Universidad de Lima

Facultad de Ciencias Empresariales y Económicas

Carrera de Economía

# EFICIENCIA EN EL MERCADO DE LAS CRIPTOMONEDAS EN EL PERIODO PRE-COVID-19 (2018-2020) Y COVID-19 (2020-2022)

Tesis para optar al Título Profesional de Economista

**Gonzalo Parodi Sánchez-Cerro**

**Código 20172462**

**Asesor**

José Luis Nolazco Cama

Lima – Perú

Diciembre del 2024

UNIVERSIDAD DE LIMA
MCMLXII
SCIENTIA ET PRAXIS

# EFFICIENCY IN THE MARKET OF CRYPTOCURRENCY AT THE PRE-COVID-19 (2018-2020) AND COVID-19 PERIOD (2020-2022)

# TABLA DE CONTENIDO

**RESUMEN** ..... **ix**
**ABSTRACT** ..... **x**
**INTRODUCCIÓN** ..... **1**
**CAPÍTULO I: OBJETIVOS** ..... **4**
1.1 Objetivo general ..... 4
1.2 Objetivos específicos ..... 4
**CAPÍTULO II: PREGUNTAS** ..... **5**
2.1 Pregunta general ..... 5
2.2 Preguntas específicas ..... 5
**CAPÍTULO III: HIPÓTESIS** ..... **6**
3.1 Hipótesis general ..... 6
3.2 Hipótesis específicas ..... 6
**CAPÍTULO IV: MARCO TEÓRICO** ..... **7**
**CAPÍTULO V: MARCO CONTEXTUAL** ..... **12**
**CAPÍTULO VI: REVISIÓN DE LITERATURA** ..... **13**
**CAPÍTULO VII: METODOLOGÍA** ..... **24**
6.1 Las variables para el trabajo de investigación ..... 24
6.2 Propuesta Empírica ..... 26
**CAPÍTULO VIII: ANÁLISIS DE RESULTADOS** ..... **28**
**CAPÍTULO IX: CONCLUSIONES** ..... **35**
**RECOMENDACIONES** ..... **37**
**MATRIZ DE CONSISTENCIA** ..... **38**
**REFERENCIAS** ..... **39**
**BIBLIOGRAFIA** ..... **42**
**ANEXOS** ..... **45**

# ÍNDICE DE TABLAS

Tabla 6.1.1 *Definición de variables seleccionadas* .....25
Tabla 7.1 *Resultados del modelo GARCH para el periodo pre-COVID-19*.....28
Tabla 7.2 *Resultados del modelo GARCH para el periodo durante el COVID-19*.....31

UNIVERSIDAD DE LIMA
MCMLXII
SCIENTIA ET PRAXIS

# ÍNDICE DE FIGURAS

Figura 6.1.1 *Peso de las cinco criptomonedas en el mercado de las criptomonedas* ....24

# ÍNDICE DE ANEXOS

Anexo 1: Gráfico de Retorno_BTC2 periodo pre-COVID-19 ..... 46
Anexo 2: Gráfico de Retorno_ETH2 periodo pre-COVID-19 ..... 47
Anexo 3: Gráfico de Retorno_USDT2 periodo pre-COVID-19 ..... 48
Anexo 4: Gráfico de Retorno_USDC2 periodo pre-COVID-19 ..... 49
Anexo 5: Gráfico de Retorno_BNB2 periodo pre-COVID-19 ..... 50
Anexo 6: Resultados del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo pre-COVID-19 ..... 51
Anexo 7: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo pre-COVID-19 ..... 52
Anexo 8: Resultados del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo pre-COVID-19 ..... 53
Anexo 9: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo pre-COVID-19 ..... 54
Anexo 10: Resultados del modelo GARCH para la criptomoneda Tether (USDT) en el periodo pre-COVID-19 ..... 55
Anexo 11: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Tether (USDT) en el periodo pre-COVID-19 ..... 56
Anexo 12: Resultados del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo pre-COVID-19 ..... 57
Anexo 13: Multiplicador de Lagrange del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo pre-COVID-19 ..... 58
Anexo 14: Resultados del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo pre-COVID-19 ..... 59
Anexo 15: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo pre-COVID-19 ..... 60
Anexo 16: Gráfico de Retorno_BTC2 periodo durante el COVID-19 ..... 61
Anexo 17: Gráfico de Retorno_ETH2 periodo durante el COVID-19 ..... 62
Anexo 18: Gráfico de Retorno_USDT2 periodo durante el COVID-19 ..... 63
Anexo 19: Gráfico de Retorno_USDC2 periodo durante el COVID-19 ..... 64
Anexo 20: Gráfico de Retorno_BNB2 periodo durante el COVID-19 ..... 65
Anexo 21: Resultados del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo durante el COVID-19 ..... 66

Anexo 22: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo durante el COVID-19 ..... 67
Anexo 23: Resultados del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo durante el COVID-19 ..... 68
Anexo 24: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo durante el COVID-19..... 69
Anexo 25: Resultados del modelo GARCH para la criptomoneda Tether (USDT) en el periodo durante el COVID-19 ..... 70
Anexo 26: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Tether (USDT) en el periodo durante el COVID-19..... 71
Anexo 27: Resultados del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo durante el COVID-19 ..... 72
Anexo 28: Multiplicador de Lagrange del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo durante el COVID-19..... 73
Anexo 29: Resultados del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo durante el COVID-19..... 74
Anexo 30: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo durante el COVID-19..... 75

# RESUMEN

El presente trabajo busca hallar si los mercados de cinco criptomonedas muestran eficiencia de mercado débil y como ésta se ve afectada por la crisis del COVID-19, razón por la cual se observará su eficiencia para la época previa a la pandemia por COVID-19 y si hubo un cambio uniforme en ésta para la época durante el COVID-19. En adición, se busca hallar si existe o no una relación significativa entre la liquidez y la eficiencia de mercado. Los resultados encontrados indican que dos de los mercados de las criptomonedas sí son eficientes y tres no, la pandemia impactó en su eficiencia y provocó que esta cambie para dos de las cinco criptomonedas en sentidos contrarios, una volviéndose eficiente y la otra ineficiente. Finalmente, se halló una relación significativa entre la liquidez y la eficiencia de mercado.

**Línea de investigación:** 5300 - 3.l4

**Palabras clave**: criptomonedas, eficiencia de mercado, liquidez, Bitcoin, Ethereum

# ABSTRACT

The present work wants to find if the markets of five cryptocurrency show weak market efficiency and how it is affected by the COVID-19 crisis, which is why their efficiency will be observed for the time prior to the COVID-19 pandemic and if there was a uniform change for the time during COVID-19. In addition, we seek to find whether or not there is a significant relationship between liquidity and market efficiency. The results found indicate that two of the cryptocurrency markets are efficient and three are not, the pandemic impacted their efficiency and caused it to change for two of the five cryptocurrencies in opposite directions, one becoming efficient and the other inefficient. Finally, a significant relationship was found between liquidity and market efficiency.

**Line of research:** 5300 - 3.l4

**Keywords**: Cryptocurrency, Market Efficiency, Liquidity, Bitcoin, Ethereum

UNIVERSIDAD DE LIMA
MCMLXII
SCIENTIA ET PRAXIS

# INTRODUCCIÓN

En el año 2010, si se le preguntase a un inversionista sobre qué es la moneda Bitcoin, este diría que desconoce sobre la existencia de la Bitcoin o se referiría a esta como aquel activo cuyo valor es menor al céntimo de dólar. Es más, en el diario ElEconomista (mayo de 2022). publicaron una noticia sobre una persona que pago en el año 2010 dos pizzas con 10,000 Bitcoins, cuyo valor al 18 de mayo de 2022 era de 290 millones de euros.

La evolución de las criptomonedas en la última década es sorprendente, activos que valían menos de 1 dólar en 2010 pueden llegar a valer hoy en día miles de dólares. A día de hoy, julio de 2022, el mercado de las criptomonedas tiene un valor capitalizable de 942 billones de dólares o 942 miles de millones de dólares, siendo el precio de su moneda más capitalizada, la criptomoneda Bitcoin, de 21,302.51 dólares. Inclusive, según Fung et al. (2022), el valor capitalizable del mercado de las criptomonedas llego a ser de 1.5 trillones de dólares en marzo de 2021, siendo su valor en marzo de 2018 de 295 billones de dólares o miles de millones de dólares. El crecimiento del mercado de las criptomonedas ha asombrado a muchas personas a lo largo de su historia, más aún cuando su valor proviene de lo que las personas consideran que esta vale; es decir, el valor de estas monedas no tiene ninguna base sólida, únicamente el valor subjetivo que las personas le dan, como indica DeVries (2016).

Este impresionante crecimiento del mercado de las criptomonedas ha generado mucho interés en estas, teniendo como consecuencia múltiples estudios realizados en base a diferentes aspectos del mercado de las criptomonedas, el presente trabajo es uno de ellos. El mercado de estas monedas es muy volátil, también es un mercado que resalta, según DeVries (2016), en que las transacciones son rápidas. Las criptomonedas pueden convertirse rápidamente en dinero tradicional, lo cual las convierte en activos líquidos. Por supuesto, asumir que las más de 7,000 criptomonedas que hay actualmente, además de la más conocida Bitcoin, tienen la misma liquidez, no es lo más coherente, habrá algunas monedas más liquidas que otras. A pesar de todo, en teoría todas tienen una buena liquidez.

La naturaleza de las criptomonedas como un activo volátil, su valor subjetivo y sus diferentes características hacen que se plantee si es que el mercado de estas monedas

es eficiente o ineficiente. Si bien, existen diferentes estudios que han investigado la eficiencia del mercado de las criptomonedas, existe una peculiaridad en los últimos dos años que hacen de la investigación una más interesante, y esa es la pandemia del COVID-19.

El presente trabajo de investigación busca hallar si el mercado de las criptomonedas es eficiente o ineficiente, específicamente los mercados de las criptomonedas Bitcoin (BTC), Ethereum (ETH), Tether (USDT), USD Coin (USDC) y Binance Coin (BNB), cuyo volumen de capitalización en conjunto representa más del 70% del mercado capitalizable de las criptomonedas, usando la teoría de los mercados eficientes de Fama (1970) y Fama (1976). En adición, teniendo en cuenta la naturaleza líquida de estas monedas, se busca hallar si existe una relación entre la liquidez y la eficiencia del mercado. Por otro lado, se busca hallar cambios en la eficiencia de las criptomonedas previamente mencionadas como consecuencia de la pandemia por el COVID-19. De darse el caso que ocurre un cambio en la eficiencia, producto del shock por el COVID-19, se observará si éste impactó de la misma manera; es decir, si todas presentan una disminución o un aumento en su eficiencia.

A diferencia de Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB), Tether (USDT) y USD Coin (USDC) buscan reflejar el precio del dólar; por lo tanto, se analizará el impacto de la pandemia por separado para estos dos grupos.

Para los inversionistas, el saber si el mercado de las diversas criptomonedas es eficiente o no genera un gran impacto en sus decisiones, pues la existencia del arbitraje en un mercado ineficiente tiene un gran impacto sobre los rendimientos del activo. Adicionalmente, al ser estos activos significativamente líquidos, será de gran interés para los inversionistas el saber si su significativa liquidez hace del mercado uno más eficiente. Por último, observar el impacto que puede tener una crisis, como la del COVID-19, en la eficiencia del mercado de las criptomonedas brinda una nueva perspectiva para los inversionistas sobre lo que esperar en un futuro si es que sucede nuevamente un periodo de estrés financiero a nivel global.

Para descubrir la eficiencia de mercado de las criptomonedas y hallar si existe o no una relación con la liquidez, se realizarán diez modelos GARCH, modelo el cual fue creado para activos especialmente volátiles y cuya volatilidad ya se asume en el modelo. Se realizará un modelo GARCH para cada criptomoneda para la época pre-COVID-19 y

uno para cada criptomoneda para la época durante el COVID-19. Estos modelos de por sí incluye los rezagos AR(p) que serán necesarios para hallar la eficiencia débil del mercado y, adicionalmente, se le agregará una variable dummy cuyo valor 1 representará la iliquidez de la criptomoneda planeado por Amihud (2002) para poder hallar si hay o no una relación entre la eficiencia de mercado y la liquidez de las criptomonedas.

Los resultados obtenidos muestran una relación significativa entre el ratio de iliquidez de Amihud y la eficiencia de mercado. En lo que respecta a la eficiencia débil de mercado, dos de los cinco mercados de las criptomonedas eran eficientes para la época pre-COVID-19. Por otro lado, para el periodo durante el COVID-19 observamos que el grupo de criptomonedas conformado por Tether (USDT) y USD Coin (USDC) no se ha visto afectado, ambas criptomonedas permanecen con ineficiencia de mercado. En lo que respecta al grupo de criptomonedas conformado por Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB), su eficiencia de mercado cambió durante la pandemia; sin embargo, una criptomoneda se volvió eficiente y otra se volvió ineficiente.

Finalmente, los siguientes capítulos de la investigación nos mostrarán los objetivos, preguntas e hipótesis planteadas para el trabajo y, también, explicarán el marco teórico, las diferentes investigaciones que ayudaron a la creación de este trabajo, la metodología del trabajo explicada más detalladamente, los resultados y las conclusiones.

# CAPÍTULO I: OBJETIVOS

## 1.1 Objetivo general

Hallar la eficiencia del mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH), Tether (USDT), USD Coin (USDC) y Binance Coin (BNB) en la época previa al COVID-19, del 16 de octubre de 2018 al 29 de febrero de 2020, observar si cambió durante el COVID-19, del 1 de marzo de 2020 al 27 de junio de 2022, y de ser así si el cambio se presenta de la misma manera entre los dos grupos de las criptomonedas.

## 1.2 Objetivos específicos

- Determinar si existe o no eficiencia de mercado para cada una de las cinco principales criptomonedas durante el periodo previo al COVID-19.
- Contrastar si la eficiencia de mercado cambio para las cinco criptomonedas en el periodo COVID-19.
- Evaluar si existe relación entre la liquidez de las criptomonedas y su eficiencia.

# CAPÍTULO II: PREGUNTAS

## 2.1 Pregunta general

¿El mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH), Tether (USDT), USD Coin (USDC) y Binance Coin (BNB) era eficiente en la época previa al COVID-19, del 16 de octubre de 2018 al 29 de febrero de 2020, y esta eficiencia cambió de manera uniforme durante el COVID-19, del 1 de marzo de 2020 al 27 de junio de 2022?

## 2.2 Preguntas específicas

- ¿Fue eficiente el mercado de las cinco principales criptomonedas durante el periodo previo al COVID-19?
- ¿Cambió la eficiencia de mercado para cada una de las cinco criptomonedas en el periodo COVID-19?
- ¿Existe una relación entre la liquidez de las criptomonedas y su eficiencia?

# CAPÍTULO III: HIPÓTESIS

## 3.1 Hipótesis general

Sí existe eficiencia del mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) en la época pre-COVID-19, del 16 de octubre de 2018 al 29 de febrero de 2020, y esta eficiencia cambió de manera uniforme durante el COVID-19, del 1 de marzo de 2020 al 27 de junio de 2022. El mercado de las criptomonedas Tether (USDT) y USD Coin (USDC) no serán eficientes en ningún periodo.

## 3.2 Hipótesis específicas

- El mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) durante el periodo pre-COVID-19 fue eficiente.
- La eficiencia de mercado cambio para Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) en el periodo COVID-19.
- El mercado de las criptomonedas Tether (USDT) y USD Coin (USDC) será ineficiente en ambos periodos.
- Existe una relación significativa entre la liquidez de las criptomonedas y su eficiencia.

# CAPÍTULO IV: MARCO TEÓRICO

Con respecto a la teoría de los mercados eficientes, uno de los primeros autores en plantearse la idea de los mercados eficientes fue el autor Bachelier (1900), quien estudia la variación de los precios de los activos en el mercado con su teoría de la especulación.

