dinero fiduciario es uno de los más dominantes, la historia ha demostrado que ha venido evolucionando, y se han implementado nuevos sistemas mundiales de dinero y de valor de una manera diferente al incluir factores como la confianza para su adopción y la percepción de su utilidad a través de una tecnología subyacente, entre ellos las criptomonedas.

Su definición etimológica está compuesta por el elemento cripto proveniente del griego *kryptós* que significa oculto, cubierto o escondido, vinculado a una raíz indoeuropea (Moreno, 2018) y la palabra moneda proveniente del latín *Moneta*, la cual deriva del verbo *monere* y se define como un medio para facilitar los intercambios. Ahora bien, su origen data a partir del año 1983 al concebir un sistema de protección de información criptográfico monetario denominado eCash por el criptógrafo estadounidense David Chaum, concebido como una especie de dinero electrónico criptográfico anónimo y/o sistema de efectivo electrónico utilizado inicialmente en bancos de Estados Unidos durante el periodo 1955 – 1998 como un sistema de micropagos, encargado de almacenar cantidades de dinero por

medio de un formato digital firmado criptográficamente por la entidad para garantizar la seguridad, confidencialidad e intercambio de cada uno de los datos aplicados dentro de la tecnología utilizada, siendo la criptografía el mecanismo cuya función se basa en la encriptación y protección de datos mediante el uso de códigos que transforman la información que es transmitida y entendida solo por el emisor y receptor, guardando el contenido de la información solo para personas autorizadas; la integridad de datos, evitando todo tipo de alteración de datos no autorizado y la autenticación, relacionada con su identificación.

Posteriormente, en el año 1995 se desarrolló un sistema denominado DigiCash, utilizando la criptografía y un software especializado como medios de seguridad para mantener de manera confidencial los datos del proceso de las transacciones económicas. En 1998 el ingeniero informático especialista en criptografía Wei Dai, propone la creación de un sistema de efectivo electrónico distribuido y anónimo a través de la publicación de su ensayo B-money planteando un objetivo principal basado en el manejo de la contabilidad colectiva por medio de protocolos criptográficos como garantía del correcto desarrollo de las transacciones. Su aporte fue significativo durante la creación y aplicación de la tecnología Blockchain conocida actualmente, como una cadena de bloques de operaciones descentralizada y registrada en una base de datos para acceder a cada uno de los movimientos y transacciones realizados de manera ordenada por parte de los participantes de la red autorizada, siguiendo un protocolo establecido para validar nuevas transacciones, siendo la tecnología más adecuada para adquirir dicha información, brindando datos instantáneos y compartidos (Dávila & Angelis-León, 2022).

Debido a su capacidad descentralizada, ofrece una mayor resistencia a la manipulación y la creación de copias que generen cualquier tipo de fraude, es decir, no

requiere de intermediarios centralizados para verificar la información, ya que se valida de forma integral entre los nodos de la red y su modificación no se puede realizar sin el consentimiento de los demás miembros; facilitando el proceso de registro de transacciones y de seguimiento de los activos. Empíricamente, desde la crisis financiera de Estados Unidos en el 2008 debido a la desestabilización de los mercados financieros a causa de la devaluación del dólar, se pudo evidenciar que las criptomonedas eran una respuesta a la necesidad de una nueva forma de dinero totalmente descentralizada; propuesta planteada por el desarrollador de pseudónimo Satoshi Nakamoto (Nakamoto, 2008), en su artículo “Bitcoin: un sistema de dinero electrónico entre pares”, el cual usa un conjunto de funciones criptográficas y plantea una nueva visión del dinero electrónico a través de una moneda digital denominada Bitcoin.

Ya que las criptomonedas a partir de su creación e implementación son muy recientes, no existe un fundamento teórico establecido que soporte su idea e influencia de manera robusta en la economía. Sin embargo, existen autores que han explorado la relación entre la teoría del dinero y los activos digitales.

Friedrich Hayek, premio Nobel de Economía, en su libro "Desestatización de Dinero" (1976), plantea la idea de que el dinero debe ser producido por el mercado en lugar de ser un monopolio estatal. Aunque Hayek no se refería específicamente a las criptomonedas, sus ideas sobre la competencia en la emisión de dinero y la descentralización tienen afinidad con los principios detrás de las criptomonedas. Adicional a eso, contempla un vínculo con su creación, en términos de competencia entre monedas y la confianza en el emisor; al igual que el dinero en el modelo de Hayek, las criptomonedas no son de curso legal, y su implantación en el mercado se basa en la aceptación voluntaria de las partes; y la confianza en el emisor se sustituye por otros elementos, es decir, en los sistemas de moneda fiduciaria existentes, la credibilidad del emisor ha jugado un papel central, en la obra “Desnacionalización del

dinero”, Hayek propone reemplazar la confianza en un emisor monopólico por la garantía de un proceso competitivo, es decir, por la supervisión mutua de los distintos emisores (públicos y privados) en su lucha por mantener e incrementar su participación de mercado, siendo un comportamiento existente en el mercado de las criptomonedas esto también ocurre, ya que la confianza ha sido reemplazada por la emisión de dinero con un algoritmo inalterable y una prueba criptográfica de transferencia (Nakamoto, 2008).

Posteriormente, Milton Friedman, ganador del Premio Nobel de Economía, planteó en su obra "Elección en Moneda" (1991) la necesidad de adoptar monedas digitales y la posibilidad de que surgieran monedas privadas compitiendo con las monedas estatales. Aunque Friedman no hizo referencia directa a las criptomonedas, sus ideas sentaron las bases para el debate sobre la descentralización del dinero de la siguiente manera:

*“La única cosa que falta, pero que pronto se desarrollará, es una forma segura de dinero electrónico, una forma de transferir fondos de A a B a través de internet, sin que A conozca a B o B conozca a A” Milton Friedman (1991).*

Ahora bien, el interés y la participación en el mercado de criptomonedas se centran en su potencial como herramienta de inversión y en la diversificación de portafolios. Las criptomonedas ofrecen a los inversionistas la oportunidad de diversificar sus activos y distribuir el riesgo, lo que puede resultar en rendimientos potencialmente más altos y una gestión más eficaz del riesgo en comparación con las inversiones tradicionales (Cheah & Fry, 2015).

Posteriormente, su aparición ha planteado desafíos y oportunidades en el ámbito de la inversión. La rentabilidad de una inversión se refiere al beneficio o retorno que se obtiene en relación con el capital invertido y el tiempo. Este concepto es esencial para analizar y gestionar decisiones de inversión a mediano y largo plazo, ya que abarca tanto las ganancias

como las pérdidas. Una inversión se considera rentable cuando logra generar un rendimiento positivo que supere las expectativas o los costos de oportunidad asociados, lo que ayuda a determinar el potencial de ganancias y el nivel de riesgo implicado.

En contraste, el riesgo está relacionado con la posibilidad de que una inversión no alcance la rentabilidad esperada, lo que puede dar lugar a beneficios menores o incluso a la pérdida de una parte o la totalidad de la inversión inicial. Este riesgo se ve influenciado por diversos factores, como la volatilidad del mercado, las condiciones económicas, los riesgos específicos de activos o sectores, y eventos imprevistos. Generalmente, el riesgo y el rendimiento están inversamente relacionados: a mayor riesgo, se espera un mayor potencial de retorno, pero también existe la posibilidad de pérdidas considerables. Los inversores adoptan estrategias como la diversificación y establecen límites de tolerancia al riesgo para encontrar un equilibrio adecuado entre el riesgo asumido y el rendimiento esperado.

Por último, la volatilidad se utiliza como una medida de riesgo derivada de los cambios en la rentabilidad de los activos debido a variaciones en los precios, rendimientos o valores en un intervalo de tiempo determinado. Cuanto más volátil sea un activo, mayor será el nivel de riesgo asociado a él. La alta volatilidad puede ofrecer la posibilidad de obtener ganancias significativas en un corto período de tiempo, pero también aumenta la posibilidad de pérdidas considerables si los precios no se comportan como se esperaba. En consecuencia, la volatilidad es una herramienta valiosa para evaluar y comprender el riesgo vinculado a diferentes activos y carteras de inversión.

De acuerdo con lo anteriormente mencionado, la visión objetiva del inversor parte del estudio de cada uno de los activos que desea dentro de su portafolio para generar la rentabilidad deseada, la cual depende del nivel de riesgo asumido. Por lo tanto, el portafolio debe cumplir con las características acordes con las decisiones del



inversor para definir la distribución de su capital a través de la diversificación en diferentes tipos de inversiones.

La teoría de la inversión y específicamente la de carteras se compone de diferentes estudios realizados por autores cuya base principal era la selección de un portafolio óptimo. Autores como Markowitz, Tobin y Sharpe, desarrollaron modelos que permitían establecer una composición de portafolios con máxima rentabilidad para un determinado nivel de riesgo, o bien, un mínimo riesgo para una rentabilidad mínima esperada. El pionero de la teoría moderna de portafolios es el economista norteamericano Harry Markowitz (1952) al estudiar la relación existente entre el riesgo y la rentabilidad por medio del análisis de la dependencia de la media y la varianza cuyo enfoque principal era la diversificación (Fabozzi, 2008).

Su trabajo se centró en analizar la dependencia de la media y la varianza del valor de una cartera de activos para predecir el comportamiento de los mercados financieros. Propuso la regla del valor esperado-varianza para maximizar el rendimiento esperado y minimizar el riesgo en la asignación de porcentajes de activos en una cartera eficiente empleando una técnica cuantitativa denominada programación cuadrática, asumiendo que si existía un portafolio óptimo con una serie de planteamientos que permitieran alcanzar la rentabilidad esperada; argumento que es posible conseguir un portafolio muy rentable y con poco riesgo tomando los activos de alta rentabilidad y así mismo de alto riesgo, pero con poca correlación de los rendimientos entre sí e incluso con una correlación negativa. También se enfocó en maximizar la utilidad esperada de las riquezas de los inversionistas al seleccionar la mejor combinación entre valor esperado-varianza de los rendimientos de los activos.

### **3.1 Modelos ARCH y GARCH**

Posteriormente, en la década de 1980 se desarrollan los modelos ARCH (Autoregressive Conditional Heteroskedasticity) y GARCH (Generalized Autoregressive Conditional Heteroskedasticity); el modelo ARCH es un modelo estadístico propuesto por Robert Engle en 1982, utilizado para abordar la heteroscedasticidad condicional en series temporales financieras, es decir, la variación en términos de volatilidad en los datos financieros existentes, la cual cambia con el tiempo en respuesta a la información y datos pasados, permitiendo evidenciar períodos de mayor o menor volatilidad en respuesta a eventos del mercado (Brockwell & Davis, 1996).

En consecuencia, surge la extensión del modelo ARCH desarrollado por Tim Bollerslev en la misma década, el modelo GARCH el cual permite capturar patrones más complejos en la volatilidad al incluir términos autorregresivos (AR) en la ecuación. Su principal enfoque se basa en evidenciar que la volatilidad condicional se puede modelar como una combinación lineal de valores pasados de errores cuadrados y valores pasados, con el objetivo de estimar los coeficientes relacionados para modelar y predecir la volatilidad condicional en los datos financieros para evaluar y gestionar el riesgo, así como tomar decisiones informadas dentro del mercado (Brockwell & Davis, 1996).

### **3.2 Teoría Clásica de Series Temporales**

La teoría clásica de series de tiempo constituye un marco fundamental para el análisis y pronóstico de datos temporales en diversos campos, incluyendo economía y finanzas. Según esta teoría, las series de tiempo se componen de tres elementos principales: tendencia, estacionalidad y componente aleatorio (Song & Esogbue, 2006).

En primer lugar, la tendencia se refiere a la dirección general de los datos a lo largo del tiempo. Esta puede ser ascendente, descendente o estable, y puede modelarse mediante

técnicas como el suavizado exponencial o el ajuste de modelos de regresión (Montgomery et al, 2015).

La estacionalidad, por su parte, representa la variación cíclica que se repite en intervalos regulares de tiempo. Esta puede estar influenciada por factores como las estaciones del año, festividades o eventos sociales, y su identificación es crucial para comprender los patrones de comportamiento repetitivos en la serie de tiempo (Montgomery et al, 2015).

