

ANÁLISIS DE SERIES DE TIEMPO PARA EL RENDIMIENTO Y VOLATILIDAD DEL BITCOIN

Guadalupe Avilés Tovar Eduardo Rosas Rojas¹

Universidad Autónoma del Estado de México, Centro Universitario UAEM Valle de México.

ABSTRACT

This study assesses whether risk factors from traditional markets explain Bitcoin's daily returns and conditional volatility (03/01/2017–04/19/2024) using ARMAX–GARCH models with heavy-tailed errors. Model selection via information criteria favors a symmetric GARCH with GED innovations. In the mean equation, the S&P 500 and Ethereum exhibit economically and statistically significant positive associations with Bitcoin. By contrast, while the contemporaneous daily correlation with gold is small and positive, the gold coefficient in the ARMAX/GARCH conditional mean is negative, consistent with gold's role as a safe-haven asset during periods of uncertainty. The lagged Bitcoin return is positive, which rejects the Efficient Market Hypothesis (EMH). In the variance, the VIX increases conditional volatility, and the news-impact curve indicates an inverse leverage effect (positive shocks raise volatility more than negative shocks). Goodness-of-fit tests (Durbin–Watson, Ljung–Box, ARCH–LM) support model adequacy. The contribution of the paper lies in quantifying conditional linkages between Bitcoin and other assets—such as altcoins, equity indices, volatility indicators, currencies, and commodities.

KEYWORDS: Volatility, GARCH, Bitcoin

MSC: 62M10, 91B84

RESUMEN

El presente trabajo de investigación evalúa si factores de riesgo de mercados tradicionales explican los rendimientos y la volatilidad condicional diaria del Bitcoin (03/01/2017–19/04/2024) mediante modelos ARMAX–GARCH con colas pesadas. La selección por criterios de información favorece un GARCH simétrico con distribución GED. En la media, el S&P500 y Ethereum muestran asociaciones positivas económica y estadísticamente significativas con Bitcoin. Por su parte la correlación contemporánea diaria con el oro es pequeña y positiva; no obstante, en la ecuación de media condicional ARMAX/GARCH el coeficiente del oro es negativo, coherente con su papel de activo refugio en periodos de incertidumbre. El rezago del propio Bitcoin es positivo, lo que rechaza la "Hipótesis de Eficiencia del Mercado" (HEM). En la varianza, el VIX incrementa la volatilidad condicional y la curva de impacto de noticias evidencia apalancamiento inverso (los choques positivos elevan más la volatilidad que los negativos). Las pruebas de ajuste (DW, Ljung–Box, ARCH–LM) avalan la idoneidad del modelo. El aporte radica en cuantificar los vínculos condicionales entre el Bitcoin y otros activos, como *altcoins*, índices bursátiles, indicadores de volatilidad, divisas y materias primas.

PALABRAS CLAVE: Volatilidad, GARCH, Bitcoin

1. INTRODUCCIÓN

Desde que [30] introdujo el Bitcoin en 2008, las criptomonedas han despertado gran interés entre inversores, autoridades reguladoras y la comunidad científica. Estas monedas digitales operan a través de sistemas electrónicos entre pares (*peer to peer*), permitiendo que se realicen pagos en línea directamente entre dos partes sin necesidad de una institución financiera. A diferencia de otros activos financieros convencionales, las criptomonedas no dependen de ninguna autoridad central, no tienen una forma física y pueden dividirse infinitamente. Su valor no se basa en activos tangibles, en la economía de un país o una empresa, sino en la robustez de un algoritmo que registra todas las transacciones. Su creciente popularidad puede atribuirse a los bajos costos de transacción, su estructura entre pares y la ausencia de control gubernamental, lo que ha generado un incremento en su volumen, precio y volatilidad [12].

La literatura actual que analiza las características financieras del mercado de criptomonedas muestra un enorme crecimiento desde la perspectiva de la economía y las finanzas [15], debido a que este mercado, con miles de millones de dólares en capitalización, puede actuar como cobertura, diversificador o refugio seguro en diversos mercados bursátiles,

¹ Corresponding author email: erosasr@uaemex.mx

dependiendo de la situación económica en los países [6]. Sin embargo, estos activos digitales demuestran algunas características comunes, como colas gruesas, memoria larga, agrupamiento de volatilidad y efectos de apalancamiento inverso [2].

El estudio del Bitcoin ha captado un gran interés en los años recientes, debido principalmente a sus características innovadoras, su simplicidad, transparencia y creciente popularidad [38]. Una línea de investigación fundamental es el análisis de los factores más importantes que afectan el rendimiento y la volatilidad de un fenómeno financiero tan volátil. Estudios previos han buscado explicar su relación con el comportamiento de las principales divisas, materias primas, bolsas de valores y el principal altcoin [15, 6, 2, 23, 9].

Otro de los temas centrales es la eficiencia del Bitcoin. Investigaciones como las de [38, 29] respaldan la ineficiencia del mercado del criptoactivo, es decir, que la hipótesis de mercado eficiente² no es válida. Este resultado ha sido respaldado por estudios posteriores que han utilizado diversos procedimientos de prueba y diferentes conjuntos de datos, como los de [37]. Estas investigaciones sugieren que los rendimientos del Bitcoin no se ajustan a la Hipótesis del Mercado Eficiente y que estos rendimientos no son independientes, sino predecibles. En este marco, surge la necesidad de indagar hasta qué punto la dinámica del Bitcoin está condicionada por factores externos. De manera particular, se plantea la pregunta: ¿En qué medida los factores de riesgo de mercados tradicionales (S&P500, oro, divisas y VIX) y el principal altcoin (Ethereum) explican los rendimientos diarios y la volatilidad condicional del Bitcoin de 2017 a 2024, y qué nos dice ello sobre (i) la eficiencia débil del mercado de BTC y (ii) la asimetría de respuesta de su volatilidad a “buenas” y “malas” noticias?

El presente estudio contribuye a ofrece evidencia cuantitativa y condicional sobre los vínculos entre los rendimientos / volatilidad del Bitcoin y activos de referencia (Ethereum, S&P 500, oro, divisas y VIX), a partir de modelos ARMAX–GARCH con innovaciones de colas pesadas (GED). La significancia estadística confirma el comovimiento positivo de BTC con el S&P 500 y Ethereum; el oro presenta un coeficiente negativo en la media condicional, coherente con su rol de refugio pese a una correlación contemporánea pequeña y positiva; el rezago del propio BTC es positivo, lo que refuta la HEM en su forma débil; y la curva de impacto de noticias revela un apalancamiento inverso, donde los choques positivos elevan más la volatilidad que los negativos.

El artículo de investigación presenta la siguiente estructura. Además de esta sección introductoria, en el segundo apartado se aborda la revisión de la literatura que expone los determinantes del rendimiento y la volatilidad del Bitcoin. En la tercera sección, se desarrolla el marco metodológico que muestra la estructura de modelos autorregresivos y de medias móviles con variables exógenas y modelos de volatilidad condicional simétrica y asimétrica. Posteriormente, en la cuarta sección del artículo se presentan los principales resultados

² La Hipótesis de Eficiencia del Mercado (HEM) plantea que la eficiencia es un estado en el cual muchos participantes racionales compiten activamente entre sí mientras maximizan sus ganancias y predicen el valor futuro de los instrumentos financieros utilizando la información disponible para los participantes del mercado [19]. Al extender este principio al mercado de criptomonedas los participantes del mercado de criptomonedas no podrían superar a otros participantes ni al mercado, ya que los precios reflejan completamente toda la información conocida.

obtenidos, acompañados de un análisis detallado y discusión crítica. Finalmente, se presentan las conclusiones principales derivadas de la investigación.