Según Riaño (2018), autor que habla sobre la historia de los mercados eficientes, la investigación de Bachelier (1900) generaría interés en los años posteriores al año 1960. Previamente a este suceso, diferentes autores comenzaron a tratar la idea de los mercados eficientes, autores como Kendall (1953) quien creó una teoría de mercados eficientes usando un paseo aleatorio al observar la evolución de los precios de los activos en la bolsa, Alexander (1961) y Cootner (1964) quienes también usaron el paseo aleatorio para analizar los precios de los activos en el mercado, llegando a la conclusión de que el precio de las acciones solo cambiaba si había nueva información.

En las investigaciones previas a Fama (1970), se realizaron diferentes metodologías para explicar la eficiencia del mercado. Estas metodologías tenían algo en común, pues todas usaban el precio de los activos en el mercado para hallar retornos esperados. Este factor en común sería tomado por la investigación de Fama, que posteriormente se convertiría en uno de los trabajos más importantes con respecto a la eficiencia de los mercados.

Fama (1970) investigó de forma teórica y empírica lo que es un mercado eficiente, creando así la teoría del mercado eficiente. Se presentan tres tipos de eficiencia de mercado: la eficiencia débil de mercado, donde no se puede obtener ganancias anormales con arbitraje usando el precio histórico del instrumento financiero, la eficiencia semi fuerte de mercado, en la cual no se puede obtener ganancias anormales con arbitraje usando la información pública disponible del instrumento financiero y, finalmente, la eficiencia fuerte de mercado en la cual no se puede obtener ganancias anormales con arbitraje usando la información pública y privada del instrumento financiero. El autor comenzó con el modelo de mercados eficientes en su trabajo Fama (1970) y terminó de especificar este modelo en Fama (1976).

Fama (1970) indica que un mercado eficiente es aquel mercado donde los precios de los diversos activos reflejan toda la información disponible en su totalidad. Sin

embargo, el "reflejar toda la información disponible en su totalidad" es una implicación muy general, lo cual hace que no pueda ser probado empíricamente; por lo tanto, para que se pueda crear un modelo que pruebe esto, se debe especificar más como la formación del precio se da por este reflejo de toda la información disponible en su totalidad.

Según Fama (1970), los modelos teóricos y empíricos hechos previamente a su investigación sobre la eficiencia del mercado no han sido muy específicos, la mayoría de las investigaciones se basan únicamente en la asunción de que las condiciones de un mercado en equilibrio pueden ser representadas en términos de los retornos esperados. Las teorías sobre los retornos esperados pueden ser descritas de la siguiente forma:

$$E(\tilde{p}_{j,t+1}|\Phi_t) = [1 + E(\tilde{r}_{j,t+1}|\Phi_t)]p_{jt}$$

Donde E es el valor esperado, $p_{jt}$ es el precio del activo j en el periodo t y, por ende, $p_{j,t+1}$ es el precio del activo j en el periodo t+1; $r_{j,t+1}$ es el retorno obtenido, en porcentaje, obtenido al calcular $\frac{(p_{j,t+1}-p_{jt})}{p_{jt}}$; $\Phi_t$ vendría a representar el set de información que se asume refleja toda la información disponible en su totalidad en el precio para el periodo t; finalmente, las marcas sobre $p_{j,t+1}$ y $r_{j,t+1}$ indican que éstas son variables aleatorias en el periodo t.

Lo que observamos en esta ecuación es que el retorno obtenido esperado en el periodo t+1 $E(\tilde{r}_{j,t+1}|\Phi_t)$, proyectado por la información en $\Phi_t$, sería determinado por la teoría sobre los retornos esperados. Esta ecuación implica que la información en $\Phi_t$ es utilizada en su totalidad para determinar los retornos de equilibrio esperados. Esta es la forma en que $\Phi_t$ es reflejada en su totalidad en la formación del precio del activo j en el periodo t ($p_{jt}$).

La hipótesis de mercados eficientes o efficient market hypothesis (EMH) creada por Fama, indica que un mercado eficiente es aquel donde el precio de un activo refleja toda la información disponible en su totalidad. Es decir, no es posible obtener ganancias por arbitraje en un mercado eficiente porque la nueva información es añadida tan rápido al precio del activo, el cual cambia por esta información, que es prácticamente imposible obtener cualquier beneficio debido a que este no está ni sobrevalorado ni infravalorado en el mercado. Esta hipótesis es probada en la investigación de Fama (1970) de forma teórica y empírica. De la misma forma, si el mercado de un activo no fuese eficiente, la nueva información tardaría en incorporarse en el precio del activo, dando así un lapso de

tiempo donde se es posible obtener ganancias por arbitraje, pues el precio del activo en el mercado se encontraría sobrevalorado o infravalorado con respecto al verdadero precio que este debería tener.

Posteriormente, en 1976, Fama realiza otra publicación. En esta el autor especificaría lo que es un mercado de capitales eficiente.

Fama (1976) explica que la eficiencia de mercado requiere que el mercado use correctamente toda la información disponible, a la hora de establecer los precios de los activos en el periodo t-1. También, para que sea más simple, asumir que los precios de los activos en el periodo t-1 depende únicamente de las características de la distribución conjunta de los precios a ser establecidos en t. Entonces, la eficiencia de mercado requeriría que el mercado use correctamente toda la información disponible para evaluar la distribución conjunta de los precios en t, al establecer los precios en t-1. De tal forma que en los mercados eficientes:

$$f(P_t|\Phi_{t-1}) = f_m(P_t|\Phi_{t-1}^m)$$

Donde $P_t = (p_{1t}, \dots, p_{nt})$ es el vector de precios de los activos al tiempo t.; $\Phi_{t-1}$ es el conjunto de información disponible en el periodo t-1; $\Phi_{t-1}^m$ es el conjunto de información usada por el mercado; Por lo tanto, $f_m(P_t|\Phi_{t-1}^m)$ vendría a ser la función de densidad evaluada por el mercado para $P_t$, mientras que $f(P_t|\Phi_{t-1})$ sería la verdadera función de densidad que implicaría $\Phi_{t-1}$.

En síntesis, lo que esta ecuación nos indica es que para que un mercado sea eficiente la información disponible en el periodo t-1 debe ser igual a la información disponible que posee el mercado en el periodo t-1. Si esto no se da y la información disponible del mercado en t-1 difiere a la información disponible en t-1, el verdadero precio del activo no se verá reflejado hasta que toda la información disponible llegue al mercado, dando espacio así a la obtención de beneficios por parte de las personas que se den cuenta que el precio del activo se encuentra sobrevalorado o infravalorado. Según la hipótesis de mercados eficientes de Fama (1970), esto convertiría al mercado de ese activo en un mercado ineficiente.

A continuación, para probar la eficiencia de mercado, se debe especificar una conexión entre $f_m(P_t|\Phi_{t-1}^m)$ y $P_{t-1}$. Para esto, se debe especificar como el equilibrio o los precios de equilibrio del mercado en t-1 son relacionados con la distribución evaluada por el mercado de los precios futuros de los activos. Las pruebas deben estar basadas en

el modelo de equilibrio y cualquiera de estas pruebas debe ser una prueba conjunta entre la eficiencia y el modelo de equilibrio.

La asunción general es que las condiciones del mercado de equilibrio pueden ser fijadas en términos de los retornos esperados. De esta forma, las características de la distribución evaluada del mercado $f_m(P_t|\Phi_{t-1}^m)$ determinaran los retornos esperados de equilibrio en los activos y, entonces, el mercado fijará los precios de los activos en el periodo t-1 de tal forma que los retornos esperados percibidos serán iguales a los de equilibrio. Dicho de forma resumida, el mercado fijará P para el activo j en el periodo t-1 ($P_{j,t-1}$):

$$P_{j,t-1} = \frac{E_m(\tilde{p}_{jt}|\Phi_{t-1}^m)}{1 + E_m(\tilde{R}_{jt}|\Phi_{t-1}^m)}$$

Donde $E_m(\tilde{R}_{jt}|\Phi_{t-1}^m)$ es el retorno esperado de equilibrio del activo j implicado por $f_m(P_t|\Phi_{t-1}^m)$ y $E_m(\tilde{p}_{jt}|\Phi_{t-1}^m)$ es el valor esperado evaluado por el mercado del precio del activo j en el periodo t.

El precio $\tilde{p}_{jt}$ será generado naturalmente; es decir, que será extraído de la verdadera distribución de precios $f(P_t|\Phi_{t-1})$. De esta forma, $E(\tilde{p}_{jt}|\Phi_{t-1})$ será el verdadero precio esperado del activo j implicado por $f(P_t|\Phi_{t-1})$ y, por lo tanto, $E(\tilde{R}_{jt}|\Phi_{t-1})$ será el verdadero retorno esperado implicado por $E(\tilde{p}_{jt}|\Phi_{t-1})$ y $P_{j,t-1}$. Para que el mercado sea eficiente, entonces:

$$E(\tilde{p}_{jt}|\Phi_{t-1}) = E_m(\tilde{p}_{jt}|\Phi_{t-1}^m)$$

$$E(\tilde{R}_{jt}|\Phi_{t-1}) = E_m(\tilde{R}_{jt}|\Phi_{t-1}^m)$$

Lo que esto nos indica, es que en un mercado eficiente el verdadero retorno esperado de cualquier activo debe ser igual al valor esperado de equilibrio, que a su vez dicho valor es el mismo evaluado en el mercado. En caso contrario, si el verdadero retorno esperado de cualquier activo no es igual al valor esperado de equilibrio, entonces estamos ante un mercado ineficiente.

Como se indicó en párrafos previos, esta ineficiencia se da debido a que la información disponible del activo en mercado no es la misma que la información disponible del activo. Esta información disponible llegará al mercado más tarde y esto provocará que el precio del activo en el mercado difiera de su precio real, otorgando así

la oportunidad de obtener beneficios por arbitraje, convirtiéndolo en un mercado ineficiente.

La conclusión que obtenemos de las investigaciones de Fama de los años 1970 y 1976 es que, para que un mercado sea eficiente, toda información disponible sobre un activo debe reflejarse en el precio de este en el mercado, de tal forma que se actualice de forma constante en el mercado, conforme vaya apareciendo nueva información, sin dar un espacio de tiempo donde las personas puedan obtener beneficios por arbitraje, al haber una diferencia entre el precio de ese activo en el mercado y su verdadero precio, siguiendo así la hipótesis de los mercados eficientes de Fama (1970).

Por otro lado, respecto a la relación entre la liquidez y la eficiencia de mercado, diferentes autores tales como Chordia et al. (2008), Hodrea (2015), Wei (2018) y Wu & Qin (2021) obtuvieron resultados que indican una relación significativa entre la liquidez y la eficiencia de mercado, donde a mayor liquidez, mayor eficiencia presenta el mercado. Además, Chordia et al. (2008) especifica que esto se da debido a que el aumento de la liquidez del activo ayuda a que la información llegue más rápidamente al precio del activo.

Se usará el ratio de Amihud para calcular la liquidez, pues si bien hay otras metodologías para calcularla, tales como el bid ask spread, el transaction-by-transaction market impact y the probability of information-based trading, estas metodologías requieren, según Amihud (2002), demasiada data micro estructurada que no esta disponible en todos los mercados de acciones y, aun si esta información estuviese disponible, éstas no cubren largos periodos de tiempo. El ratio de Amihud es llamado ILLIQ y permite realizar investigaciones que cubren largos periodos de tiempo, lo cual es idónea para la presente investigación. Este ratio es creado usando el volumen capitalizado del activo y su retorno.

# CAPÍTULO V: MARCO CONTEXTUAL

El presente trabajo contempla dos periodos diferentes, del año 2018 al año 2020, conocido como el periodo Pre-Covid-19, y del año 2020 al año 2022, conocido como el periodo del Covid-19.

Durante el periodo del Covid-19, la economía mundial entró en una fuerte crisis que llevó a varios países a proyectar fuertes caídas en su PBI como resultado de la parálisis económica. Para amortiguar el impacto negativo en sus economías, diversos países llevaron a cabo estímulos monetarios y fiscales; por ejemplo, Suecia llevó a cabo varios programas, entre ellos los préstamos corporativos donde se repartieron 500,000 millones de SEK a diversos bancos financieros para que estos realicen préstamos a las empresas con tasas de interés significativamente bajas. Perú, por otro lado, repartió bonos a su población más vulnerable y también realizaron programas de apoyo empresarial.

Como resultado de la pandemia, varios mercados se vieron fuertemente afectados de manera negativa, principalmente el sector turístico; por otro lado, algunos mercados se dispararon y crecieron significativamente como resultado del estado de emergencia que llevó a millones de personas a estar encerradas en casa. Empresas como Zoom tuvieron un significativo crecimiento y, ante la necesidad de la gente de quedarse en casa, nuevas empresas como Globo, conocido actualmente como Pedidos Ya, y Rappi nacieron y crecieron a un ritmo muy acelerado.

Estos cambios en la economía y los mercados hacen a uno mismo cuestionarse sobre qué tanto puede variar la eficiencia de un mercado en particular ante una crisis de tal tamaño.

Al ser el mercado de las criptomonedas uno virtual, existe la probabilidad de que la eficiencia de este se haya visto impactado como resultado de la pandemia, no solo por el impacto en la economía, sino también por la nueva política de quedarse en casa que fue adoptada por un tiempo prologando.

# CAPÍTULO VI: REVISIÓN DE LITERATURA

Para realizar el trabajo de investigación, se leyeron numerosas investigaciones de diferentes autores con respecto a la eficiencia del mercado de las criptomonedas, la liquidez y su relación con la eficiencia del mercado, el modelo GARCH y, por último, qué es una criptomoneda. Estas investigaciones son detalladas de forma cronológica:

Fama (1970) y Fama (1976) son los trabajos que realizo Fama que terminarían convirtiéndose en los trabajos más importantes con respecto a los mercados eficientes debido a la creación de la teoría de los mercados eficientes. En Fama (1970), el autor realiza una investigación teórica y empírica sobre los mercados eficientes, demostrando la forma en que la información disponible de un activo en el mercado se refleja en la formación de su precio. De esta forma, el autor creó la hipótesis de los mercados eficientes que indica que, en un mercado eficiente, el precio de un activo en el mercado refleja la información disponible de este en el mercado, información que debe ser igual a la información disponible del activo en su totalidad, de esta forma no se podrá obtener ganancia por arbitraje en el mercado de este activo.

En Fama (1976), termina de especificar el modelo de los mercados eficientes, el cual indica que, en un mercado eficiente, el verdadero retorno esperado de cualquier activo debe ser igual al valor esperado de equilibrio, el cual debe ser el mismo evaluado en el mercado.

Bollerslev (1987) propone el modelo GARCH, modelo que es aplicado en el trabajo de investigación. El autor propondría un modelo como extensión del modelo ARCH de Engle (1982), el cual tendría en cuenta la volatilidad de los activos; es decir, es un modelo especialmente creado para activos volátiles. Este modelo incluiría una varianza condicional, que debe ser positiva, los rezagos ARCH y un modelo AR como su media condicional. A lo largo del paper de Bollerslev (1987), se muestra el proceso teórico detrás de la formación del modelo GARCH.

Amihud (2002) realiza una investigación donde propone una nueva forma de calcular la liquidez llamada ILLIQ, la cual permite realizar investigaciones de largos periodos de tiempo. Además, encuentra una relación entre el retorno de los activos y su liquidez. El autor propone usar un modelo de sección transversal para hallar la relación

entre el retorno de los activos y su liquidez, usando data de la NYSE para los periodos del 1963 al 1997.

Los resultados obtenidos por el autor muestran una relación significativa entra la iliquidez de un activo y sus retornos, donde a mayor iliquidez, mayor será el retorno de este activo, pues se presenta un mayor riesgo de liquidez que debe ser compensando con un mayor retorno del activo ilíquido.

Chordia et al. (2008) en su investigación, buscan hallar la relación respecto a la liquidez y la eficiencia de mercado. Para hallar esta relación, realizarán regresiones usando información del NYSE del periodo 1993 al 2002. Según los autores, reciente evidencia indica que la liquidez varia de periodo a periodo y que las condiciones de mercado pueden llegar a ser muy turbulentos, lo cual provoca que los costos de comerciar efectivos pueden saltar dramáticamente y la liquidez puede disminuir o incluso desaparecer.