Finalmente, el componente aleatorio constituye la parte de la serie de tiempo que no puede ser explicada por la tendencia o la estacionalidad. Este componente representa la variabilidad inherente y el ruido en los datos, y su modelado es esencial para comprender la incertidumbre asociada a la serie de tiempo (Montgomery et al, 2015).

En resumen, la teoría clásica de series de tiempo proporciona un marco analítico robusto para el estudio de datos temporales, permitiendo entender y prever el comportamiento de variables a lo largo del tiempo, así como tomar decisiones fundamentadas en análisis estadísticos rigurosos.

### **3.3 Modelo ARIMA**

El modelo ARIMA es una herramienta ampliamente utilizada en el análisis de series de tiempo para modelar y predecir datos temporales. Este modelo combina tres componentes principales: autoregresión (AR), integración (I) y media móvil (MA) (Box & Jenkins, 1976).

El componente de autoregresión (AR) se refiere a la relación entre una variable y sus valores pasados. En un modelo ARIMA, el término AR representa la dependencia lineal de la variable en estudio con sus propias observaciones pasadas, lo que permite capturar la tendencia y los patrones de autocorrelación en los datos (Hassan, 2014).

La integración (I) se relaciona con el proceso de diferenciación de la serie de tiempo para hacerla estacionaria, es decir, eliminar la tendencia y la estacionalidad presentes en los

datos. La diferenciación se utiliza para convertir una serie no estacionaria en una serie estacionaria, lo que facilita el modelado y la predicción con el modelo ARIMA (Hamilton, 1994). Por último, la media móvil (MA) modela la relación entre una variable y los errores de predicción de observaciones pasadas. Este componente permite capturar la influencia de los errores residuales en las predicciones futuras, ayudando a mejorar la precisión del modelo ARIMA (Hassan, 2014).

En conjunto, el modelo ARIMA proporciona un enfoque flexible y poderoso para el análisis y pronóstico de series de tiempo, permitiendo a los investigadores y analistas entender mejor la dinámica temporal de los datos y realizar predicciones precisas sobre su comportamiento futuro.

## Metodología

Esta investigación se centra en analizar la volatilidad de los precios de las criptomonedas más representativas del mercado, utilizando un enfoque basado en procesos estocásticos. Este enfoque resulta fundamental para el análisis de series temporales, ya que permite no solo examinar el comportamiento histórico de la volatilidad, sino también proyectar posibles tendencias futuras. Esta capacidad de predicción es crucial, ya que ofrece a los inversores herramientas para medir y prever fluctuaciones, ayudándoles así a anticipar riesgos y minimizar pérdidas imprevistas debido a eventos futuros (Rodríguez Pinzón, 2009).

En particular, se enfoca en entender cómo varían los precios de las acciones de las criptomonedas durante el período comprendido entre el 19 de noviembre de 2017 y el 30 de diciembre de 2023, así como su correlación a lo largo de distintos intervalos temporales. Esto permite obtener una comprensión profunda de la dinámica de dichos precios, esencial para la creación de un portafolio diversificado y adecuadamente gestionado en el contexto de inversiones en criptomonedas. Este estudio se apoya en dos modelos de varianza condicional, ARCH y GARCH, con el propósito de analizar la volatilidad en las 10 principales criptomonedas con mayor capitalización. Estos modelos son fundamentales para estimar y predecir la volatilidad, lo que proporciona información esencial para la gestión de riesgos y la toma de decisiones en las inversiones relacionadas con criptomonedas. Ambos modelos se basan en la varianza de las rentabilidades futuras de las criptomonedas para calcular la volatilidad, ofreciendo una visión precisa de la dinámica del mercado. Además, se llevan a cabo análisis estadísticos, incluyendo pruebas de estacionariedad, autocorrelación, auto regresión y correlogramas. Estos análisis son fundamentales para validar la adecuación de los modelos seleccionados y aportar a la metodología del estudio, asegurando que las predicciones sean tanto precisas como confiables.

## 4.1 Estimación del Modelo

A continuación, se presentan las ecuaciones que sustentan los modelos utilizados para analizar y prever el comportamiento de las criptomonedas. Estos modelos estadísticos y econométricos se basan en técnicas avanzadas de series temporales para explicar las variaciones. Conceptos como ARIMA (Modelos Autorregresivos Integrados de Media Móvil), ARCH (Autorregresión Condicionada Heterocedástica) y GARCH (Modelos Autorregresivos Condicionales Heterocedásticos Generalizados) y otros modelos de volatilidad se utilizan para describir la autocorrelación y la heterocedasticidad en los datos de las criptomonedas. Además, se aplican pruebas como Dickey-Fuller y Phillips-Perron, que son fundamentales en el análisis de series temporales para verificar la estacionariedad de los datos.

### 4.1.1 Modelo ARIMA ( $p, d, q$ )

Se define como una combinación lineal de componentes autorregresivos (AR), integrados (I) y de las medias móviles (MA). Siendo el Modelo Autorregresivo Integrado de Medias Móviles. Utilizada en este estudio para modelar la estructura de una serie temporal y realizar predicciones y pronósticos en los valores futuros de la serie. (Ríos, 2008)

Los parámetros que determinan la estructura del modelo ARIMA, respectivamente es:

- $p$ : Indica cuantas observaciones pasadas se incluyen en el modelo, siendo el orden de los términos autorregresivos. (Ríos, 2008)
- $d$ : Indica las veces que se diferencia la serie para lograr la estacionariedad. (Ríos, 2008)

- q: Muestra cuántos errores pasados se incluyen en el modelo de medias móviles (suavizar datos para identificar patrones en la serie temporal). (Ríos, 2008)

Su fórmula general es:

$$Y_t = C + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (1)$$

Donde:  $Y_t$  se expresa como el valor observado en el tiempo (t) del 2017 al 2024; C es una constante que permite representar el precio base del cual fluctúan los datos a lo largo del tiempo;  $\phi_1, \phi_2, \dots, \phi_p$  son los coeficientes en términos autorregresivos que indican cuánto influye la observación anterior;  $\phi_1$  a la observación actual, mientras  $\phi_2$  indica cuánto influye la observación dos periodos anteriores en la observación actual;  $\theta_1, \theta_2, \dots, \theta_q$  explican cómo los errores de predicción pasados afectan en el valor actual de las series temporales, permitiendo comprender la influencia de las fluctuaciones aleatorias en los datos;  $\varepsilon_t$  representa el error blanco, siendo el error en la predicción del valor observado y el valor predicho, y blanco porque son errores aleatorios e independientes de los valores pasados o futuros. (Ramírez et al).

#### 4.1.2 Modelo ARCH(p) en regresión

Engle (1982) le dio el nombre de Modelo Autorregresivo Condicionalmente Heterocedástico. Este modelo permite comprender la variabilidad de la volatilidad en los precios de las criptomonedas, para entender cómo afecta el comportamiento de los precios pasados en el presente, gestionando el riesgo y mejora de la precisión del pronóstico. (Chung Alva, V, 2021)

Su fórmula es la siguiente:

$$\sigma_t^2 = \text{var}(e_t | e_{t-1}, e_{t-2}, \dots) = E \left[ (e_t - E(e_t))^2 | e_{t-1}, e_{t-2}, \dots \right] \quad (2)$$

Dado que  $E(e_t) = 0$ , es:

$$\sigma_t^2 = \text{var}(e_t | e_{t-1}, e_{t-2}, \dots) = E[e_t^2 | e_{t-1}, e_{t-2}, \dots] \quad (3)$$

Donde,  $\sigma_t^2$  es la varianza condicional, es la medida de volatilidad de los precios de criptomonedas en un periodo de tiempo específico;  $e_t$  explicada como la variable aleatoria, esta hace parte de la varianza que no está explicada por los errores pasados y que se mantiene constante a lo largo del tiempo, siendo esencial para capturar la heterocedasticidad condicional en los datos y modelar la volatilidad en series temporales, la variable aleatoria es igual a la variable condicional del cuadrado;  $e_{t-1}$ , esta incluye todos los valores pasados de la serie temporal hasta el presente. (Chung Alva, V, 2021)

#### 4.1.2.1 Autocorrelación de la volatilidad

Según (Chung Alva, V, 2021), Brooks afirmó que “la autocorrelación de la volatilidad se modela permitiendo que la varianza condicional del término error dependa del valor inmediatamente anterior del error al cuadrado” (citado en Chung Alva, V., 2021, p. 2). Esto implica que el error se define como la diferencia entre el valor observado y el valor predicho por el modelo. Por lo tanto, errores cuadrados significativos en el pasado aumentan la varianza del error actual, elevando así su nivel. (Chung Alva, V, 2021) Esto se explica por la forma en que los períodos de alta volatilidad tienden a ser precedidos por períodos igualmente volátiles. La ecuación se expresa así:

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 \quad (4)$$

Donde:  $\sigma_t^2$  es la varianza condicional;  $\alpha_0$ ,  $\alpha_1$  son los parámetros desconocidos que deben ser estimados por los datos observados;  $\alpha_0$  es la varianza mínima del error cuando en el tiempo pasado los errores son cero;  $\alpha_1$  es la varianza de tiempo e indica que la volatilidad



de los precios actuales está explicada por los precios anteriores. Estos parámetros desconocidos permiten maximizar la probabilidad de observar datos reales;  $e_{t-1}^2$  representa la volatilidad ajustada en el periodo presente por la información del periodo pasado. (Chung Alva, V, 2021)

Con el fin de implementar una evaluación robusta de la varianza condicional de los precios de las criptomonedas, se sugiere ajustar la ecuación anterior. Se va a tener en cuenta que  $e_t$  se distribuye normalmente, ya que los valores de esa variable en diferentes momentos del tiempo siguen una distribución normal, con una media igual a cero. La ecuación ajustada se expresa así:

$$\text{Var}(e_t) = \alpha_0 + \alpha_1 e_{t-1}^2 \quad (5)$$

Es decir;

$$e_t \sim N(0, \alpha_0 + e_{t-1}^2) \quad (6)$$

La ecuación (5) se puede explicar como la volatilidad del precio de la criptomoneda cambia a lo largo del tiempo, donde genera un cambio en la varianza del error. Seguido de esto, la ecuación (6) se explica de la siguiente manera. Donde: N representa la distribución normal con media cero, la varianza que incluye una componente constante y la contribución del cuadrado del error en el precio anterior  $e_{t-1}^2$  (Chung Alva, V, 2021).

Según (Chung Alva, V, 2021) Brooks describe la ecuación bajo ARCH cómo “ $r_t$  varía con el tiempo (la ecuación media) podría tomar cualquier forma” (citado en Chung Alva, V., 2021, p. 2). Expresado el modelo como:

$$r_t = \mu + e_t, e_t \sim N(0, \sigma_t^2) \quad (7)$$

Es decir;

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 \quad (8)$$

Donde, en la ecuación (7);  $r_t$  es el rendimiento de una criptomoneda;  $\mu$  representa el valor esperado que es el constante del modelo; la ecuación (8) se modela en función a los errores al cuadrado de periodo anteriores, aunque  $\sigma_t^2$  es una varianza condicional que debe ser expresada siempre con valor positivo, la varianza del error puede depender de varios errores al cuadrado rezagados. Por consiguiente, el modelo ARCH puede incluir múltiples rezagos de error al cuadrado ( $p$  rezagos), permitiendo obtener más patrones de volatilidad en la serie temporal (Chung Alva, V, 2021).

En el modelo ARCH, la ecuación (8) se expresaría según lo mencionado anteriormente de la siguiente manera,

$$\sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2 \quad (9)$$

Donde, sus condiciones  $\alpha_0 > 0$  garantiza que la varianza condicional no sea negativa;  $\alpha_i \geq 0$  para  $i > 0$  esto afirma que la dependencia de la volatilidad del precio en los errores al cuadrado de periodos anteriores no puede generar volatilidades negativas, ya que experimentan movimientos en los precios.