2. REVISIÓN DE LA LITERATURA

Determinantes del rendimiento del Bitcoin

La capacidad de predecir los rendimientos de los activos financieros ha sido un tema de gran interés en la literatura financiera. De acuerdo con [3], la evidencia empírica indica que los rendimientos de las acciones son parcialmente predecibles. Sin embargo, los rendimientos del Bitcoin presentan particularidades que exigen un análisis profundo. [26] analizaron la predictibilidad de Bitcoin utilizando un conjunto reducido de variables dependientes, logrando pronosticar con precisión la dirección de los rendimientos, pero no su magnitud. En un estudio más reciente, [27] añaden varios predictores adicionales, como las *altcoins*, los mercados bursátiles globales y el índice de incertidumbre económica. A continuación, se exponen las principales variables que ayudarían a explicar el comportamiento de los rendimientos de la moneda virtual.

La investigación de [22] destaca que la relación entre Bitcoin y las *altcoins*, como Ethereum, Litecoin y Ripple, puede analizarse mediante métodos de cointegración, lo que revela vínculos de largo plazo entre estos activos. A pesar de sus movimientos similares, las *altcoins* mantienen un equilibrio con Bitcoin. [28] compararon Bitcoin y Ethereum, mostrando que ambas criptomonedas experimentan volatilidad persistente. Otra variable relevante es el índice S&P500, ampliamente considerado como un indicador clave del mercado financiero de EE. UU., ha sido utilizado en estudios que exploran la interacción entre Bitcoin y los mercados tradicionales. En [11] se encontró una correlación positiva significativa entre el precio del Bitcoin y el rendimiento del S&P500, lo que sugiere que los movimientos en el mercado de criptomonedas están influenciados por factores macroeconómicos. [23] ampliaron esta investigación, mostrando que durante periodos de alta volatilidad en el S&P500, la correlación con Bitcoin aumenta, lo que indica que los inversores recurren a Bitcoin como estrategia para diversificar riesgos. Estos estudios reflejan una creciente integración de la criptomoneda en las estrategias de inversión junto a activos financieros convencionales.

Bitcoin, como activo altamente volátil, es muy sensible a la incertidumbre económica y política. Indicadores como el Índice de Incertidumbre de la Volatilidad (VIX) y el Índice de Incertidumbre de la Política Económica (EPU) reflejan estas percepciones, afectando la confianza de los inversores. Durante periodos de alta incertidumbre, Bitcoin puede verse como un refugio alternativo, mientras que en tiempos de estabilidad económica su demanda tiende a disminuir, aunque su impacto es de baja magnitud [13]. También es importante señalar que las principales monedas fiduciarias, como el euro, la libra esterlina y el yuan chino, juegan un papel clave en la determinación del precio del Bitcoin. Estudios como el de [15] muestran que Bitcoin reacciona con mayor fuerza al tipo de cambio dólar-libra esterlina, lo que indica que distintas regiones pueden influir en su precio.

Finalmente, la relación entre el Bitcoin y oro ha sido ampliamente estudiada. Según [16], Bitcoin comparte con el oro características como la escasez, el costo de producción y la falta

de control gubernamental, lo que lo posiciona como una opción atractiva para inversores especulativos. Sin embargo, estudios como el de [2] señalan que Bitcoin no se comporta como el oro en respuesta a eventos macroeconómicos. Además, las investigaciones de [33] concluyen que Bitcoin no es un refugio seguro tan eficaz como el oro, ya que ambos activos compiten como alternativas de inversión en momentos de incertidumbre.

2.2.Determinantes de la volatilidad del Bitcoin

En lo que respecta a las investigaciones sobre la volatilidad del Bitcoin, se ha demostrado que los niveles de inestabilidad en estos activos digitales son considerablemente más altos que en las monedas tradicionales. Un hecho incontrovertible es que la volatilidad anualizada del activo digital supera significativamente la de cualquier activo financiero estándar, como las monedas fiduciarias, acciones o productos básicos, alcanzando niveles superiores al 84%. Esta volatilidad experimenta grandes fluctuaciones a lo largo del tiempo, lo que la hace altamente fluctuante y dificulta la predicción de su comportamiento [35]. Esta característica plantea un desafío aún mayor en comparación con variables más convencionales, como los índices bursátiles o los tipos de cambio, lo que complica la tarea de predecir los movimientos de los precios de las criptomonedas.

Por su parte, [15] estudió la volatilidad del Bitcoin en comparación con el dólar estadounidense y el oro, utilizando modelos GARCH (1,1) y EGARCH (1,1), y encontró similitudes significativas entre Bitcoin y estos activos tradicionales en términos de capacidad de cobertura y respuesta de la volatilidad ante noticias. En otro estudio para el mismo año, [16] también señala que las reacciones de la criptomoneda pueden ser más rápidas que las del oro y el dólar. El autor replica el estudio utilizando TGARCH (1,1) y encuentra conclusiones similares a su anterior trabajo. [8] realizaron un análisis econométrico utilizando datos de 2014-2016. A través de diversas estructuras GARCH, concluyeron que el modelo TGARCH (1,1) es el que mejor se ajusta a todos los datos de muestra según criterios de discriminación como la verosimilitud logarítmica, el AIC y el BIC.

Adicionalmente, en el estudio de [25], se explora cómo el sentimiento de los inversores, los rendimientos del S&P500 y el comportamiento del VIX impactan en la volatilidad del Bitcoin mediante la aplicación de modelos GARCH y EGARCH. Los resultados revelan que los rendimientos del VIX son significativos, sugiriendo que la volatilidad del mercado global afecta directamente a la volatilidad de la divisa virtual, en línea con lo reportado por [6]. Sus hallazgos sugieren que los modelos GARCH (1,1) y EGARCH(1,1) son adecuados para capturar la dinámica de la volatilidad del Bitcoin, especialmente en relación con factores externos como el sentimiento del mercado y los índices financieros. El estudio también muestra que los inversores en Bitcoin tienden a estar más conectados con la información tecnológica, reflejando una sensibilidad particular hacia las percepciones difundidas en medios digitales. Asimismo, se evidencia que la volatilidad del Bitcoin no es constante, sino que varía a lo largo del tiempo. En momentos de alta volatilidad en los mercados de valores, la moneda digital puede actuar como un refugio seguro; sin embargo, cuando los mercados son más estables, este activo se convierte en un atractivo instrumento para los inversores especulativos, destacando su doble rol dentro de diferentes escenarios económicos.

Un aspecto relevante y de reciente investigación es la presencia de colas más pesadas en la distribución de las criptomonedas, lo que las convierte en activos más riesgosos que las

monedas fiduciarias. [36] estudia las distribuciones más adecuadas para modelar las innovaciones en los modelos GARCH. A través de pruebas no paramétricas, como la de Kolmogorov-Smirnov y la transformación de martingala de Khmaladze, sus resultados empíricos cuestionan la suposición de normalidad en dichas innovaciones y proponen, en su lugar, el uso de distribuciones con error generalizado (GED) como una alternativa más apropiada.