Los resultados obtenidos por los autores indican que al mejorar la liquidez la información se incorpora de forma más eficiente en los precios, mejorando así la eficiencia de mercado.

Hodrea (2015) habla sobre como la liquidez de un mercado tiene una implicación profunda en el hecho de que no halla arbitraje en un mercado eficiente. La investigación estudiará la relación entre eficiencia de mercado y su liquidez usando datos de panel. La metodología aplicada en este estudio son los datos de panel, se usará información recopilada de todo el año 2011 de trece de las compañías más liquidas listadas en la BSE, siendo estas SIFI, FIC2, SIF3, SIF4, SIF 5, AZO, BIO, BRK, BSE, SNP, TLV, BRD y TEL.

Los resultados que obtuvo la autora en su investigación muestran una relación significativa entre la liquidez y la eficiencia de mercado, donde a mayor liquidez, mayor eficiencia.

DeVries (2016) explica qué son las criptomonedas y resalta sus fortalezas, oportunidades, debilidades y amenazas. Según el autor, las criptomonedas son una red cifrada de igual a igual para facilitar el trueque digital. Estas criptomonedas usan una tecnología desarrollada en el año 2008, siendo la primera criptomoneda la moneda Bitcoin. Se indica que estas monedas podrían revolucionar los mercados de comercio digitales creando un sistema de comercio de flujo libre sin cuotas. Además, se especifica

que el valor de estas monedas es otorgado por las mismas personas, quienes deciden si aceptar o no esta como método de pago; por lo tanto, su valor aumentará o disminuirá en función del valor que las personas le otorguen.

Según DeVries (2016), la fortaleza de las criptomonedas radica en el hecho de que estas no sufrirán por inflación generada por los gobiernos, convirtiéndose así en un refugio seguro para la riqueza de las personas. En lo que respecta a sus oportunidades, se indica que las criptomonedas irán transformándose y mejorando en el largo plazo en los sistemas financieros, pues estas son capaces de llenar los vacíos de las tecnologías financieras y serán capaces de ayudar a resolver diversos problemas bancarios tradicionales gracias a su sistema de igual a igual. En base a esto, las personas comienzan a valorar más a las criptomonedas. Por otro lado, estas monedas también presentan debilidades, como la forma en que están diseñadas, pues debido a la tecnología que usan, los usuarios pueden ver cada transacción de criptomoneda que hay. Aun si existe el semi-anonimato, este hecho puede resultar estresante para algunos poseedores de la moneda. Además, es susceptible a ataques de DDos; sin embargo, este último punto se está mejorando gracias a diferentes pruebas de estrés contra estos tipos de ataques. Finalmente, respecto a las amenazas de las criptomonedas, estas son la alta volatilidad que estas presentan.

La conclusión a la que llega el autor con respecto a las criptomonedas, es que estas aun se encuentran en su etapa inicial; por lo tanto, teniendo en cuenta que éstas irán mejorando, tienen la capacidad de convertirse en la corriente principal de los mercados globales.

En el estudio realizado por Jiang et al. (2018), los autores buscan investigar la variación en el tiempo de la memoria a largo plazo del mercado de la criptomoneda Bitcoin (BTC). La investigación observará si el mercado de la criptomoneda es o no eficiente y si ésta eficiencia aumenta con el tiempo.

Para la investigación de Jiang et al. (2018) se recopilaron datos para el periodo de 2010 a 2017. La metodología consiste en aplicar “generalized Hurst exponents” para analizar la memoria a largo plazo del mercado de las Bitcoin, utilizar “Rolling Windows approach” para examinar la variación de la ineficiencia del mercado de la criptomoneda Bitcoin considerando diferentes periodos de tiempo para obtener resultados más decentes.

Los resultados obtenidos señalan que el mercado de las Bitcoin sí presenta memoria a largo plazo, es ineficiente y éste no se vuelve más eficiente con el tiempo.

Wei (2018) realiza un estudio sobre la liquidez y la eficiencia de mercado de las criptomonedas usando una gran sección transversal de criptomonedas, donde se espera que el mercado sea más eficiente en cuanto a mayor sea su liquidez.

El autor realiza un modelo de sección transversal usando data de 456 criptomonedas para el año 2017, donde divide las criptomonedas en cinco grupos en base a su ratio de iliquidez, siendo el primer grupo el más líquido y el quinto el menos líquido. El ratio a utilizar es el ratio de iliquidez de Amihud.

Los resultados obtenidos por Wei (2018) indican que en los mercados de las criptomonedas más liquidas, estas son menos volátiles y más eficientes. Por otro lado, con respecto a la eficiencia de mercado de las criptomonedas, si bien se vuelven más eficientes, éstas aun muestran ineficiencia de mercado.

Riaño (2018), en su trabajo de fin de grado hipótesis de mercados eficientes y sabiduría de masas, estudia el trabajo de Fama con respecto a los mercados capitales eficientes publicado en el año 1970, trabajo que forma parte del marco teórico de esta investigación para hallar la eficiencia de mercado de las criptomonedas, y el trabajo de Francis Galton en el año 1907, pues ambos trabajos supusieron la base de las dos teorías que investiga su trabajo de fin de grado, la teoría de los mercados eficientes y la sabiduría de las masas. El autor resalta la importancia de estos dos trabajos, pues tuvieron un gran impacto en sus respectivas áreas.

El trabajo de Riaño (2018) nos explica la historia detrás de la teoría de los mercados eficientes. El autor habla acerca de uno de los primeros autores en plantearse la idea de eficiencia de mercado, Louise Bachelier, en el año 1900. Además, se habla sobre diferentes autores previos a Fama tales como Maurice Kendall en el año 1953, Sidney Alexander en el año 1961, Paul Cootner en el año 1964, entre otros autores.

La metodología aplicada por Riaño (2018) se basa en analizar las obras de Fama y Galton e investigar los trabajos relacionados con los autores previamente mencionados para sacar conclusiones respecto a las preguntas que el mismo autor plantea, las cuales son: ¿Incluye toda la información disponible en el mercado el precio de una acción? ¿Se cumple la teoría de la sabiduría de las masas en la formación del precio de una acción?

Comparación y evaluación del trabajo de los trabajos de Fama y Galton ¿Transmiten la misma idea?

Las conclusiones a las que llega el autor con respecto a sus preguntas son las siguientes: No se puede rechazar la idea de que el precio de una acción incluya toda la información disponible en el mercado, no se cumple la teoría de la sabiduría de las masas en la formación del precio de la acción y, con respecto a la última pregunta, ambos autores pueden o no transmitir la misma idea dependiendo del cómo se quiera aplicar cada teoría.

Hu et al. (2019) realiza una investigación sobre la eficiencia de mercado de las 31 criptomonedas más grandes del mercado de las criptomonedas, entre ellas se encuentran las criptomonedas Bitcoin (BTC), Binance Coin (BNB) y Ethereum (ETH). Se recopilaron datos para el periodo del 16 de agosto de 2017 al 16 de enero de 2019.

La metodología aplicada en el trabajo realizado por Hu et al. (2019) consiste en realizar diversas pruebas de panel. Inicialmente, se examinó la dependencia transversal en los paneles y se realizaron pruebas de no estacionariedad; posteriormente, se utilizan las pruebas estacionarias de los paneles que permiten cualquier dependencia transversal y consideran las posibles rupturas estructurales en los paneles para examinar de forma conjunta la eficiencia de mercado de las criptomonedas.

Finalmente, los resultados obtenidos por la investigación muestran ineficiencia de mercado en las criptomonedas.

En el trabajo de Le Tran & Leivik (2020), se realiza un estudio de la eficiencia de mercado para las criptomonedas Bitcoin, Litecoin, Ripple, Ethereum y EOS. El presente trabajo de investigación usará datos de los precios de las criptomonedas para el periodo del 29 de abril de 2013 al 28 de febrero de 2019.

La metodología aplicada por Le Tran & Leivik (2020) es el Adjusted Market Inefficiency Magnitud (AMIM). Esta será usada para hallar la eficiencia de mercado de las criptomonedas, pues el modelo refleja eficientemente la influencia de los eventos económicos en los activos.

A lo largo de la investigación realizada por Le Tran & Leivik (2020), los autores mencionan que la eficiencia de mercado de las criptomonedas, especialmente la criptomoneda Bitcoin (BTC), ha sido mayormente ineficiente según varias investigaciones como Jiang et al. (2018) y Wei (2018); sin embargo, ésta puede llegar a ser eficiente en algunos periodos como se ha demostrado en otras investigaciones como

Kristoufek (2018) y Kristoufek and Vosvrda (2019); es decir, la eficiencia de mercado de las criptomonedas varía dependiendo del periodo.

Los resultados hallados por los autores indican que los mercados de las cinco criptomonedas eran significativamente ineficientes en los años previos al año 2017; sin embargo, su eficiencia creció significativamente durante los años 2017, 2018 y 2019. Durante estos tres años, el crecimiento del volumen capitalizado de estas criptomonedas tuvo un crecimiento exponencial, especialmente en el año 2017.

Además, los autores especifican que las criptomonedas demostraron ser volátiles, pues estas son especialmente sensibles a diversos eventos tales como el hackeo de DAO en el año 2016 y la Bitcoin siendo acusada de estar relacionada con actividades ilegales.

La conclusión a la que llegan Le Tran & Leivik (2020) es que las monedas fueron significativamente ineficientes, pero esta eficiencia creció significativamente en los años del 2017 al 2019. Según los autores, estos resultados son consistentes con varias investigaciones realizadas en el año 2020. Finalmente, el mercado de las criptomonedas crece de forma excepcional.

La investigación realizada por Noda (2020) examina la eficiencia de mercado de las criptomonedas Bitcoin (BTC) y Ethereum (ETH), siendo el periodo de datos recopilados para BTC del 28 de abril de 2013 hasta el 30 de septiembre de 2019 y del 7 de agosto de 2015 al 30 de septiembre de 2019 para ETH.

La metodología aplicada para medir la eficiencia de mercado de las criptomonedas es el modelo “generalized least squares-based time-varying”, metodología que no depende del tamaño de la muestra.

Los resultados obtenidos por la investigación de Noda (2020) muestran la existencia de eficiencia de mercado para las criptomonedas Bitcoin y Ethereum; sin embargo, ésta varía con el tiempo.

Según Wang & Wang (2021), la eficiencia del mercado durante esta crisis por pandemia por COVID-19 ha sido un interés en las investigaciones financieras, pues la pandemia afecto significativamente a los mercados financieros. Teniendo en cuenta lo antes mencionado, los autores presentan interés en estudiar la eficiencia de mercado durante el COVID-19.

La metodología que los autores buscan aplicar es el método refined composite multiscale fuzzy entropy (RCMFE). La data que usarán proviene del S&P 500 index, la criptomoneda Bitcoin, el US Dollar Index y los precios futuros del oro para el periodo del 2 de enero de 2018 al 29 de marzo de 2020 y el periodo de 2 de diciembre de 2019 al 29 de marzo de 2020.

Los resultados obtenidos por Wang & Wang (2021) indican que la eficiencia de mercado del S&P 500 index, Bitcoin, US Dollar index y los precios futuros del oro se ha reducido por la pandemia del COVID-19.

Wu & Qin (2021) explican que el precio del carbón de china es inestable y tiene un nivel de participación de mercado bajo, lo cual reduce la eficiencia de mercado y su liquidez. Según los autores, la eficiencia de mercado y la liquidez tienen un rol clave en la operatividad del mercado de carbón, donde la eficiencia del mercado de carbón es definida como una extensión del como el precio del carbón en el mercado refleja el valor de la información disponible y; por otro lado, la liquidez del mercado de carbón es definida como la habilidad de ejecutar transacciones de activos de reducción de emisión de carbón, lo cual se refleja en sus beneficios potenciales. Teniendo esto en cuenta, es importante enfocarse en la eficiencia y la liquidez del mercado de carbón. La investigación de Wu & Qin (2021) busca hallar la relación entre la eficiencia y la liquidez del mercado de carbón desde una perspectiva estática y dinámica.

La metodología utilizada por estos autores es un modelo GARCH usando data del periodo posterior al año 2017 de los China ETS. Los resultados obtenidos por el estudio indican una correlación positiva entra la liquidez y la eficiencia de mercado del carbón; es decir, a mayor liquidez, mayor es la eficiencia de mercado.

Montasser et al. (2022) realiza un trabajo donde compara el grado de eficiencia del mercado de las criptomonedas con el grado de eficiencia de estas durante los periodos de burbujas en los precios de las monedas y periodos de precios. Además, el autor examina y agrupa 18 criptomonedas explorando la similitud de su eficiencia.

La data que usará el autor para su investigación abarca el precio de cierre de 18 criptomonedas que fueron emitidas y comerciadas previamente al periodo de la burbuja de 2017-2018. Estas 18 criptomonedas son Bitcoin (BTC), Ethereum (ETH), Ripple (XRP), Cardano (ADA), Litecoin (LTC), Bitcoin Cash (BCH), Chainlink (Link), Stellar (XLM), Binance (BNB), TRON (TRX), Tezos (XTZ), Maker (MKR), OMG Network

(OMG), Loopring (LRC), 0X (0X), Monero (XMR), EOS (EOS) y NEM (XEM). La data es del periodo del 2 de octubre de 2017 al 15 de enero de 2021.

La metodología aplicada fue motivada por los autores Le Tran & Leivik (2020), siendo esta la Adjusted Market Innefficiency Magnitud (AMIM) para medir la eficiencia del mercado de las criptomonedas. Adicionalmente, se aplicó el Dinamyc Time Warping (DTW) para realizar un análisis de la eficiencia de los conglomerados de las criptomonedas, el cual es conformado por tres agrupaciones que representan las monedas mineras, no mineras y categorizaciones de tokens.

Los resultados obtenidos por Montasser et al. (2022) muestran que la eficiencia del mercado de las criptomonedas cambió significativamente después del anuncio de la pandemia del COVID-19. En adición, se identificaron tres burbujas en el precio de las criptomonedas a finales del año 2017, inicios de 2018 y durante julio de 2020, siendo el impacto de la pandemia mayor al impacto de estas burbujas. Además, el modelo DTW muestra que las tres agrupaciones realizadas son eficientes.

Fung et al. (2022) realiza un trabajo que explora el riesgo y el retorno característico de 254 criptomonedas. Los autores mencionan que el crecimiento de las criptomonedas ha sido exponencial, pues el mercado de las criptomonedas pasó de tener 1600 monedas a 7800, mientras que la capitalización del mercado de estas monedas pasó de ser de 295 billones de dólares, o 295 miles de millones de dólares, en marzo de 2018 a 1.5 trillones de dólares en marzo de 2021. En adición, los autores hacen mención a la significativa volatilidad que presentan las criptomonedas, las cuales pueden tener altos retornos, pero estos a su vez pueden variar significativamente de un momento a otro.

Los autores indican que las criptomonedas poseen varias características tales como colas pesadas, refiriéndose a mayores probabilidades de obtener valores grandes, y una volatilidad excesiva a comparación de otros activos tales como el oro. Este hecho ya fue comentado por autores pasados como Montasser et al. (2022) y, inclusive, DeVries (2016) ya hacía mención de que la naturaleza de las criptomonedas es volátil en base a como es que estas obtienen su valor.

La metodología aplicada por Fung et al. (2022) fue el modelo Generalized Autoregressive Conditional Heteroscedasticity o modelo GARCH, debido a que este modelo se adecua bien a activos muy volátiles como lo son las criptomonedas.

La data que será usada en el modelo consiste de 254 criptomonedas para el periodo del 1 de marzo de 2019 al 1 de marzo de 2021. Estas fueron agrupadas en 6 categorías en base a su uso principal.

