

TRABAJO DE INVESTIGACIÓN FINAL

Eficiencia débil en mercado cripto:
Evolución temporal y diferencias según la
madurez de los activos (2020-2025)

Autor/es:

Alejo Fernandez Alric – L.U: 1153731

Matias Jantzón – L.U: 1150389

Carrera:

Licenciatura en Finanzas

Tutor/a:

Diego Ariel Onna

Año: 2026

Agradecimientos

La realización de este Trabajo Final de Grado representa el cierre de una etapa muy importante en nuestra formación profesional, y no habría sido posible sin el acompañamiento de muchas personas que contribuyeron, de distintas maneras, a este recorrido.

En primer lugar, queremos agradecer a la Universidad y a cada uno de los docentes que formaron parte de nuestra carrera. A través de sus enseñanzas, dedicación y compromiso, nos brindaron las herramientas y conocimientos que hicieron posible el desarrollo de este trabajo y nuestra formación como futuros profesionales.

Expresamos un especial reconocimiento a nuestro tutor, Diego Ariel Onna, por su predisposición, su acompañamiento permanente y sus valiosos aportes a lo largo de todo el proceso.

Asimismo, agradecemos a Karina Elizabeth Díaz, quien nos brindó el apoyo metodológico necesario y nos acompañó durante el desarrollo del trabajo, aportando su experiencia y orientándonos para alcanzar los objetivos propuestos.

Por último, queremos dedicar un agradecimiento muy especial a nuestras familias, amigos y seres queridos, quienes estuvieron presentes durante todo este camino. Su paciencia, comprensión, confianza y constante apoyo fueron una fuente de motivación para superar los desafíos y llegar a la culminación de esta etapa académica.

Resumen

El presente trabajo analiza la evolución temporal del grado de eficiencia débil en el mercado de criptomonedas durante el período 2020–2025, considerando las diferencias existentes entre activos consolidados, como Bitcoin y Ethereum, y un conjunto de altcoins seleccionadas en función de la disponibilidad de datos históricos y su permanencia durante el período de estudio. La investigación se enmarca en la hipótesis de eficiencia de mercado y en los desarrollos posteriores asociados a la hipótesis de mercados adaptativos. Mientras la hipótesis de eficiencia sostiene que los precios incorporan rápidamente la información disponible, la hipótesis de mercados adaptativos plantea que el grado de eficiencia puede variar según las condiciones y el desarrollo del mercado.

El estudio adopta un enfoque cuantitativo de carácter correlacional. Para medir el grado de eficiencia se utilizará el índice AMIM (Adjusted Market Inefficiency Magnitude), basado en la estructura de autocorrelación de los rendimientos, complementado con

metodologías de ventanas móviles sobre series de precios diarias. Asimismo, se incorporarán variables asociadas al desarrollo del mercado, como liquidez e intensidad de negociación. Se espera aportar evidencia empírica sobre la dinámica temporal de la eficiencia en el mercado cripto y sus diferencias según el nivel de madurez de los activos.

Palabras clave: Eficiencia de mercado; Criptomonedas; Eficiencia débil; Hipótesis de mercados adaptativos; AMIM

Abstract

This study analyzes the temporal evolution of weak-form efficiency in the cryptocurrency market during the 2020–2025 period, considering the differences between consolidated assets such as Bitcoin and Ethereum and a representative group of altcoins. The research is grounded in the Efficient Market Hypothesis (EMH) and in the subsequent developments associated with the Adaptive Market Hypothesis (AMH). While the EMH argues that asset prices rapidly incorporate available information, the AMH proposes that market efficiency may vary over time according to market conditions, liquidity, competition, and the degree of market development.

The study adopts a quantitative and correlational approach. To evaluate the degree of weak-form efficiency, the research will employ the Adjusted Market Inefficiency Magnitude (AMIM) index, based on the autocorrelation structure of returns, complemented by rolling window methodologies applied to daily price series. In addition, variables associated with market development, such as liquidity and trading intensity, will be incorporated into the analysis.

The research aims to provide empirical evidence on the dynamic behavior of efficiency in the cryptocurrency market and on the differences observed between assets with distinct levels of relative maturity. In this context, the study seeks to contribute to the literature on informational efficiency in digital assets from a temporal and comparative perspective, particularly within a market characterized by rapid structural transformation and increasing institutional participation.

Keywords: Market efficiency; Cryptocurrencies; Weak-form efficiency; Adaptive Market Hypothesis; AMIM.

ÍNDICE

1. Planteamiento del tema.....	5
2. Justificación de la investigación y preguntas de investigación.....	7
3. Objetivos.....	7
4. Hipótesis.....	8
5. Marco teórico.....	8
5.1 Hipótesis de Mercados Eficientes.....	8
5.1.1 Origen y fundamentos de la EMH.....	9
5.1.2 Eficiencia débil, semi-fuerte y fuerte.....	9
5.1.3 Random Walk y predictibilidad.....	10
5.1.4 Autocorrelación y eficiencia.....	11
5.2 Hipótesis de Mercados Adaptativos.....	12
5.2.1 Críticas a la visión estática de eficiencia.....	12
5.2.2 Adaptive Market Hypothesis de Andrew Lo.....	12
5.2.3 Eficiencia dinámica y adaptación del mercado.....	13
5.3 Mercado de criptomonedas.....	14
5.3.1 Características del mercado crypto.....	14
5.3.2 Bitcoin, Ethereum y Altcoins.....	15
5.3.3 Evolución del mercado crypto entre 2020-2025.....	15
5.4 Evidencia empírica sobre eficiencia en criptomonedas.....	16
5.4.1 Estudios que encuentran ineficiencia.....	16
5.4.2 Estudios que encuentran mejoras en la eficiencia.....	17
5.4.3 Diferencias en la eficiencia entre criptomonedas.....	17
6. Metodología.....	18
6.1 Datos y muestra.....	18
6.2 Construcción de las variables.....	19
6.2.1 Rendimientos logarítmicos.....	19
6.2.2 Construcción de las variables explicativas.....	20
6.3 Medición de la eficiencia informacionl mediante el AMIM.....	21
6.3.1 Hipótesis de eficiencia débil y autocorrelación.....	21
6.3.2 Modelos autorregresivos y dependencia temporal.....	22
6.3.3 Construcción del indicador AMIM.....	23
6.3.4 Implementación empírica del AMIM.....	26
6.4 Modelo econométrico.....	27

6.4.1 Especificación del modelo de datos de panel.....	28
6.4.2 Modelo de efectos fijos.....	29
6.4.3 Método de estimación.....	29
7. Resultados.....	30
7.1 Resultados del indicador AMIM.....	30
7.1.1 Comparación del AMIM entre Bitcoin, Ethereum y Altcoins.....	30
7.1.2 Evolución temporal del indicador AMIM.....	31
7.2 Relación entre AMIM y las variables explicativas.....	33
7.2.1 Matriz de correlaciones.....	33
7.3 Resultados del modelo econométrico.....	34
8. Discusión de los resultados e implicancias.....	37
8.1 Evolución temporal de la eficiencia informacional.....	37
8.2 Diferencias según la madurez de los activos.....	37
8.3 Relación entre el desarrollo del mercado y la eficiencia informacional.....	38
8.4 Evaluación de la hipótesis.....	39
8.5 Limitaciones y futuras investigaciones.....	39
9. Conclusiones.....	40
10. Anexos.....	42
11. Bibliografía.....	51

1. PLANTEAMIENTO DEL PROBLEMA

La teoría de los mercados eficientes desarrollada por Eugene Fama (1970) sostiene que los precios de los activos financieros reflejan rápidamente la información disponible, reduciendo la posibilidad de obtener beneficios extraordinarios de manera sistemática mediante el análisis de información ya conocida por el mercado. Dentro de este enfoque, la eficiencia débil establece que la información contenida en precios y rendimientos pasados ya se encuentra incorporada en las cotizaciones actuales. Por lo tanto, las variaciones futuras de precios no deberían presentar patrones persistentes de predictibilidad ni relaciones sistemáticas de autocorrelación entre retornos sucesivos.

Años más tarde, distintos desarrollos teóricos comenzaron a cuestionar el carácter estático de dicha hipótesis. En particular, Andrew Lo (2004), a través de la hipótesis de mercados adaptativos, plantea que la eficiencia financiera evoluciona según factores como la competencia entre participantes, la liquidez, el avance tecnológico y las condiciones generales del mercado. Desde esta perspectiva, los mercados pueden atravesar períodos de mayor o menor eficiencia relativa, modificando temporalmente el grado de predictibilidad de los retornos (Lo, 2004, p.18).

Bajo este marco conceptual, el mercado de criptomonedas representa un entorno especialmente relevante para el estudio empírico de la eficiencia financiera. Se trata de un mercado reciente que experimentó una expansión significativa durante el período 2020–2025, impulsada por el crecimiento del volumen negociado, la incorporación de inversores institucionales, el desarrollo de infraestructura financiera y la creciente utilización de estrategias automatizadas y algorítmicas de trading. Sin embargo, al mismo tiempo, continúa presentando elevados niveles de volatilidad y una importante participación especulativa, características que podrían favorecer la aparición de ineficiencias temporales en la formación de precios.

Asimismo, el ecosistema crypto presenta diferencias significativas entre activos según su nivel de desarrollo y madurez relativa. Criptomonedas consolidadas, como Bitcoin y Ethereum, poseen mayores niveles de capitalización, liquidez, profundidad de mercado y participación institucional respecto de otras altcoins de menor desarrollo. En consecuencia, resulta razonable considerar la posibilidad de que existan diferencias en el grado de eficiencia entre activos con distintas características estructurales y distinto nivel de evolución dentro del mercado.

La evidencia empírica sobre la eficiencia del mercado de criptomonedas presenta

resultados heterogéneos y sin consenso definitivo. Mientras Urquhart (2016), Sensoy (2019) y Noda (2020) encuentran evidencia de una evolución hacia mayores niveles de eficiencia a medida que el mercado madura, Bariviera (2017), Miller (2019) y Cheah y Fry (2015) documentan la existencia de dependencia temporal, restricciones al arbitraje, comportamiento especulativo e ineficiencias transitorias, resultados compatibles con la Hipótesis de Mercados Adaptativos. Asimismo, estudios como Hu, Valera y Oxley (2019) y Tran y Leirvik (2019) muestran que el grado de eficiencia difiere entre criptomonedas y evoluciona a lo largo del tiempo. No obstante, aún son escasos los trabajos que analizan simultáneamente la evolución temporal de la eficiencia, las diferencias entre activos según su nivel de madurez y las transformaciones estructurales experimentadas por el mercado de criptomonedas durante el período 2020–2025.