3. MARCO METODOLÓGICO

El estudio se organiza de la siguiente forma: Primero, se recopilan precios diarios y se transforman en rendimientos para hacer comparables las series. Segundo, se verifica la estacionariedad y se especifica la ecuación de media mediante un ARMAX, definiendo como candidatas las variables exógenas (S&P500, Ethereum, oro, VIX y divisas). Tercero, se selecciona la especificación final con un procedimiento automático y parsimonioso basado en la metodología stepwise y criterios de información (AIC, BIC); en paralelo, se modela la volatilidad condicional con estructuras GARCH (simétrica y asimétricas) empleando distribuciones de colas pesadas para capturar eventos extremos (GED, t-student y normal). Cuarto, se estiman los modelos y se aplican diagnósticos estándar (Ljung–Box, Durbin–Watson, ARCH–LM) para garantizar la bondad de ajuste y la ausencia de patrones remanentes. Finalmente, se interpretan los coeficientes en términos económicos.

El análisis de series temporales distingue entre componentes estocásticos, que son impredecibles, y componentes determinísticos, que siguen patrones definidos. Por ejemplo, cuando una serie presenta una caminata aleatoria, esto sugiere que no es estacionaria, lo que compromete su capacidad de predicción. Por su parte, el supuesto de estacionariedad implica que la media y la varianza se mantienen constantes a lo largo del tiempo. Las pruebas de raíz unitaria permiten identificar si es necesario diferenciar los datos para obtener un modelo estacionario [14, 34].

Posteriormente, empleando la metodología de [7] se puede identificar la estructura que mejor se adecue al proceso generador de datos. Actualmente, el algoritmo "*Automatic ARIMA Forecasting*" del software *Econometric Views* y *auto.arima()* de la librería *forecast* en R-Project facilitan este proceso³. En una siguiente etapa se estiman los coeficientes empleando métodos como la máxima verosimilitud o mínimos cuadrados. Finalmente, se diagnostica la superioridad en cada estructura empleando criterios de selección como el AIC y BIC, lo que optimiza el proceso.

Con base en los trabajos de investigación de [26, 27] se incorporan al modelo ARMA un conjunto de variables exógenas para la estimación del rendimiento del Bitcoin. Los modelos ARMAX permiten capturar factores externos que influyen significativamente en la tasa de

³ Tanto *Automatic ARIMA Forecasting* (EViews) como *auto.arima()* (R-forecast) implementan el procedimiento de [21]: (i) determinan el grado de diferenciación ddd (y DDD estacional) mediante pruebas de raíz unitaria; (ii) exploran, por búsqueda stepwise los órdenes (p,d,q) y (P,D,Q)s, estimando cada candidato por máxima verosimilitud; (iii) evalúan las especificaciones con AICc (o BIC) penalizando la complejidad; y (iv) reestiman el modelo óptimo y reportan diagnósticos residuales. Cuando se incluyen regresores exógenos (ARIMAX/ARMAX), el conjunto se mantiene fijo y el algoritmo selecciona los órdenes que minimizan el criterio de información. En condiciones equivalentes (misma transformación, estacionalidad y variables exógenas), ambos motores suelen converger a la misma especificación óptima de la media condicional.

crecimiento de la criptomoneda, como los *altcoins*, índices bursátiles, divisas principales, *commodities*, la percepción del riesgo y la incertidumbre económica global. Además, la estructura autorregresiva y de medias móviles captura eficazmente tanto la dinámica interna como la autocorrelación. A continuación, se presenta la estructura general del modelo de media condicional.

$$y_t = a_0 + \sum_{i=1}^p a_i y_{t-i} + \sum_{j=1}^q \beta_j \varepsilon_{t-j} + \sum_{k=1}^r \delta_k X_{t-k} + \varepsilon_t \quad (1)$$

donde a_0 es la constante, a_i los coeficientes de los procesos autorregresivos, β_j los coeficientes de las medias móviles, δ_k los estimadores de las variables exógenas y ε_t el término de perturbación estocástica. La estructura fue desarrollados por [7] y [40] como respuesta a los complejos modelos vectoriales multivariantes autorregresivos y de medias móviles (VARMA). Para complementar el análisis, se incorporan modelos ARCH y GARCH simétricos y asimétricos, que estiman la volatilidad condicional del Bitcoin. De acuerdo con [17], se parte de la siguiente estructura:

$$\varepsilon_t = v_t \sqrt{\alpha_0 + \alpha_1 \varepsilon_{t-1}^2} \quad (2)$$

donde v_t es un proceso estacionario tal que $\sigma_v^2 = 1$, v_t y ε_{t-1} se distribuyen independientemente, y α_0 y α_1 son constantes tales que $\alpha_0 > 0$ y $0 \leq \alpha_1 \leq 1$. En esta misma línea [4] amplió la metodología ARCH al desarrollar el modelo GARCH, diseñado para capturar de manera más eficaz las características de heteroscedasticidad condicional en las series temporales financieras. La estructura del modelo GARCH es la siguiente:

$$\begin{aligned} \varepsilon_t &= v_t \sqrt{h_t} \\ h_t &= \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \end{aligned} \quad (3)$$

Esta estructura permite modelar la varianza condicional como una función lineal de los valores pasados de la serie, volviéndola más flexible, ya que se puede interpretar un modelo GARCH (1,1) como un proceso ARCH de orden infinito⁴. Estas estructuras son especialmente útiles para identificar los hechos estilizados comunes en series financieras, como la agrupación de volatilidad y permiten un decaimiento más lento de las

⁴

$$\begin{aligned} \sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \\ \sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 (\alpha_0 + \alpha_1 \varepsilon_{t-2}^2 + \beta_1 \sigma_{t-2}^2) \\ \sigma_t^2 &= \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_0 \beta_1 + \alpha_1 \beta_1 \varepsilon_{t-2}^2 + \beta_1^2 \sigma_{t-2}^2 \\ \sigma_t^2 &= \alpha_0 + \varepsilon_{t-1}^2 + \alpha_0 \beta_1 + \alpha_1 \beta_1 \varepsilon_{t-2}^2 + \beta_1^2 (\alpha_0 + \alpha_1 \varepsilon_{t-3}^2 + \beta_1 \sigma_{t-3}^2) \\ &\vdots \\ \sigma_t^2 &= \frac{\alpha_0}{1 - \beta_1} + \alpha_1 \sum_{i=0}^{\infty} \varepsilon_{t-1-i}^2 \beta_1^i \end{aligned}$$

autocorrelaciones de los rendimientos cuadráticos, lo que facilita su aplicación en escenarios donde la varianza condicional cambia con el tiempo. Existen múltiples variaciones de estos modelos que responden de manera asimétrica a perturbaciones positivas y negativas, lo cual es útil para comprender la volatilidad condicional.