#### 4.1.3 Modelo GARCH ( $p, q$ )

Según (Borda, 2000) el modelo GARCH, es una extensión del modelo ARCH de Engle (1982). Desarrollado por Bollerslev en 1986. El término GARCH representa "Modelo Autorregresivo Generalizado de Heteroscedasticidad Condicional". Según (Borda, 2000), este enfoque modela la varianza condicional como un proceso estocástico estacionario, donde la variabilidad de los datos, condicionada al tiempo  $t$ , depende tanto de los precios pasados como de los errores previos. Es esencial comprender que la varianza condicional sigue una distribución con media cero y desviación típica igual a uno. Además, como señala (Chung Alva, V, 2021) el modelo GARCH se caracteriza por su naturaleza autorregresiva y de

promedio móvil en la modelización de las varianzas condicionales, lo convierte en una herramienta versátil y poderosa para el análisis de la volatilidad en los mercados financieros (Chung Alva, V, 2021).

A continuación, se presentan ecuaciones que explican el modelo GARCH para su aplicación en el portafolio de inversión.

Su fórmula es la siguiente:

$$e_t = \sigma_t E_t \quad (10)$$

$$\sigma_t^2 = \alpha_0 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2 + \beta_1 \sigma_{t-1}^2 + \dots + \beta_p \sigma_{t-p}^2 \quad (11)$$

Donde:  $(p)$  son los coeficientes GARCH conocidos por varianzas rezagadas y  $(q)$  son los coeficientes ARCH conocidos por varianzas cuadradas rezagadas. Esta ecuación modela la varianza condicional en errores del pasado al cuadrado y varianzas cuadradas rezagadas; los coeficientes  $\alpha$  y  $\beta$  que determinan la importancia de ver el tiempo pasado para entender la volatilidad en el tiempo presente (Chung Alva, V, 2021). Por consiguiente;  $\alpha$  indica el aporte de la volatilidad del periodo anterior;  $\beta$  indica el aporte a la nueva volatilidad (tiempo presente) y  $\sigma_{t-1}^2$  representa la volatilidad presente influenciada por el por periodo pasado.

#### 4.1.3.1 La estacionariedad y positividad

Según (Chung Alva, V, 2021) es explicada por las siguientes tres condiciones, pero antes se explica brevemente qué es positividad según (Borda, 2000), la positividad en las estimaciones de la varianza condicional se asegura en nuestro estudio sobre criptomonedas, porque todos los parámetros estimados en la especificación de la varianza son positivos. Esto significa que, al multiplicar estos parámetros por números positivos, como el cuadrado del error y la varianza previa, siempre obtendremos un resultado positivo en el modelo GARCH. Esta característica es crucial para garantizar que la varianza condicional resultante sea

siempre mayor o igual a cero, lo que es esencial para que nuestro modelo sea válido y útil en el análisis de criptomonedas (Borda, 2000).

Ahora bien, se presentan tres condiciones a cumplir:

$$\alpha_0 > 0 \quad (12)$$

$$\alpha \geq 0, \beta \geq 0 \quad (13)$$

$$\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j < 1 \quad (14)$$

La condición (12) establece que, incluso en ausencia de volatilidad en precios pasados, el modelo GARCH generará una varianza condicional positiva en el precio. Esto significa que el modelo puede predecir con precisión las variaciones presentes en el mercado de criptomonedas. La condición (13) asegura que los coeficientes  $\alpha$  y  $\beta$  sean mayores o iguales a cero, lo que garantiza predicciones precisas y realistas. Esta restricción es esencial, ya que tanto los errores pasados como las varianzas pasadas deben contribuir positivamente a la varianza condicional para una modelización efectiva. Finalmente, la condición (14) es una suma de  $\alpha$  y  $\beta$  la cual no debe exceder 1. Si esta suma supera 1, se considera que la volatilidad condicional aumentaría sin límites a medida que avanza en el tiempo. Esta condición asegura que el modelo GARCH produzca resultados coherentes y realistas a lo largo del tiempo, siendo crucial para la precisión de las predicciones y la toma de decisiones en el contexto del mercado de criptomonedas (Chung Alva, V, 2021) (Borda, 2000).

#### 4.1.4 Variables del modelo a emplear

En el marco de esta investigación, se utilizó información proveniente de Yahoo Finance, abarcando el periodo comprendido entre el 19 de noviembre de 2017 y el 30 de diciembre de 2023. Se seleccionó este intervalo temporal para el análisis de datos de las 10

criptomonedas con el fin de modelar el portafolio de inversión. A continuación, se presenta una breve descripción de cada una de estas criptomonedas, con el propósito de facilitar la comprensión de la tabla de estadísticas descriptivas SUM.

*Tabla 1 Criptomonedas empleadas en el análisis.*

Moneda	Ticker	Año	Descripción
Namecoin	NMC-USD	2011	Cumple con una función dual: sistema de nombres de dominio descentralizado y moneda digital utilizada para transacciones en línea.
Binance Coin	BNB-USD	2017	Token de utilidad para reducir las tarifas de transacción en una plataforma de intercambio de criptomonedas llamada Binance Exchange.
Litecoin	LTC-USD	2011	Diseñada con el propósito de ofrecer transacciones rápidas, seguras y económicas.
Cardano	ADA-USD	2017	Permite la realización de transacciones, la participación en la red y el acceso a servicios y productos dentro del ecosistema de Cardano.
Peercoin	PPC-USD	2012	Se utiliza como medio de intercambio digital y destaca por su enfoque en la sostenibilidad y eficiencia energética.
Ethereum	ETH-USD	2015	Ejecuta contratos inteligentes y aplicaciones descentralizadas (dApps) a través de su red.
Dogecoin	DOGE-USD	2013	Se utiliza para llevar a cabo transacciones en línea y para dar propinas a contenido en el web considerado valioso o entretenido.
Ripple	XRP-USD	2012	Se utiliza como un puente entre diferentes monedas fiduciarias y digitales en el proceso de liquidación de pagos.
Tether	USDt-USD	2014	Se utiliza para transferir valor de forma rápida y eficiente y como refugio temporal en períodos de alta volatilidad del mercado.
Bitcoin	BTC-USD	2009	Se emplea para facilitar transacciones en línea seguras y transparentes, así como para preservar valor como una opción de inversión.

*Nota, creación propia de la descripción básica de las criptomonedas a emplear en el análisis.*

**La tabla de estadísticas descriptivas SUM**, como definida por, (Ojeda Cárdenas et al, 2010) se centra en la obtención de parámetros relevantes para la comprensión de la información. Esta rama de la estadística se enfoca en organizar y analizar los datos, presentándolos a través de tablas y gráficos. Su objetivo es resumir las características

esenciales de un conjunto de datos, ofreciendo una visión rápida y clara de su distribución y tendencias.

En este contexto, la tabla de estadísticas descriptivas SUM proporciona parámetros relevantes para cada criptomoneda en el periodo comprendido entre el 19 de noviembre de 2017 y el 30 de diciembre de 2023. Estos parámetros incluyen variables como observaciones, la media de la rentabilidad esperada de cada criptomoneda, la desviación estándar que refleja la volatilidad, el mínimo y el máximo de la rentabilidad. Estos parámetros permiten una comprensión detallada del comportamiento de cada criptomoneda a lo largo del tiempo. Además, se presenta un breve análisis de cada criptomoneda basada en la tabla.

La tabla ofrece un análisis exhaustivo de la rentabilidad de diversas criptomonedas durante el período bajo análisis. Los valores se expresan en notación científica, multiplicados por 10 elevado a la potencia de 10. En algunos casos, la unidad de medida es millones o mil millones de dólares. Algunas criptomonedas, como Namecoin (NMCUSD), muestran una variación significativa en su rentabilidad, con una media negativa y una desviación estándar que refleja una volatilidad considerable en su rendimiento. Su rentabilidad osciló entre -1.81 millones de dólares y 140 millones de dólares. Por otro lado, criptomonedas como Binance USD (BNBUSD) y Ethereum (ETHUSD) exhiben una media positiva, indicando un rendimiento promedio, pero también muestran una alta volatilidad, como lo demuestra su desviación estándar. Para BNB-USD, el valor mínimo fue de -16.9 mil millones de dólares y el máximo de 13.7 millones de dólares. En cuanto a ETHUSD, sus valores oscilaron entre -91.9 mil millones de dólares y 53.4 mil millones de dólares.

Por otro lado, se evidencian criptomonedas como Dogecoin (DOGEUSD) y Ripple (XRPUSD) que muestran medias cercanas a cero, lo que sugiere un rendimiento más estable en comparación con otras criptomonedas. Sin embargo, su alta desviación estándar indica

que también experimentan una volatilidad significativa en su rendimiento. Para DOGEUSD, su valor mínimo fue de -14.2992 millones de dólares y su valor máximo fue de 18.3663 millones de dólares. Respecto a XRPUSD, su valor mínimo fue de -92.16 millones de dólares y su valor máximo fue de 78.372 millones de dólares.

Se presenta la tabla 2:

*Tabla 2 Estadísticas descriptivas SUM*

Variable	Observaciones	Media	Desviación Estándar	Min.	Max.
R_NMCUSD	2,234	-71742.57	2.12e+07	-1.81e+08	1.40e+08
R-BNBUSD	2,234	1.39e+07	1.18e+09	-1.69e+10	1.37e+10
R-LTCUSD	2,234	141214.8	7.62e+08	-1.05e+10	1.02e+10
R-ADAUSD	2,291	.0245839	4.451389	-52.1141	40.8669
R-PPCUSD	3,390	-49713.26	1.45e+07	-2.29e+08	1.64e+08
R-ETHUSD	2,233	8.71e+07	7.47e+09	-9.19e+10	5.34e+10
R- DOGEUSD	2,291	.0040155	1.101192	-14.2992	18.3663
R-XRPUSD	2,291	.0144343	5.225302	-92.16	78.372
R-USDTUSD	2,234	-44866.11	4.31e+07	-1.05e+08	1.05e+08
R-BTCUSD	2,234	1.54e+09	9.61e+10	-7.55e11	7.29e+11

*Nota. Elaboración propia en base a las rentabilidades y volatilidad de las criptomonedas. Resume las características esenciales de un conjunto de datos.*

Esta tabla proporciona información de la rentabilidad y la volatilidad de criptomonedas para evaluar el riesgo y las oportunidades de inversión asociadas con cada una de ellas, así como para desarrollar estrategias efectivas de gestión de portafolios con el fin de desarrollar un análisis más detallado con decisiones informadas sobre inversiones en criptomonedas.

## **4.2 Pruebas estacionariedad modelado en Stata**

### **4.2.1 Correlograma**

Según (Granados, 2013), el correlograma proporciona una visualización crucial para comprender el comportamiento de una variable. (Granados, 2013) Un correlograma con un descenso lento indica que las variables son no estacionarias, mientras que un descenso rápido

señala estacionariedad en las variables. Se expresa el correlograma de la siguiente manera, teniendo en cuenta que el correlograma es una función de autocorrelación.

$$P_k = \frac{cov(x_t, x_{t+k})}{\sqrt{var(x_t)var(x_{t+k})}}; \forall k = 1, \dots, m \quad (15)$$

Donde:  $P_k$  es el coeficiente de autocorrelación en el rezago de  $k$  periodos de tiempo;  $cov(x_t, x_{t+k})$  mide la covarianza entre los precios de las criptomonedas en dos momentos diferentes y su fluctuación en conjunto;  $var(x_t)$  indica la varianza de la dispersión de los precios de las criptomonedas en un periodo;  $var(x_{t+k})$  se refiera a la varianza de la dispersión de los precios de las criptomonedas hasta  $k$  periodos.

La fórmula explicada por (Granados, 2013), compara la covarianza entre dos periodos de tiempo distintos (numerador) con la raíz cuadrada del producto de las varianzas de esas observaciones (denominador). Un valor a -1 indica una correlación negativa, mientras un valor 1 indica una correlación positiva, si el valor es cercano a 0 indica una correlación débil o inexistente entre los precios de las criptomonedas en el periodo de tiempo. (Granados, 2013). Ver los resultados de esta prueba en el Anexo A.