En consecuencia, el problema de investigación del presente trabajo surge de la necesidad de analizar cómo evoluciona el grado de eficiencia débil en criptomonedas seleccionadas durante el período 2020–2025 y si dicho comportamiento presenta diferencias según el nivel de madurez de los activos. Particularmente, resulta relevante estudiar si criptomonedas consolidadas, como Bitcoin y Ethereum, exhiben menores niveles de autocorrelación y predictibilidad en comparación con un conjunto de altcoins seleccionadas en función de la disponibilidad de datos históricos y su permanencia durante el período de estudio, así como también evaluar si la expansión y evolución estructural del mercado crypto se encuentra asociada a cambios en el grado de eficiencia observado.

En función de lo expuesto previamente, el presente trabajo busca responder las siguientes preguntas de investigación:

- ¿Cómo evoluciona el grado de eficiencia débil en el mercado de criptomonedas durante el período 2020–2025?
- ¿Cómo varía el grado de eficiencia entre criptomonedas según su nivel de madurez relativa, particularmente entre activos consolidados como Bitcoin y Ethereum y un conjunto de altcoins seleccionadas en función de la disponibilidad de datos históricos y su permanencia durante el período de estudio?
- ¿En qué medida variables asociadas al desarrollo y las condiciones del mercado, como la capitalización, la volatilidad y el rendimiento de los activos, se encuentran relacionadas con el grado de eficiencia observado en el mercado de criptomonedas?

2. JUSTIFICACIÓN DE LA INVESTIGACIÓN

La presente investigación resulta relevante desde el punto de vista académico porque contribuye al debate sobre la eficiencia de mercado en activos digitales, un campo donde la evidencia empírica aún no presenta conclusiones uniformes. La literatura revisada muestra que existen resultados divergentes respecto de la eficiencia en criptomonedas, lo que abre espacio para nuevos estudios que permitan profundizar la comprensión de este mercado desde enfoques más dinámicos y adaptativos.

Desde una perspectiva financiera, la existencia de patrones de predictibilidad en los rendimientos puede afectar el diseño de estrategias de inversión y la evaluación de oportunidades mediante modelos cuantitativos. En mercados donde las ineficiencias persisten, estrategias basadas en información histórica podrían encontrar oportunidades explotables; en cambio, en mercados más eficientes, dichas oportunidades tenderían a reducirse por la acción de arbitrajistas, algoritmos y participantes más sofisticados. En este sentido, estudiar la eficiencia en criptomonedas permite vincular la teoría financiera tradicional con las nuevas dinámicas observadas en mercados digitales de rápida evolución.

Desde el punto de vista metodológico, la adopción del Adjusted Market Inefficiency Magnitude (AMIM) sobre ventanas móviles permite analizar la eficiencia como un fenómeno dinámico, complementando enfoques estáticos más frecuentes en la literatura previa. En conjunto, el trabajo busca aportar una lectura útil para investigadores, inversores y analistas interesados en la calidad del proceso de formación de precios dentro del ecosistema cripto.

3. OBJETIVOS

El presente trabajo se propone analizar la evolución temporal del grado de eficiencia débil en el mercado de criptomonedas durante el período 2020–2025, considerando comparativamente las diferencias existentes entre activos según su nivel de madurez relativa. En particular, se buscará: (1) evaluar el comportamiento de eficiencia débil en criptomonedas seleccionadas, distinguiendo entre activos consolidados, como Bitcoin y Ethereum, y el conjunto seleccionado de altcoins, con el objetivo de identificar posibles diferencias en los niveles de autocorrelación y predictibilidad de los rendimientos; (2) analizar la evolución temporal de la eficiencia en el mercado cripto mediante

metodologías basadas en ventanas móviles sobre series de precios, a fin de examinar posibles cambios en el comportamiento eficiente de los activos a lo largo del período analizado; y (3) examinar la relación entre variables asociadas al desarrollo y las condiciones del mercado, tales como la capitalización, la volatilidad y el rendimiento acumulado de los activos, se encuentran relacionadas con el grado de eficiencia observado en las criptomonedas analizadas.

4. HIPÓTESIS

El grado de eficiencia débil en el mercado de criptomonedas presenta variaciones a lo largo del tiempo y diferencias según el nivel de madurez relativa de los activos, observándose menores niveles de autocorrelación y predictibilidad en criptomonedas consolidadas, como Bitcoin y Ethereum, en comparación las altcoins seleccionadas de menor desarrollo relativo durante el período 2020–2025.

5. MARCO TEÓRICO

El análisis de la eficiencia en el mercado de criptomonedas se basa en la Hipótesis de Mercados Eficientes de Fama (1970, 1991) y en la Hipótesis de Mercados Adaptativos propuesta por Lo (2004). Mientras la primera sostiene que los precios reflejan toda la información disponible, la segunda plantea que el grado de eficiencia puede variar a lo largo del tiempo en función de la evolución del mercado y del comportamiento de sus participantes. Asimismo, se incorporan conceptos vinculados con autocorrelación, predictibilidad y características estructurales del ecosistema cripto. Finalmente, se revisa evidencia empírica sobre eficiencia en criptomonedas y sobre las diferencias entre activos según su nivel de madurez y desarrollo relativo.

5.1 Hipótesis de mercados eficientes

La Hipótesis de Mercados Eficientes, desarrollada principalmente por Fama (1970), establece que los precios de los activos reflejan rápidamente la información disponible, eliminando la posibilidad de obtener ganancias extraordinarias de manera sistemática. Si bien trabajos posteriores cuestionaron el carácter estático de esta hipótesis, la EMH continúa representando el principal marco teórico de referencia para el estudio de la eficiencia informacional en mercados financieros.

5.1.1 Origen y fundamentos de la EMH

Los antecedentes de la Hipótesis de Mercados Eficientes pueden rastrearse hasta los primeros estudios sobre el comportamiento de los precios financieros. Uno de los aportes pioneros fue el de Louis Bachelier en *Théorie de la Spéculation* (1900), donde sostiene que las variaciones de los precios responden a información imposible de anticipar completamente, dando origen a la noción de *random walk* o paseo aleatorio. Posteriormente, Samuelson (1965) formalizó esta idea al demostrar que, bajo determinadas condiciones, los precios correctamente anticipados deberían fluctuar aleatoriamente, introduciendo el concepto de *fair game*, según el cual no es posible obtener beneficios extraordinarios de manera sistemática utilizando únicamente información ya conocida por el mercado.

La formalización de la Hipótesis de Mercados Eficientes se produce con el trabajo de Fama (1970), quien define un mercado eficiente como aquel "in which prices always fully reflect available information" [en el cual los precios siempre reflejan completamente la información disponible] (Fama, 1970, p. 383). Bajo este enfoque, los precios incorporan rápidamente toda la información disponible, por lo que cualquier oportunidad de arbitraje tiende a desaparecer debido a la competencia entre los participantes del mercado. En consecuencia, las variaciones futuras de los precios dependen principalmente de nueva información, la cual es, por definición, impredecible.

5.1.2 Eficiencia débil, semi-fuerte y fuerte

A partir de los desarrollos de Fama (1970), la Hipótesis de Mercados Eficientes se clasifica según el conjunto de información incorporado en los precios de los activos financieros. Esta clasificación distingue tres formas de eficiencia: débil, semi-fuerte y fuerte. En términos generales, cuanto mayor es el conjunto de información reflejado en los precios, menor es la posibilidad de obtener rendimientos extraordinarios de manera sistemática.

La eficiencia débil sostiene que los precios incorporan toda la información contenida en los precios y rendimientos históricos, por lo que no deberían existir patrones sistemáticos de predictibilidad basados únicamente en información pasada. En consecuencia, gran parte de la evidencia empírica se centra en el análisis de la autocorrelación, la dependencia temporal y el comportamiento *random walk* de los retornos.

La eficiencia semi-fuerte plantea que los precios reflejan toda la información pública

disponible, mientras que la eficiencia fuerte incorpora además la información privada. No obstante, esta última ha sido ampliamente cuestionada debido a la existencia de asimetrías informativas y acceso diferencial a la información.

Tabla 5.1. Resume las principales características de las tres formas de eficiencia propuestas por Fama (1970).

Forma de eficiencia	Información incorporada en precios	Implicancia principal	Enfoques de análisis frecuentes
Débil	Precios y rendimientos históricos	El análisis técnico no debería generar retornos extraordinarios sistemáticos	Random walk, autocorrelación, predictibilidad de retornos
Semi-fuerte	Toda la información pública disponible	El análisis fundamental no debería permitir ventajas persistentes	Estudios de eventos y velocidad de ajuste de precios
Fuerte	Toda la información pública y privada	Ningún inversor podría obtener ventajas sistemáticas incluso con información privilegiada	Estudios sobre insider trading y acceso diferencial a información

Dado que el presente trabajo analiza la relación entre autocorrelación, predictibilidad y eficiencia en el mercado de criptomonedas, el análisis se centra en la forma débil de eficiencia, evaluando si los rendimientos históricos contienen información útil para anticipar la evolución futura de los precios.

5.1.3 Random walk y predictibilidad

La relación entre eficiencia de mercado y comportamiento aleatorio de los precios constituye uno de los fundamentos de la teoría financiera moderna. Bajo la Hipótesis de Mercados Eficientes, los precios incorporan rápidamente la información disponible, por lo que las variaciones futuras dependen únicamente de nueva información, la cual resulta inherentemente impredecible. En este sentido, Samuelson (1965) sostiene que los precios correctamente anticipados deberían fluctuar aleatoriamente (*properly anticipated prices fluctuate randomly*), estableciendo uno de los principales fundamentos teóricos de la relación entre eficiencia y predictibilidad.

A partir de esta idea surge el concepto de *random walk* o paseo aleatorio, utilizado para describir procesos en los que las variaciones futuras de una variable no dependen sistemáticamente de sus valores pasados. Aplicado a los mercados financieros, este enfoque implica que los rendimientos no deberían presentar patrones persistentes de predictibilidad. Formalmente, esta relación puede expresarse como:

$$E(r_{t+1} | \Omega_t) = 0$$

donde:

r_{t+1} : rendimiento futuro del activo

Ω_t : conjunto de información disponible en el período t

Una implicancia de este enfoque es la ausencia de dependencia serial significativa entre los rendimientos, condición habitualmente evaluada mediante pruebas de autocorrelación:

$$Corr(r_t, r_{t-k}) = 0$$

Esta expresión indica que los rendimientos pasados no deberían contener información útil para predecir rendimientos futuros de manera sistemática.