Los resultados obtenidos por Fung et al. (2022) muestran que, en primer lugar, las criptomonedas tienen como característica el tener colas pesadas, heterocedasticidad condicional, entre otros. En segundo lugar, el modelo GARCH muestra mejores propiedades de bondad de ajuste, lo cual lo convierte en un buen modelo para activos volátiles. En tercero y último lugar, se pudo crear las estimaciones VAR apropiadas para la mayoría de las criptomonedas.

El trabajo de investigación realizado por Kakinaka & Umeno (2022) busca investigar la multifractalidad asimétrica y la eficiencia del mercado de las más grandes criptomonedas durante la época previa a la pandemia del COVID-19 y posterior a esta teniendo en cuenta diferentes horizontes de inversión, a corto y a largo plazo.

Los autores califican a las criptomonedas como activos con características diferentes a los activos convencionales, debido a la tecnología "block-chain". Además, se hace mención de que la criptomoneda Bitcoin se ha vuelto menos ineficiente, llegando a declararla como un refugio seguro para los inversionistas.

La metodología aplicada para la investigación es el Asymmetric multifracta detrended fluctuation analysis (A-MFDFA). La data que serpa utilizada en el modelo son los precios de las criptomonedas Bitcoin y Ethereum contra la criptomoneda Tether, que se supone que debe mantener un valor igual al US Dollar, para los periodos del 1 de enero de 2019 al 31 de diciembre de 2020.

Los resultados obtenidos demuestran un aumento de la ineficiencia por parte de estas criptomonedas en el corto plazo, mientras que muestran eficiencia en el largo plazo.

En el trabajo realizado por Zitis et al. (2023) se analiza el impacto del COVID-19 en la eficiencia de mercado débil de las criptomonedas y las monedas tradicionales. Las criptomonedas que fueron analizadas por la investigación son Bitcoin (BTC), Ethereum (ETH), Litecoin (LTC), EOS (EOS), Binance Coin (BNB) y Stellar Lumen (XLM); por otro lado, las monedas tradicionales son el Euro (EUR), el Dólar Canadiense (CAD), la Libra Esterlina (GBP), el Dólar Australiano (AUD), el Yen Japonés (JPY) y el Franco Suizo (CHF). Se recopilaron datos de estas monedas para el periodo del 1 de mayo de 2019 al 20 de enero de 2021.

La metodología aplicada por Zitis et al. (2023) para medir la eficiencia débil del mercado fue “the asymmetric market deficiency measure (MDM)” derivada usando “the asymmetric multifractal detrended fluctuation análisis (A-MF-DFA) con “fuzzy entropy”, “Tsallis entropy” y “Fisher information”.

En los resultados obtenidos por Zitis et al. (2023) se observa que las monedas tradicionales y la criptomoneda Bitcoin (BTC) presentan un decrecimiento significativo en su eficiencia débil de mercado.

Mallesha & Archana (2024) presentan una investigación sobre la eficiencia de mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH), Tether (USDT) y Binance Coin (BNB) basado en la capitalización de mercado de éstas. La investigación es realizada para el periodo de enero de 2018 a diciembre de 2023, donde se recopilaron los precios de cierre de las diversas criptomonedas, y se aplicó la metodología de “random walk test” para determinar la eficiencia de mercado, adicionalmente se aplicaron un conjunto de pruebas robustas incluyendo “the generalized spectral test”, “automatic portmanteu test” y “automatic variance ratio test”.

Los resultados obtenidos en la investigación realizada por Mallesha & Archana (2024) muestran eficiencia de mercado para Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB); sin embargo, Tether (USDT) no presenta eficiencia de mercado.

La investigación concluye en que la mayoría de las criptomonedas presenta eficiencia de mercado débil basado en test estadísticos.

Mokni et al. (2024) realiza una investigación para observar la fluctuación de la eficiencia de mercado de las criptomonedas Bitcoin (BTC) y Ethereum (ETH)) recopilando datos sobre sus precios para el periodo del 7 de agosto de 2016 al 15 de febrero de 2023. Adicionalmente, analiza el impacto de la liquidez sobre la eficiencia de mercado de éstas.

La metodología aplicada para la investigación es “the adjusted market inefficiency magnitude measure (AMIMs)” y “quantile regression”.

Los resultados obtenidos por Mokni et al. (2024) muestran variación en la eficiencia de mercado para ambas criptomonedas a lo largo del tiempo, variando entre eficiencia y ineficiencia de mercado. Particularmente, los periodos de estrés financiero global afectan negativamente a la eficiencia del mercado de las criptomonedas; sin embargo, ésta sigue fluctuando entre eficiencia y ineficiencia de mercado, aunque los

periodos de eficiencia de mercado son más cortos. Por último, la liquidez muestra tener un significativo impacto positivo en la eficiencia de mercado de las criptomonedas.

UNIVERSIDAD DE LIMA
MCMLXII
SCIENTIA ET PRAXIS

# CAPÍTULO VII: METODOLOGÍA

## 6.1 Las variables para el trabajo de investigación

El presente trabajo busca analizar la eficiencia débil del mercado para las criptomonedas Bitcoin (BTC), Ethereum Bitcoin (BTC), Ethereum (ETH), Tether (USDT), USD Coin (USDC) y Binance Coin (BNB) en la época previa COVID-19, pues estas monedas representan el 71.8% del mercado de las criptomonedas a la fecha del tres de julio del año 2022, y cómo afectó la pandemia a la eficiencia de mercado de éstas usando el periodo durante el COVID-19.

**Figura 6.1.1**

*Peso de las cinco criptomonedas en el mercado de las criptomonedas 2022*

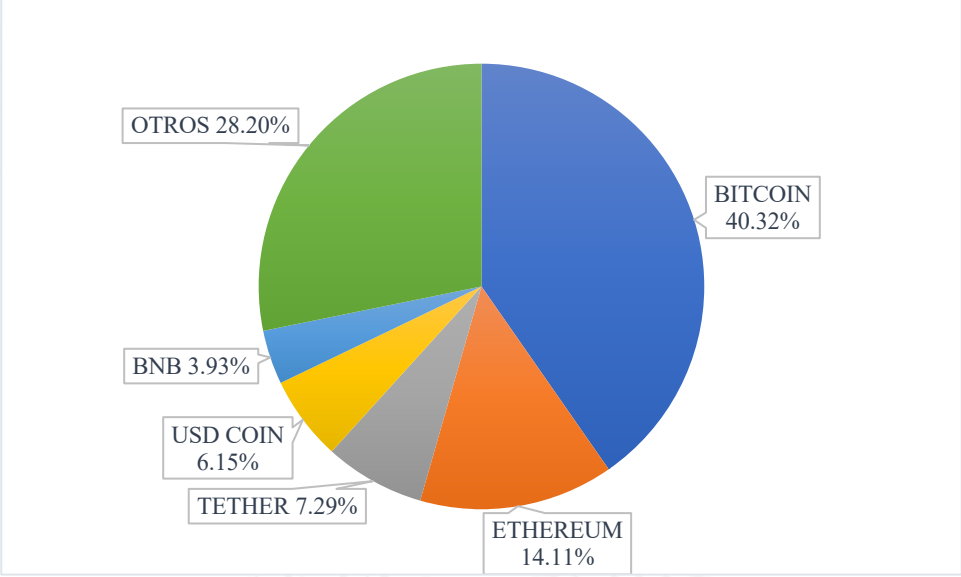


*Nota. Elaboración Propia. Data sustraída de Coingecko el 03/07/2022.*

Teniendo en cuenta esto, se recopiló información de los precios de estas criptomonedas de coinmarketcap y se creó una base de datos para el periodo del 16 de octubre de 2018 al 27 de junio de 2022. Lo que será considerado como periodo pre-COVID-19 es del 16 de octubre de 2018 al 29 de febrero de 2020; por otro lado, el periodo durante COVID-19 es desde el 1 de marzo de 2020 al 27 de junio de 2022.

Con los precios de las diferentes criptomonedas antes mencionadas se creará el retorno para hallar la eficiencia débil de mercado, siguiendo la teoría de los mercados eficientes de Fama (1970) y Fama (1976) que nos indica que la información de los activos se halla en el precio, de una forma que no presente raíz unitaria en la regresión:

$$Retorno = \ln(p_t) - \ln(p_{t-1})$$

De esta forma, se generarán 5 diferentes variables con esta fórmula, una para cada una de las criptomonedas de la base de datos: Retorno_BTC, Retorno_ETH, Retorno_USDT, Retorno_USDC y Retorno_BNB.

Por otro lado, el trabajo también tiene como objetivo hallar la relación entre la liquidez y eficiencia de mercado estas monedas. Por lo tanto, se creará una variable liquidez para cada una usando el método de Amihud (2002):

$$ILLIQ = Amihud = \frac{|r_t|}{VOLD_t}$$

Donde $r_t$ es el retorno hallado de la criptomoneda en el periodo t usando el método previamente presentado para que no presente raíz unitaria y $VOLD_t$ es el volumen bursátil de la criptomoneda en el periodo t.

De esta forma, se generarán 5 diferentes variables, una para cada criptomoneda: Amihud_BTC, Amihud_ETH, Amihud_USDT, Amihud_USDC y Amihud_BNB.

Siguiendo lo explicado por Amihud (2002), la criptomoneda será ilíquida si Amihud es mayor a la suma del promedio y su desviación estándar.

**Tabla 6.1.1**

*Definición de variables seleccionadas*

| Variable | Definición |
|---|---|
| **Retorno_BTC** | Retorno de la moneda Bitcoin |
| **Retorno_ETH** | Retorno de la moneda Ethereum |
| **Retorno_USDT** | Retorno de la moneda Tether |
| **Retorno_USDC** | Retorno de la moneda USD Coin |
| **Retorno_BNB** | Retorno de la moneda Binance Coind |
| **Amihud_BTC** | Liquidez de la moneda Bitcoin |
| **Amihud_ETH** | Liquidez de la moneda Ethereum |
| **Amihud_USDT** | Liquidez de la moneda Tether |
| **Amihud_USDC** | Liquidez de la moneda USD Coin |
| **Amihud_BNB** | Liquidez de la moneda Binance Coin |

*Nota. Elaboración Propia*

## 6.2 Propuesta Empírica

Según la investigación realizada por parte de diferentes autores tales como Le Tran & Leivik (2020) y Fung et al. (2022), las criptomonedas son catalogadas como activos volátiles. Por lo tanto, la metodología más apropiada para tratar con este tipo de activos sería el modelo Generalized Autorregresive Conditional Heteroskedastic (GARCH), modelo propuesto en Bollerslev (1987) como una extensión del modelo Autorregresive Conditional Heteroskedastic (ARCH) introducido por Engle (1982).

El modelo GARCH propuesto por Bollerslev (1987) es utilizado para modelar series de tiempo de activos volátiles, como varios activos financieros. Este modelo incluye una varianza condicional, la cual tiene que ser positiva, y, al ser una extensión del modelo ARCH, se incluyen los rezagos ARCH. Además, el modelo usa como media condicional para su constante el modelo AR(q):

$$y_t = \alpha_0 + \alpha_1 y_{t-1} + \cdots + \alpha_q y_{t-q} + \epsilon_t \rightarrow\ y_t = \alpha_0 + \sum_{i=1}^{q} \alpha_i y_{t-i} + \epsilon_t$$

Por lo tanto, se debe hallar un número de rezagos óptimos para el modelo GARCH. De esta forma, el modelo toma la siguiente forma:

$$r_t = w + \sum_{i=1}^{q} \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^{p} \beta_j \varepsilon_{t-j}^2$$

Sin embargo, en el trabajo se busca hallar también la relación entre la eficiencia del mercado y la liquidez, pero el actual modelo solo hallaría la eficiencia del mercado de las criptomonedas, faltaría agregarle al modelo la forma de comprobar su relación con la liquidez. Por esta razón, se le implementa al modelo una variable Dummy que tomará la forma de $\gamma$. Esta variable Dummy es creada aplicando la metodología de Amihud (2002) con respecto a la liquidez de las criptomonedas. Según el autor, el activo será ilíquido siempre y cuando:

$$\frac{|r_t|}{VOLD_t} > Promedio + DE\ del\ ratio\ de\ iliquidez\ de\ Amihud$$

Por lo tanto, la variable Dummy $\gamma$ tomará el valor de 1 cuando la anterior condición se cumpla, señalando el activo como ilíquido, y en caso contrario tomará el valor de 0, señalando el activo como líquido. De esta forma, el modelo GARCH termina tomando la siguiente forma:

$$r_t = \omega + \sum_{i=1}^{q} \alpha_i \epsilon_{t-i}^2 + \sum_{j=1}^{p} \beta_j \varepsilon_{t-j}^2 + \gamma Amihud_t$$

Donde $\omega > 0$, $\alpha_i > 0$ y $\beta_j > 0$ ; $\alpha_i + \beta_j < 1$; finalmente, los coeficientes $\alpha$ pertenecen a ARCH y los coeficientes $\beta$ pertenecen a GARCH.

Por último, Se realiza la prueba del multiplicador de Lagrange para comprobar si hay o no efectos ARCH que puedan afectar al modelo. El modelo de Lagrange usa los residuos y las varianzas de la criptomoneda para verificar si hay o no efectos ARCH.

# CAPÍTULO VIII: ANÁLISIS DE RESULTADOS

Tras realizar los 10 modelos GARCH, cinco para cada criptomoneda en la época pre-COVID-19 y otros 5 para la época durante el COVID-19, se obtuvieron los siguientes resultados.

Para la época pre-COVID-19, se obtuvieron los gráficos del cuadrado de los retornos de las diferentes monedas, los cuales pueden ser vistos en los anexos del 1 al 5, con los cuales observaremos los periodos de volatilidad, demostrando así que la varianza de las criptomonedas no es constante; pues, esa es la naturaleza de las criptomonedas, son activos volátiles. Este hecho ya había sido constatado por diferentes autores analizados para este trabajo, autores como Fung et al. (2022) y Le Tran & Leivik (2020), razón por la cual se escogió realizar un modelo GARCH, pues este modelo ya asume que se usan variables volátiles e incorporan la volatilidad dentro de estos mismos.

En los gráficos obtenidos se puede diferenciar cuales criptomonedas son más volátiles, siendo Bitcoin y Ethereum las más volátiles, mientras que Tether, USD Coin y Binance Coin son menos volátiles en comparación. A pesar de esto, las cinco criptomonedas muestran ser bastante volátiles.

Posterior a la obtención de los gráficos, se calcularon los resultados con respecto al modelo GARCH para las cinco criptomonedas. Estos resultados se pueden observar en los anexos 6, 8, 10, 12 y 14 o en la tabla 7.1 de forma resumida.

**Tabla 7.1**

*Resultados del modelo GARCH para el periodo pre-COVID-19*

| | **Bitcoin (BTC)** | **Ethereum (ETH)** | **Tether (USDT)** | **USD Coin (USDC)** | **Binance Coin (BNB)** |
|---|---|---|---|---|---|
| **Constante** | 0.0011802 | 0.0013254 | 0.0001315 | 0.0000895 | 0.002587 (0.165) |
| (P. Value) | (0.363) | (0.353) | (0.256) | (0.532) | |
| **ARMA** | 0.1135955 | -0.0568296 | -0.4582079 | -0.4018644 | 0.0207118 |
| (P. Value) | (0.004) | (0.108) | (0.000) | (0.000) | (0.582) |
| **Amihud** | 2.563303 | 2.013488 | 1.891643 | 2.051604 | 1.526539 (0.000) |
| (P. Value) | (0.000) | (0.000) | (0.000) | (0.000) | |
| **ARCH** | 0.4325898 | 0.0518455 | 0.4038791 | 0.2646654 | -0.0066186 |
| (P. Value) | (0.000) | (0.012) | (0.000) | (0.001) | (0.768) |
| **GARCH** | 0.0020982 | -0.1367835 | 0.085221 | 0.1205419 | -0.1737043 |
| (P. Value) | (0.942) | (0.003) | (0.405) | (0.361) | (0.016) |

*Nota. Elaboración Propia*

El modelo de Lagrange realizado para cada modelo GARCH demuestra que los resultados obtenidos aceptan la hipótesis nula al 5% del nivel de confianza en su primer rezago, demostrando así que no sufren efectos ARCH y, por lo tanto, los modelos no presentan problemas de heterocedasticidad. Esto puede observarse en los anexos 7, 9, 11, 13 y 15.