Uno de los principales desarrollos en los modelos de heterocedasticidad condicional asimétrica es el trabajo de [20] (GJR-GARCH), que permite estimar el impacto diferenciado de las buenas y malas noticias sobre la volatilidad condicional (ecuación [4]). En este modelo, $\varepsilon_{t-1} = 0$ actúa como un umbral, de manera que los choques por encima o por debajo de este valor generan efectos distintos. Esto facilita la captura de asimetrías en la respuesta de la volatilidad ante diferentes tipos de noticias.

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 h_{t-1} + \gamma \varepsilon_{t-1}^2 I_{t-1} \quad (4)$$

En el modelo GJR-GARCH, h_t sigue la misma estructura que la ecuación (3), pero incluye el término I_{t-1} , una variable binaria que toma el valor de 1 si $\varepsilon_{t-1} < 0$ y 0 si $\varepsilon_{t-1} > 0$. Esto significa que, cuando $\gamma > 0$, los choques negativos tienen un mayor impacto en la volatilidad que los choques positivos. Para garantizar la no negatividad, las condiciones necesarias son $\alpha_0 > 0, \alpha_1 > 0, \beta \geq 0$ y $\alpha_1 + \gamma \geq 0$. Finalmente, existen versiones que incorporan distribuciones alternativas, como la distribución *t-student* en lugar de la normal, o la distribución generalizada de errores (*GED*), lo que permite manejar mejor las colas pesadas observadas en series financieras.

4. RESULTADOS

La presente investigación tiene como objetivo comprender la relación entre los rendimientos y la volatilidad del Bitcoin, utilizando datos diarios desde el 3 de enero de 2017 hasta el 19 de abril de 2024. La elección de datos diarios es clave, ya que permite capturar de manera detallada las reacciones inmediatas del mercado a eventos específicos, lo que ayuda a evaluar la eficiencia del mercado y desarrollar modelos predictivos más precisos. Estos datos también revelan la naturaleza especulativa del mercado de la divisa virtual. Los precios de Bitcoin y Ethereum se obtienen de la Reserva Federal de San Luis (FRED), mientras que los datos del índice de incertidumbre de la volatilidad (VIX), la incertidumbre de la política económica de EE.UU. y el S&P500 provienen de FRED y Bloomberg. Además, los datos de monedas fiduciarias (Euro, Libra esterlina y Yuan) y de *commodities* (oro y petróleo) se extraen de la plataforma *Quandl*. La base de datos contiene un total de 1814 observaciones, lo que permite una evaluación detallada y precisa.

Todas las series financieras se transformaron a rendimientos diarios en diferencias logarítmicas multiplicadas por 100. En consecuencia, los coeficientes de la ecuación de media del ARMAX/GARCH se interpretan como cambios en puntos porcentuales del rendimiento diario de Bitcoin por cada punto porcentual de cambio en el rendimiento diario de la variable explicativa. A continuación, se presenta la prueba de Dickey-Fuller aumentada (ADF) [14], que permite identificar la presencia de raíces unitarias. También se presenta como alternativa la prueba de Phillips-Perron (PP) [34] con ajuste por correlación serial. Para asegurar la estacionariedad se calcula la tasa de crecimiento para obtener los rendimientos de las variables. Se identifica que los rendimientos de las variables se encuentran libres de raíz

unitaria, lo que evita problemas de regresiones espurias y estabiliza las relaciones entre variables.

Series	ADF	PP	Decisión	Series	ADF	PP	Decisión
<i>A. Niveles</i>				<i>B. Rendimientos</i>			
BTC	-0.5534	-0.6289	I (1)	BTCR	-44.0207 ***	-44.1782 ***	I (0)
ETH	-0.1941	-1.3278	I (1)	ETHR	-28.4900 ***	-44.0735 ***	I (0)
EPU	-1.7764	-28.8498 ***	I (0)	EPUR	-18.7972 ***	-443.2127 ***	I (0)
SP500	1.3671	-0.7516	I (1)	SP500R	-13.0711 ***	-49.7287 ***	I (0)
VIX	-1.5729	-4.7904 ***	I (0)	VIXR	-46.2203 ***	-48.1962 ***	I (0)
EURO	0.0108	-1.9317	I (1)	EUROR	-40.9928 ***	-40.9988 ***	I (0)
LIBRA	-0.0749	-2.5253 *	I (0)	LIBRAR	-41.4387 ***	-41.4593 ***	I (0)
YUAN	-1.5311	-1.1741	I (1)	YUANR	-44.0925 ***	-44.1584 ***	I (0)
GOLD	1.8433	-0.1040	I (1)	GOLDR	-43.9899 ***	-44.0545 ***	I (0)
WTICO	-2.5097	-1.9932	I (1)	WTICOR	-15.0882 ***	-31.6189 ***	I (0)

Fuente: Elaboración propia.

Nota:***, ** y * denotan significancia en los niveles 0.01, 0.05 y 0.1 respectivamente y la estructura empleada es constante y tendencia.

Tabla 1. Pruebas Dickey-Fuller (ADF) y Phillips-Perron (PP).

En seguida se estima la matriz de correlaciones para identificar el signo y el grado de asociación lineal entre las variables del estudio, revelando patrones de comportamiento conjunto y dependencias cruzadas que explican la dinámica de los rendimientos y la volatilidad del Bitcoin. En la tabla 2, destaca la fuerte relación lineal entre los rendimientos de las dos principales criptomonedas, Bitcoin y Ethereum, destacando una correlación positiva (0.7075). Además, los resultados muestran que el rendimiento del índice S&P500 tiene un efecto positivo sobre el precio del Bitcoin, con un coeficiente de correlación de 0.2517, uno de los más altos entre las variables independientes. Esto sugiere que cuando los mercados bursátiles representados por el S&P500 muestran una tendencia alcista, es probable que el precio de la criptomoneda también suba, posiblemente debido a que los inversores transfieren su optimismo desde los mercados tradicionales hacia las criptomonedas.

	BTCR	ETHR	SP500R	VIXR	GOLDR	LIBRAR	EUROR	YUANR	EPUR	WTICOR
BTCR	1	0.7075	0.2517	-0.2092	0.0987	0.1133	0.1063	-0.0892	-0.0064	0.0417
ETHR		1	0.2725	-0.2242	0.1029	0.115	0.1242	-0.1046	-0.0002	0.0354
SP500R			1	-0.7006	0.1099	0.2277	0.1389	-0.1669	0.0213	0.1189
VIXR				1	0.005	-0.1201	-0.0664	0.143	-0.0134	-0.1032
GOLDR					1	0.3019	0.3681	-0.3499	0.0153	0.0374
LIBRAR						1	0.644	-0.3791	-0.0283	0.0619
EUROR							1	-0.4343	-0.0222	0.0163
YUANR								1	-0.0142	-0.0462
EPUR									1	0.003
WTICOR										1

Las correlaciones diarias contemporáneas no incluyen los fines de semana. Los rendimientos diarios se basan en los precios de cierre. Fuente: Elaboración propia.

Tabla 2. Matriz de correlaciones de los rendimientos diarios.