No obstante, la literatura posterior señala que la relación entre eficiencia y *random walk* no es completamente equivalente. Lo (2004) y MacKinlay (1988) muestran que la existencia de cierta dependencia serial no implica necesariamente ineficiencia informacional, ya que pueden observarse patrones estadísticos compatibles con distintos grados de eficiencia. Esta distinción resulta particularmente relevante para la presente investigación, ya que permite interpretar la autocorrelación como un indicador del grado de eficiencia, más que como una prueba absoluta de eficiencia o ineficiencia financiera.

5.1.4 Autocorrelación y eficiencia

La autocorrelación constituye una de las herramientas más utilizadas para evaluar la existencia de dependencia temporal en los rendimientos de los activos financieros. En términos generales, mide el grado de relación entre los retornos observados en distintos períodos, permitiendo analizar si la información contenida en los rendimientos pasados contribuye a explicar o anticipar el comportamiento futuro de los precios. Bajo la hipótesis

de eficiencia débil, no deberían existir patrones persistentes de dependencia temporal, dado que la información histórica ya se encontraría incorporada en los precios actuales. En este contexto, la presencia de autocorrelación significativa suele interpretarse como una señal de predictibilidad y, por lo tanto, como evidencia potencialmente incompatible con un comportamiento estrictamente aleatorio de los retornos. En particular, una autocorrelación positiva puede reflejar persistencia en los movimientos de precios, mientras que una autocorrelación negativa suele asociarse con procesos de reversión a la media. Por este motivo, las pruebas de autocorrelación constituyen una de las herramientas más utilizadas para evaluar el grado de eficiencia informacional en los mercados financieros.

5.2 Hipótesis de mercados adaptativos

5.2.1 Críticas a la visión estática de eficiencia

La evidencia empírica acumulada comenzó a cuestionar la visión estática de la Hipótesis de Mercados Eficientes al identificar fenómenos difícilmente compatibles con un nivel constante de eficiencia informacional. La presencia de anomalías, episodios especulativos y patrones temporales de predictibilidad sugirió que la eficiencia puede variar a lo largo del tiempo y entre distintos mercados.

Entre las principales anomalías documentadas se destacan el *momentum*, la reversión a la media, los excesos de volatilidad y determinadas anomalías de calendario, las cuales indican que los precios no siempre se ajustan de manera instantánea y homogénea a la información disponible.

5.2.2 Adaptive Market Hypothesis de Andrew Lo

Las limitaciones observadas en la evidencia empírica de la Hipótesis de Mercados Eficientes dieron lugar al desarrollo de la Hipótesis de Mercados Adaptativos (Adaptive Markets Hypothesis, AMH) propuesta por Lo (2004), sostiene que la eficiencia de mercado no constituye una condición fija, sino un fenómeno dinámico que evoluciona en función de la capacidad de adaptación de los participantes frente a cambios en el entorno económico y competitivo. Desde esta perspectiva, los mercados financieros se interpretan como sistemas adaptativos en los que los agentes modifican continuamente sus estrategias de inversión y arbitraje en respuesta a factores como la innovación financiera, la disponibilidad de información, la regulación, la liquidez y el desarrollo tecnológico.

En este marco, el grado de eficiencia depende de las características estructurales y competitivas de cada mercado, por lo que puede variar tanto entre activos como a lo largo del tiempo. De manera conceptual, esta relación puede representarse como:

$$Efficiency = f(Market Structure, Competition, Liquidity, Technology)$$

Fuente: elaboración propia a partir de Lo (2004).

Bajo esta lógica, los mercados pueden atravesar períodos relativamente más eficientes y otros donde aparecen temporalmente comportamientos asociados a dependencia serial o ineficiencias transitorias.

La Hipótesis de Mercados Adaptativos no busca reemplazar completamente a la Hipótesis de Mercados Eficientes, sino reinterpretarla dentro de un marco más flexible y contextual. En esta línea, Lo (2005) sostiene que los principios de eficiencia pueden coexistir con determinados comportamientos conductuales y episodios temporales de predictibilidad, especialmente en mercados sujetos a cambios frecuentes en liquidez, competencia o estructura de negociación

5.2.3 Eficiencia dinámica y adaptación del mercado.

La AMH resulta especialmente útil para analizar mercados caracterizados por cambios estructurales frecuentes, heterogeneidad entre participantes y rápida evolución de las condiciones de negociación. Bajo este enfoque, el grado de eficiencia puede modificarse a lo largo del tiempo como consecuencia de variaciones en la liquidez, el volumen negociado, la competencia, el desarrollo tecnológico y la incorporación de nuevos participantes.

En mercados emergentes o en proceso de consolidación, estos cambios suelen reflejarse en variaciones de la predictibilidad, la autocorrelación y el comportamiento de los retornos. Si bien el aumento de la profundidad del mercado y de los mecanismos de arbitraje tiende a reducir las ineficiencias, episodios de elevada volatilidad o shocks externos pueden generar temporalmente nuevos patrones de dependencia.

Esta perspectiva resulta particularmente pertinente para el mercado de criptomonedas, cuyo ecosistema experimentó una profunda transformación durante el período 2020–2025 como consecuencia del crecimiento de la participación institucional, el aumento de la liquidez, el desarrollo de instrumentos derivados y la expansión de las plataformas de negociación. Asimismo, persisten diferencias relevantes entre criptomonedas consolidadas y activos de menor capitalización o desarrollo relativo.

En este marco, la presente investigación adopta una perspectiva de eficiencia dinámica

para analizar la evolución temporal de la eficiencia débil en el mercado de criptomonedas durante el período 2020–2025, interpretando la autocorrelación y la predictibilidad de los retornos como indicadores que pueden variar según las características de cada activo y las condiciones del mercado.

5.3 Mercado de criptomonedas

5.3.1 Características del mercado cripto

El mercado de criptomonedas presenta características que lo diferencian de los mercados financieros tradicionales. Entre las principales se destacan su elevada volatilidad, la operatoria continua, la descentralización y la creciente automatización de las transacciones, factores que influyen sobre la formación de precios y el comportamiento de los participantes.

Una de las características más relevantes es la elevada volatilidad. Criptomonedas como Bitcoin y Ethereum han registrado históricamente fluctuaciones de precios superiores a las observadas en los mercados tradicionales, reflejando una alta sensibilidad frente a cambios regulatorios, innovaciones tecnológicas, expectativas de adopción y comportamiento especulativo. En esta línea, Cheah y Fry (2015) sostienen que los precios de Bitcoin presentaron un importante componente especulativo y patrones compatibles con la formación de burbujas financieras.

Otra característica distintiva es la operatoria continua durante las veinticuatro horas del día y los siete días de la semana. A diferencia de las bolsas tradicionales, las criptomonedas se negocian ininterrumpidamente mediante plataformas digitales distribuidas globalmente, favoreciendo una incorporación constante de nueva información en los precios.

Asimismo, el mercado se caracteriza por una estructura descentralizada basada en tecnología *blockchain*, donde las transacciones se validan sin la intervención de una autoridad central. Según Budish (2024), estos sistemas dependen de mecanismos de consenso e incentivos económicos destinados a garantizar la seguridad y confiabilidad de la red.

Finalmente, la creciente automatización mediante algoritmos de *trading*, bots de arbitraje y plataformas integradas mediante APIs incrementó la velocidad de negociación y la competencia entre participantes, especialmente en los activos con mayor liquidez y volumen operado

5.3.2 Bitcoin, Ethereum y altcoins

El crecimiento del mercado de criptomonedas dio lugar a diferencias significativas entre los distintos activos que integran el ecosistema. Bitcoin y Ethereum, las dos criptomonedas de mayor capitalización, exhiben mayores niveles de liquidez, profundidad de mercado y adopción que la mayoría de las altcoins, reflejando distintos grados de madurez relativa.

Bitcoin constituye el activo más consolidado del mercado, tanto por su capitalización como por su volumen negociado y participación institucional. Desde su creación en 2009, se consolidó como la principal referencia del ecosistema cripto, favoreciendo el desarrollo de productos financieros, custodios especializados y una mayor integración con los mercados tradicionales.

Ethereum presenta características diferenciales al combinar su función como activo digital con una infraestructura basada en contratos inteligentes, lo que impulsó el desarrollo de aplicaciones descentralizadas (*dApps*), finanzas descentralizadas (*DeFi*) y otros proyectos basados en tecnología *blockchain*. Como resultado, alcanzó elevados niveles de liquidez, capitalización y adopción dentro del mercado.

Por el contrario, las altcoins —criptomonedas distintas de Bitcoin y Ethereum— suelen presentar menores niveles de liquidez, capitalización y profundidad de mercado, además de una mayor exposición a episodios especulativos y volatilidad. Estas diferencias en el grado de desarrollo constituyen un aspecto central para el análisis de eficiencia realizado en la presente investigación.

5.3.3 Evolución del mercado cripto entre 2020–2025

El período comprendido entre 2020 y 2025 estuvo marcado por una profunda transformación del mercado de criptomonedas, caracterizada por un crecimiento sostenido de la capitalización, el volumen negociado y la participación institucional, junto con una mayor integración con el sistema financiero tradicional.

Durante 2020 y 2021, el contexto de elevada liquidez global favoreció un fuerte incremento en la demanda de activos digitales y el desarrollo de plataformas de negociación, mercados derivados y aplicaciones basadas en tecnología *blockchain*. Posteriormente, en 2022, el mercado atravesó un proceso de corrección asociado a episodios de elevada volatilidad y a las dificultades financieras de distintos participantes del ecosistema.

A partir de 2023, y especialmente durante 2024, se consolidó un proceso de mayor institucionalización impulsado por la aprobación de ETFs spot sobre Bitcoin en Estados Unidos y el crecimiento de mercados regulados, factores que contribuyeron a incrementar la liquidez y la profundidad de negociación. Durante 2025, estas tendencias continuaron consolidándose, con una mayor participación institucional y un mercado relativamente más desarrollado que en los primeros años del período analizado.

En conjunto, estos cambios permiten interpretar al mercado de criptomonedas como un ecosistema en proceso de maduración. Desde la perspectiva de la Hipótesis de Mercados Adaptativos, esta evolución constituye un contexto adecuado para analizar posibles variaciones temporales en el grado de eficiencia informacional.