Respecto a los resultados obtenidos en la tabla 7.1, para el periodo previo al COVID-19, con respecto al grupo de criptomonedas que buscan igualar el valor del dólar estadounidense, Tether (USDT) y USD Coin (USDC), se observa que se puede predecir el precio actual del mercado de las criptomonedas usando los precios históricos con un 5% del nivel de confianza; por lo tanto, se puede obtener ganancias anormales por arbitraje y, por ende, según la teoría de los mercados eficientes de Fama (1970) y Fama (1976), son mercados ineficientes. Al ser monedas que buscan igualar el valor del dólar estadounidense de tal manera que un USDC o un USDT pueda ser cambiado por un dólar, se vuelven predecibles, pues se sabe que su precio va a fluctuar en dirección a donde fluctúe el precio del dólar.

Por otro lado, con respecto al grupo de criptomonedas conformado por Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB), en los resultados obtenidos en la tabla 7.1 se observa que se puede predecir el precio actual de mercado de la criptomoneda Bitcoin (BTC) con precios históricos, mientras que el precio actual de mercado de las criptomonedas Ethereum (ETH) y Binance Coin (BNB) no se puede predecir con los precios históricos con un 5% del nivel de confianza; razón por la cual, se pueden obtener ganancias anormales por arbitraje en el mercado de las Bitcoin, pero no en el mercado de Ethereum y Binance Coin; por lo tanto, según la teoría de los mercados eficientes de Fama (1970) y Fama (1976), el mercado de Bitcoin es ineficiente y el mercado de Ethereum y Binance Coin presenta eficiencia débil.

Los resultados obtenidos, tanto para la eficiencia como la ineficiencia de mercado observada en las criptomonedas de la investigación, son consistentes con los resultados obtenidos por los diversos autores presentados en la revisión de literatura. Autores como Jiang et al. (2018) y Hu et al. (2019) obtuvieron resultados que reflejaban ineficiencia de mercado en las criptomonedas, mientras que otro grupo de autores como Noda (2020) y Mallesha & Archana (2024) obtuvieron resultados que reflejan eficiencia de mercado;

sin embargo, los resultados no deben ser considerados como absolutos, pues la eficiencia o ineficiencia de mercado de las criptomonedas que se observa en los resultados obtenidos no necesariamente persistirán con el paso del tiempo o si se realiza la misma prueba para un periodo distinto, pues hay autores que han demostrado que la eficiencia de mercado de las criptomonedas fluctúa, como se observa en los resultados de las investigaciones realizadas pro Noda (2020) y Mokni et al. (2024).

Respecto a la relación de la eficiencia de mercado y la liquidez, se demuestra que el ratio de iliquidez de Amihud (2002) es significativo inclusive al 1% del nivel de confianza; por lo tanto, se demuestra que existe una relación entre la liquidez y la eficiencia de mercado para el periodo analizado previo al COVID-19. Estos resultados son consistentes con los resultados obtenidos por los autores Chordia et al. (2008) y Wu & Qin (2021). Según Chordia et al. (2008), este evento se da debido a que un aumento en la liquidez permite a la información llegar más rápidamente al precio del activo.

Para la época durante el COVID-19, también se obtuvo gráficos que demuestran la naturaleza volátil de las criptomonedas, estos pueden ser observados en los anexos del 16 al 20; sin embargo, la volatilidad que estos muestran es mucho menor a comparación de la época pre-COVID-19

En los gráficos podemos diferenciar a Binance Coin siendo la criptomoneda más volátil, mientras que Ethereum es la segunda más volátil y la siguen las otras tres criptomonedas. En comparación al pasado, la moneda Bitcoin se ha vuelto de las menos volátiles junto con USD Coin y Tether, efecto provocado por la aparición de la pandemia del COVID-19, mientras que Binance Coin, la cual antes era la menos volátil, ahora es la más volátil de las cinco criptomonedas. La aparición de la pandemia ha tenido un impacto significativo en la volatilidad de las criptomonedas.

Con respecto a los resultados del modelo GARCH para las cinco criptomonedas, estos resultados se pueden observar en los anexos 21, 23, 25, 27 y 29 o en la tabla 7.2 de forma resumida.

**Tabla 7.2**

*Resultados del modelo GARCH para el periodo durante el COVID-19*

| | **Bitcoin (BTC)** | **Ethereum (ETH)** | **Tether (USDT)** | **USD Coin (USDC)** | **Binance Coin (BNB)** |
|---|---|---|---|---|---|
| **Constante** | 0.0015904 | 0.0030668 | 5.35e-06 | -9.88e-06 | 0.0022342 |
| (P. Value) | (0.107) | (0.018) | (0.084) | (0.608) | (0.147) |
| **ARMA** | -0.0175791 | -0.0345789 | -0.8079841 | -0.4998783 | -0.0824832 |
| (P. Value) | (0.510) | (0.230) | (0.000) | (0.000) | (0.043) |
| **Amihud** | 2.36444 | 2.276437 | 9.178997 | 5.911534 | 1.169614 (0.001) |
| (P. Value) | (0.000) | (0.000) | (0.000) | (0.000) | |
| **ARCH** | 0.0519376 | 0.0652827 | 7.576207 | 0.2991603 | 0.187903 (0.000) |
| (P. Value) | (0.000) | (0.011) | (0.000) | (0.000) | |
| **GARCH** | -0.0585671 | -0.0787806 | 0.2727133 | 0.2824954 | 0.8110929 |
| (P. Value) | (0.000) | (0.000) | (0.000) | (0.000) | (0.000) |

*Nota. Elaboración Propia*

Al igual que con los modelos GARCH del periodo pre-COVID-19, el modelo de Lagrange realizado para cada modelo GARCH demuestra que los resultados obtenidos aceptan la hipótesis nula al 5% del nivel de confianza en el primer rezago, demostrando así que no sufren efectos ARCH y, por lo tanto, los modelos no presentan problemas de heterocedasticidad. Esto puede observarse en los anexos 22, 24, 26, 28 y 30.

Respecto a los resultados obtenidos en la tabla 7.1, para el periodo previo al COVID-19, con respecto al grupo de criptomonedas Tether (USDT) y USD Coin (USDC), se observa que el impacto de la pandemia por el COVID-19 no cambió su eficiencia de mercado, pues ambas siguen siendo ineficientes.

Por otro lado, para el grupo de criptomonedas de Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB), la pandemia por el COVID-19 sí tuvo un impacto en la eficiencia de mercado para Bitcoin y Binance Coin; sin embargo, el impacto no fue el mismo, pues el mercado de la criptomoneda Bitcoin pasó de ser ineficiente a presentar eficiencia débil de mercado, mientras que Binance Coin se volvió un mercado ineficiente.

Los resultados obtenidos nos hacen plantearnos las siguientes preguntas:

¿Por qué varía la eficiencia de mercado de las criptomonedas de débilmente eficiente a ineficiente, y viceversa, de un periodo a otro? ¿Por qué ante un mismo impacto, dos criptomonedas cuyo valor radica en el nivel de aceptación de las personas y empresas, sus expectativas y percepciones sobre éstas, tienen efectos contrarios en su eficiencia

volviendo el precio de mercado de una en predecible y la otra en impredecible? Se plantea una hipótesis al respecto.

A diferencia de otros instrumentos financieros, las criptomonedas no tienen activos tangibles, flujos de caja o flujo de dividendos que sustenten el valor de éstas, tampoco son respaldadas por un gobierno como las monedas tradicionales, tales como el euro y el dólar. El valor de las criptomonedas radica en el valor que le otorgan las personas, los individuos, y las empresas que deciden si aceptarlas o no como método de pago, como menciona el autor DeVries (2016), y las expectativas de éstos con respecto al futuro de éstas y la percepción que éstos tienen sobre éstas. Éste hecho implica que las criptomonedas se encuentran más expuestas al comportamiento irracional de los inversionistas, comportamientos que son investigados en el libro de Statman (2019), Behavioral Finance.

En Statman (2019) se replantea racionalidad del inversionista. La investigación concluye que los inversionistas no son los tomadores de decisiones racionales que maximizan la utilidad, ni tampoco cuentan con información completa como se supone en las finanzas tradicionales; de hecho, los inversionistas han mostrado tener comportamientos irracionales como un exceso de confianza en sus habilidades a la hora de analizar el valor intrínseco de los instrumentos financieros, llegando a considerar su valoración como una más acertada que la del mismo mercado, sesgo de auto control, provocando que individuos prioricen la satisfacción en el corto plazo antes que en el largo plazo; es decir, un inversionista prioriza usar su dinero en el corto plazo antes que invertirlo en instrumentos financieros o ahorrarlo y obtener ganancias en el largo plazo, aversión al arrepentimiento, teniendo como consecuencia que inversionistas no inviertan por miedo a que la inversión termine con rendimientos negativos. Adicionalmente, se ha demostrado que inversionistas menos informados en instrumentos financieros observan y imitan las decisiones de inversionistas que consideran más informados que ellos.

En base a lo anteriormente mencionado, se plantea la siguiente hipótesis: Al ser el mercado de las criptomonedas un mercado más expuesto al comportamiento irracional de los inversionistas, estos comportamientos impactan significativamente la eficiencia de mercado de las criptomonedas. Comportamientos como la sobre confianza, la aversión a invertir por miedo a la pérdida y el sesgo de auto control vuelven impredecible al mercado de las criptomonedas, y por ende se convierte en un mercado eficiente, pues si se presenta

un periodo de incremento en el precio de una criptomoneda en particular, un grupo de inversionistas con sobre confianza decidirá no invertir porque consideran que el valor intrínseco de la criptomoneda es menor al reflejado en el precio del mercado, otro grupo de inversionistas con aversión a invertir por miedo a la pérdida no invertirá porque son conscientes de la volatilidad de las criptomonedas, y pesa más la probabilidad de una bajada súbita del precio antes que la actual subida; por último, otro grupo de inversionistas decidirá no invertir porque prefiere consumir su riqueza en el presente. Finalmente, comportamientos como el de los inversionistas menos informados observando y imitando las acciones de inversionistas más informados vuelve al mercado de una criptomoneda en uno predecible, pues tan pronto el inversionista compre o venda la criptomoneda, o haga un comentario positivo o negativo sobre ésta, habrá un grupo de inversionistas que imitarán ésta acción o actuarán en base al comentario, provocando que el precio suba o baje dependiendo de la decisión tomada o del tipo de comentario que realizó. Un ejemplo a lo último mencionado es la variación del precio de la criptomoneda Dogecoin con respecto a los comentarios de Elon Must,en mayo de 2021 sobre ésta, teniendo como consecuencia un desplome del 30% en su precio.

Las respuestas a las preguntas previamente realizadas están basadas en la hipótesis planteada. La eficiencia de mercado de las criptomonedas varía y los impactos no tienen un afecto uniforme en éstas porque las criptomonedas se encuentran más expuestas a los inversionistas irracionales a comparación de las monedas tradicionales o de los otros instrumentos financieros, pues su valor depende de la percepción de los inversionistas sobre éstas, mientras que el valor de las monedas tradicionales y los otros instrumentos financieros depende en mayor medida de los activos tangibles, flujos de caja o flujos de dividendos que presentan, haciendo que el precio de las criptomonedas varíe entre predecible e impredecible de un periodo a otro.

Retornando a la eficiencia de mercado de las criptomonedas, la variación constante entre eficiencia débil de mercado y ineficiencia de mercado que se observa de periodo a periodo no permite llegar a una conclusión absoluta. La realidad, según los resultados del trabajo y de los autores en la revisión de literatura, es que el mercado de las criptomonedas, en general, puede ser tanto débilmente eficiente como ineficiente, dependiendo del periodo en el que se realice, y ésta eficiencia o ineficiencia variará de un periodo a otro.

En lo que respecta a la relación de la eficiencia de mercado y la liquidez, esta permanece como significativa con un nivel de confianza al 1%, indicándonos que, a pesar de la pandemia del COVID-19, la relación existente entre estas permanece intacta.

En síntesis, los resultados rechazan la hipótesis general, la criptomoneda Bitcoin (BTC) no presentó eficiencia de mercado débil en el periodo previo al COVID-19 y el impacto generado por el COVID-19 no fue uniforme para Bitcoin, Ethereum y Binance Coin. Con respecto a las hipótesis específicas, BTC no presento eficiencia débil de mercado, mientras que ETH y BNB sí, para el periodo previo al COVID-19, la eficiencia de mercado cambió para Bitcoin y Binance Coin, pero no para Ethereum, los mercados de las criptomonedas Tether y USD Coin presenta ineficiencia de mercado en el periodo pre-COVID-19 y persiste en el periodo durante el COVID-19. Finalmente, se demuestra una relación significativa entre la liquidez de las criptomonedas y su eficiencia.

# CAPÍTULO IX: CONCLUSIONES

El presente trabajo de investigación tenía como objetivo hallar si el mercado de cinco criptomonedas, cuyo peso representaba el 71.8% del mercado de las criptomonedas a la fecha del tres de julio del año 2022, era débilmente eficiente o ineficiente y si existía una relación significativa entre la liquidez y la eficiencia de mercado.

A lo largo de la investigación se estudiaron varias investigaciones realizadas que estudiaban la eficiencia débil de mercado de las criptomonedas, además de investigaciones que estudiaban la relación de la liquidez de los activos con su eficiencia de mercado. Se hallaron investigaciones cuyos resultados rechazaban la eficiencia débil de mercado de las criptomonedas, otras cuyos resultados mostraban la existencia de eficiencia débil de mercado y, por último, se encontraron investigaciones cuyos resultados demostraban que el mercado de las criptomonedas más bien presentaba variación en su eficiencia, siendo débilmente eficiente en un periodo, ineficiente en el siguiente a éste y, nuevamente, débilmente eficiente posterior a éste último.

Los resultados que se obtuvieron con el modelo GARCH, modelo aplicado en este trabajo para hallar la eficiencia débil de mercado de las criptomonedas, mostraron que, para la época previa al COVID-19, el mercado de las criptomonedas Tether (USDT), USD Coin (USDC) y Bitcoin (BTC) no eran mercados eficientes y que el precio de éstos podía predecirse usando precios históricos, suceso que no sucede con Ethereum (ETH) y Binance Coin (BNB) para ese mismo periodo. Posteriormente, para el periodo durante el COVID-19, se encontró que el shock producido por la pandemia tuvo efectos contrarios para el mercado de las criptomonedas Bitcoin y Binance Coin, volviéndose el mercado de las Bitcoin un mercado con eficiencia débil y Binance Coin se convirtió en un mercado ineficiente. Por último, se encontró una relación significativa entra la liquidez y la eficiencia de mercado.

Con respecto a los resultados obtenidos en la eficiencia de mercado de las criptomonedas y cómo afectó el impacto de la pandemia a éstos, además de los resultados observados en los distintos trabajos de investigación que fueron estudiados, se presentó una hipótesis que pretende explicar la ambigüedad de la eficiencia de mercado de las criptomonedas y sus variaciones, teorizando que el valor de mercado de las

criptomonedas se encuentra más expuesto al comportamiento irracional del inversionista a comparación de otros instrumentos financieros o monedas tradicionales cuyo valor, a diferencia de las criptomonedas, se encuentra respaldado por activos tangibles, flujos de caja y flujos de dividendos. Al encontrarse más expuesto al comportamiento irracional de los inversionistas, los distintos comportamientos irracionales como pueden ser el exceso de confianza, el sesgo de auto control y la aversión al arrepentimiento convierten al mercado de las criptomonedas más impredecible, mientras que otro tipo de comportamientos como inversionistas menos informados imitando y observando las decisiones y opiniones de inversionistas más calificados pueden convertir al mercado de las criptomonedas en uno más predecible.