Se identifica que las noticias relacionadas con la tasa de crecimiento del VIX tienen un poder predictivo negativo sobre los rendimientos del Bitcoin, con un coeficiente de -0.2092. En cuanto al oro, considerado un activo refugio, la correlación con Bitcoin es positiva (0.0986), cabe mencionar que esta correlación incondicional no implica causalidad⁵. En relación con

⁵ Los modelos ARMAX-GARCH empleados caracterizan asociaciones condicionales entre rendimientos y su dinámica de volatilidad. No constituyen un diseño de identificación causal, por lo que los coeficientes

el tipo de cambio de la libra y el euro, los resultados muestran una correlación positiva de 0.1133 y 0.1062, respectivamente. Para calcular el valor esperado de los rendimientos del Bitcoin se consideró el algoritmo "Automatic ARIMA Forecasting" del *Econometric Views*, tomando el criterio de información Bayesiano (BIC). Este algoritmo evalúa diversas combinaciones de parámetros y elige el modelo que minimiza este criterio, garantizando un equilibrio entre ajuste y parsimonia. Además, realiza pruebas diagnósticas para verificar la adecuación del modelo, como la revisión de residuos y la estabilidad.

El modelo ARMAX incorpora variables exógenas, siguiendo la recomendación de [26]. Estas variables incluyen los rendimientos de Ethereum y del índice S&P500, junto con un proceso autorregresivo. Como resultado, el modelo presenta un nivel de significancia alto y una bondad de ajuste del 50%. Además, todos los coeficientes estimados son estadísticamente significativos y la prueba Durbin-Watson confirmó la ausencia de autocorrelación, resaltando la robustez del modelo.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000533	0.000872	0.611100	0.5412
ETHR	0.516815	0.006925	74.62752	0.0000
SP500R	0.243656	0.061381	3.969562	0.0001
AR(1)	0.053271	0.012332	4.319852	0.0000
R-cuadrada	0.505730		Prob (F-statistic)	0.000000
R ² Ajustada	0.504636		Durbin-Watson Stat	1.998341

Fuente: Elaboración propia.

Tabla 3. Modelo ARMAX.

Se estimaron pruebas de multiplicador de Lagrange (LM) de Engle y se detectó heterocedasticidad condicional autoregresiva en el modelo ARMAX. También se consideró el efecto asimétrico que generan los impactos positivos y negativos, y en concordancia con las investigaciones de [6, 22, 2] en las que se señala la presencia de un efecto de apalancamiento invertido, por lo que se estima un modelo GJR-GARCH.


Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000109	0.000406	-0.268512	0.7883
ETHR	0.615170	0.007832	78.54180	0.0000
SP500R	0.075060	0.034474	2.177264	0.0295
AR(1)	0.046497	0.020898	2.224968	0.0261
Variance Equation				
a_0	1.54E-05	5.53E-06	2.786367	0.0053
a_1	0.229324	0.060624	3.782742	0.0002
γ	-8.95E-02	4.85E-02	-1.846344	0.0648
β	0.872025	0.015854	55.00357	0.0000
VIXR	0.000379	0.000217	1.745007	0.0810
T-DIST. DOF	2.698355	0.225351	11.97401	0.0000
R ² ajustada	0.487143		Akaike info criterion	-4.63762
Durbin-Watso	1.957373		Schwarz criterion	-4.60725
Observations	1812		Hannan-Quinn criter.	-4.62641

Fuente: Elaboración propia.

Tabla 4. Modelo ARMAX-GJR-GARCH con distribución t-student.

reportados no deben interpretarse como efectos causales. Toda mención a "impacto", "efecto" o "influencia" se entiende en sentido asociativo y condicional a la especificación.

El modelo ARMAX-GJR-GARCH, que incluye el rendimiento de Ethereum, el S&P500 y un coeficiente autorregresivo, presenta coeficientes positivos y estadísticamente significativos al nivel del 3%. Estos hallazgos coinciden con los resultados de [23], quienes indicaron que los precios del Bitcoin y el S&P500 tienden a aumentar juntos. Además, se ajustó una función de distribución t-student, reconocida por su capacidad para capturar colas pesadas y manejar mejor las fluctuaciones abruptas y anomalías en los datos. Estos resultados son consistentes con los trabajos de [8].



Fuente: Elaboración propia.

Figura 1. Curva de impacto de noticias positivas y negativas.

Adicionalmente a la estimación de la volatilidad promedio de los rendimientos del Bitcoin, se identificó de qué manera las variables responden asimétricamente a los distintos choques del mercado. Para ello, se emplearon pruebas de asimetría en el signo y la magnitud, desarrolladas por [18], que permiten detectar si la estructura tiene sesgos en la predicción de la dirección (signo) o el tamaño (magnitud) de la moneda virtual. En estos activos, que experimentan fluctuaciones abruptas, es indispensable comprender si los modelos subestiman o sobrestiman la respuesta ante noticias o eventos, tanto positivos como negativos. De esta manera, la curva de impacto de noticias (*News Impact Curve*), mostrada en la figura 1, derivada del modelo ARMAX-GJR-GARCH con distribución t-student, permite identificar cómo los choques, especialmente los positivos, afectan la volatilidad condicional del Bitcoin.

La reacción del rendimiento de la criptomoneda a buenas y malas noticias revela su sensibilidad y cómo los inversores responden a los eventos. El modelo presentado en la tabla 4 analiza estos efectos, y el coeficiente gamma (γ) que es negativo y significativo (-0.0895) confirma la presencia de un efecto de apalancamiento inverso. Esto implica que las buenas y malas noticias no tienen un impacto simétrico en la volatilidad del Bitcoin, con un mayor aumento en la volatilidad ante impactos positivos. Por ejemplo, si se detecta que Bitcoin reacciona con mayor intensidad a noticias positivas, se ajusta el modelo para capturar este sesgo, mejorando las previsiones de volatilidad y optimizando la gestión de riesgos. Además, la variable VIX, calculada con diferencia logarítmica, es estadísticamente significativa.

5. DISCUSIÓN

La identificación de un efecto de apalancamiento inverso en la volatilidad del Bitcoin refleja la naturaleza especulativa y volátil de la criptomoneda. Sin embargo, es esencial que el modelo estadístico utilizado cumpla con las condiciones de estabilidad ($\alpha + \beta < 1$),

especialmente la estacionariedad de la varianza condicional, para garantizar la fiabilidad de las predicciones y la interpretación de los resultados. La tabla 5 muestran que el modelo GARCH(1,1) presenta un ajuste robusto y parsimonioso, con parámetros estadísticamente significativos en media y varianza y en los criterios de información (AIC y BIC) los estadísticos son superiores respecto a las estructuras GARCH alternativas. Además, reporta un *log-likelihood* superior. Estos resultados justifican el uso del GARCH(1,1) simétrico como especificación base para el análisis de los determinantes de la volatilidad en el mercado del Bitcoin. Esto es especialmente relevante en inversión y gestión de riesgos, donde la estabilidad y predictibilidad de la volatilidad son esenciales para decisiones informadas.

Modelo	Log-Likelihood	AIC	BIC	ARCH (α)	GARCH(β)	($\alpha + \beta$)
GARCH(0,1)	4124.1730	-4.5410	-4.5106	0.000002	-	0.000002
GARCH(1,0)	4104.0970	-4.5184	-4.4885	-	0.61080	0.6108
GARCH(1,1)	4212.9160	-4.6357	-4.6623	0.145700	0.85300	0.9987
GARCH(2,1)	4212.3010	-4.6260	-4.5996	0.113200	0.884800	0.9980
GARCH(1,2)	4211.9700	-4.6356	-4.6222	0.168000	0.82950	0.9975
GJR-GARCH(1,1)	4211.7090	-4.6354	-4.5990	0.158900	0.858400	1.0173

Fuente: Elaboración propia.