5.4 Evidencia empírica sobre eficiencia en criptomonedas

La literatura empírica sobre eficiencia en criptomonedas experimentó un importante crecimiento a partir de la consolidación de Bitcoin como activo financiero y de la expansión del ecosistema de activos digitales. La mayor parte de las investigaciones se concentró en evaluar si los precios siguen un comportamiento compatible con la hipótesis de eficiencia débil mediante pruebas de *random walk*, autocorrelación, memoria larga, *variance ratio tests* y modelos de eficiencia dinámica. En términos generales, la evidencia no resulta concluyente. Mientras algunos estudios encuentran importantes ineficiencias, otros identifican una evolución hacia mayores niveles de eficiencia a medida que el mercado incrementa su liquidez, profundidad y participación institucional. Asimismo, una línea reciente de investigación sostiene que la eficiencia difiere entre criptomonedas según su grado de desarrollo y las características propias de cada activo.

5.4.1 Estudios que encuentran ineficiencia

Una parte importante de la literatura inicial encuentra evidencia contraria a la hipótesis de eficiencia débil, especialmente durante las primeras etapas de desarrollo del mercado de Bitcoin. En términos generales, estos trabajos identifican autocorrelación, dependencia temporal y patrones de predictibilidad que sugieren que la información no se incorporaba de manera inmediata y completa a los precios.

En este contexto, Urquhart (2016) presenta una de las primeras evidencias de ineficiencia en Bitcoin al rechazar la hipótesis de *random walk* para gran parte del período analizado. En una línea similar, Bariviera (2017) demuestra que el grado de

eficiencia no permanece constante, sino que varía a lo largo del tiempo, observándose mayores niveles de dependencia temporal durante las primeras etapas del mercado.

Desde una perspectiva complementaria, Miller (2019) atribuye parte de estas ineficiencias a características estructurales del ecosistema de criptomonedas, como la fragmentación entre *exchanges*, las limitaciones al arbitraje y determinados problemas operativos que dificultaban una rápida convergencia de precios. Asimismo, Cheah y Fry (2015) sostienen que el fuerte componente especulativo presente en los primeros años de Bitcoin favoreció la formación de burbujas financieras y una elevada volatilidad, factores que podrían contribuir a explicar las ineficiencias detectadas por la literatura.

En conjunto, estos estudios coinciden en que el mercado de criptomonedas presentó, durante sus primeras etapas de desarrollo, condiciones incompatibles con un mercado plenamente eficiente.

5.4.2 Estudios que encuentran mejoras en la eficiencia

A medida que el mercado de criptomonedas aumentó su liquidez, capitalización y profundidad, comenzaron a surgir investigaciones que identifican una evolución hacia mayores niveles de eficiencia. Esta corriente sostiene que la incorporación de nuevos participantes, el desarrollo de la infraestructura de negociación y la creciente institucionalización del mercado favorecieron una incorporación más rápida de la información en los precios.

En esta línea, Wei (2018) encuentra que las criptomonedas con mayores niveles de liquidez presentan comportamientos más cercanos a la eficiencia débil, mientras que los activos menos líquidos exhiben una mayor persistencia de dependencia temporal. Por su parte, Sensoy (2019) observa que Bitcoin presenta un comportamiento más eficiente durante períodos de mayor actividad y liquidez, resultado que atribuye a la creciente sofisticación de los participantes y al desarrollo del mercado.

Desde una perspectiva dinámica, Noda (2020) analiza la evolución temporal de la eficiencia de Bitcoin y Ethereum bajo el marco de la Hipótesis de Mercados Adaptativos, concluyendo que la eficiencia varía según las condiciones del mercado y tiende a incrementarse a medida que el ecosistema madura.

5.4.3 Diferencias en la eficiencia entre criptomonedas

Diversos estudios han analizado si la eficiencia informacional difiere entre las distintas

criptomonedas, encontrando que variables como la liquidez, la capitalización de mercado, la profundidad de negociación y el grado de desarrollo pueden generar distintos niveles de eficiencia entre los activos digitales.

Hu, Valera y Oxley (2019) encuentran evidencia de diferencias significativas en la eficiencia de las principales criptomonedas según su tamaño y profundidad de mercado. De manera complementaria, Tran y Leirvik (2019) desarrollan el indicador *Adaptive Market Inefficiency Measure* (AMIM) y muestran que el grado de ineficiencia difiere entre activos y evoluciona a lo largo del tiempo. En la misma línea, Noda (2020) identifica diferencias en la evolución de la eficiencia entre Bitcoin y Ethereum, asociadas al distinto grado de madurez alcanzado por cada mercado.

En conjunto, la evidencia empírica sugiere que el mercado de criptomonedas no constituye un conjunto homogéneo desde el punto de vista de la eficiencia informacional. Estas diferencias justifican la realización de estudios comparativos entre activos con distintos niveles de desarrollo, como el propuesto en la presente investigación, que analiza la evolución temporal de Bitcoin, Ethereum y un conjunto de altcoins durante el período 2020–2025 mediante el indicador AMIM.

6. METODOLOGÍA

6.1 Datos y muestra

La presente investigación utiliza información diaria correspondiente al mercado de criptomonedas para el período comprendido entre el 1 de enero de 2020 y el 15 de octubre de 2025. La elección de una frecuencia diaria responde a la necesidad de capturar la elevada dinámica y volatilidad que caracterizan a estos activos, permitiendo analizar con mayor precisión la evolución de su eficiencia informacional. Si bien los cálculos requieren observaciones previas para la construcción de las primeras ventanas de estimación, el período considerado para el análisis y la presentación de resultados se encuentra comprendido entre las fechas mencionadas.

La muestra está integrada por nueve criptomonedas: Bitcoin (BTC), Ethereum (ETH), Litecoin (LTC), Monero (XMR), Stellar (XLM), TRON (TRX), EOS (EOS), NEO (NEO) y Ethereum Classic (ETC). La selección responde al objetivo central de la investigación, que consiste en comparar el comportamiento de criptomonedas consolidadas con el de un conjunto de criptomonedas alternativas. Bitcoin y Ethereum fueron seleccionadas como representantes de los activos de mayor madurez dentro del mercado, debido a su elevada capitalización, liquidez y grado de adopción. Por su parte, las siete altcoins

fueron elegidas considerando la disponibilidad de información histórica suficiente y su permanencia en el mercado durante el período de estudio, garantizando así la comparabilidad entre los distintos activos.

El detalle de las criptomonedas incluidas en la muestra se presenta en el Anexo 1.

La información de precios diarios fue obtenida a partir de una base de datos pública disponible en Kaggle, recomendada por el director de la investigación y utilizada como fuente principal para la construcción de las series de precios. Complementariamente, la información correspondiente a capitalización de mercado y volumen negociado fue obtenida de CoinGecko, una de las principales plataformas de seguimiento del mercado de criptoactivos. A partir de estas fuentes se construyó la base de datos empleada en el análisis empírico, integrando para cada criptomoneda las series de precios, volumen de negociación y capitalización de mercado necesarias para el desarrollo de la investigación.

6.2 Construcción de las variables

6.2.1 Rendimientos logarítmicos

A partir de las series de precios de cierre diarios de cada criptomoneda se construyeron los rendimientos logarítmicos, los cuales constituyen la variable base para la estimación del indicador de eficiencia utilizado en esta investigación. La utilización de rendimientos, en lugar de precios, responde a la necesidad de trabajar con series más apropiadas para el análisis econométrico, reduciendo problemas asociados a tendencias, diferencias de escala entre activos y procesos no estacionarios. Los rendimientos logarítmicos diarios fueron calculados mediante la siguiente expresión:

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

donde el rendimiento logarítmico se obtiene como el logaritmo natural del cociente entre el precio de cierre del período actual y el precio de cierre del período inmediatamente anterior.

La utilización de rendimientos logarítmicos presenta diversas ventajas respecto de los rendimientos simples. En particular, permiten una interpretación aditiva en el tiempo, facilitan la comparación entre activos con distintos niveles de precios y constituyen una práctica ampliamente aceptada en la literatura financiera. Las series obtenidas

constituyen el insumo principal para la estimación de los modelos autorregresivos y el cálculo del indicador Adaptive Market Inefficiency Measure (AMIM), desarrollado en la siguiente sección.

6.2.2 Construcción de las variables explicativas

Además del indicador de eficiencia, la investigación incorpora un conjunto de variables explicativas con el objetivo de analizar los factores asociados al comportamiento de la eficiencia informacional de las criptomonedas.

La primera variable considerada es la volatilidad, calculada como el desvío estándar móvil de los rendimientos logarítmicos utilizando una ventana de 365 días. Esta medida refleja el nivel de riesgo e incertidumbre asociado a cada activo, permitiendo evaluar si períodos de mayor volatilidad se relacionan con cambios en el grado de eficiencia del mercado.

Como aproximación al tamaño y nivel de desarrollo de cada criptomoneda, se incorporó la capitalización de mercado (*Market Capitalization*), definida como el valor de mercado del activo obtenido a partir del producto entre su precio y la cantidad de unidades en circulación. Con el propósito de reducir la influencia de fluctuaciones de corto plazo, se utilizó el promedio móvil de 365 días de esta variable. Asimismo, en el modelo econométrico se empleó su transformación mediante logaritmo natural, con el fin de reducir la asimetría de la distribución y facilitar la interpretación de los resultados.

También se calculó el volumen negociado, medido como el monto diario transaccionado para cada criptomoneda. Al igual que en el caso de la capitalización de mercado, se construyó un promedio móvil de 365 días para suavizar las variaciones diarias y representar el nivel de actividad del mercado. Si bien esta variable fue considerada durante el análisis exploratorio y en las primeras especificaciones econométricas, no fue incluida en el modelo final debido a su elevada correlación con la capitalización de mercado.

Finalmente, se incorporó el retorno acumulado de 365 días, calculado como la variación porcentual del precio respecto del mismo día del año anterior. Esta variable permite capturar el desempeño reciente de cada activo y evaluar si la evolución de los precios se encuentra asociada con cambios en el grado de eficiencia informacional.

La definición operativa y la fuente de cada variable se presentan en el Anexo 2.