#### 4.2.2 Dickey-Fuller (1979,1984)

Para llevar a cabo el análisis de estacionariedad en una serie temporal, se recurre a la prueba Dickey-Fuller Aumentado (ADF) desarrollado por Dickey y Fuller en 1979. Este método se utiliza para determinar si una serie temporal es estacionaria o no. El fundamento central de la prueba se basa en la hipótesis nula de que la serie presenta una raíz unitaria, lo que implica que es no estacionaria. La principal utilidad del ADF está en su capacidad para determinar el número de diferencias necesarias para convertir la serie en un proceso estacionario (Ramírez et al).



La prueba de hipótesis asociada a Dickey-Fuller aumentada tiene como hipótesis nula  $H_0: r = 0$  y como hipótesis alternativa  $H_1: r \neq 0$ , donde  $r$  representa el coeficiente de raíz unitaria. Bajo esta premisa, se evalúa si la serie temporal posee una raíz unitaria. Si no se puede rechazar la hipótesis nula reflejada en un valor ( $p\text{-valor} > 0.05$ ), se concluye que la serie es no estacionaria y posee una raíz unitaria. Por el contrario, si la hipótesis nula es rechazada, reflejada por un valor ( $p\text{-valor} < 0.05$ ), se establece que la serie es estacionaria y no posee raíz unitaria. Este resultado proporciona una base sólida para el análisis subsiguiente de la serie temporal (Jenkins, 2016).

La prueba se expresa con la siguiente ecuación:

$$dx_t = \alpha_0 + r x_{t+1} + \alpha_1 t + \sum_{i=1}^p b dx_{t-i} + u_t \quad (16)$$

Donde:  $dx_t$  indica la diferencia entre el precio del periodo anterior y el precio del periodo actual;  $\alpha_0$  representa el precio base de la criptomoneda para predecir su comportamiento;  $r$  indica la raíz unitaria, siendo la influencia del valor anterior en valor actual;  $x_{t+1}$  es el precio de un periodo anterior de la criptomoneda;  $\alpha_1 t$  implica que hay un efecto de tendencia en el precio de la criptomoneda en el periodo de tiempo a analizar;  $\sum_{i=1}^p b dx_{t-i}$  se agrega esta suma de la formula general de Dickey-Fuller sin aumento, representa la suma de las variaciones de los precios de las criptomonedas en  $p$  periodos anteriores. Esta inclusión ayuda a mejorar la precisión de las predicciones (autocorrelación) considerando cómo los errores en las predicciones pasadas afectan a las actuales. Ver los resultados de esta prueba en el Anexo B.

### 4.2.3 Phillips y Perron (1988)

Según los investigadores (Tomás et al, 2013) las pruebas de raíz unitaria de Phillips-Perron (PP) son herramientas fundamentales para abordar la correlación serial en series temporales, sin depender de parámetros. Estas pruebas se destacan por su capacidad para estimar la varianza a largo plazo de manera constante en el proceso de error.

A diferencia de la prueba Dickey-Fuller, las pruebas Phillips-Perron tienen ventajas significativas:

- Rechazan la hipótesis nula  $H_0$  de no estacionariedad cuando el valor de (p-valor > 0.05) (Tomás et al, 2013).
- Incorporan rezagos en la prueba, lo que aumenta su capacidad para detectar patrones en los datos (Tomás et al, 2013).

Al concluir que una serie es estacionaria, se implica que su media y varianza son constantes a lo largo del tiempo, mientras que el ruido blanco, un proceso estocástico, se caracteriza por observaciones independientes e idénticamente distribuidas. La raíz unitaria nula señala la estacionariedad en niveles de la serie, lo que aporta claridad al análisis de tendencias y estacionariedad en los datos. (Granados, 2013).

La ecuación se expresa de la siguiente manera:

$$Z_p = n(\hat{P}_n - 1) - \frac{1}{2} \frac{n^2 \hat{\sigma}^2}{S_n^2} (\hat{\lambda}_n^2 - \hat{\gamma}_{0,n}) \quad (17)$$

$$Z_t = \sqrt{\frac{\hat{\gamma}_{0,n} \hat{P}_n - 1}{\hat{\lambda}_n^2 \hat{\sigma}^2}} - \frac{1}{2} (\hat{\lambda}_n^2 - \hat{\gamma}_{0,n}) \frac{1}{\hat{\lambda}_n} \frac{n \hat{\sigma}}{S_n} \quad (18)$$

Donde:  $Z_p$  y  $Z_t$  son dos parámetros que calcula si una serie tiene raíz unitaria, bajo la hipótesis nula de presencia de no estacionariedad en los datos;  $\hat{P}_n$  indica la variación de errores;  $\hat{\sigma}^2$  es la varianza estimada, es decir, la volatilidad del precio de la criptomoneda;  $S_n^2$

es la suma al cuadrado de los errores hallados en el modelo;  $\hat{\lambda}_n^2$  refleja la velocidad de tendencia de los precios de las criptomonedas;  $\hat{\gamma}_{0,n}$  explica si los precios de las criptomonedas están por debajo o por encima de la media. Ver los resultados de esta prueba en el Anexo C.

### **Hechos estilizados**

El estudio de la volatilidad en los mercados financieros es fundamental para la creación y gestión de portafolios de inversión. En el ámbito de las criptomonedas, caracterizado por su alta volatilidad, entender estas fluctuaciones se convierte en un pilar crucial para la evaluación de estrategias de inversión robustas y diversificadas. Este trabajo se centra en analizar la volatilidad de las criptomonedas con el objetivo de ofrecer un aporte significativo a la Teoría de la Generación de Portafolios Financieros basados en principios de maximización de retornos y minimización de riesgos por medio de modelos estadísticos avanzados de series temporales, como ARCH (Auto-Regresión Condicional Heterocedástica) y GARCH (Heterocedasticidad Condicional Autorregresiva Generalizada).

Utilizando datos de Yahoo Finance, la volatilidad se calcula a través de la desviación estándar de los retornos diarios. Este enfoque permite identificar períodos de alta y baja volatilidad, cruciales para decidir la asignación de activos en un portafolio. Los hechos estilizados extraídos de este análisis ayudarán a los inversores a entender mejor cuándo y cómo ajustar sus posiciones en el mercado de criptomonedas.

El entendimiento profundo de la volatilidad de las criptomonedas capacita a los inversores para tomar decisiones fundamentadas sobre la diversificación de sus portafolios, la gestión de riesgos y el momento oportuno para comprar o vender activos, con el propósito de optimizar ganancias y reducir pérdidas. Esta metodología posibilita la identificación de

tendencias de comportamiento y la anticipación de fluctuaciones futuras, elementos claves para la toma de decisiones informadas en la gestión de portafolios de inversión.

A lo largo de los últimos seis años, las criptomonedas han demostrado una volatilidad significativa, influenciada por factores económicos, tecnológicos y regulatorios. Se pueden identificar dos periodos distintivos que han marcado la dinámica de esta volatilidad. El comportamiento de las criptomonedas sugiere que están sujetas a un análisis de series temporales mediante un proceso estocástico estacionario, definido por (Borda, 2000) como una sucesión ordenada de variables aleatorias cuya función de distribución es invariable ante intervalos igualmente espaciados. Por lo tanto, cuando la volatilidad se acerca a cero en un gráfico, indica que la serie exhibe poca variabilidad en su comportamiento a lo largo del tiempo, lo que podría indicar estacionariedad, ya que la serie se mantiene en torno a un valor constante.

Este fenómeno se observa en el primer periodo distintivo que marca la dinámica de la volatilidad de las criptomonedas, desde el 19 de noviembre de 2017 hasta finales de 2020. Durante este tiempo, se destaca que las criptomonedas mantuvieron una varianza constante, lo que indica que tanto la media como la varianza de sus precios se mantuvieron estables. Esta estacionariedad proporciona a los inversores una mayor seguridad para la inversión, minimizando el riesgo y potenciando la rentabilidad.

La estabilidad observada puede atribuirse parcialmente a que el mercado de criptomonedas, siendo aun relativamente joven, experimentó durante este periodo una adopción y participación institucional más consolidada. Esta maduración del mercado permitió a los inversores familiarizarse, estudiar y comprender mejor el funcionamiento de las criptomonedas. En apoyo a esta observación, el informe trimestral de 2018 del Banco de Pagos Internacionales (BIS) analiza cómo las noticias regulatorias afectaron el precio de las

criptomonedas, especialmente el del Bitcoin. Según este informe, a pesar de que hubo un aumento en los precios impulsado por la percepción favorable hacia la naturaleza jurídica de la criptomoneda, el régimen regulatorio ligero y descentralizado en ese momento no representó un riesgo para la estabilidad financiera global (Claessens, 2018).


Este contexto sugiere que, aunque hubo un aumento en los precios, la variación general durante este periodo se mantuvo cerca de la media, aportando estabilidad y rentabilidad en los precios y fomentando una confianza descentralizada entre los inversores. La combinación de factores como la estabilidad regulatoria, la maduración del mercado y la participación institucional influyó significativamente en mantener la estabilidad de las criptomonedas durante estos años críticos.

Durante el segundo periodo distintivo, que abarca desde mediados de 2020 hasta mediados de 2022, se observa un aumento significativo en la volatilidad de las criptomonedas, impulsado por eventos macroeconómicos y geopolíticos. La crisis sanitaria y económica desencadenada por la pandemia mundial afectó la percepción de los inversores, generando fluctuaciones más pronunciadas en los precios. Además, los avances tecnológicos en blockchain y la creciente adopción de criptomonedas a nivel global han suscitado especulaciones sobre el futuro del mercado financiero.


Este cambio se refleja en la transición de los agentes económicos hacia los mercados digitales, abandonando progresivamente los mercados analógicos. La pandemia ha acelerado esta tendencia, evidenciando una mayor demanda de bienes y servicios a través de canales digitales en comparación con los analógicos. Esta migración hacia lo digital ha llevado a una disminución del uso de moneda física, exacerbando la alta volatilidad que se observa en el gráfico 1.

## Gráfica 1. Volatilidad


Volatilidad, Namecoin USD (NMC-USD).




Volatilidad, Binance USD (BNB-USD).



Volatilidad, Litecoin USD (LTC-USD).




Volatilidad, Cardona USD (ADA-USD).




Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance.


Volatilidad, Peercoin USD (PPC-USD).




Volatilidad, Ethereum (ETH-USD)



Volatilidad, Dogecoin (DOGE-USD).




Volatilidad, Ripple (XRP-USD)




Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance.

Volatilidad, Tether USDt USD (USDt-USD).



Volatilidad, Bitcoin (BTC-USD).



Nota: Elaboración propia con datos tomados de Yahoo Finance. Nota: Elaboración propia con datos tomados de Yahoo Finance.

Nota, elaboración propia con datos tomados de Yahoo Finance de los precios de las criptomonedas en el periodo 19 de noviembre de 2017 hasta 30 de diciembre del 2023.

## Materiales y Métodos Subtitulo

Esta es una investigación correlacional-inferencial, también analiza el comportamiento de crypto activos en una serie temporal. El proceso estacionario aplicado en este trabajo analiza la volatilidad de los precios de las criptomonedas en el periodo 19 de noviembre de 2017 y el 30 de diciembre de 2023, obteniendo un total de 2.233 observaciones. Los resultados obtenidos se presentarán en un portafolio que se calculó de la siguiente manera, formula de portafolio:  $NMC - USD * 0.1 + BNB + USD * 0.1 + LTC + USD *$

$0.1 + ADA - USD * 0.1 + PPC - USD * 0.1 + ETH - USD * 0.1 + DOGE - USD * 0.1 + XRP - USD * 0.1 + USDT - USD * 0.1 + BTC - USD * 0.1$ . La recolección de datos diarios se obtuvo de los registros de Yahoo Finance. Para el análisis de Datos se aplicaron modelos de series de tiempo que aportan claridad al análisis de tendencias y estacionalidad en los datos, tales como, ARCH, GARCH, Dicker-Fuller y Phillips-Perron. Los resultados que se exponen se obtuvieron utilizando el Software estadístico Stata para la estimar el modelo.