Nota: Se mantuvieron constantes estimadores de la ecuación de media y varianza en las diferentes especificaciones. Esto permite garantizar la comparabilidad de los resultados.

Tabla 5. Estructuras GARCH simétricas y asimétricas con distribución GED.

Entre las principales investigaciones que emplean esta estructura se encuentra el trabajo de [5], quienes no encontraron evidencia de una relación asimétrica entre el rendimiento y la volatilidad del Bitcoin, lo que sugiere que los cambios en la volatilidad no dependen de la dirección de los rendimientos. Los autores aplicaron pruebas para detectar sesgo de signo y concluyeron que la respuesta de la volatilidad a rendimientos positivos o negativos no es significativa. Esto indica que la volatilidad de la moneda digital no responde de manera asimétrica, lo cual es un comportamiento inusual frente a activos financieros tradicionales.

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000004	0.000320	0.011754	0.9906
ETHR	0.624779	0.006976	89.56161	0.0000
SP500R	0.070389	0.029120	2.417198	0.0156
GOLDR	-0.085699	0.039160	-2.188455	0.0286
LIBRAR	0.121158	0.055369	2.18819	0.0287
AR(1)	0.050031	0.017629	2.837992	0.0045
Variance Equation				
α_0	1.49E-05	4.10E-06	3.632783	0.0003
α_1	0.145704	0.02466	5.908564	0.0000
β	0.853046	0.01903	44.82743	0.0000
VIXR	0.000257	0.000145	1.767912	0.0771
GED PARAMETER	0.904099	0.036187	24.98382	0.0000
R^2 ajustada	0.483052	Akaike info criterion	-4.63578	
Durbin-Watson Stat.	1.962985	Schwarz criterion	-4.60238	
Observations	1812	Hannan-Quinn criter.	-4.62345	

Fuente: Elaboración propia.

Nota: El valor del parámetro para la distribución t-stat es: 11.8795 significativo al 1%.

Tabla 6. Modelo ARMAX-GARCH con distribución GED.

Los resultados mostrados en la tabla 6 indican que, en la ecuación de la media, el rendimiento de Ethereum tiene el coeficiente de pendiente más alto (0.6247), estadísticamente significativo y el signo del coeficiente refleja una relación directamente proporcional. Estos hallazgos coinciden con lo señalado por [10, 22], quienes explican que los precios de criptomonedas como Ethereum, LiteCoin y Dash, al igual que Bitcoin, se basan en el mecanismo de *Proof of Work*, lo que genera una relación más cercana con el precio de la criptomoneda. Los autores concluyen que estas *altcoins* comparten mecanismos de fijación de precios similares a los del Bitcoin (oferta, demanda, validación de transacciones) y presentan una cointegración más fuerte con Bitcoin en comparación con otras criptomonedas.

Otro hallazgo clave es la significancia estadística de la tasa de crecimiento del S&P500 con un coeficiente positivo. En particular, se observó que un incremento del 1% en los rendimientos de esta variable se asocia con un aumento del 7.03% en el precio del Bitcoin. Este resultado sugiere que el mercado de criptomonedas, en especial el del Bitcoin, está fuertemente influenciado por el comportamiento de los mercados bursátiles tradicionales, lo que refleja una creciente interconexión entre estos activos financieros. La interpretación plausible es que cuando aumenta el optimismo en los mercados financieros, los inversores también muestran mayor confianza en Bitcoin. Estos resultados están en línea con estudios previos de [15, 23], quienes también identificaron un impacto del mercado de valores en el precio del Bitcoin.

En contraste, los resultados revelan una correlación negativa entre los rendimientos del Bitcoin y el precio del oro, en consonancia con los estudios de [15] y [2]. Por cada aumento del 1% en el rendimiento del oro, el precio de la moneda digital disminuye en un 8.5%. Esto sugiere que, ante un aumento del precio de esta *commodity*, los inversores perciben mayor incertidumbre y preferirán mantenerse refugiados en el oro, pues es considerado un activo seguro. Estos hallazgos, respaldados por [6], sugieren que Bitcoin puede actuar como cobertura durante turbulencias en los mercados de materias primas y en ciertos momentos como refugio frente a riesgos del mercado de valores.

Continuando con el modelo de la media, la moneda fiduciaria presenta el segundo coeficiente de pendiente más alto, siendo estadísticamente significativo al 5%. Esto quiere decir que un aumento del 1% en el tipo de cambio de la libra esterlina incrementa el precio del Bitcoin en un 12.11%. Estos resultados coinciden con el estudio de [16], que también encontró una relación entre Bitcoin y los tipos de cambio. Asimismo, los hallazgos son consistentes con [9], quienes utilizaron datos diarios y técnicas de *machine learning*, concluyendo que la incertidumbre causada por el Brexit impulsó el impacto positivo del tipo de cambio de la Libra en el precio del Bitcoin.

Respecto al último coeficiente de la media, se identifica una relación positiva y significativa entre el precio del Bitcoin y su rezago (AR(1)), incluso al nivel del 1%. Esto se traduce en que un aumento del 1% en el rendimiento del día anterior se asocia con un incremento del 5% en el rendimiento actual de divisa virtual; este hallazgo es relevante porque sugiere que la hipótesis del mercado eficiente no se cumple, dado que los rendimientos pasados no

deberían predecir los rendimientos presentes. [23] atribuyen esta ineficiencia a errores en el razonamiento humano y al procesamiento de información.

Dado que muchos inversores tienen poca experiencia con Bitcoin y deben tomar decisiones rápidas en un entorno de incertidumbre, es probable que se vean influenciados por el impulso de precios al alza. Se podría interpretar que observar el incremento de precios del día anterior alimenta la demanda y crea un impulso en el precio. Combinado con la teoría del impulso, esto puede interpretarse en el marco de la teoría del "*mayor tonto (greater fool theory)*", en la cual, a medida que el precio aumenta rápidamente, los inversores ven un potencial de enriquecimiento rápido al comprar ahora y vender a un ingenuo la próxima semana [23].

Estos resultados coinciden con los de [38], quien sostiene que en un mercado eficiente los precios futuros no son previsibles y siguen una caminata aleatoria debido a la naturaleza estocástica de los eventos. Encuentra que los rendimientos del Bitcoin son persistentemente ineficientes, lo que se atribuye a su condición de activo en desarrollo y lo hace vulnerable a la volatilidad de los mercados emergentes. Además, los hallazgos amplían estudios previos sobre la dinámica de precios en criptomonedas, como los de [29, 37] demostrando la ineficiencia del mercado en criptomonedas clave, lo que puede ser útil para *traders* que analizan Ethereum y otras criptomonedas importantes.

En la ecuación de la varianza, se observa que el coeficiente ARCH, que mide el impacto de las noticias recientes en la volatilidad, es estadísticamente significativo al 1%, lo que sugiere que la volatilidad del rendimiento de la criptomoneda en el día anterior influye en su volatilidad actual. Del mismo modo, el coeficiente GARCH, también significativo al 1%, confirma que la volatilidad pasada afecta su presente. Estos resultados indican que el modelo GARCH(1,1) es adecuado para modelar la volatilidad del Bitcoin. Además, la suma de los coeficientes es menor a la unidad, lo que asegura la estabilidad del modelo.