6.3 Medición de la eficiencia informacional mediante el AMIM

La evaluación de la eficiencia informacional constituye uno de los principales objetivos de la presente investigación. En la literatura financiera se han desarrollado diversos enfoques para analizar la eficiencia de los mercados, entre los que se destacan las pruebas de autocorrelación, los tests de razón de varianza (Variance Ratio Test), el exponente de Hurst y distintas medidas basadas en teoría de la información y entropía. Si bien estas metodologías permiten detectar desviaciones respecto de la hipótesis de eficiencia, muchas de ellas se limitan a contrastar la existencia o ausencia de eficiencia en un momento determinado, sin ofrecer una medida continua que permita analizar su evolución temporal.

Con el propósito de superar esta limitación, la presente investigación adopta el Adjusted Market Inefficiency Magnitude (AMIM), desarrollado por Tran y Leirvik (2019). Este indicador se fundamenta en la Hipótesis de Mercados Eficientes en su forma débil y cuantifica el grado de dependencia temporal presente en los rendimientos mediante modelos autorregresivos. A diferencia de los enfoques tradicionales, el AMIM permite medir la magnitud de la ineficiencia informacional y evaluar su evolución a lo largo del tiempo, facilitando además la comparación entre distintos activos financieros.

En las subsecciones siguientes se presentan los fundamentos teóricos del indicador, el modelo autorregresivo sobre el cual se construye y el procedimiento metodológico empleado para su estimación en las criptomonedas analizadas.

6.3.1 Hipótesis de eficiencia débil y autocorrelación

Tal como se desarrolló en el marco teórico (sección 2.1), la eficiencia débil implica la ausencia de dependencia temporal entre los rendimientos. Desde el punto de vista estadístico, una de las principales implicancias de la eficiencia débil es la ausencia de dependencia temporal entre los rendimientos. En otras palabras, los rendimientos observados en un período no deberían encontrarse sistemáticamente relacionados con los rendimientos de períodos anteriores. La existencia de autocorrelación en la serie implica que la información pasada conserva capacidad explicativa sobre los rendimientos futuros, constituyendo una posible evidencia de predictibilidad y, por lo tanto, de ineficiencia informacional.

La autocorrelación se define como el grado de relación existente entre una variable y sus propios valores rezagados en el tiempo. En mercados plenamente eficientes, dichas

correlaciones deberían ser cercanas a cero, reflejando que los precios incorporan rápidamente toda la información disponible. Por el contrario, valores significativamente distintos de cero indican la presencia de patrones de dependencia temporal que pueden ser aprovechados para anticipar parcialmente el comportamiento futuro de los rendimientos.

En consecuencia, el análisis de la autocorrelación constituye la base conceptual de numerosos indicadores de eficiencia de mercado. Entre ellos, el Adjusted Market Inefficiency Magnitude (AMIM) utiliza la estructura de dependencia temporal de los rendimientos para cuantificar el grado de ineficiencia informacional y analizar su evolución a lo largo del tiempo.

6.3.2 Modelos autorregresivos y dependencia temporal

Con el objetivo de cuantificar la dependencia temporal presente en los rendimientos, la literatura financiera recurre frecuentemente a los modelos autorregresivos (Autoregressive Models, AR). Estos modelos permiten evaluar en qué medida los rendimientos observados en un determinado período pueden explicarse a partir de sus propios valores pasados, constituyendo una herramienta ampliamente utilizada para analizar la existencia de predictibilidad en series temporales financieras.

En términos generales, un proceso autorregresivo de orden (q), denotado como AR(q), puede expresarse de la siguiente manera:

$$r_t = \alpha + \sum_{i=1}^q \beta_i r_{t-i} + \varepsilon_t$$

donde r_t representa el rendimiento observado en el período t ; α corresponde al término constante del modelo; β_i representa el coeficiente autorregresivo asociado al rezago i ; q indica el número de rezagos considerados en la estimación; r_{t-i} representa el rendimiento observado i períodos atrás; y ε_t corresponde al término de error aleatorio.

En este modelo, los coeficientes autorregresivos β_i cuantifican el grado de dependencia temporal de los rendimientos. Cuanto mayor sea su magnitud, mayor será la evidencia de predictibilidad y, en consecuencia, de ineficiencia informacional.

La interpretación de los coeficientes autorregresivos resulta fundamental para el análisis de la eficiencia informacional. En un mercado consistente con la hipótesis de eficiencia débil, los rendimientos pasados no deberían aportar información útil para explicar los

rendimientos futuros. En consecuencia, los coeficientes autorregresivos deberían ser estadísticamente cercanos a cero, reflejando la ausencia de dependencia temporal entre las observaciones.

Por el contrario, coeficientes significativamente distintos de cero indican que los rendimientos pasados conservan capacidad explicativa sobre los rendimientos presentes, evidenciando la existencia de patrones de predictibilidad incompatibles con un mercado plenamente eficiente. En este sentido, la magnitud de los coeficientes autorregresivos constituye una aproximación al grado de dependencia temporal existente en la serie de rendimientos.

6.3.3 Construcción del indicador AMIM

A partir de los modelos autorregresivos estimados, Tran y Leirvik (2019) desarrollan el Adjusted Market Inefficiency Magnitude (AMIM), un indicador diseñado para cuantificar el grado de ineficiencia informacional de un mercado. La idea central es que los coeficientes autorregresivos contienen información sobre la dependencia temporal de los rendimientos: cuanto mayor sea su magnitud, mayor será la capacidad de los rendimientos pasados para explicar los rendimientos presentes y, por lo tanto, mayor será el nivel de ineficiencia.

Los coeficientes autorregresivos estimados no pueden compararse directamente, ya que presentan diferentes niveles de variabilidad y pueden encontrarse correlacionados entre sí. Con el fin de obtener una medida homogénea de la dependencia temporal, Tran y Leirvik (2019) proponen estandarizar el vector de coeficientes autorregresivos utilizando la matriz de covarianzas estimada y una descomposición de Cholesky. Este procedimiento elimina el efecto de las diferencias de escala y de la correlación existente entre los coeficientes, permitiendo que cada uno de ellos refleje de manera comparable la magnitud de la dependencia temporal presente en la serie de rendimientos.

Una vez obtenidos los coeficientes autorregresivos estandarizados, se construye el Market Inefficiency Magnitude (MIM), definido como la suma de los valores absolutos de dichos coeficientes, normalizada mediante una transformación que restringe el indicador al intervalo [0,1]. Formalmente, el MIM se expresa de la siguiente manera:

$$MIM_t = \frac{\sum_{j=1}^q |\beta_{j,t}^{std}|}{1 + \sum_{j=1}^q |\beta_{j,t}^{std}|}$$

donde MIM_t representa el indicador de magnitud de la ineficiencia de mercado en el período t ; $\beta_{j,t}^{std}$ corresponde al coeficiente autorregresivo estandarizado asociado al rezago j ; y q indica el número de rezagos considerados en el modelo autorregresivo.

La utilización del valor absoluto permite medir la magnitud de la dependencia temporal independientemente de su dirección, evitando que coeficientes positivos y negativos se compensen entre sí. Asimismo, la normalización garantiza que el indicador tome valores comprendidos entre cero y uno, facilitando su interpretación y comparación entre distintos activos y períodos.

Si bien el MIM constituye una medida de la magnitud de la dependencia temporal presente en los rendimientos, su interpretación requiere un valor de referencia que permita determinar si el nivel observado de ineficiencia resulta estadísticamente relevante. Esto se debe a que, aun bajo la hipótesis de un mercado perfectamente eficiente, el MIM puede adoptar valores positivos como consecuencia de la variabilidad muestral y del procedimiento de estimación. En otras palabras, un determinado valor del MIM no implica necesariamente la existencia de ineficiencia, sino que debe compararse con un umbral crítico que represente el comportamiento esperado del indicador bajo condiciones de eficiencia.

Con el objetivo de interpretar adecuadamente el MIM, Tran y Leirvik (2019) introducen el Reference Critical Interval (RCI), un valor crítico que actúa como referencia para distinguir entre valores del MIM compatibles con la hipótesis de eficiencia de mercado y aquellos que constituyen evidencia de dependencia temporal significativa. La incorporación de este umbral resulta necesaria porque, incluso en un mercado perfectamente eficiente, el MIM puede adoptar valores positivos debido a la variabilidad inherente al proceso de estimación. En consecuencia, la existencia de un MIM distinto de cero no constituye, por sí sola, evidencia suficiente de ineficiencia, sino que debe compararse con un valor crítico previamente establecido.

Los valores del RCI fueron obtenidos por Tran y Leirvik (2019) mediante simulaciones de Monte Carlo bajo la hipótesis nula de eficiencia de mercado. Para cada orden autorregresivo q los autores generan un gran número de vectores de coeficientes estandarizados independientes con distribución normal estándar y calculan el correspondiente valor del MIM en cada simulación. A partir de la distribución empírica obtenida, determinan el percentil 95%, el cual se adopta como valor crítico de referencia RCI_q . De este modo, cada orden autorregresivo posee un umbral específico que representa el percentil 95 de la distribución del MIM bajo la hipótesis de eficiencia de

mercado. Valores del MIM superiores a dicho umbral constituyen evidencia de una dependencia temporal mayor a la esperada por azar.

Los valores críticos del Reference Critical Interval (RCI) utilizados en la presente investigación se presentan en la Tabla 6.1. Dichos valores corresponden a los reportados por Tran y Leirvik (2019) para cada orden autorregresivo considerado.

[TABLA 6.1]. Valores críticos del Reference Critical Interval (RCI) según el orden del modelo autorregresivo

Orden AR (q)	RCI
1	0.6619
2	0.7605
3	0.8111
4	0.8424
5	0.8643
6	0.8806
7	0.8932
8	0.9033
9	0.9116
10	0.9185

Fuente: Elaboración propia a partir de Tran y Leirvik (2019).

En función de lo anterior, Tran y Leirvik (2019) proponen el Adjusted Market Inefficiency Magnitude (AMIM), el cual ajusta el valor observado del MIM utilizando el correspondiente valor crítico RCI_q . Mediante esta transformación, el indicador expresa el grado de ineficiencia observado en relación con el umbral esperado bajo la hipótesis de eficiencia de mercado, permitiendo distinguir entre desviaciones atribuibles al azar y aquellas que constituyen evidencia de dependencia temporal significativa. Formalmente, el AMIM se define de la siguiente manera:

$$AMIM_t = \frac{MIM_t - RCI_q}{1 - RCI_q}$$

donde $AMIM_t$ representa el indicador ajustado de ineficiencia de mercado en el período

t ; MIM_t corresponde al Market Inefficiency Magnitude calculado para dicho período; y RCI_q representa el valor crítico asociado al orden autorregresivo q .