## **Resultados**

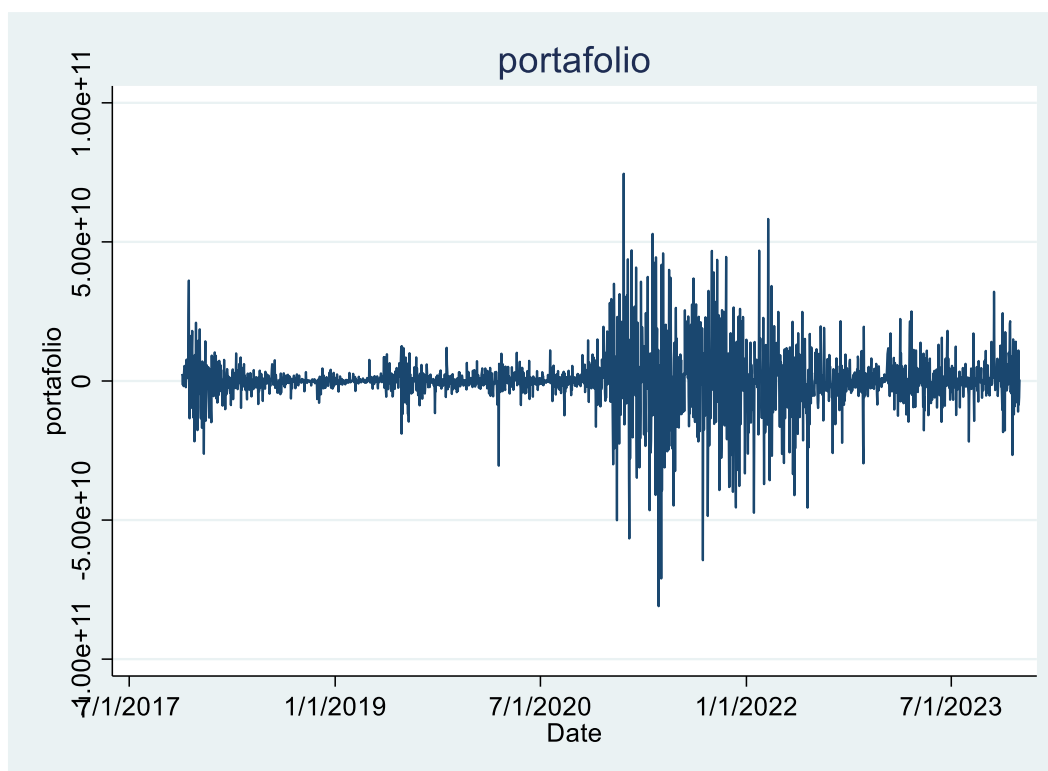
En esta sección se estiman y seleccionan los modelos ARIMA-ARCH-GARCH que se ajustan a las 10 criptomonedas analizadas en el estudio, se presentan resultados de cada modelo de series de tiempo aplicado para la creación del portafolio de inversión de criptomonedas.

### ***6.1 Análisis Descriptivo***

Iniciamos nuestro estudio analizando la volatilidad del portafolio antes de la aplicación de los modelos de series de tiempo. Para ello, consideramos un periodo que abarca desde el 19 de noviembre de 2017 hasta el 30 de diciembre de 2023, con un total de 2.233 observaciones. Esta representación visual se obtiene tras cargar los datos diarios en Stata y generar los gráficos de volatilidad individuales de cada criptomoneda, como se observa en la gráfica 1. Stata es una herramienta que recopila de manera automatizada toda la información relevante de cada criptomoneda, incluyendo sus series temporales. De este modo, se consolida la información de las distintas criptomonedas para crear un único gráfico que ilustre el comportamiento del portafolio en su conjunto.



*Gráfica 2 Volatilidad Portafolio*



*Nota, elaboración propia de volatilidad de portafolio sin la estimación de un modelo. Datos tomados de Yahoo Finance de los precios de las criptomonedas en el periodo 19 de noviembre de 2017 hasta 30 de diciembre del 2023.*

Podemos observar en la gráfica 2 una marcada variabilidad en la volatilidad a lo largo del período analizado, lo que refleja la naturaleza dinámica y cambiante de los mercados de criptomonedas.

Un aspecto relevante observado en los datos es la agrupación de volatilidad, como se mencionó en la metodología, donde la volatilidad actual de las criptomonedas tiende a correlacionarse positivamente con su nivel en períodos anteriores. Este fenómeno implica que grandes fluctuaciones en los precios de los activos son seguidas por cambios similares en magnitud, mientras que los cambios menores tienden a ser seguidos por ajustes igualmente suaves. Esta característica sugiere una mayor probabilidad de cometer errores significativos en la predicción, lo que contribuye a mantener una alta volatilidad en el futuro.

La gráfica 2 proporciona una visualización de la volatilidad en los precios de las criptomonedas durante el período de análisis. Se destacan varios hallazgos importantes sobre la volatilidad observada: Durante los años 2017 hasta mediados del 2020, se identifica una volatilidad relativamente baja, con las fluctuaciones de precios manteniéndose cerca de la media. Este período estuvo caracterizado por retornos en su mayoría positivos, indicando un mercado relativamente estable con oportunidades favorables para los inversores.

Por el contrario, desde mediados del 2020 hasta enero del 2024, se observa un aumento notable en la volatilidad. Durante este lapso, se registraron tanto grandes ganancias como grandes pérdidas en un corto intervalo de tiempo. Este incremento en la volatilidad puede atribuirse, según lo señalado por Chung Alva (2021), a una mayor correlación entre los datos. Es decir, los movimientos de precios de diferentes criptomonedas están más interconectados, lo que puede intensificar tanto los retornos positivos como las pérdidas. (Chung Alva, V, 2021).

Estos hallazgos resaltan la importancia de comprender y modelar adecuadamente la volatilidad en el análisis económico de activos financieros, particularmente en un entorno tan volátil como el de las criptomonedas. La correlación entre sus precios tiene implicaciones significativas para los inversores, subrayando la importancia de una comprensión profunda de estos fenómenos para desarrollar estrategias de inversión que permitan gestionar y anticipar pérdidas.

## ***6.1 Resultados de la Estimación de los modelos***

### ***6.1.1 Resultado de la regresión de ARIMA portafolio (1.1)***

La tabla 3 ilustra el aporte de cada parámetro del modelo ARIMA (Modelos Autorregresivos Integrados de Media Móvil), se modelo con datos de series temporales de

precio diario de las criptomonedas, se toma la muestra desde el 19 de noviembre de 2017 y el 30 de diciembre de 2023, obteniendo un total de observaciones de 2.233.

*Tabla 3 Resultado de la regresión de ARIMA portafolio*

Portafolio	Coef.	OPG Std. Err.	Z	P> z	[95% Conf.	Interval]
ARIMA regresión						
Muestra: 11/19/2017 - 12/30/2023						
Logaritmo de la verosimilitud = -54652.47						
Número de Obs = 2.233						
Wald chi2(2) = 213.41						
Prob > chi2 = 0.0000						
Portafolio	Coef.	OPG Std. Err.	Z	P> z	[95% Conf.	Interval]
Portafolio						
_cons	1.67e+08	2.53e+08	0.66	0.510	-3.29e+08	6.63e+08
ARMA						
ar						
L3.	.8439903	.0956249	8.83	0.000	.6565689	1.031412
ma						
L3.	-.8200671	.1023726	-8.01	0.000	-1.020714	-.6194205
/sigma	1.03e+10	6.35e+07	162.24	0.000	1.02e+10	1.04e+10

*Nota, elaboración propia de los resultados de la estimación de la regresión de ARIMA portafolio.*

La estimación del portafolio en el modelo ARIMA revela resultados significativos que ofrecen una comprensión más profunda de su comportamiento. El análisis del Wald chi2(2) muestra un valor elevado de 213.41 con 2 grados de libertad, y una probabilidad asociada de 0.0000, lo que indica un alto nivel de significancia. En cuanto a los coeficientes y estadísticas asociadas al modelo, el término constante del portafolio \_cons representa su media constante. Su valor  $p > |z|$  de 0.510 indica que no es significativo al nivel del 95% de confianza. Sin embargo, los coeficientes de los términos autorregresivos (AR) y de medias móviles (MA) muestran una significancia estadística notable, con los valores que presenta  $p > |z|$  de 0.000. El error estándar para el término AR es .0956249, con un valor Z de 8.83, que mide el rango que se encuentra de las desviaciones estándar y el valor esperado para aceptar la hipótesis nula igual a 0. El intervalo de confianza del 95% para este coeficiente va desde .6565689 hasta 1.031412. Para el término de medias móviles MA, el valor Z es de -8.01,

sugiriendo que su coeficiente es significativamente menor que cero. Esto subraya la importancia de las medias móviles en la predicción del comportamiento del portafolio de inversión en criptomonedas. Este análisis ARIMA confirma lo mencionado en el apartado 4.1.1; la dependencia del portafolio de sus propios errores pasados para predecir su comportamiento futuro permite comprender y pronosticar las tendencias en los datos del portafolio.

### 6.1.2 Resultados de la regresión de la familia ARCH portafolio (1.2 y 1.3)

El análisis de regresión de la familia ARCH (Modelo Autorregresivo Condicionalmente Heterocedástico) es una herramienta fundamental para modelar la volatilidad condicional en el portafolio de inversión de criptomonedas y para predecir los precios en este mercado. Estos resultados permiten comprender la relación entre las variables y la volatilidad del portafolio, así como la significancia estadística de los coeficientes estimados.

*Tabla 4 Resultados de la regresión de la familia ARCH portafolio*

Regresión de la familia ARCH	
Muestra: 11/19/2017 -12/30/2023	Número de Obs = 2.233
Distribución: Gaussian	Wald chi2(.) = .
Logaritmo de la verosimilitud = -53489.89	Prob > chi2 = .

portafolio	Coef.	OPG Std. Err.	Z	P> z	[95% Conf.	Interval]
portafolio						
_cons	6.19e+07	8.29e+07	0.74	0.457	-1.01e+08	2.24e+08
ARCH						
arch						
L1.	.0828802	.0036208	22.89	0.000	.0757835	.0899769
garch						
L1.	.9228842	.0025633	360.05	0.000	.9178602	.9279082
_cons	1.31e+17					

*Nota, elaboración propia de los resultados de la estimación de la regresión de la familia ARCH portafolio.*

El análisis de regresión dentro de la Familia ARCH aplicado durante el período de estudio, empleó una distribución Gaussiana. Esta elección permite modelar los errores asumiendo una distribución normal, caracterizada por su media y desviación estándar. Los errores estándar robustos (OPG Std. Err.) se calcularon para mejorar la precisión de la estimación de los coeficientes.

El coeficiente Arch L1 es lag rezago, con un valor estimado de 0.0828802, refleja el impacto del valor de la serie temporal en el período actual debido a su volatilidad en el período anterior. Su correspondiente OPG Std. Err. es de 0.0036208. El valor Z, calculado en 22.89 desviaciones estándar, muestra una marcada diferencia respecto a cero. Con un valor de  $P > |z|$  de 0.000, se confirma su significancia estadística. El intervalo de confianza, de 0.0757835 a 0.0899769, proporciona una estimación precisa del coeficiente con un 95% de confianza, validando la relevancia del modelo.