Un aspecto clave en la determinación de la volatilidad del Bitcoin es el impacto positivo y estadísticamente significativo del índice de volatilidad del mercado (VIX), con un coeficiente de 0.000257 al nivel de significancia del 10%. El VIX, conocido como el "índice del miedo", mide la volatilidad esperada en el S&P500 durante los próximos 30 días y refleja el sentimiento del mercado. Un aumento en el VIX indica mayor incertidumbre, mientras que una disminución sugiere estabilidad. Estos resultados coinciden con los estudios de [25, 6], quienes también destacan la influencia de la volatilidad del mercado en los rendimientos del criptoactivo.

Finalmente, se realizaron pruebas para determinar si las innovaciones que mejor definen la función de densidad de probabilidad corresponden a distribuciones gaussianas, *t-student* o errores generalizados (GED), utilizando los criterios de información de Akaike y Bayesiano. Los resultados mostraron que el modelo con el mejor ajuste y estabilidad es el de tipo GED, que presentó las estimaciones más precisas. En consonancia con este hallazgo, [31] recomienda el uso del modelo GARCH con distribución GED, ya que permite capturar colas más gruesas que la distribución normal y evita problemas como la varianza incondicional infinita que puede surgir con la distribución *t-student*, mejorando así la curtosis y reduciendo la autocorrelación de las observaciones.

El modelo simétrico para la media y la varianza condicional con distribución GED presenta un coeficiente de determinación R-cuadrado = 0.4844, superior al reportado en estudios previos [2, 22]. La estadística Durbin–Watson ($DW = 1.9629$) y las pruebas Ljung–Box aplicadas a los residuos y a los residuos al cuadrado no detectan autocorrelación remanente. Asimismo, la prueba ARCH–LM arroja $F = 0.4354$ (p-value de 0.8804), descartando efectos ARCH no modelados. En conjunto, estos resultados respaldan la validez de la especificación y su robustez para capturar una volatilidad simétrica en el mercado de criptomonedas.

6. CONCLUSIÓN

El estudio analiza el rendimiento y la volatilidad condicional del Bitcoin entre enero de 2017 y abril de 2024. Dada su elevada volatilidad y creciente integración con los mercados financieros, se adopta un marco ARMAX para la media y GARCH para la varianza, con distribuciones de colas pesadas, a fin de capturar adecuadamente eventos extremos y dependencias condicionadas.

La selección de la ecuación de media (ARMAX) se realiza con un procedimiento automático y parsimonioso (búsqueda stepwise y criterios de información), mientras que la volatilidad se modela con estructuras GARCH simétrica y asimétricas (GJR-GARCH) bajo innovaciones GED. Si bien el GJR-GARCH detecta un patrón de “apalancamiento inverso”, no satisface la condición de estabilidad de la varianza condicional; por ello, se privilegia la especificación GARCH simétrica con GED, que ofrece un equilibrio superior entre ajuste, estabilidad y diagnóstico.

Los resultados indican volatilidad simétrica en el periodo y comovimiento positivo condicional de Bitcoin con Ethereum y con el S&P 500; ello es consistente con una mayor integración financiera. El oro presenta un coeficiente negativo en la media condicional, pese a una correlación contemporánea pequeña y positiva, compatible con su función de activo refugio. Adicionalmente, el rendimiento de monedas fiduciarias como la libra esterlina muestra una influencia positiva sobre Bitcoin. Estas relaciones son condicionales y multivariadas; no deben leerse como causalidad.

Otro de los hallazgos principales es la comprobación de una relación positiva entre el precio del Bitcoin y su propio rezago, lo que contradice la hipótesis de eficiencia del mercado (HEM), sugiriendo que las imperfecciones del mercado, debido, principalmente a que los inversores minoristas, generalmente considerados no informados o poco sofisticados, son particularmente activos en estos mercados [32], crean oportunidades de arbitraje basadas en patrones pasados, como indican [38, 23]. La HEM en su forma débil ha sido ampliamente estudiada para activos financieros tradicionales y productos básicos [24], pero pocas investigaciones se han centrado en Bitcoin, lo que resalta la relevancia de esta investigación. A medida que más inversores analicen y negocien con Bitcoin, es probable que su mercado se vuelva más eficiente con el tiempo, cerrando las oportunidades de ineficiencia actuales. También se confirma que un VIX más alto incrementa la volatilidad del Bitcoin, evidenciando su sensibilidad al sentimiento del mercado.

Finalmente, se identifican dos frentes que requieren atención en investigaciones futuras. Primero, es necesario reconocer plenamente el régimen posterior a la aprobación de los ETF

spot de Bitcoin, lo acontecido de 2024 a la fecha; la evidencia reciente indica que este hito reconfiguró de manera apreciable los rendimientos y la volatilidad de las criptomonedas, en línea con una “hipótesis de estabilización”, y alteró sus vínculos con otros activos, por lo que conviene contrastar cambios estructurales [1]. Segundo, el enfoque univariado ARMAX/GARCH limita la identificación de efectos de contagio o transmisión (spillovers) desde el mercado cripto hacia acciones, *commodities*, divisas e índices de volatilidad; en consecuencia, se propone para un análisis posterior el incorporar un BGVAR (Bayesian Global VAR) para identificar y cuantificar la magnitud, dirección de causalidad y persistencia de los choques cripto mediante funciones de impulso–respuesta y descomposiciones acumuladas de varianza [39].

RECEIVED: OCTOBER, 2024

REVISED: DECEMBER, 2025.

REFERENCIAS

- [1] BABALOS, V., BOURI, E., & GUPTA, R. (2025). Does the introduction of US spot Bitcoin ETFs affect spot returns and volatility of major cryptocurrencies? **The Quarterly Review of Economics and Finance**, 102, 102006. <https://doi.org/10.1016/j.qref.2025.102006>
- [2] BAUR, D. G., DIMPFLB, T., & KUCKC, K. (2018). Bitcoin, gold and the US dollar – A replication and extension. **Finance Research Letter**, 25, 103–110. <https://doi.org/10.1016/j.frl.2017.10.012>
- [3] BINSBERGEN, J., M. BRANDT, & KOIJEN, R. (2012). "On the Timing and Pricing of Dividends." **American Economic Review**, 102 (4): 1596–1618.
- [4] BOLLERSLEV, T. (1986). Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- [5] BOURI, E., AZZI, G. & DYHRBERG, A. (2016). On the Return-Volatility Relationship in the Bitcoin Market around the Price Crash of 2013. **Economics Discussion Papers** No. 2016/41, Kiel Institute for the World Economy. <https://doi.org/10.2139/ssrn.2869855>
- [6] BOURI, E., MOLNÁR, P., AZZI, G., ROUBAUD, D., & HAGFORS, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier? **Finance Research Letters**, 20, 192-198.
- [7] BOX, G. E. P., & JENKINS, G. M. (1976). Time series analysis: Forecasting and control. Holden-Day.
- [8] CHEN F , TIAN K , DING X , MIAO & , LU C . (2016). Finite-size effect and the components of multifractality in transport economics volatility based on multifractal detrending moving average method. **Physica A**; 462:1058–66 .
- [9] CHEN T., CHEN M. Y. Y DU, G.T. (2021). "The Determinants of Bitcoin’s Price: Utilization of GARCH and Machine Learning Approaches," **Computational Economics**, Springer; Society for Computational Economics, vol. 57(1), pages 267-280, January.
- [10] CIAIAN, P., RAJCANIOVA, M., & D'ARTIS, K. (2018). Virtual relationships: Short-and long-run evidence from bitcoin and altcoin markets. **Journal of International Financial Markets, Institutions & Money**, 52, 173-195. <https://doi.org/10.1016/j.intfin.2017.11.001>
- [11] CONRAD, C., CUSTOVIC, A., & GHYSELS, E. (2018). Long-and short term cryptocurrency volatility components: A garch-midas analysis. **Journal of Risk and Financial Management**, 11, 23.