En base a los resultados obtenidos y al estudio de las distintas investigaciones, se llega a la conclusión de que la eficiencia de mercado de las criptomonedas es fluctuante, presentando eficiencia débil en un periodo y ineficiencia en el periodo posterior a éste; razón por la cual, no se puede llegar a una conclusión absoluta. Dependiendo del periodo en el que se realice la investigación se puede hallar tanto eficiencia débil de mercado como ineficiencia de mercado, y ésta variará en periodos previos o posteriores.

# RECOMENDACIONES

El presente trabajo recomienda a futuros trabajos de investigación, que quieran observar la eficiencia de mercado de las criptomonedas, que consideren las finanzas conductuales en su investigación, añadiendo, por ejemplo, variables Dummy que busquen reflejar comportamientos irracionales de los inversionistas.

# MATRIZ DE CONSISTENCIA

<table>
<tr><th>Objetivo General</th><th>Objetivos Específicos</th><th>Hipótesis General</th><th>Hipótesis Específicos</th><th>Estructura de Capítulos</th><th>Conclusiones</th></tr>
<tr><td rowspan="4">Hallar la eficiencia del mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH), Tether (USDT), USD Coin (USDC) y Binance Coin (BNB) en la época previa al COVID-19, del 16 de octubre de 2018 al 29 de febrero de 2020, observar si cambió durante el COVID-19, del 1 de marzo de 2020 al 27 de junio de 2022, y de ser así si el cambio se presenta de la misma manera entre los dos grupos de las criptomonedas.</td><td>Determinar si existe o no eficiencia de mercado para cada una de las cinco principales criptomonedas durante el periodo previo al COVID-19.</td><td rowspan="4">Sí existe eficiencia del mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) en la época pre-COVID-19, del 16 de octubre de 2018 al 29 de febrero de 2020, y esta eficiencia cambió de manera uniforme durante el COVID-19, del 1 de marzo de 2020 al 27 de junio de 2022. El mercado de las criptomonedas Tether (USDT) y USD Coin (USDC) no serán eficientes en ningún periodo.</td><td>El mercado de las criptomonedas Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) durante el periodo pre-COVID-19 fue eficiente.</td><td>Capítulo I: Objetivos, capítulo II: Preguntas y capítulo III: Hipótesis<br>Capítulos dedicados para la formulación de objetivos, preguntas y hipótesis</td><td rowspan="4">En base a los resultados obtenidos y al estudio de las distintas investigaciones, se llega a la conclusión de que la eficiencia de mercado de las criptomonedas es fluctuante, presentando eficiencia débil en un periodo y ineficiencia en el periodo posterior a éste; razón por la cual, no se puede llegar a una conclusión absoluta. Dependiendo del periodo en el que se realice la investigación se puede hallar tanto eficiencia débil de mercado como ineficiencia de mercado, y ésta variará en periodos previos o posteriores.</td></tr>
<tr><td rowspan="2">Contrastar si la eficiencia de mercado cambio para las cinco criptomonedas en el periodo COVID-19.</td><td>La eficiencia de mercado cambio para Bitcoin (BTC), Ethereum (ETH) y Binance Coin (BNB) en el periodo COVID-19.</td><td>Capítulo IV: Marco teórico y Capítulo V: Marco Contextual<br>Capítulos dedicados a la teoría y el contexto detrás de la investigación</td></tr>
<tr><td rowspan="3">El mercado de las criptomonedas Tether (USDT) y USD Coin (USDC) será ineficiente en ambos periodos.</td><td>Capítulo VI: Revisión de literatura<br>Capítulo dedicado a las diversas investigaciones consultadas para la realización del trabajo</td></tr>
<tr><td>Capítulo VII: Metodología<br>Capítulo dedicado al análisis de las variables del trabajo y de la propuesta empírica</td></tr>
<tr><td>Evaluar si existe relación entre la liquidez de las criptomonedas y su eficiencia.</td><td>Existe una relación entre la liquidez de las criptomonedas y su eficiencia.</td><td>Capítulo VIII: Análisis de resultados<br>Capítulo dedicado al análisis de los resultados obtenidos en el modelo GARCH<br><br>Capítulo IX: Conclusiones<br>Capítulo dedicado a las conclusiones del trabajo</td></tr>
</table>

# REFERENCIAS


Alexander, S. S. (1961). Price movements in speculative markets: Trends or Random Walks. *Industrial Management Review.*

Amihud, Y. (2002). Illiquidity and stock returns: cross-section and time-series effects. *Journal of Financial Markets*, 5(1), p. 31-56. https://doi.org/10.1016/S1386-4181(01)00024-6

Bachelier, L. (1900). Théorie de la spéculation. *Annales scientifiques de l'École Normale Supérieure,* 17(3), p. 21-86.

Bollerslev, T. (1987). A Conditionally Heteroskedastic Time Series Model for Speculative Prices and Rates of Return. *The Review of Economics and Statistics*, 69(3), p. 542-547. http://www.jstor.org/stable/1925546?origin=JSTOR-pdf

Cootner, P. (1964). The random character of stock market prices. *Cambridge.*

Chordia, T., Roll, R. & Subrahmanyam, A. (2008). Liquidity and market efficiency. *Journal of Financial Economics.* 87(2), p. 249-268. https://doi.org/10.1016/j.jfineco.2007.03.005

Wei, W. C. (2018). Liquidity and market efficiency in cryptocurrencies. *Economics Letters*. 168, p. 21-24. https://doi.org/10.1016/j.econlet.2018.04.003

DeVries, P. (2016). An Analysis of Cryptocurrency, Bitcoin, and the Future. *International Journal of Business Management and Commerce.* 1(2), p. 1-9. https://www.researchgate.net/publication/316656878_An_Analysis_of_Cryptocurrency_Bitcoin_and_the_Future

Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of U.K. Inflation. *Econometrica*, 50(4), p. 987-1008. https://www.jstor.org/stable/1912773

El Montasser, G., Charfeddine, L. & Benhamed, A. (2022). COVID-19, cryptocurrencies bubbles and digital market efficiency: sensitivity and similarity analysis. *Finance Research Letters.* 46, 102362. https://doi.org/10.1016/j.frl.2021.102362

Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), p. 383-417. http://www.jstor.org/stable/2325486?origin=JSTOR-pdf

Fama, E. F. (1976). Efficient Capital Markets: Reply. *The Journal of Finance*, 31(1), p. 143-145. http://www.jstor.org/stable/2326404

Fung, K., Jeong, J. & Pereira, J. (2022). More to cryptos than bitcoin: A GARCH modelling of heterogeneous cryptocurrencies. *Finance Research Letters.* 47, 102544. https://doi.org/10.1016/j.frl.2021.102544

Hodrea, R. (2015). An Intraday Analysis of the Market Efficiency-liquidity Relationship: The Case of BVB Stock Exchange. *Procedia Economics and Finance.* 32, p. 1432-1441. https://doi.org/10.1016/S2212-5671(15)01519-1

Hu, Y., Valera, H. G. A., & Oxley, L. (2019). Market efficiency of the top market-cap cryptocurrencies: Further evidence from a panel framework. *Finance Research Letters*. doi:10.1016/j.frl.2019.04.012

Jiang, Y., Nie, H., & Ruan, W. (2018). Time-varying long-term memory in Bitcoin market. *Finance Research Letters*, 25, 280–284. doi:10.1016/j.frl.2017.12.009

Kendall, M. G. (1953). The analysis of economic time-series-part I: Prices. *Journal of the Royal Statistical Society.* Series A(General), 116(1), p. 11-34. https://www.jstor.org/stable/2980947

Kakinaka, S. & Umeno, K. (2022). Cryptocurrency market efficiency in short- and long-term horizons during COVID-19: An asymmetric multifractal analysis approach. *Finance Research Letters.* 46, 102319. https://doi.org/10.1016/j.frl.2021.102319

Le Tran, V. & Leivik, T. (2020). Efficiency in the market of crypto-currencies. *Finance Research Letters*, 35(1), 101382. https://doi.org/10.1016/j.frl.2019.101382

Millán, V. (mayo de 2022). "No me arrepiento": así piensa ahora el hombre que cambió 10,000 bitcoins por dos pizzas. *ElEconomista.* *https://www.eleconomista.es/mercados-cotizaciones/noticias/11772855/05/22/No-me-arrepiento-asi-piensa-ahora-el-hombre-que-cambio-10000-bitcoins-por-dos-pizzas.html*

Mallesha, L. & Archana, H. N. (2024). Evolving Efficiency of Cryptocurrency Market: Evidence from Leading Cryptocurrencies. *Review of Finance & Banking*, 16(1), 73–84. https://doi.org/10.24818/rfb.23.16.01.06

Mokni, K., El Montasser, G., Ajmi, A. N., & Bouri, E. (2024). On the efficiency and its drivers in the cryptocurrency market: the case of Bitcoin and Ethereum. *Financial Innovation*, 10(1), 1–25. https://doi.org/10.1186/s40854-023-00566-3

Noda, A. (2020). On the evolution of cryptocurrency market efficiency. *Applied Economics Letters*, 28(6), 433–439. https://doi.org/10.1080/13504851.2020.1758617

Riaño, C. D. (2018). Hipótesis de los mercados eficientes y la sabiduría de las masas. [Trabajo de Fin de Grado para optar el grado en Administración y Dirección de Empresas (E-2), Universidad Pontificia Comillas]. Repositorio de la Universidad Pontificia Comillas. https://repositorio.comillas.edu/xmlui/handle/11531/23086

Wang, J. & Wang, X. (2021). COVID-19 and financial market efficiency: Evidence from an entropy-based analysis. *Finance Research Letters.* 42, 101888. https://doi.org/10.1016/j.frl.2020.101888

Wu, R. & Qin, Z. (2021). Assessing market efficiency and liquidity: Evidence from China's emissions trading scheme pilots. *Science of The Total Environment*. 769, 144707. https://doi.org/10.1016/j.scitotenv.2020.144707

Zitis, P. I., Kakinaka, S., Umeno, K., Stavrinides, S. G., Hanias, M. P., & Potirakis, S. M. (2023). The Impact of COVID-19 on Weak-Form Efficiency in Cryptocurrency and Forex Markets. *Entropy*, 25(12), 1622. https://doi.org/10.3390/e25121622

UNIVERSIDAD DE LIMA
MCMLXII
SCIENTIA ET PRAXIS

# BIBLIOGRAFIA


Alexander, S. S. (1961). Price movements in speculative markets: Trends or Random Walks. *Industrial Management Review.*

Amihud, Y. (2002). Illiquidity and stock returns: cross-section and time-series effects. *Journal of Financial Markets*, 5(1), p. 31-56. https://doi.org/10.1016/S1386-4181(01)00024-6

Bachelier, L. (1900). Théorie de la spéculation. *Annales scientifiques de l'École Normale Supérieure,* 17(3), p. 21-86.

Bollerslev, T. (1987). A Conditionally Heteroskedastic Time Series Model for Speculative Prices and Rates of Return. *The Review of Economics and Statistics*, 69(3), p. 542-547. http://www.jstor.org/stable/1925546?origin=JSTOR-pdf

Cootner, P. (1964). The random character of stock market prices. *Cambridge.*

Chordia, T., Roll, R. & Subrahmanyam, A. (2008). Liquidity and market efficiency. *Journal of Financial Economics.* 87(2), p. 249-268. https://doi.org/10.1016/j.jfineco.2007.03.005

Wei, W. C. (2018). Liquidity and market efficiency in cryptocurrencies. *Economics Letters*. 168, p. 21-24. https://doi.org/10.1016/j.econlet.2018.04.003

Choi, S. H., & Jarrow, R. A. (2022). Applying the Local Martingale Theory of Bubbles to Cryptocurrencies. *International Journal of Theoretical & Applied Finance*, 25(3), 1–25. https://doi.org/10.1142/S0219024922500133

DeVries, P. (2016). An Analysis of Cryptocurrency, Bitcoin, and the Future. *International Journal of Business Management and Commerce.* 1(2), p. 1-9. https://www.researchgate.net/publication/316656878_An_Analysis_of_Cryptocurrency_Bitcoin_and_the_Future

Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of U.K. Inflation. *Econometrica*, 50(4), p. 987-1008. https://www.jstor.org/stable/1912773

El Montasser, G., Charfeddine, L. & Benhamed, A. (2022). COVID-19, cryptocurrencies bubbles and digital market efficiency: sensitivity and similarity analysis. *Finance Research Letters.* 46, 102362. https://doi.org/10.1016/j.frl.2021.102362

Fama, E. F. (1970). Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, 25(2), p. 383-417. http://www.jstor.org/stable/2325486?origin=JSTOR-pdf

Fama, E. F. (1976). Efficient Capital Markets: Reply. *The Journal of Finance*, 31(1), p. 143-145. http://www.jstor.org/stable/2326404

Fung, K., Jeong, J. & Pereira, J. (2022). More to cryptos than bitcoin: A GARCH modelling of heterogeneous cryptocurrencies. *Finance Research Letters.* 47, 102544. https://doi.org/10.1016/j.frl.2021.102544

Hodrea, R. (2015). An Intraday Analysis of the Market Efficiency-liquidity Relationship: The Case of BVB Stock Exchange. *Procedia Economics and Finance.* 32, p. 1432-1441. https://doi.org/10.1016/S2212-5671(15)01519-1

Hu, Y., Valera, H. G. A., & Oxley, L. (2019). Market efficiency of the top market-cap cryptocurrencies: Further evidence from a panel framework. *Finance Research Letters*. doi:10.1016/j.frl.2019.04.012

Haykir, O., & Yagli, I. (2022). Speculative bubbles and herding in cryptocurrencies. *Financial Innovation*, 8(1), 1–33. https://doi.org/10.1186/s40854-022-00383-0

Jiang, Y., Nie, H., & Ruan, W. (2018). Time-varying long-term memory in Bitcoin market. *Finance Research Letters*, 25, 280–284. doi:10.1016/j.frl.2017.12.009

Kendall, M. G. (1953). The analysis of economic time-series-part I: Prices. *Journal of the Royal Statistical Society.* Series A(General), 116(1), p. 11-34. https://www.jstor.org/stable/2980947

Kakinaka, S. & Umeno, K. (2022). Cryptocurrency market efficiency in short- and long-term horizons during COVID-19: An asymmetric multifractal analysis approach. *Finance Research Letters.* 46, 102319. https://doi.org/10.1016/j.frl.2021.102319

Kaplan, Inc. (2023). *Schwesernotes 2024 Level 1 CFA Book 3: Financial Statement Analysis and Equity Investments.* Kaplan Schweser.

Kaplan, Inc. (2023). *Schwesernotes 2024 Level 1 CFA Book 5: Alternative Investments, Portfolio Management (Part Two), and Ethical and Professional Standards*. Kaplan Schweser

Le Tran, V. & Leivik, T. (2020). Efficiency in the market of crypto-currencies. *Finance Research Letters*, 35(1), 101382. https://doi.org/10.1016/j.frl.2019.101382

Millán, V. (mayo de 2022). "No me arrepiento": así piensa ahora el hombre que cambió 10,000 bitcoins por dos pizzas. *ElEconomista.* *https://www.eleconomista.es/mercados-cotizaciones/noticias/11772855/05/22/No-me-arrepiento-asi-piensa-ahora-el-hombre-que-cambio-10000-bitcoins-por-dos-pizzas.html*

Mallesha, L. & Archana, H. N. (2024). Evolving Efficiency of Cryptocurrency Market: Evidence from Leading Cryptocurrencies. *Review of Finance & Banking*, 16(1), 73–84. https://doi.org/10.24818/rfb.23.16.01.06

Mokni, K., El Montasser, G., Ajmi, A. N., & Bouri, E. (2024). On the efficiency and its drivers in the cryptocurrency market: the case of Bitcoin and Ethereum. *Financial Innovation*, 10(1), 1–25. https://doi.org/10.1186/s40854-023-00566-3

Noda, A. (2020). On the evolution of cryptocurrency market efficiency. *Applied Economics Letters*, 28(6), 433–439. https://doi.org/10.1080/13504851.2020.1758617

Riaño, C. D. (2018). Hipótesis de los mercados eficientes y la sabiduría de las masas. [Trabajo de Fin de Grado para optar el grado en Administración y Dirección de Empresas (E-2), Universidad Pontificia Comillas]. Repositorio de la Universidad Pontificia Comillas. https://repositorio.comillas.edu/xmlui/handle/11531/23086

Statman, M. (2019). *Behavioral Finance.* CFA Institute Research Foundation.