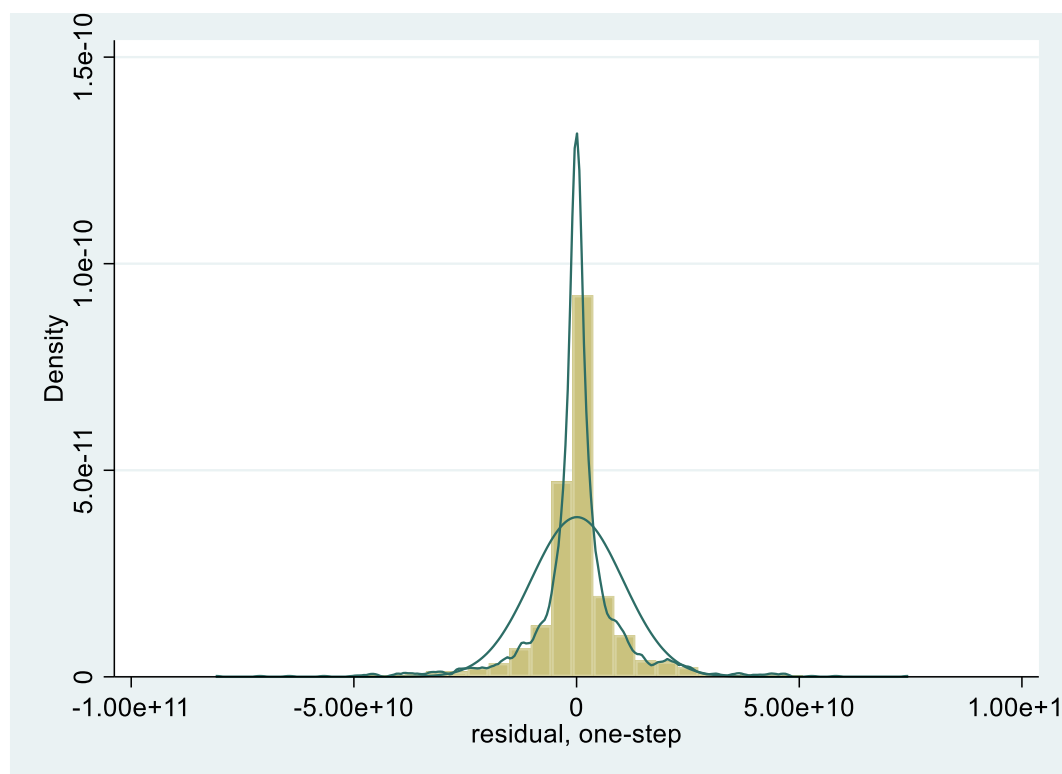
Para el coeficiente Garch L1, el valor Z, muy alejado de cero (360.05 veces su error estándar), y el intervalo de confianza (0.9178602 a 0.9279082), refuerzan su fuerte asociación con la volatilidad del modelo. Esto indica que la volatilidad de los precios de criptomonedas en un período influye significativamente en la volatilidad en el período actual, corroborando su relevancia estadística y coherencia con los resultados previamente discutidos. La variable Cons se representa con la siguiente ecuación:

$$Y = 1.31E + 17 + .9228842Y_{t-1} + \mu_t \quad (19)$$

### 6.1.3 Resultados prueba de Histograma Portafolio

La grafica a continuación del histograma del portafolio se utiliza para visualizar la distribución de rendimientos o perdidas dentro de las criptomonedas, a su vez para evaluar la volatilidad del portafolio diversificado de criptomonedas.

Gráfica 3 Histograma Portafolio



*Nota, elaboración propia de histograma. Suma de rendimientos diarios de las criptomonedas presentadas en el portafolio.*

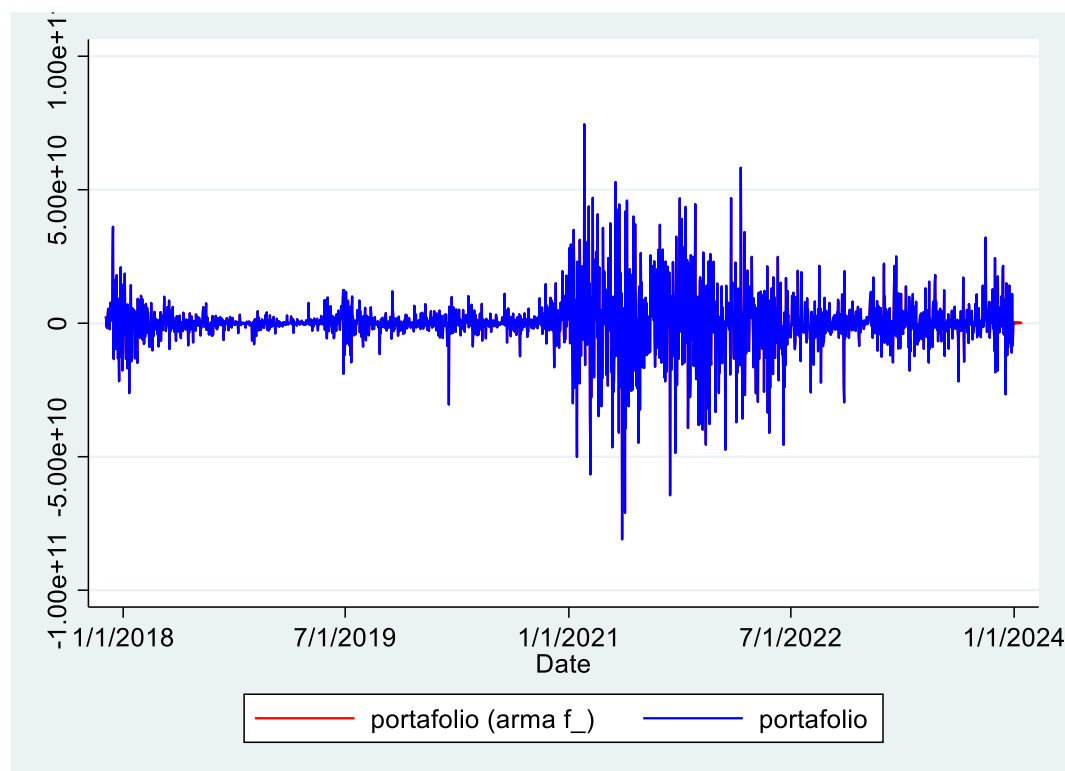
La creación de este histograma se llevó a cabo sumando los rendimientos diarios de las diversas criptomonedas en el portafolio. En el eje X, se representan los diferentes rangos de rendimientos, mientras que en el eje Y se muestra la frecuencia con la que ocurre un rendimiento dentro de cada rango. Este análisis nos permite entender la distribución de los rendimientos del portafolio, contribuyendo a los inversores comprender mejor el perfil de riesgo y rendimiento de su inversión. Los resultados de este histograma muestran que el comportamiento del portafolio diversificado no sigue una distribución normal, lo que implica que la probabilidad de ganar o perder no es equitativa, como sería el caso en una distribución gaussiana normal. Esto se evidencia en la media de los rendimientos, que es igual a cero, lo que indica que, en promedio, el portafolio no genera ni ganancias ni pérdidas. Sin embargo,

el histograma revela una tendencia hacia pérdidas al invertir en este portafolio. Las colas de la distribución se inclinan hacia valores negativos, lo que indica una probabilidad más alta de pérdidas que de ganancias. Esta asimetría en la distribución sugiere un mayor riesgo de pérdida para los inversores que participan en este portafolio diversificado de criptomonedas. En resumen, la presencia de una media cero y una distribución no normal en el histograma indica un alto riesgo de pérdida para los inversionistas, en otras palabras, es una serie con presencia de leptocurtosis en el portafolio.

#### *6.1.4 Resultado final de volatilidad del portafolio*

La gráfica de volatilidad del portafolio utiliza el modelo GARCH (Modelo Autorregresivo Generalizado de Heteroscedasticidad Condicional) para estimar el comportamiento de la volatilidad. Este modelo permite modelar la volatilidad del portafolio, donde la volatilidad en un período actual depende de los errores al cuadrado de períodos anteriores. Además, incorpora para establecer el comportamiento de la variable portafolio, se utiliza el modelo ARIMA. En este contexto, la variable dependiente se explica mediante un tiempo anterior AR1, mientras que los errores del modelo se explican a través de un modelo MA1. Esto permite obtener el modelo ARMA F para el análisis; donde F representa el pronóstico. La gráfica muestra la evolución y las fluctuaciones de la volatilidad del portafolio durante el período analizado utilizando datos diarios para su estimación.

Gráfica 4 Resultado gráficos de validación predictiva



*Nota, elaboración propia de resultados gráficos de la validación predictiva. Modelado con GARCH y pronosticado con AR1 y MA1 (línea roja); volatilidad sin la estimación de un modelo (línea azul).*

Los resultados obtenidos del análisis de volatilidad de un portafolio de criptomonedas aplicando el modelo GARCH, como señala (Chung Alva, V, 2021) el cual se caracteriza por su naturaleza autorregresiva y de promedio móvil en la modelización de las varianzas condicionales, lo convierte en una herramienta versátil y poderosa para el análisis de la volatilidad en los mercados financieros, proporcionando de forma clara la interpretación de la volatilidad y precisión en el comportamiento de la volatilidad. Este modelo, refleja lo explicado anteriormente en la metodología acerca de los parámetros  $p$  y  $q$ ;  $p$  indica su dependencia de la volatilidad al cuadrado de periodos de tiempos anteriores;  $q$  indica su dependencia de varianza al cuadrado de los errores pasados de la volatilidad.



El gráfico brinda la representación de la volatilidad, con dos líneas distintas: una roja, que representa la volatilidad estimada mediante el modelo GARCH con el ARMA F y la línea azul, muestra la volatilidad del portafolio sin la estimación de un modelo. La línea de volatilidad estimada refleja cómo la volatilidad del portafolio fluctúa a medida que transcurre el tiempo, gracias a las estimaciones autorregresivas AR1 y media móvil MA1. Esta línea también presenta una volatilidad condicional, lo que indica que se espera que la volatilidad cambie en el futuro, teniendo en cuenta los errores de tiempo pasado y presente. Estos resultados señalan cambios significativos en la volatilidad del portafolio, evidenciados por picos y valles pronunciados en la línea roja, indicando la volatilidad real del portafolio. Al comparar con la línea azul se observa que ambas reflejan la misma aleatoriedad en los datos del portafolio, sugiriendo que el modelo GARCH es idóneo para explicar y predecir de manera efectiva la volatilidad del portafolio de criptomonedas. Se destaca un patrón temporal identificado durante el periodo del 1 de enero de 2021 al 7 de enero de 2022, donde se observa un aumento significativo en la volatilidad del portafolio. Este hallazgo tiene implicaciones importantes para la gestión del riesgo y la toma de decisiones de inversión, ya que muestra un mayor riesgo de pérdidas para los inversionistas. Los resultados obtenidos a través del modelo GARCH y las estimaciones de Autorregresión AR1 y media móvil MA1 brindan una comprensión detallada de cómo la volatilidad fluctúa en el período analizado dentro del portafolio de criptomonedas. La precisión de estos resultados se destaca por su capacidad superior de adaptación a las variaciones de la volatilidad, lo que indica que la rentabilidad del portafolio conlleva un riesgo significativo para el inversionista.

## Conclusiones

- Debido a la alta volatilidad inherente a los portafolios de criptomonedas, se ha comprobado en el portafolio de estudio que este fenómeno influye significativamente en su rentabilidad y se caracteriza por la presencia de leptocurtosis y asimetrías negativas, lo que indica una mayor concentración de datos alrededor de la media y la existencia de valores atípicos que sugieren riesgos de pérdida. Los modelos ARCH y GARCH se revelan como herramientas cruciales para modelar con precisión esta volatilidad, destacando el último por su capacidad de adaptación a los cambios en los precios diarios. Estos hallazgos ofrecen un aporte relevante a la Teoría de la Generación de Carteras Financieras para maximizar retornos y minimizar riesgos en un contexto de alta volatilidad en criptomonedas. El modelo GARCH, caracterizado por su naturaleza autorregresiva AR1 y media móvil MA1 en la modelización de las varianzas condicionales, se ha demostrado como una herramienta versátil y poderosa para el análisis de la volatilidad en los mercados financieros. Esto es crucial para la construcción de un portafolio más eficiente, ya que permite a los inversores ajustar sus estrategias de inversión en función de la volatilidad esperada, optimizando así la relación entre riesgo y retorno. Por lo tanto, la eficiencia del portafolio se mide a través de la precisión en la estimación de la volatilidad y la capacidad del modelo para adaptarse a los cambios en el mercado, lo que facilita la toma de decisiones informadas y estratégicas para maximizar la rentabilidad mientras se minimiza el riesgo.
- El análisis de estacionariedad en las criptomonedas se revela como un paso crucial para evitar retrocesos al aplicar modelos de análisis de volatilidad. Las pruebas indican que el portafolio de criptomonedas exhibe una serie temporal estacionaria,

con la aceptación de la Hipótesis Alternativa. Lo que se sustenta en la constancia de la media y la varianza a lo largo del tiempo, con un p-valor menor a 0.05 y la ausencia de una raíz unitaria. Estos resultados fortalecen la base para el análisis de volatilidad y la implementación de estrategias de inversión en criptomonedas.