La interpretación del AMIM resulta directa. Cuando el valor del indicador es positivo, el MIM observado supera el correspondiente valor crítico RCI_q , indicando que la dependencia temporal presente en los rendimientos es mayor que la esperada bajo la hipótesis de eficiencia de mercado. En consecuencia, existe evidencia de ineficiencia informacional. Por el contrario, valores negativos del AMIM indican que el MIM permanece por debajo del umbral crítico, por lo que la dependencia temporal observada puede atribuirse al azar y resulta compatible con un mercado eficiente. Asimismo, cuanto mayor sea el valor positivo del AMIM, mayor será el grado de ineficiencia informacional observado.

En comparación con otros enfoques utilizados para evaluar la eficiencia de mercado, el AMIM presenta la ventaja de proporcionar una medida continua del grado de ineficiencia, permitiendo comparar distintos activos y analizar su evolución temporal.

6.3.4 Implementación empírica del AMIM

La estimación del indicador Adjusted Market Inefficiency Magnitude (AMIM) se realizó para cada una de las criptomonedas incluidas en la muestra, siguiendo la metodología propuesta por Tran y Leirvik (2019). Con el propósito de analizar la evolución temporal de la eficiencia informacional, el indicador fue calculado de manera dinámica mediante un procedimiento de ventanas móviles, permitiendo obtener una medida continua del grado de ineficiencia para cada activo a lo largo del período analizado.

Para cada criptomoneda se empleó una ventana móvil de 365 observaciones diarias. En cada fecha de la muestra, el indicador se estimó utilizando una ventana compuesta por los 365 rendimientos diarios más recientes para estimar el modelo autorregresivo y calcular el indicador AMIM. La elección de una ventana anual permite disponer de un número suficiente de observaciones para obtener estimaciones robustas, manteniendo al mismo tiempo la capacidad de capturar posibles cambios en la eficiencia informacional a lo largo del tiempo. Una vez calculado el indicador para una determinada ventana, esta se desplaza un día hacia adelante y el procedimiento se repite sucesivamente hasta cubrir todo el período de estudio.

Dentro de cada ventana móvil se estimaron modelos autorregresivos de distinto orden, considerando especificaciones desde AR(1) hasta AR(10). Con el objetivo de seleccionar el modelo que mejor representara la estructura de dependencia temporal de

los rendimientos en cada ventana, se utilizó el Criterio de Información de Akaike (Akaike Information Criterion, AIC). Este criterio permite comparar modelos con diferente número de parámetros, penalizando aquellos de mayor complejidad y favoreciendo el equilibrio entre capacidad explicativa y parsimonia.

$$AIC = 2k - 2 \ln(\hat{L})$$

donde AIC representa el Criterio de Información de Akaike; k corresponde al número de parámetros estimados en el modelo; y $\hat{L}$ representa el valor máximo de la función de verosimilitud del modelo. El término $2k$ penaliza los modelos con un mayor número de parámetros, mientras que $-2 \ln(\hat{L})$ favorece aquellos que presentan un mejor ajuste a los datos.

En consecuencia, para cada ventana móvil se calculó el AIC para las especificaciones AR(1) a AR(10), seleccionando el orden autorregresivo q correspondiente al menor valor del criterio. Dicho modelo fue posteriormente utilizado para el cálculo del MIM y, posteriormente, del AMIM, siguiendo el procedimiento descrito en la sección anterior.

Una vez seleccionado el modelo autorregresivo óptimo, se obtuvieron los coeficientes autorregresivos estimados y su correspondiente matriz de covarianzas. A partir de esta información, los coeficientes fueron estandarizados mediante la descomposición de Cholesky y se procedió al cálculo del Market Inefficiency Magnitude (MIM), siguiendo la metodología propuesta por Tran y Leirvik (2019).

Posteriormente, el MIM fue ajustado utilizando el valor crítico correspondiente al orden autorregresivo seleccionado RCI_q , obteniéndose el indicador Adjusted Market Inefficiency Magnitude (AMIM). Finalmente, el procedimiento se repitió de manera sucesiva al desplazar la ventana una observación por vez, generando una serie temporal del AMIM para cada una de las criptomonedas analizadas.

El procedimiento de construcción del indicador, junto con las funciones implementadas en Python para la selección del orden autorregresivo, el cálculo del AMIM y la estimación mediante ventanas móviles, se presenta en el Anexo 3.

6.4 Modelo econométrico

Con el objetivo de analizar los factores asociados al grado de eficiencia informacional de las criptomonedas, se estimó un modelo econométrico de datos de panel utilizando como variable dependiente el indicador Adjusted Market Inefficiency Magnitude (AMIM). La

utilización de esta metodología permite combinar la dimensión temporal con la dimensión transversal de la muestra, aprovechando simultáneamente la información correspondiente a las distintas criptomonedas y a los diferentes períodos de observación. En comparación con modelos estimados individualmente para cada activo o exclusivamente con series de tiempo, los modelos de panel ofrecen una mayor cantidad de observaciones, incrementan la eficiencia de las estimaciones y permiten controlar la heterogeneidad no observable entre las unidades analizadas.

6.4.1 Especificación del modelo de datos de panel

El análisis econométrico se realizó mediante un modelo de datos de panel, utilizando como variable dependiente el indicador Adjusted Market Inefficiency Magnitude (AMIM). La estructura de panel combina observaciones correspondientes a distintas criptomonedas a lo largo del tiempo, permitiendo analizar simultáneamente la variación temporal del indicador de eficiencia y las diferencias existentes entre los distintos activos considerados en la muestra.

La especificación inicial del modelo consideró como variables explicativas la volatilidad anual de los rendimientos, la capitalización de mercado, el volumen negociado y el rendimiento acumulado de los últimos 365 días. Estas variables fueron seleccionadas por representar distintos atributos relevantes de cada criptomoneda, vinculados con el riesgo, el tamaño del mercado, la liquidez y el desempeño reciente.

La capitalización de mercado fue transformada mediante logaritmo natural para reducir la asimetría de la distribución. El volumen negociado fue excluido de la especificación final debido a su elevada correlación con la capitalización de mercado, tal como se señaló en la sección 6.2.2. La volatilidad anual y el rendimiento acumulado de 365 días fueron incorporados en su escala original.

En consecuencia, la especificación final del modelo puede expresarse de la siguiente manera:

$$AMIM_{it} = \beta_0 + \beta_1 Volatility_{it} + \beta_2 \ln(MarketCap_{it}) + \beta_3 Return365_{it} + \alpha_i + \varepsilon_{it}$$

donde $AMIM_{it}$ representa el indicador de ineficiencia informacional de la criptomoneda i en el período t ; $Volatility_{it}$ corresponde a la volatilidad anual de los rendimientos; $\ln(MarketCap_{it})$ representa el logaritmo natural de la capitalización de mercado; $Return365_{it}$ corresponde al rendimiento acumulado de los últimos 365 días; α_i

representa el efecto fijo específico de cada criptomoneda; y ε_{it} corresponde al término de error.

6.4.2 Modelo de efectos fijos

Con el propósito de controlar las diferencias estructurales existentes entre las criptomonedas analizadas, el modelo fue estimado mediante un esquema de efectos fijos por criptomoneda. Esta especificación permite que cada activo posea un intercepto propio, capturando aquellas características no observadas que permanecen relativamente constantes durante el período de estudio, tales como la antigüedad del proyecto, la tecnología subyacente, el mecanismo de consenso, el grado de adopción o el tamaño de su comunidad.

La incorporación de efectos fijos evita que estas diferencias estructurales sean atribuidas erróneamente a las variables explicativas incluidas en el modelo. En consecuencia, los coeficientes estimados reflejan la relación entre las variaciones temporales de la volatilidad, la capitalización de mercado y el rendimiento acumulado, y los cambios observados en el AMIM dentro de una misma criptomoneda.

En términos prácticos, los efectos fijos fueron implementados mediante la incorporación de variables indicadoras (*dummy variables*) para cada criptomoneda dentro del modelo de regresión. De esta manera, cada activo presenta un intercepto específico que captura sus características estructurales propias, mientras que los coeficientes asociados a la volatilidad, la capitalización de mercado y el rendimiento acumulado se estiman de forma común para el conjunto de criptomonedas analizadas.

6.4.3 Método de estimación

La especificación econométrica fue estimada mediante el método de Mínimos Cuadrados Ordinarios (*Ordinary Least Squares, OLS*) utilizando la biblioteca *statsmodels* del lenguaje de programación Python. Los efectos fijos por criptomoneda fueron incorporados mediante variables indicadoras (*dummy variables*), siguiendo el enfoque de *Least Squares Dummy Variables (LSDV)*.

Con el propósito de obtener inferencias estadísticas robustas frente a posibles problemas de heterocedasticidad, los errores estándar fueron estimados mediante el estimador robusto HC3. La significancia estadística de los coeficientes se evaluó utilizando un nivel de significancia del 5%, complementando el análisis con los correspondientes valores t , valores p , coeficiente de determinación $\underline{R}^2$ y $\underline{R}^2$ ajustado y el

estadístico (F), con el fin de evaluar el ajuste global y la significancia de las variables explicativas.

7. RESULTADOS

En este capítulo se presentan los principales resultados obtenidos a partir de la metodología desarrollada en el capítulo anterior. En primer lugar, se analizan los resultados del indicador Adjusted Market Inefficiency Magnitude (AMIM), comparando su comportamiento entre Bitcoin, Ethereum y el conjunto de las altcoins, así como su evolución temporal durante el período de estudio. Posteriormente, se examina la relación entre el AMIM y las variables explicativas mediante una matriz de correlaciones y, finalmente, se presentan los resultados del modelo econométrico de datos de panel con efectos fijos, interpretando los coeficientes estimados y contrastándolos con la evidencia presentada en la literatura.

7.1 Resultados del indicador AMIM

7.1.1 Comparación del AMIM entre Bitcoin, Ethereum y Altcoins.

Tabla 7.1. Indicadores promedio de eficiencia informacional para Bitcoin, Ethereum y el conjunto de Altcoins

	AMIM_promedio	MIM_promedio	Pct_AR1
BTC	-0.506	0.502	94.326
ETH	-0.405	0.540	91.442
Altcoins	-0.223	0.606	88.480

Fuente: Elaboración propia.

NOTA: El análisis individual por criptomoneda y los rankings anuales del indicador AMIM se presentan en los Anexos 4.1. y 4.2.