Wang, J. & Wang, X. (2021). COVID-19 and financial market efficiency: Evidence from an entropy-based analysis. *Finance Research Letters.* 42, 101888. https://doi.org/10.1016/j.frl.2020.101888

Wu, R. & Qin, Z. (2021). Assessing market efficiency and liquidity: Evidence from China's emissions trading scheme pilots. *Science of The Total Environment*. 769, 144707. https://doi.org/10.1016/j.scitotenv.2020.144707

Waters, G. A., & Bui, T. (2022). An empirical test for bubbles in cryptocurrency markets. *Journal of Economics & Finance*, 46(1), 207–219. https://doi.org/10.1007/s12197-021-09561-9

Zitis, P. I., Kakinaka, S., Umeno, K., Stavrinides, S. G., Hanias, M. P., & Potirakis, S. M. (2023). The Impact of COVID-19 on Weak-Form Efficiency in Cryptocurrency and Forex Markets. *Entropy*, 25(12), 1622. https://doi.org/10.3390/e25121622

# ANEXOS

## Anexo 1: Gráfico de Retorno_BTC2 periodo pre-COVID-19

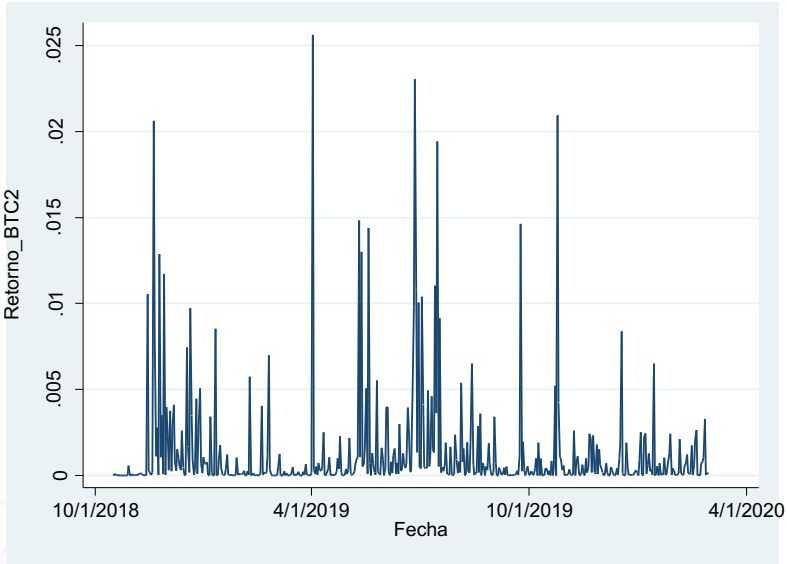

## Anexo 2: Gráfico de Retorno_ETH2 periodo pre-COVID-19

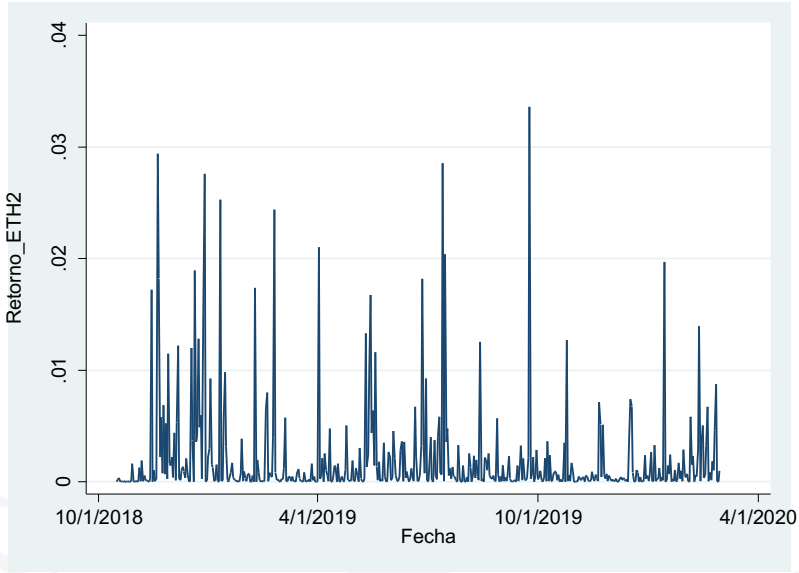

**Anexo 3: Gráfico de Retorno_USDT2 periodo pre-COVID-19**

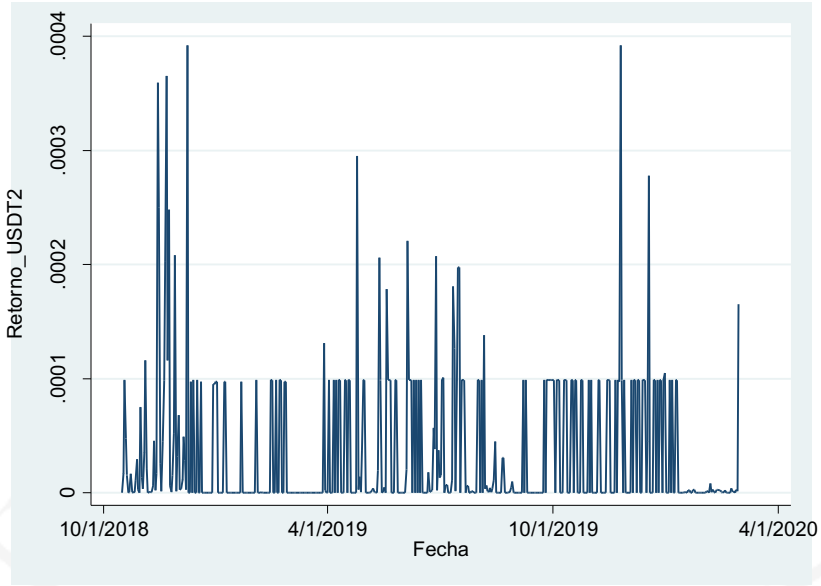

## Anexo 4: Gráfico de Retorno_USDC2 periodo pre-COVID-19

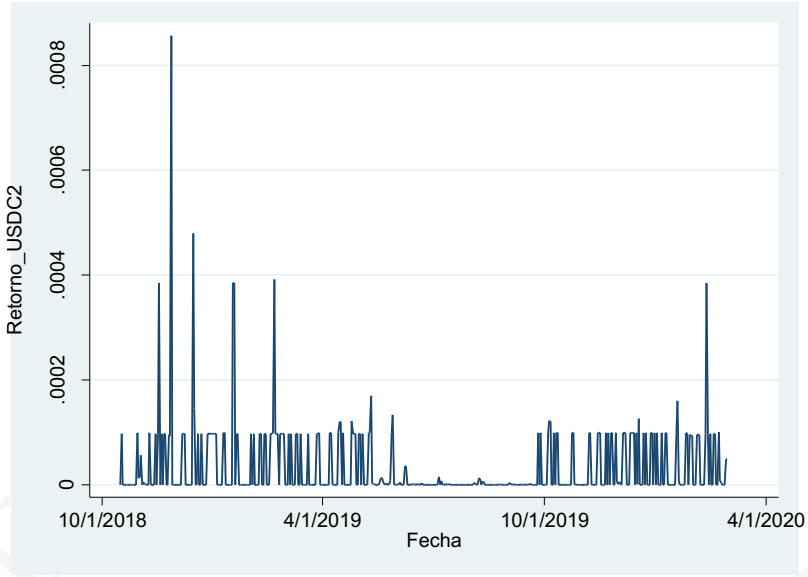

## Anexo 5: Gráfico de Retorno_BNB2 periodo pre-COVID-19

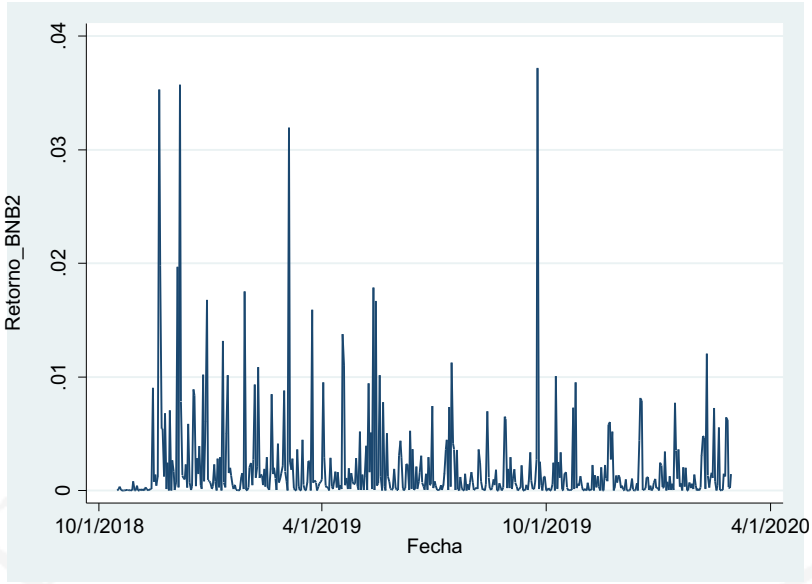

## Anexo 6: Resultados del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo pre-COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **10/16/2018 - 2/29/2020** Number of Obs = **502**
Distribution: **Gaussian** Wald chi2(1) = **8.13**
Log Likelihood = **1060.45** Prob > Chi2 = **0.0044**

| Retorno_BTC | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_BTC** | | | | | | |
| _cons | 0.0011802 | 0.0012961 | 0.91 | 0.363 | -0.00136 | 0.0037205 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| ll. | 0.1135955 | 0.0398419 | 2.85 | 0.004 | 0.0355068 | 0.1916843 |
| **HET** | | | | | | |
| amihud_BTC | 2.563303 | 0.3001397 | 8.54 | 0 | 1.97504 | 3.151566 |
| _cons | -7.747093 | 0.0810464 | -95.59 | 0 | -7.905941 | -7.588245 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| ll. | 0.4325898 | 0.0683081 | 6.33 | 0 | 0.2987083 | 0.5664712 |
| garch | | | | | | |
| ll. | 0.0020982 | 0.0286358 | 0.07 | 0.942 | -0.054027 | 0.0582234 |

## Anexo 7: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo pre-COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.625 | 1 | 0.4291 |
| 5 | 26.63 | 5 | 0.0001 |
| 10 | 46.141 | 10 | 0 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 8: Resultados del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo pre-COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **10/16/2018 - 2/29/2020** Number of Obs = **502**
Distribution: **Gaussian** Wald chi2(1) = **2.59**
Log Likelihood = **946.3952** Prob > Chi2 = **0.1078**

| Retorno_ETH | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_ETH** | | | | | | |
| _cons | 0.0013254 | 0.0014261 | 0.93 | 0.353 | -0.0014698 | 0.0041205 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.0568296 | 0.0353355 | -1.61 | 0.108 | -0.1260859 | 0.0124266 |
| **HET** | | | | | | |
| amihud_ETH | 2.013488 | 0.3237168 | 6.22 | 0 | 1.379014 | 2.647961 |
| _cons | -6.66102 | 0.0698142 | -95.41 | 0 | -6.797853 | -6.524186 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.0518455 | 0.0205418 | 2.52 | 0.012 | 0.0115842 | 0.0921068 |
| garch | | | | | | |
| Ll. | -0.1367835 | 0.0458353 | -2.98 | 0.003 | -0.226619 | -0.0469479 |

## Anexo 9: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo pre-COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 1.744 | 1 | 0.1867 |
| 5 | 11.525 | 5 | 0.0419 |
| 10 | 14.989 | 10 | 0.1325 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 10: Resultados del modelo GARCH para la criptomoneda Tether (USDT) en el periodo pre-COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **10/16/2018 - 2/29/2020** Number of Obs = **502**
Distribution: **Gaussian** Wald chi2(1) = **62.58**
Log Likelihood = **1960.385** Prob > Chi2 = **0.0000**

| Retorno_USDT | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_USDT** | | | | | | |
| _cons | 0.0001315 | 0.0001158 | 1.14 | 0.256 | -0.0000954 | 0.0003584 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.4582079 | 0.0579225 | -7.91 | 0 | -0.5717339 | -0.3446819 |
| **HET** | | | | | | |
| amihud_USDT | 1.891643 | 0.3007934 | 6.29 | 0 | 1.302098 | 2.481187 |
| _cons | -11.35745 | 0.1452732 | -78.18 | 0 | -11.64218 | -11.07272 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.4038791 | 0.1014965 | 3.98 | 0.012 | 0.2049497 | 0.6028086 |
| garch | | | | | | |
| Ll. | 0.085221 | 0.1023575 | 0.83 | 0.405 | -0.115396 | 0.285838 |

## Anexo 11: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Tether (USDT) en el periodo pre-COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 1.509 | 1 | 0.2192 |
| 5 | 10.338 | 5 | 0.0662 |
| 10 | 21.625 | 10 | 0.0171 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 12: Resultados del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo pre-COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **10/16/2018 - 2/29/2020** Number of Obs = **502**
Distribution: **Gaussian** Wald chi2(1) = **72.9**
Log Likelihood = **1965.999** Prob > Chi2 = **0.0000**

| Retorno_USDC | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_USDC** | | | | | | |
| _cons | 0.0000895 | 0.0001433 | 0.62 | 0.532 | -0.0001913 | 0.0003703 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.4018644 | 0.0470667 | -8.54 | 0 | -0.4941134 | -0.3096154 |
| **HET** | | | | | | |
| amihud_USDC | 2.051604 | 0.5066842 | 4.05 | 0 | 1.058521 | 3.044687 |
| _cons | -11.13864 | 0.1756297 | -63.42 | 0 | -11.48287 | -10.79442 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.2646654 | 0.0811815 | 3.26 | 0.001 | 0.1055329 | 0.4237979 |
| garch | | | | | | |
| Ll. | 0.1205419 | 0.1319991 | 0.91 | 0.361 | -0.1381717 | 0.3792554 |

## Anexo 13: Multiplicador de Lagrange del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo pre-COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0 | 1 | 0.996 |
| 5 | 1.211 | 5 | 0.9438 |
| 10 | 20.048 | 10 | 0.0288 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 14: Resultados del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo pre-COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **10/16/2018 - 2/29/2020** Number of Obs = **502**
Distribution: **Gaussian** Wald chi2(1) = **0.3**
Log Likelihood = **881.4582** Prob > Chi2 = **0.5819**

| Retorno_BNB | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_BNB** | | | | | | |
| _cons | 0.002583 | 0.0018631 | 1.39 | 0.165 | -0.0010647 | 0.0062387 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | 0.0207118 | 0.0376127 | 0.55 | 0.582 | -0.0530078 | 0.0944313 |
| **HET** | | | | | | |
| amihud_BNB | 1.526539 | 0.2975165 | 5.13 | 0 | 0.9434178 | 2.109661 |
| _cons | -6.260043 | 0.0797655 | -78.48 | 0 | -6.416381 | -6.103706 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | -0.0066186 | 0.0224438 | -0.29 | 0.768 | -0.0506077 | 0.0373705 |
| garch | | | | | | |
| Ll. | -0.1737043 | 0.0719117 | -2.42 | 0.016 | -0.3146487 | -0.0327599 |

## Anexo 15: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo pre-COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.181 | 1 | 0.6706 |
| 5 | 5.378 | 5 | 0.3715 |
| 10 | 9.338 | 10 | 0.5003 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 16: Gráfico de Retorno_BTC2 periodo durante el COVID-19