- El análisis del portafolio de criptomonedas revela que invertir en activos digitales altamente volátiles no es una estrategia viable. La distribución no normal de los rendimientos diarios del portafolio evidencia una clara asimetría hacia pérdidas, con las colas de la distribución inclinadas hacia valores negativos, lo que refleja un alto riesgo para los inversores y sugiere la presencia de leptocurtosis en el portafolio. Estos hallazgos subrayan la importancia de comprender el perfil de riesgo y rendimiento de la inversión en criptomonedas para tomar decisiones informadas. Además, el comportamiento del portafolio diversificado de criptomonedas revela la influencia significativa de la alta volatilidad en la rentabilidad de este, lo que enfatiza la necesidad imperante de evaluar cuidadosamente el riesgo asociado a estas inversiones.
- El comportamiento observado resulta altamente intrigante para proyectar el Valor en Riesgo (VaR) en futuras ocasiones, ya sea mediante intervalos de rentabilidades extensos o reducidos. Este proceso respalda la idoneidad de utilizar estos modelos para evaluar los niveles de riesgo en series financieras de manera diaria.

## Referencias

- Angelis-León, J. D. (2018). *Criptomonedas: un acercamiento a su definición, estructura y mercado*. Banco Central de Venezuela.
- Böhme et al, .. (2015). Bitcoin: Economics, Technology, and Governance. En R. Böhme, N. Christin, B. Edelman, & T. Moore, *Journal of Economic Perspectives* (págs. 29 (2): 213-38).
- Borda, D. R. (10 de 2000). *Modelización ARCH estimación de la volatilidad del Ibex-35*.  
Obtenido de Universidad Autónoma de Madrid, Facultad de Ciencias Económicas y Empresariales, Departamento de Economía Aplicada:  
[https://www.researchgate.net/publication/41224703\\_Modelizacion\\_ARCH\\_estimacion\\_de\\_la\\_volatilidad\\_del\\_Ibex-35](https://www.researchgate.net/publication/41224703_Modelizacion_ARCH_estimacion_de_la_volatilidad_del_Ibex-35)
- Brockwell, P. J., & Davis, R. A. (1996). *Introduction to Time Series and Forecasting*.  
Obtenido de <https://link.springer.com/book/10.1007/978-3-319-29854-2>
- Casas Monsegny, M., & Cepeda Cuervo, E. (2008). *MODELOS ARCH, GARCH YEGARCH: APLICACIONES A SERIES FINANCIERAS*. Obtenido de MODELOS ARCH, GARCH YEGARCH: APLICACIONES A SERIES FINANCIERAS:  
<https://revistas.unal.edu.co/index.php/ceconomia/article/view/1460/2083>
- César, A. C. (25 de 12 de 2010). Obtenido de Universidad Icesi:  
[https://www.icesi.edu.co/departamentos/images/departamentos/FCAE/economia/aportesEconomia/Tutorial\\_para\\_Pruebas\\_de\\_Raices\\_Unitarias\\_Dickey-Fuller\\_Aumentado\\_y\\_Phillips-Perron\\_en\\_EasyReg.pdf](https://www.icesi.edu.co/departamentos/images/departamentos/FCAE/economia/aportesEconomia/Tutorial_para_Pruebas_de_Raices_Unitarias_Dickey-Fuller_Aumentado_y_Phillips-Perron_en_EasyReg.pdf)
- Cheah, E.-T., & Fry, J. (Mayo de 2015). *¿Burbujas especulativas en los mercados de Bitcoin? Una investigación empírica sobre el valor fundamental de Bitcoin*.

Obtenido de

<https://www.sciencedirect.com/science/article/abs/pii/S0165176515000890>

Chung Alva, V. (15 de 07 de 2021). *Modelación de la Volatilidad del Tipo de Cambio del Dólar en el Perú: Aplicación de los Modelos GARCH y EGARCH*. Obtenido de REVISTA DE ANÁLISIS ECONÓMICO Y FINANCIERO, 4(2), 7-12.:  
<https://doi.org/10.24265/raef.2021.v4n2.40>

Claessens, R. A. (Septiembre de 2018). *Informe Trimestral del BPI*. Obtenido de Bank for International Settlements: [https://www.bis.org/publ/qtrpdf/r\\_qt1809f\\_es.pdf](https://www.bis.org/publ/qtrpdf/r_qt1809f_es.pdf)

Dávila, J., & Angelis-León, R. (2022). *Criptomonedas: un acercamiento a su definición, estructura y mercado*. Obtenido de <https://www.bcv.org.ve/system/files/publicaciones/bcvozecon032018.pdf>

Díaz Figueroa, S. M. (2008). *Aplicación del modelo Arch y Garch para el cálculo de la volatilidad en riesgo de mercado*. Obtenido de Repositorio Institucional Universidad Autónoma de Bucaramanga.:  
[https://repository.unab.edu.co/bitstream/handle/20.500.12749/13930/2008\\_Tesis\\_Diaz\\_Figueroa\\_Sandra\\_Milena.pdf](https://repository.unab.edu.co/bitstream/handle/20.500.12749/13930/2008_Tesis_Diaz_Figueroa_Sandra_Milena.pdf)

Fabozzi, F. (22 de Junio de 2008). *Portfolio Selection*. Obtenido de <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=8a07a080384061d6ecd4d3263a7476075b0b7a8f>

Fang, F., Ventre, C., Basios, M., Kanthan, L., Martinez-Rego, D., Wu, F., & Li, L. (Febrero de 2 de 2022). *Comercio de criptomonedas: una encuesta completa*. Obtenido de Comercio de criptomonedas: una encuesta completa: <https://jfin-swufe.springeropen.com/articles/10.1186/s40854-021-00321-6#citeas>

- Granados, R. M. (03 de 2013). *Variables no estacionarias y cointegración*. Obtenido de Universidad de Granada. España:  
<https://www.ugr.es/~montero/maticas/cointegracion.pdf>
- Gutiérrez Urzúa, M., & Salgado, M. (21 de 08 de 2012). *Construcción de una cartera de inversión usando modelos GARCH*. Obtenido de Construcción de una cartera de inversión usando modelos GARCH:  
<https://www.redalyc.org/pdf/816/81624969010.pdf>
- Hassan, J. (2014). *ARIMA and regression models for prediction of daily and monthly clearness index*. Obtenido de  
<https://www.sciencedirect.com/science/article/abs/pii/S0960148114000962>
- Jenkins, A. M. (14 de 06 de 2016). *Modelo GARCH para la volatilidad de las criptomonedas Bitcoin y Ether*. Obtenido de  
[https://www.academia.edu/35825887/Modelo\\_GARCH\\_para\\_la\\_volatilidad\\_de\\_las\\_criptomonedas\\_Bitcoin\\_y\\_Ether](https://www.academia.edu/35825887/Modelo_GARCH_para_la_volatilidad_de_las_criptomonedas_Bitcoin_y_Ether)
- Latorre, S. F. (2014). *Análisis de la volatilidad de series financieras mediante modelos ARMA-GARCH*. Obtenido de <https://core.ac.uk/reader/289980658>
- Mauricio, M. H., & Andrés, G. G. (29 de 09 de 2022). *Spillover de volatilidad entre el mercado de las criptomonedas, los mercados financieros y commodities*. Obtenido de Dialnet: <https://dialnet.unirioja.es/servlet/articulo?codigo=8721839>
- McLea et al, .. (2015). *Revista de Economía Institucional*. Obtenido de Revista de Economía Institucional: <https://www.redalyc.org/articulo.oa?id=41943054015>
- Montgomery et al. (2015). *Introduction to time series analysis and forecasting*. Obtenido de  
<https://books.google.es/books?hl=es&lr=&id=Xeh8CAAAQBAJ&oi=fnd&pg=PR1>

1&dq=(Montgomery,+Jennings,+%26+Kulahci,+2015).&ots=AK7jeUkE4n&sig=6  
 gjnkYUpwKf9TfYnE8yCuuTtTWg#v=onepage&q=(Montgomery%2C%20Jenning  
 s%2C%20%26%20Kulahci%2C%202015).&f=false

Moreno, M. V. (Abril de 2018). *Bitcoin ¿Él principio del fin de los Bancos?* Obtenido de  
[https://revista-aletheia.ieu.edu.mx/documentos/A\\_opinion/abril/bitcoin.pdf](https://revista-aletheia.ieu.edu.mx/documentos/A_opinion/abril/bitcoin.pdf)

Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. Obtenido de  
<https://bitcoin.org/bitcoin.pdf>

Ojeda Cárdenas et al. (2010). Estadística descriptiva. En S. P. Ojeda Cárdenas. Obtenido de  
 Universidad Pedagógica Y Tecnológica De Colombia:  
<https://repositorio.uptc.edu.co/bitstream/handle/001/4362/3581.pdf?sequence=1>

Ramírez et al. (s.f.). ARIMA, ARCH, GARCH Y REDES NEURONALES: MODELOS  
 PARA PRONOSTICAR SERIES DE TIEMPO FINANCIERAS. En F. O. Ramírez.  
 Obtenido de Componentes Electronicas Ltda:  
<https://www.bing.com/ck/a?!&&p=faeef5e12b92722bJmltdHM9MTcxNDg2NzIwMCZpZ3VpZD0xNzlhNDU3My03NGI1LTZiOTYtMzUxOS01MTM1NzUxMjZhYWQmaW5zaWQ9NTE5Mw&ptn=3&ver=2&hsh=3&fclid=179a4573-74b5-6b96-3519-513575126aad&psq=ARIMA%2c+ARCH%2c+GARCH+Y+REDES+NEURONALES%3a+MOD>

Ríos, G. (14 de Noviembre de 2008). *Series de Tiempo*. Obtenido de Universidad de Chile-  
 Departamento de Ciencias de la ComputaciÛn:  
[https://gc.scalahed.com/recursos/files/r161r/w24113w/Semana%2011/Series\\_de\\_Tiempo.pdf](https://gc.scalahed.com/recursos/files/r161r/w24113w/Semana%2011/Series_de_Tiempo.pdf)

- Rodríguez Pinzón, H. Y. (28 de 08 de 2009). *Profundización teórica de modelos de volatilidad ARCH - GARCH y una aplicación al caso colombiano*. Obtenido de Repositorio Universidad Santo tomas:  
<https://revistas.usantotomas.edu.co/index.php/estadistica/article/view/36>
- Russell Davidson & James G. MacKinnon. (2021). *Econometric Theory and Methods*. Obtenido de Queen´s University: <https://econ.queensu.ca/ETM/ETM-davidson-mackinnon-2021.pdf>
- Sáez, E. G. (27 de Diciembre de 2012). *inBestia*. Obtenido de inBestia:  
<https://inbestia.com/analisis/john-law-y-la-historia-de-una-burbuja-financiera-en-el-siglo-xviii>
- Song, Q., & Esogbue, A. (Diciembre de 2006). *A New Algorithm for Automated Box-Jenkins*. Obtenido de [https://www.researchgate.net/profile/Qiang-Song-16/publication/241520953\\_A\\_New\\_Algorithm\\_for\\_Automated\\_Box-Jenkins\\_ARMA\\_Time\\_Series\\_Modeling\\_Using\\_Residual\\_AutocorrelationPartial\\_Autocorrelation\\_Functions/links/541793480cf2f48c74a40c75/A-New-Algorithm-for](https://www.researchgate.net/profile/Qiang-Song-16/publication/241520953_A_New_Algorithm_for_Automated_Box-Jenkins_ARMA_Time_Series_Modeling_Using_Residual_AutocorrelationPartial_Autocorrelation_Functions/links/541793480cf2f48c74a40c75/A-New-Algorithm-for)
- Tapia, E. P. (2017). *Análisis de volatilidad de los precios de las acciones Holcim S.A. utilizando el modelo GARCH*. Obtenido de <https://repositorio.uta.edu.ec/bitstream/123456789/25993/1/T4055ig.pdf>
- Tomás et al. (05 de 2013). On the Behaviour of Phillips-Perron Tests in the Presence of Persistent Cycles. En D. B. Tomás, M. R. Paulo, & A. R. Taylor. Obtenido de Universidad de Évora - CEFAGE:  
[https://www.academia.edu/66887825/On\\_the\\_Behaviour\\_of\\_Phillips\\_Perron\\_Tests\\_in\\_the\\_Presence\\_of\\_Persistent\\_Cycles?sm=b](https://www.academia.edu/66887825/On_the_Behaviour_of_Phillips_Perron_Tests_in_the_Presence_of_Persistent_Cycles?sm=b)