La Tabla 7.1 presenta los valores promedio del indicador Adjusted Market Inefficiency Magnitude (AMIM), del Market Inefficiency Magnitude (MIM) y el porcentaje de ventanas en las que el modelo autorregresivo seleccionado correspondió a un proceso AR(1) para Bitcoin, Ethereum y el conjunto de altcoins. Con el objetivo de facilitar la comparación, los resultados de las siete altcoins consideradas en la muestra se presentan de manera

agregada mediante el promedio simple de los indicadores obtenidos para cada activo. Los resultados muestran que Bitcoin registra el menor valor promedio del AMIM (-0,506), seguido por Ethereum (-0,405), mientras que el conjunto de altcoins presenta un valor promedio de -0,223. Dado que valores más bajos del AMIM indican un menor grado de ineficiencia informacional, estos resultados sugieren que Bitcoin constituye el activo más eficiente de la muestra durante el período analizado, seguido por Ethereum, mientras que las altcoins exhiben, en promedio, una mayor dependencia temporal en sus rendimientos.


El mismo orden relativo se observa al analizar los valores promedio del MIM, los cuales aumentan progresivamente desde Bitcoin (0,502) hasta las altcoins (0,606). Si bien el MIM constituye una medida de la magnitud de la dependencia temporal, el ajuste mediante el Reference Critical Interval (RCI) permite interpretar estas diferencias en términos del grado de ineficiencia informacional, dando origen al indicador AMIM utilizado en esta investigación.

Por otra parte, el porcentaje de ventanas en las que el criterio de selección basado en el AIC identificó un modelo AR(1) supera el 88 % en todos los grupos analizados, alcanzando el 94,3 % en Bitcoin. Este resultado indica que, durante la mayor parte del período de estudio, la dinámica de los rendimientos pudo representarse adecuadamente mediante una estructura autorregresiva de primer orden, siendo menos frecuente la necesidad de incorporar un mayor número de rezagos.

En conjunto, la evidencia descriptiva presentada en la Tabla 7.1 sugiere que las criptomonedas de mayor madurez y capitalización de mercado, representadas por Bitcoin y Ethereum, exhibieron un mayor grado de eficiencia informacional que el conjunto de las altcoins durante el período analizado. No obstante, estas diferencias descriptivas serán analizadas con mayor profundidad en las secciones siguientes mediante el estudio de la evolución temporal del indicador AMIM y la estimación del modelo econométrico de datos de panel.

7.1.2 Evolución temporal del indicador AMIM

Figura 7.1. Evolución temporal del indicador Adjusted Market Inefficiency Magnitude (AMIM) para Bitcoin, Ethereum y el promedio de las altcoins (2020–2025).



Fuente: Elaboración propia.

NOTA: Con fines exclusivamente gráficos, las series fueron suavizadas mediante un promedio móvil de 30 días. Esta transformación se utilizó únicamente para facilitar la visualización de la evolución temporal y no modifica los valores empleados en los análisis descriptivos ni en las estimaciones econométricas.

La Figura 7.1 presenta la evolución temporal del indicador Adjusted Market Inefficiency Magnitude (AMIM) para Bitcoin, Ethereum y el promedio de las altcoins durante el período comprendido entre 2020 y 2025. A diferencia de los valores promedio presentados en la Tabla 7.1, la representación temporal permite analizar la dinámica de la eficiencia informacional e identificar cambios en el comportamiento relativo de los distintos grupos de criptomonedas a lo largo del tiempo.

En términos generales, se observa que el indicador presenta variaciones significativas durante el período analizado, lo que sugiere que el grado de eficiencia no permanece constante en el tiempo. Este comportamiento resulta consistente con la AMH, según la cual la eficiencia evoluciona en respuesta a cambios en las condiciones del mercado, la incorporación de nueva información y la interacción entre los participantes.

Asimismo, si bien las tres series presentan una tendencia general similar, se observan diferencias en la magnitud y el momento en que se producen las variaciones del indicador. Estas diferencias sugieren que la evolución de la eficiencia informacional no fue homogénea entre Bitcoin, Ethereum y el conjunto de las altcoins durante el período analizado. En consecuencia, resulta pertinente profundizar este análisis mediante el modelo econométrico desarrollado en las secciones siguientes, con el propósito de

identificar los factores asociados a dichas variaciones.

7.2 Relación entre el AMIM y las variables explicativas

7.2.1 Matriz de correlaciones

Tabla 7.2. Matriz de correlaciones de Pearson entre el AMIM y las variables explicativas.

	AMIM	Volatilidad	ln(Capitalización)	ln(Volumen)	Rendimiento 365 días
AMIM	1.000	0.140	-0.214	-0.179	0.138
Volatilidad	0.140	1.000	-0.411	-0.068	0.179
ln(Capitalización)	-0.214	-0.411	1.000	0.868	0.143
ln(Volumen)	-0.179	-0.068	0.868	1.000	0.255
Rendimiento 365 días	0.138	0.179	0.143	0.255	1.000

Fuente: Elaboración propia.

NOTA: Los valores corresponden a coeficientes de correlación de Pearson. Las celdas resaltadas indican las correlaciones del AMIM con las variables explicativas y la elevada correlación entre la capitalización de mercado y el volumen negociado.

Con el propósito de examinar la relación lineal entre el indicador Adjusted Market Inefficiency Magnitude (AMIM) y las variables explicativas consideradas en el modelo, la Tabla 7.2 presenta la matriz de correlaciones de Pearson. Este análisis constituye una primera aproximación a la asociación entre las variables y permite identificar posibles problemas de multicolinealidad antes de la estimación del modelo econométrico.

En términos generales, las correlaciones entre el AMIM y las variables explicativas presentan magnitudes reducidas. En particular, el indicador exhibe una correlación positiva con la volatilidad anualizada (0,140) y con el rendimiento acumulado de los últimos 365 días (0,138), mientras que mantiene una relación negativa con el logaritmo de la capitalización de mercado (-0,214) y con el logaritmo del volumen negociado (-0,179). Estos resultados sugieren que las asociaciones lineales individuales son relativamente débiles, por lo que resulta necesario recurrir a un modelo econométrico que permita evaluar el efecto conjunto de las variables sobre el grado de eficiencia informacional.

Por otra parte, se observa una elevada correlación positiva entre el logaritmo de la capitalización de mercado y el logaritmo del volumen negociado (0,868). Este resultado indica que ambas variables contienen información estrechamente relacionada sobre el

tamaño y la actividad del mercado. En consecuencia, y considerando además las estimaciones preliminares realizadas durante la especificación del modelo, se decidió excluir el volumen negociado de la regresión final, manteniendo la capitalización de mercado como variable representativa para evitar problemas de multicolinealidad y reducir la incorporación de información redundante.

7.3 Resultados del modelo econométrico

Con el propósito de analizar los factores asociados al grado de eficiencia informacional de las criptomonedas, se estimaron tres especificaciones econométricas mediante el método de Mínimos Cuadrados Ordinarios (OLS), utilizando errores estándar robustos HC3. La primera corresponde a un modelo base que incorpora todas las variables explicativas consideradas en la investigación. La segunda incorpora efectos fijos por criptomoneda con el objetivo de controlar la heterogeneidad no observada entre los distintos activos. Finalmente, la tercera presenta la especificación adoptada como modelo final, la cual excluye el volumen negociado debido a la elevada correlación observada con la capitalización de mercado y a los resultados obtenidos en las estimaciones preliminares. La Tabla 7.3 resume los principales resultados obtenidos para cada una de las especificaciones.

Tabla 7.3. Resultados de las especificaciones econométricas estimadas

	Modelo 1 (base)	Modelo 2 (EF)	Modelo 3 (final)
Volatilidad	2.487***	2.696***	5.882***
ln(Capitalización)	-0.030***	-0.188***	-0.170***
ln(Volumen)	-0.039***	0.060***	—
Rendimiento 365 días	0.132***	0.075***	0.080***
Efectos fijos	No	Sí	Sí
Observaciones	16,769	16,769	16,769
R²	0.078	0.273	0.271
R² ajustado	0.078	0.273	0.271

Fuente: Elaboración propia.

Nota: *** $p < 0,01$; ** $p < 0,05$; * $p < 0,10$. Se reportan los coeficientes estimados mediante Mínimos Cuadrados Ordinarios (OLS) con errores estándar robustos HC3. Los resultados completos de la estimación econométrica se presentan en el Anexo 4.5.

La **Tabla 7.3** presenta los resultados obtenidos para las tres especificaciones econométricas estimadas. En términos generales, los coeficientes mantienen signos consistentes entre los modelos, aunque su magnitud se modifica al incorporar efectos fijos por criptomoneda. Asimismo, la inclusión de estos efectos incrementa considerablemente el poder explicativo del modelo, evidenciando la importancia de controlar por características específicas de cada activo que permanecen constantes en el tiempo.

En primer lugar, la volatilidad anualizada presenta un coeficiente positivo y estadísticamente significativo en las tres especificaciones estimadas. En particular, el coeficiente aumenta de 2,487 en el modelo base a 2,696 al incorporar efectos fijos por criptomoneda, alcanzando un valor de 5,882 en el modelo final. Estos resultados indican que mayores niveles de volatilidad se asocian con incrementos en el indicador AMIM y, en consecuencia, con un mayor grado de ineficiencia informacional.

El incremento en la magnitud del coeficiente al incorporar efectos fijos sugiere que parte de la relación entre volatilidad e ineficiencia permanecía oculta al no controlar por las características propias de cada criptomoneda. Una vez controladas estas diferencias individuales, la asociación entre ambas variables se vuelve más intensa, reforzando la importancia de la volatilidad como uno de los principales factores explicativos del nivel de eficiencia observado en la muestra.

En segundo lugar, el logaritmo de la capitalización de mercado presenta un coeficiente negativo y estadísticamente significativo en las tres especificaciones estimadas. En el modelo base, el coeficiente alcanza un valor de -0,030, mientras que en el modelo con efectos fijos aumenta en magnitud hasta -0,188 y se mantiene en un nivel similar (-0,170) en el modelo final. Estos resultados indican que, manteniendo constantes las demás variables, las criptomonedas con mayor capitalización de mercado tienden a presentar menores valores del indicador AMIM y, por lo tanto, un mayor grado de eficiencia informacional.