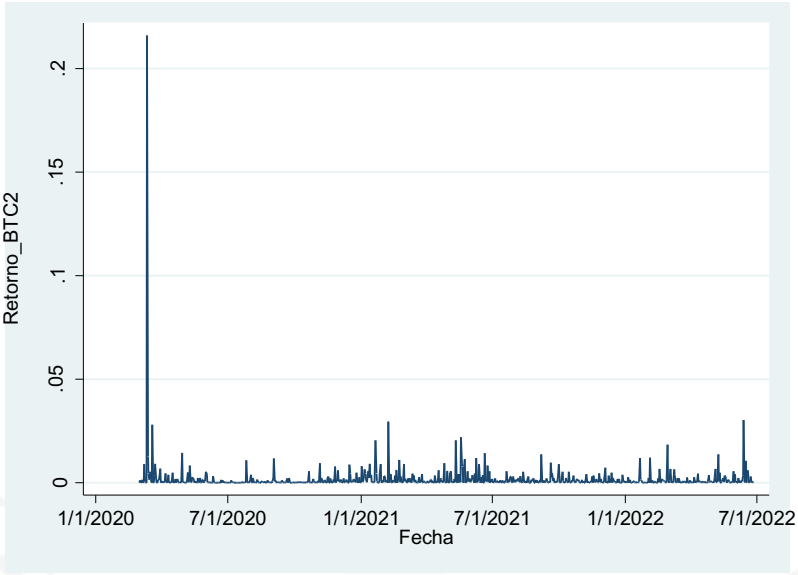

**Anexo 17: Gráfico de Retorno_ETH2 periodo durante el COVID-19**

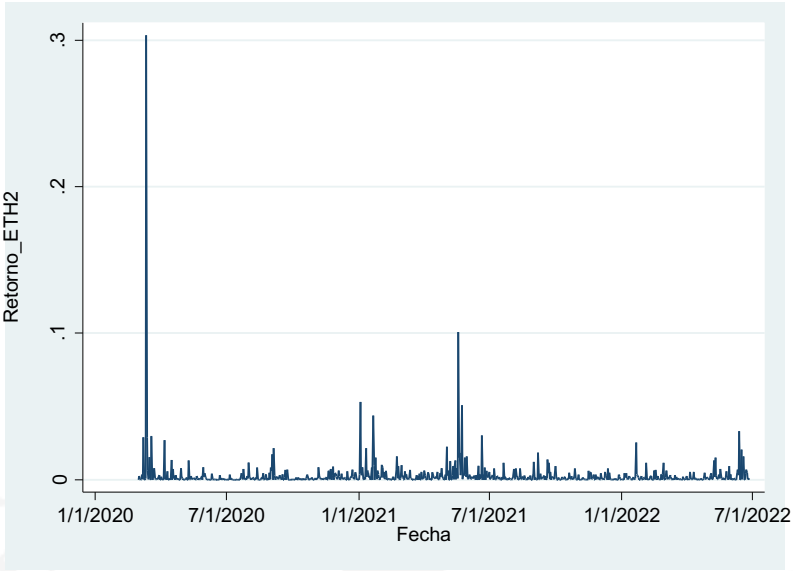

**Anexo 18: Gráfico de Retorno_USDT2 periodo durante el COVID-19**

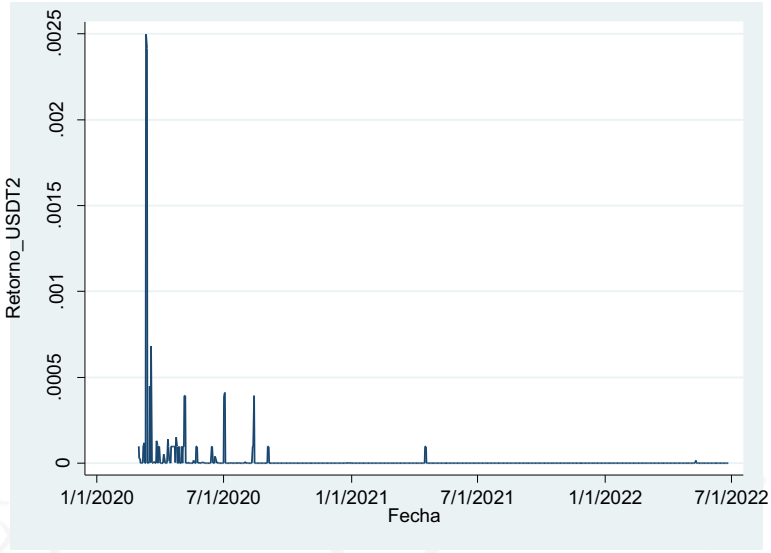

**Anexo 19: Gráfico de Retorno_USDC2 periodo durante el COVID-19**

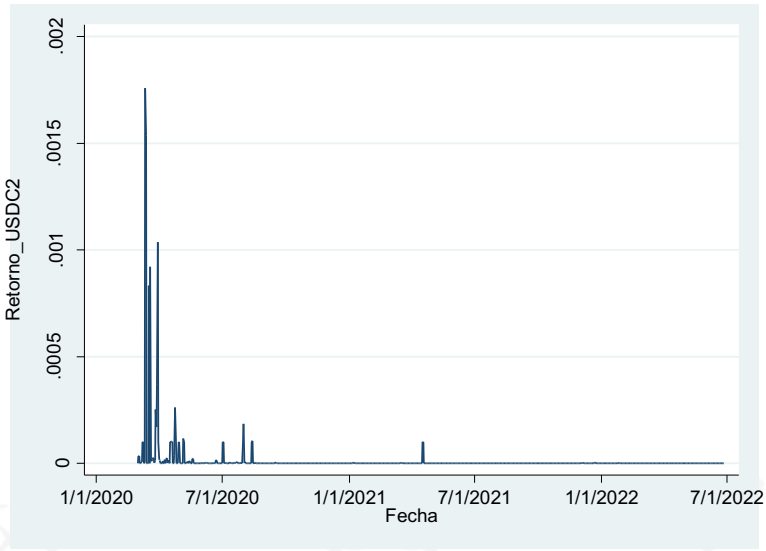

**Anexo 20: Gráfico de Retorno_BNB2 periodo durante el COVID-19**

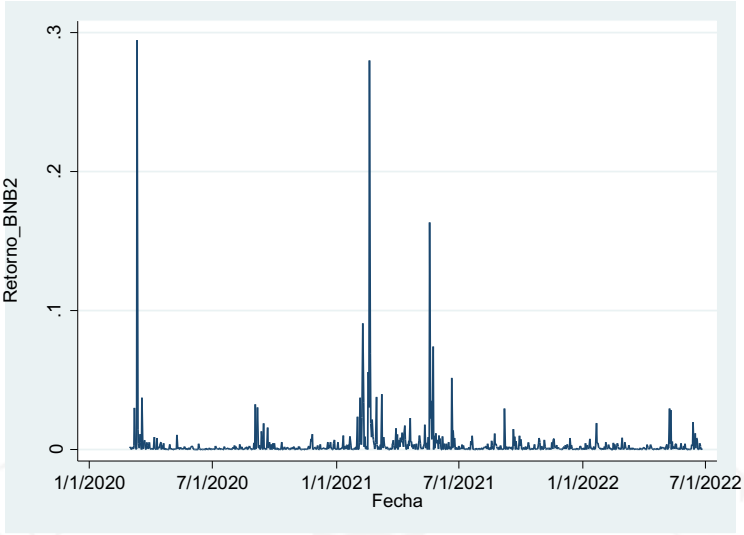

## Anexo 21: Resultados del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo durante el COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: 3**/1/2020 - 6/27/2022** Number of Obs = **849**
Distribution: **Gaussian** Wald chi2(1) = **0.43**
Log Likelihood = **1734.274** Prob > Chi2 = **0.5104**

| Retorno_BTC | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. Interval] | |
|---|---|---|---|---|---|---|
| **Retorno_BTC** | | | | | | |
| _cons | 0.0015904 | 0.000988 | 1.61 | 0.107 | -0.0003461 | 0.0035269 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.0175791 | 0.0267086 | -0.66 | 0.51 | -0.069927 | 0.0347688 |
| **HET** | | | | | | |
| amihud_BTC | 2.36444 | 0.0883085 | 26.77 | 0 | 2.191359 | 2.537522 |
| _cons | -7.214551 | 0.0475159 | -151.83 | 0 | -7.307681 | -7.121422 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.0519376 | 0.0147403 | 3.52 | 0 | 0.0230472 | 0.080828 |
| garch | | | | | | |
| Ll. | -0.0585671 | 0.0107509 | -5.45 | 0 | -0.0796384 | -0.0374957 |

## Anexo 22: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Bitcoin (BTC) en el periodo durante el COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 2.616 | 1 | 0.1058 |
| 5 | 45.034 | 5 | 0 |
| 10 | 52.441 | 10 | 0 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 23: Resultados del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo durante el COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **3/1/2020 - 6/27/2022** Number of Obs = **849**
Distribution: **Gaussian** Wald chi2(1) = **1.44**
Log Likelihood = **1474.789** Prob > Chi2 = **0.2296**

| Retorno_ETH | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_ETH** | | | | | | |
| _cons | 0.0030668 | 0.0012984 | 2.36 | 0.018 | 0.000522 | 0.0056117 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.0345789 | 0.0287848 | -1.2 | 0.23 | -0.0909962 | 0.218383 |
| **HET** | | | | | | |
| amihud_ETH | 2.276437 | 0.1074018 | 21.2 | 0 | 2.065933 | 2.486941 |
| _cons | -6.521864 | 0.0526602 | -123.85 | 0 | -6.625077 | -6.418652 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.0652827 | 0.0256158 | 2.55 | 0.011 | 0.0150766 | 0.1154889 |
| garch | | | | | | |
| Ll. | -0.0787806 | 0.0162518 | -4.85 | 0 | -0.1106336 | -0.0469276 |

## Anexo 24: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Ethereum (ETH) en el periodo durante el COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.774 | 1 | 0.3789 |
| 5 | 39.687 | 5 | 0 |
| 10 | 65.138 | 10 | 0 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 25: Resultados del modelo GARCH para la criptomoneda Tether (USDT) en el periodo durante el COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **3/1/2020 - 6/27/2022** Number of Obs = **849**
Distribution: **Gaussian** Wald chi2(1) = **202.66**
Log Likelihood = **5296.401** Prob > Chi2 = **0.0000**

| Retorno_USDT | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_USDT** | | | | | | |
| _cons | 5.35E-06 | 3.09E-06 | 1.73 | 0.084 | -7.12E-07 | 0.0000114 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.8079841 | 0.0567565 | -14.24 | 0 | -0.9192249 | -0.6967434 |
| **HET** | | | | | | |
| amihud_USDT | 9.178997 | 0.4022826 | 22.82 | 0 | 8.390537 | 9.967456 |
| _cons | -18.52954 | 0.0790053 | -234.54 | 0 | -18.68439 | -18.3747 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 7.576207 | 0.7664411 | 9.88 | 0 | 6.07401 | 9.078404 |
| garch | | | | | | |
| Ll. | 0.2727133 | 0.0058686 | 46.47 | 0 | 0.261211 | 0.2842156 |

## Anexo 26: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Tether (USDT) en el periodo durante el COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.126 | 1 | 0.7227 |
| 5 | 0.366 | 5 | 0.9962 |
| 10 | 0.893 | 10 | 0.9999 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 27: Resultados del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo durante el COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **3/1/2020 - 6/27/2022** Number of Obs = **849**
Distribution: **Gaussian** Wald chi2(1) = **63.51**
Log Likelihood = **4976.689** Prob > Chi2 = **0.0000**

| Retorno_USDC | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_USDC** | | | | | | |
| _cons | -9.88E-06 | 1.93E-05 | -0.51 | 0.608 | -4.76E-05 | 0.0000279 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.4998783 | 0.0627261 | -7.97 | 0 | -0.6228192 | -0.3769373 |
| **HET** | | | | | | |
| amihud_USDC | 5.911534 | 0.0788568 | 74.97 | 0 | 5.756978 | 6.066091 |
| _cons | -15.73954 | 0.0253815 | -620.12 | 0 | -15.78928 | -15.68979 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.2991603 | 0.0575887 | 5.19 | 0 | 0.1862885 | 0.4120321 |
| garch | | | | | | |
| Ll. | 0.2824954 | 0.018938 | 14.92 | 0 | 0.2453776 | 0.3196133 |

## Anexo 28: Multiplicador de Lagrange del modelo GARCH para la criptomoneda USD Coin (USDC) en el periodo durante el COVID-19

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.001 | 1 | 0.977 |
| 5 | 0.009 | 5 | 1 |
| 10 | 0.036 | 10 | 1 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

## Anexo 29: Resultados del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo durante el COVID-19

ARCH family regression - ARMA disturbances and mult. Heteroskedasticity

Sample: **3/1/2020 - 6/27/2022** Number of Obs = **849**
Distribution: **Gaussian** Wald chi2(1) = **4.10**
Log Likelihood = **1323.993** Prob > Chi2 = **0.0430**

| Retorno_BNB | Coef. | OPG Std. Err. | z | P>\|z\| | [95% conf. | Interval] |
|---|---|---|---|---|---|---|
| **Retorno_BNB** | | | | | | |
| _cons | 2.23E-03 | 1.54E-03 | 1.45 | 0.147 | -7.87E-04 | 0.0052554 |
| **ARMA** | | | | | | |
| ar | | | | | | |
| Ll. | -0.0824832 | 0.0407578 | -2.02 | 0.043 | -0.1623671 | -0.0025994 |
| **HET** | | | | | | |
| amihud_BNB | 1.169614 | 0.3501786 | 3.34 | 0.001 | 0.4832766 | 1.855951 |
| _cons | -9.378317 | 0.2945073 | -31.84 | 0 | -9.95554 | -8.801093 |
| **ARCH** | | | | | | |
| arch | | | | | | |
| Ll. | 0.187903 | 0.0169661 | 11.08 | 0 | 0.1546501 | 0.2211559 |
| garch | | | | | | |
| Ll. | 0.8110929 | 0.0156431 | 51.85 | 0 | 0.780433 | 0.8417529 |

**Anexo 30: Multiplicador de Lagrange del modelo GARCH para la criptomoneda Binance Coin (BNB) en el periodo durante el COVID-19**

LM test for autoregressive conditional heteroskedasticity (ARCH)

| Lags (p) | chi2 | df | Prob > chi2 |
|---|---|---|---|
| 1 | 0.686 | 1 | 0.4076 |
| 5 | 6.945 | 5 | 0.2248 |
| 10 | 8.99 | 10 | 0.533 |

H0: no ARCH effects vs. H1: ARCH(p) disturbance

# 7% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

## Filtrado desde el informe

- Bibliografía
- Texto citado

## Fuentes principales

6% Fuentes de Internet
3% Publicaciones
2% Trabajos entregados (trabajos del estudiante)

## Marcas de integridad

**N.º de alertas de integridad para revisión**

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.

## Fuentes principales

6% Fuentes de Internet
3% Publicaciones
2% Trabajos entregados (trabajos del estudiante)

## Fuentes principales

Las fuentes con el mayor número de coincidencias dentro de la entrega. Las fuentes superpuestas no se mostrarán.

1 Internet
repositorio.comillas.edu 1%

2 Internet
es.fxmag.com 1%

3 Publicación
José Antonio Morales Castro, Francisco López Herrera. "Probabilidad de ganancia... 1%

4 Internet
rdu.unc.edu.ar 1%

5 Internet
www.wikibit.com 0%

6 Internet
repositorio.ulima.edu.pe 0%

7 Internet
repository.urosario.edu.co 0%

8 Internet
www.scielo.org.co 0%

9 Internet
hdl.handle.net 0%

10 Internet
qspace.qu.edu.qa 0%

11 Publicación
Maria A. Fiol-deRoque, Maria J. Serrano-Ripol, Montserrat Gens-Barberà, Encarna ... 0%

12 Trabajos del estudiante
Universidad del Valle 0%

13 Internet
www.scribd.com 0%

14 Internet
www.mdpi.com 0%

15 Trabajos del estudiante
Universidad Santiago de Cali 0%

16 Internet
docplayer.es 0%

17 Internet
www.analitica.com 0%

18 Internet
www.slideshare.net 0%

19 Internet
www.transparencia.gob.sv 0%