## Anexos

### 9.1 Anexo A. Análisis correlación: Rendimiento diario del Portafolio de Criptomonedas

El análisis de la autocorrelación del rendimiento diario de un portafolio de inversión en criptomonedas es fundamental para comprender la estructura temporal presente en los datos y desarrollar estrategias de inversión informadas. El análisis del correlograma presentado en la Tabla 2 proporciona una valiosa visión sobre la dinámica temporal de los rendimientos del portafolio de inversión en criptomonedas. Se evaluaron varios aspectos clave: la autocorrelación (AC), la autocorrelación parcial (PAC) para fines predictivos, el estadístico Q y la probabilidad asociada al estadístico Q ( $\text{Prob}>Q$ ), en relación con diferentes retrasos (lags). Estos resultados revelan patrones importantes que pueden ser fundamentales para la comprensión y modelado del comportamiento del mercado de criptomonedas. A continuación, se presenta el correlograma que ilustra las correlaciones en diferentes retrasos temporales entre los rendimientos del portafolio

*Tabla 5 Correlograma Portafolio*

LAG	AC	PAC	Q	Prob>Q	-1	0	1	-1	0	1
					[Autocorrelación]			[Parcial Autocor]		
1	-0.0325	-0.0325	2.367	0.1239						
2	0.0111	0.0100	2.6424	0.2668						
3	0.0211	0.0218	3.6358	0.3036						
4	0.0323	0.0336	5.9658	0.2017						
5	0.0085	0.0102	6.1275	0.2940						
6	0.0245	0.0241	7.4752	0.2791						
7	-0.0440	-0.0443	11.817	0.1068						
8	-0.0378	-0.0430	15.018	0.0588						
9	0.0791	0.0763	29.046	0.0006						
10	0.0207	0.0273	30.006	0.0009						
11	-0.0030	0.0011	30.026	0.0016						
12	-0.0579	-0.0602	37.555	0.0002						
13	0.0263	0.0194	39.115	0.0002						

14	-0.0112	-0.0114	39.396	0.0003
15	-0.0077	-0.0138	39.53	0.0005
16	-0.0298	-0.0234	41.528	0.0005
17	0.0176	0.0253	42.229	0.0006
18	-0.0003	0.0012	42.229	0.0010
19	-0.0440	-0.0543	46.587	0.0004
20	0.0524	0.0492	52.776	0.0001
21	-0.0293	-0.0149	54.709	0.0001
22	0.0151	0.0132	55.221	0.0001
23	-0.0395	-0.0433	58.736	0.0001
24	0.0703	0.0679	69.899	0.0000
25	-0.0019	0.0148	69.907	0.0000
26	0.0261	0.0154	71.452	0.0000
27	0.0463	0.0472	76.306	0.0000
28	0.0511	0.0588	82.227	0.0000
29	-0.0503	-0.0540	87.964	0.0000
30	0.0223	0.0056	89.093	0.0000
31	0.0554	0.0530	96.044	0.0000
32	-0.0775	-0.0608	109.66	0.0000
33	0.0952	0.0809	130.23	0.0000
34	0.0096	0.0150	130.43	0.0000
35	0.0121	0.0134	130.76	0.0000
36	-0.0520	-0.0545	136.9	0.0000
37	0.0515	0.0253	142.92	0.0000
38	-0.0344	-0.0176	145.61	0.0000
39	-0.0181	-0.0183	146.36	0.0000
40	0.0499	0.0518	152.02	0.0000

*Nota, elaboración propia del correlograma el cual permite analizar el rendimiento diario del Portafolio de Criptomonedas.*

Los resultados de la tabla 3 son los siguientes. En el primer retraso (lag 1) se evidencia una autocorrelación negativa, dada por un valor de AC de -0.0325 y una PAC de -0.0325. Esta relación se da si el valor de la serie temporal en el tiempo  $t$  es relevante, es probable que el valor en el tiempo  $t+1$  sea más bajo, y viceversa. En contraste, se identificó una autocorrelación positiva moderada en el noveno retraso (lag 9), con un valor de AC ascendiendo a 0.0791 y una PAC de 0.0763. Esta autocorrelación positiva indica una persistencia en los cambios del rendimiento del portafolio a lo largo de varios días, lo que

sugiere tendencias o patrones subyacentes en el mercado de criptomonedas. Indicando que, si el valor de la serie temporal es alto en el momento  $t$ , es probable que también sea alto en el momento  $t+9$ , reflejando una correlación positiva con su valor 9 períodos atrás. Finalmente, en el trigésimo segundo retraso (lag 32), se observó nuevamente una autocorrelación negativa moderada, con un valor de AC de -0.0775 y una correspondiente PAC de -0.0608. Esta autocorrelación negativa sugiere una reversión a largo plazo en los movimientos del rendimiento del portafolio. En otras palabras, los cambios significativos pueden tender a corregirse después de un período extendido, similar a la relación observada en el lag 1 con el valor en el tiempo  $t+1$ . En conjunto, los resultados del estadístico Q y la probabilidad asociada para varios retrasos indican la presencia de autocorrelaciones significativas en los datos del rendimiento del portafolio, respaldando así la existencia de una estructura temporal que permite identificar tendencias en el comportamiento del rendimiento de criptomonedas en el portafolio.

### ***9.2 Anexo B. Resultados prueba Dickey-Fuller***

La prueba de Dickey-Fuller es una herramienta estadística fundamental para evaluar la estacionariedad de una serie temporal. Al aplicar esta prueba, se busca determinar si la hipótesis nula  $H_0$ , que postula la existencia de raíces unitarias en la serie, siendo esto la no estacionariedad, puede ser aceptada o rechazada. Un valor de p (p-value) menor que el nivel de significancia seleccionado, usualmente es establecido en 0.05, indica que la hipótesis nula puede ser rechazada, lo que sugiere que la serie es estacionaria.

*Tabla 6 Resultados de la prueba Dickey-Fuller.*

Dfuller portafolio

Dickey-Fuller Prueba para raíz unitaria

Número de obs = 2.233

---

Dickey-Fuller Interpolado

	Prueba Estadística	Valor Critico 1%	Valor Critico 5%	Valor Critico 10%
Z(t)	-48.786	-3.430	-2.860	-2.570

Valor p aproximado de MacKinnon para  $Z(t) = 0.0000$

*Nota, elaboración propia de los resultados de la prueba Dickey-Fuller para raíz unitaria del portafolio.*

### **9.3 Anexo C. Resultados prueba Phillips-Perron.**

La prueba de Phillips-Perrón desempeña un papel esencial al utilizar una técnica de corrección para la autocorrelación y la heterocedasticidad en la serie de tiempo. Evalúa si una serie es estacionaria basándose en sus hipótesis, rechazando la hipótesis nula  $H_0$  de no estacionariedad cuando el valor de p es mayor que 0.05. Además, al incorporar rezagos en la prueba, aumenta su capacidad para identificar tendencias en los datos. Este enfoque de detección de estacionariedad contribuye al análisis de tendencias, fortaleciendo así la interpretación de los resultados.

*Tabla 7 Resultados Prueba Phillips-Perron*

Pperron portafolio

Phillips-Perron Prueba para raíz unitaria

Número de obs= 2.233

Dickey-Fuller Interpolado				
	Prueba Estadística	Valor Critico 1%	Valor Critico 5%	Valor Critico 10%
Z(rho)	-2400.960	-20.700	-14.100	-11.300
Z(t)	-48.763	-3.430	-2.860	-2.570

Valor p aproximado de MacKinnon para  $Z(t) = 0.0000$

*Nota, elaboración propia de los resultados de la prueba Phillips-Perron para raíz unitaria del portafolio.*

El análisis de los resultados de las pruebas de hipótesis de Dickey-Fuller y Phillips-Perron, basado en los datos presentados en las Tablas 5 y 6, revela información crucial sobre la estacionariedad de la serie temporal del portafolio. Se utilizaron 2.233 observaciones en

ambas pruebas. La prueba estadística  $Z(t)$  en ambas pruebas se calcula para contrastar la presencia de una raíz unitaria en la serie de tiempo. Se plantea la Hipótesis Nula ( $H_0$ ), indicando que la serie no es estacionaria, y la Hipótesis Alternativa ( $H_1$ ), que sugiere estacionariedad. Tras realizar ambas pruebas, se observa que el valor p para ambas, p-value  $Z(T)$ , es igual a 0.0000, rechazando así la hipótesis nula. Este resultado favorece la hipótesis alternativa, sugiriendo que la variable del portafolio es una serie estacionaria, lo que implica que la variable aleatoria se mueve alrededor de su media. Los valores críticos aplicados en ambas pruebas (1%, 5%, 10%) miden la significancia de las estadísticas de prueba. Se obtienen valores negativos para ambas pruebas, rechazando así la hipótesis nula de la raíz unitaria; La prueba de MacKinnon <sup>1</sup> se aplica para evaluar si el valor p puede rechazar la hipótesis nula de una raíz unitaria en la serie de tiempo del portafolio. Al obtener un valor de  $Z(t) = 0.0000$ , se rechaza la hipótesis nula, consolidando la evidencia de estacionariedad en la serie de tiempo del portafolio. Para concluir, tanto la prueba de Dickey-Fuller como la prueba de Phillips-Perron arrojan el mismo resultado para la serie de tiempo del portafolio estudiada: no tiene una raíz unitaria, lo que indica que es estacionaria.

#### ***9.4 Anexo D. Resultados de la Prueba Portmanteau para Ruido Blanco***

La prueba Portmanteau se utiliza en el análisis de series temporales, específicamente para evaluar si los residuos de un modelo, como un modelo ARIMA, muestran autocorrelación significativa. Esta autocorrelación indicaría que el modelo no está capturando toda la información en los datos. Cuando los residuos son ruido blanco, las autocorrelaciones

---

<sup>1</sup> La prueba de MacKinnon, es la prueba J de Davidson y MacKinnon (1981), que fue simplificada de la prueba de hipótesis no anidada. La prueba J es aplicada tanto a modelos de regresión lineales y no lineales para realizar la prueba de hipótesis no anidada; Davidson y MacKinnon (1981) explicaron que es posible obtener valores P confiables aplicando su prueba J, basada en la estadística t ordinaria para  $\alpha = 0$ , conocida como la Prueba J. (Russell Davidson & James G. MacKinnon, 2021).

deberían ser cercanas a cero para todos los rezagos. La prueba también utiliza la distribución chi-cuadrado para determinar si hay evidencia suficiente para rechazar la hipótesis nula de que los residuos son ruido blanco. En resumen, la prueba Portmanteau permite determinar si el modelo captura correctamente la información en los datos o si hay tendencias sistemáticas no explicadas.

*Tabla 8 Resultados de la Prueba Portmanteau Para Ruido Blanco*

Prueba Portmanteau para Ruido Blanco

Estadística Portmanteau (Q) = 152.0192

Prob > chi2 (40) = 0.0000

*Nota, elaboración propia de resultados de la Prueba Portamanteo Para Ruido Blanco.*

Los resultados de la prueba Portmanteau para ruido blanco son importantes para establecer si hay correlación entre los activos en el portafolio. Se plantean dos hipótesis: la Hipótesis Nula ( $H_0$ ), que indica la presencia de ruido blanco, y la Hipótesis Alternativa ( $H_1$ ), que sugiere la ausencia de ruido blanco. La probabilidad chi-cuadrado (40) obtenida es de 0.00, lo que significa que no hay ruido blanco presente y se rechaza la Hipótesis Nula. Esta ausencia de alteración en el ruido blanco conlleva a la conclusión de que no existe correlación estadística entre los activos dentro del portafolio diversificado.