- [12] CORBET, S., LUCEY, B., URQUHART, A., & YAROVAYA, L. (2019). Cryptocurrencies as a financial asset: A systematic analysis. **International Review of Financial Analysis**, 62, 182-199.
- [13] DAS, D., & KANNADHASAN, M. (2018). Do global factors impact bitcoin prices? Evidence from wavelet approach. **Journal of Economic Research**, 23(1), 227-264.
- [14] DICKEY, D. A., & FULLER, W. A. (1979): Distribution of the estimators for autoregressive time series with a unit root. **Journal of the American Statistical Association**, 74(366a), 427-431. <https://doi.org/10.1080/01621459.1979.10482531>
- [15] DYHRBERG, A. H. (2016a). Bitcoin, gold and the dollar a garch volatility analysis. **Finance Research Letters**, 16 , 85–92 .
- [16] DYHRBERG, A. H. (2016b). Hedging capabilities of Bitcoin. Is it the virtual gold? **Finance Research Letters**, 16, 139-144. <https://doi.org/10.1016/j.frl.2015.10.025>
- [17] ENGLE, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. **Econometrica**, 50(4), 987-1007. <https://doi.org/10.2307/1912773>
- [18] ENGLE, R. F., & NG, V. K. (1993). Measuring and testing the impact of news on volatility. **The Journal of Finance**, 48(5), 1749-1778. <https://doi.org/10.1111/j.1540-6261.1993.tb05127.x>
- [19] FAMA, E. F. (1998). Market efficiency, long-term returns, and behavioral finance. **Journal of Financial Economics**, 49(3), 283-306. [https://doi.org/10.1016/S0304-405X\(98\)00026-9](https://doi.org/10.1016/S0304-405X(98)00026-9)
- [20] GLOSTEN, L. R., JAGANNATHAN, R., & RUNKLE, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. **The Journal of Finance**, 48(5), 1779-1801. <https://doi.org/10.1111/j.1540-6261.1993.tb05128.x>
- [21] HYNDMAN, R. J., & KHANDAKAR, Y. (2008). Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>
- [22] KATSIAMPA, P. (2017). Volatility estimation for Bitcoin: A comparison of GARCH models. **Economic Letters**, 158, 3–6. <https://doi.org/10.1016/j.frl.2015.10.008>
- [23] KJÆRLAND F, KHAZALI A, KROGSTAD EA, NORDSTRØM FBG, OUST A. (2018). An Analysis of Bitcoin's Price Dynamics. **Journal of Risk and Financial Management**. 2018; 11(4):63. <https://doi.org/10.3390/jrfm11040063>
- [24] KRISTOUFEK, L., & VOSVRDA, M. (2014). Commodity futures and market efficiency. **Physica A: Statistical Mechanics and its Applications**, 410, 225-234.
- [25] LÓPEZ-CABARCOS, M. Á., PÉREZ-PICO, A. M., PIÑEIRO-CHOUSA, J., & ŠEVIĆ, A. (2021). Bitcoin volatility, stock market and investor sentiment: Are they connected? **Finance Research Letters**, 38, 101399.
- [26] MALLADI R., DHEERIYA P. & MARTINEZ J. (2019). Predicting Bitcoin return and volatility using gold and the stock market. **Quarterly Review of Business Disciplines** 5(4):357–373.
- [27] MALLADI R., & DHEERIYA, P. L. (2021). "Time series analysis of Cryptocurrency returns and volatilities," **Journal of Economics and Finance**, Springer; Academy of Economics and Finance, vol. 45(1), pages 75-94, January.
- [28] MENSI, W., AL-YAHYAEE, K. H., & KANG, S. H. (2019). Structural breaks and double long memory of cryptocurrency prices: A comparative analysis from Bitcoin and Ethereum. **Finance Research Letters**, 29, 222-230. <https://www.sciencedirect.com/science/article/abs/pii/S1544612318303076>

- [29] NADARAJAH, S., & CHU, J. (2017). On the inefficiency of bitcoin. **Economics Letters**, 150, 6–9.
- [30] NAKAMOTO, S. (2008). Bitcoin: a peer-to-peer electronic cash system. <https://bitcoin.org/bitcoin.pdf>.
- [31] NELSON, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. **Econometrica**, 59(2), 347-370. <https://doi.org/10.2307/2938260>
- [32] OYEDELE, A. (2017). One group of traders has risen to dominate bitcoin trading. <https://www.businessinsider.de/bitcoin-trading-driven-by-japanese-menyen-201712?r=US&IR=T>.
- [33] PAL, D. & MITRA S.K. (2019). Hedging bitcoin with other financial assets, **Finance Research Letters**, Elsevier, vol. 30(C), 30-36.
- [34] PHILLIPS, P. C. B., & PERRON, P. (1988): Testing for a unit root in time series regression. **Biometrika**, 75(2), 335-346. <https://doi.org/10.1093/biomet/75.2.335>
- [35] SAPURIC, S., KOKKINAKI, A., & GEORGIU, I. (2020). The relationship between Bitcoin returns, volatility and volume: asymmetric GARCH modeling. **Journal of Enterprise Information Management**. <https://doi.org/10.1108/JEIM-10-2018-0228>
- [36] SHAW, C. (2018). Conditional Heteroskedasticity in Crypto-Asset Returns, **Journal of Statistics: Advances in Theory and Applications**, vol. 20, no. 1, pp. 15-65.
- [37] TIWARI, A. K., KUMAR, S., & PATHAK, R. (2018). Modelling the dynamics of Bitcoin and Litecoin: GARCH versus stochastic volatility models. **Applied Economics**, 51(37), 4073–4082. <https://doi.org/10.1080/00036846.2019.1588951>
- [38] URQUHART, A. (2016). The inefficiency of Bitcoin. **Economics Letters**, 148, 80–82. <https://doi.org/10.1016/j.econlet.2016.09.019>
- [39] VUKOVIĆ, D. B., FRÖMMEL, M., VIGNE, S. A., & ZINOVEV, V. (2025). Spillovers between cryptocurrencies and financial markets in a global framework. **Journal of International Money and Finance**, 150, 103235. <https://doi.org/10.1016/j.jimonfin.2024.103235>
- [40] WICHERN, D. W., & JONES, R. H. (1977). A vector autoregressive-moving average (VARMA) model. **Journal of Multivariate Analysis**, 7(2), 232-255.