Este hallazgo resulta consistente con la literatura, que sostiene que los activos de mayor tamaño suelen caracterizarse por una mayor liquidez, una participación más amplia de inversores y una incorporación más rápida de la información en los precios. En consecuencia, la capitalización de mercado emerge como un factor asociado a un mayor nivel de eficiencia de las criptomonedas analizadas.

En tercer lugar, el rendimiento acumulado de los últimos 365 días presenta un coeficiente positivo y estadísticamente significativo en las tres especificaciones estimadas. Si bien

su magnitud disminuye al incorporar efectos fijos, el coeficiente permanece estable entre el segundo y el tercer modelo, alcanzando un valor de 0,080 en la especificación final. Estos resultados indican que las criptomonedas que registran mayores rendimientos acumulados tienden a presentar valores más elevados del indicador AMIM y, por consiguiente, un mayor grado de ineficiencia informacional.

Una posible explicación de este resultado radica en que períodos de elevados rendimientos suelen coincidir con episodios de mayor actividad especulativa, incrementos en la incertidumbre y una mayor intensidad en el proceso de incorporación de información al mercado. En este contexto, la mayor rentabilidad observada puede estar asociada a desviaciones temporales respecto de la eficiencia informacional, en línea con la naturaleza dinámica planteada por la Hipótesis de Mercados Adaptativos.

Por otra parte, el volumen negociado presenta un comportamiento diferente al de las restantes variables explicativas. Mientras que en el modelo base exhibe un coeficiente negativo y estadísticamente significativo, al incorporar efectos fijos por criptomoneda dicho coeficiente cambia de signo y pasa a ser positivo, manteniendo su significancia estadística. Esta sensibilidad a la especificación utilizada sugiere que la relación entre el volumen negociado y la eficiencia no resulta suficientemente robusta.

Adicionalmente, la matriz de correlaciones presentada en la Tabla 7.2 evidenció una elevada asociación entre el logaritmo del volumen negociado y el logaritmo de la capitalización de mercado (0,868). En conjunto, estos resultados respaldan la decisión de excluir el volumen negociado de la especificación final del modelo, evitando posibles problemas de multicolinealidad y privilegiando una especificación más parsimoniosa, sin afectar de manera significativa el poder explicativo del modelo.

En términos de ajuste, la incorporación de efectos fijos incrementa sustancialmente el poder explicativo del modelo. Mientras que el modelo base alcanza un coeficiente de determinación (R^2) de 0,078, las especificaciones que incorporan efectos fijos elevan este valor hasta aproximadamente 0,27. Este resultado evidencia la importancia de controlar por características propias de cada criptomoneda que permanecen constantes en el tiempo y que influyen sobre el nivel de eficiencia.

Asimismo, la exclusión del volumen negociado no implica una pérdida relevante en la capacidad explicativa del modelo, ya que el coeficiente de determinación prácticamente no se modifica entre la segunda y la tercera especificación. En consecuencia, el modelo final constituye la alternativa más adecuada para el análisis, al combinar una elevada capacidad explicativa con una especificación más parsimoniosa y libre de problemas

potenciales de multicolinealidad.

8. DISCUSIÓN DE LOS RESULTADOS E IMPLICANCIAS.

8.1 Evolución temporal de la eficiencia informacional.

Los resultados obtenidos evidencian que el grado de eficiencia informacional de las criptomonedas analizadas no permaneció constante durante el período 2020–2025. La evolución temporal del indicador *Adjusted Market Inefficiency Magnitude* (AMIM) mostró variaciones significativas tanto en Bitcoin y Ethereum como en el conjunto de las altcoins, indicando que el comportamiento eficiente de estos activos experimentó cambios a lo largo del tiempo. Por lo tanto, los resultados permiten descartar una visión estática de la eficiencia de mercado y sugieren que el proceso de incorporación de información en los precios evolucionó conforme se modificaron las condiciones del mercado.

Esta evidencia resulta consistente con la Hipótesis de Mercados Adaptativos (Lo, 2004), bajo la cual resulta esperable que un mercado en proceso de expansión y transformación, como el de las criptomonedas durante el período analizado, presente fluctuaciones en su grado de eficiencia.

En línea con ello, los resultados obtenidos coinciden con los hallazgos de Bariviera (2017), Tran y Leirvik (2019) y Noda (2020), quienes sostienen que la eficiencia en el mercado de criptomonedas presenta un comportamiento dinámico y puede modificarse a lo largo del tiempo en función de la evolución del mercado y de las condiciones de negociación. En este sentido, la evidencia obtenida en la presente investigación refuerza la idea de que la eficiencia debe interpretarse como un fenómeno evolutivo y no como una propiedad fija de los mercados financieros.

8.2 Diferencias según la madurez de los activos.

La literatura revisada sostiene que las diferencias en liquidez, capitalización de mercado, profundidad de negociación y participación institucional pueden dar lugar a distintos niveles de eficiencia informacional entre las criptomonedas. Desde esta perspectiva, resulta esperable que los activos con mayor grado de madurez relativa presenten un comportamiento más cercano a las condiciones de eficiencia débil que aquellos con menor desarrollo estructural.

La evidencia obtenida en la presente investigación respalda este planteamiento. Bitcoin y Ethereum registraron, en promedio, menores niveles del indicador AMIM que el conjunto de las altcoins durante el período 2020–2025, lo que indica un menor grado de

ineficiencia informacional. Este resultado sugiere que la mayor madurez de estos activos favorece un proceso de incorporación de información más eficiente, consistente con la mayor liquidez, profundidad de mercado y participación institucional que caracterizan a ambas criptomonedas.

Estos resultados son consistentes con los hallazgos de Wei (2018), quien identifica una relación positiva entre liquidez y eficiencia en el mercado de criptomonedas. Asimismo, Hu, Valera y Oxley (2019) encuentran que las criptomonedas de mayor capitalización presentan, en promedio, niveles de eficiencia superiores a los de activos con menor desarrollo relativo. En una línea similar, Tran y Leirvik (2019) muestran que el grado de ineficiencia difiere entre criptomonedas y evoluciona a lo largo del tiempo, mientras que Noda (2020) destaca que las diferencias en eficiencia entre Bitcoin y Ethereum responden al distinto nivel de madurez alcanzado por cada mercado. En conjunto, esta evidencia respalda la idea de que el mercado de criptomonedas no constituye un sistema homogéneo, sino un ecosistema en el que la eficiencia varía de acuerdo con las características estructurales de cada activo.

No obstante, el análisis individual presentado en el Anexo 4.1 muestra que determinadas altcoins alcanzaron, en algunos períodos o en el ranking promedio, niveles de eficiencia comparables e incluso superiores a los observados en Bitcoin y Ethereum. Esto indica que, si bien la madurez constituye un factor importante para explicar las diferencias de eficiencia, no resulta suficiente por sí sola. En consecuencia, la eficiencia informacional también depende de factores específicos de cada criptomoneda y de la evolución de las condiciones del mercado, en línea con el carácter dinámico planteado por la Hipótesis de Mercados Adaptativos.

8.3 Relación entre el desarrollo del mercado y la eficiencia informacional

Desde la Hipótesis de Mercados Adaptativos, la eficiencia informacional depende de las condiciones en las que opera el mercado y puede verse influenciada por factores como la liquidez, la competencia entre participantes y el grado de desarrollo alcanzado por cada activo. Bajo este enfoque, resulta esperable que variables asociadas a la evolución del mercado contribuyan a explicar las diferencias observadas en el grado de eficiencia de las criptomonedas.

En este contexto, la evidencia obtenida en la presente investigación muestra que la volatilidad, el rendimiento acumulado y la capitalización de mercado mantienen una

relación estadísticamente significativa con el indicador AMIM. En particular, mayores niveles de volatilidad y rendimiento se asociaron con incrementos en la ineficiencia informacional, mientras que una mayor capitalización de mercado se vinculó con menores niveles de ineficiencia, sugiriendo que los activos de mayor tamaño presentan un proceso de incorporación de información más eficiente.

Estos resultados son consistentes con los hallazgos de Wei (2018), quien encuentra que las criptomonedas con mayores niveles de liquidez tienden a exhibir un comportamiento más cercano a la eficiencia informacional. Asimismo, Tran y Leirvik (2019) muestran que el grado de ineficiencia varía entre criptomonedas y evoluciona a lo largo del tiempo, reflejando la influencia de las condiciones del mercado sobre el comportamiento eficiente de los activos digitales. En conjunto, la evidencia respalda la idea de que el desarrollo del mercado constituye un elemento central para comprender las diferencias de eficiencia observadas entre las distintas criptomonedas.

8.4 Evaluación de la hipótesis

La evidencia obtenida permite aceptar la hipótesis planteada en la presente investigación. En primer lugar, los resultados muestran que el grado de eficiencia informacional de las criptomonedas no permaneció constante durante el período analizado, sino que presentó variaciones temporales compatibles con la Hipótesis de Mercados Adaptativos. En segundo lugar, Bitcoin y Ethereum exhibieron, en promedio, menores niveles de ineficiencia que el conjunto de las altcoins, confirmando la existencia de diferencias asociadas al nivel de madurez relativa de los activos.

A su vez, el modelo econométrico evidenció que variables vinculadas al desarrollo del mercado, como la capitalización de mercado, la volatilidad y el rendimiento acumulado, se encuentran significativamente asociadas al grado de eficiencia informacional, aportando evidencia adicional sobre los factores que explican dichas diferencias.

8.5 Limitaciones y futuras investigaciones

La presente investigación presenta algunas limitaciones que deben ser consideradas al interpretar los resultados obtenidos. En primer lugar, el análisis se circunscribe a un conjunto de nueve criptomonedas seleccionadas en función de la disponibilidad de información histórica y su permanencia en el mercado durante el período analizado. Si bien esta selección permitió realizar comparaciones consistentes entre activos con

distintos niveles de madurez, los resultados no necesariamente pueden generalizarse al universo completo de criptomonedas, especialmente a aquellas de reciente creación o con menor liquidez.

En segundo lugar, el estudio se centra exclusivamente en la eficiencia débil del mercado, evaluada a partir del indicador Adjusted Market Inefficiency Magnitude (AMIM). En consecuencia, no se analizan otras dimensiones de la eficiencia informacional, como la eficiencia semi-fuerte o fuerte, ni el impacto de información pública o privada sobre el proceso de formación de precios.

Asimismo, aunque el modelo econométrico incorpora variables representativas del desarrollo del mercado, como la volatilidad, la capitalización de mercado y el rendimiento acumulado, existen otros factores potencialmente relevantes que no fueron considerados, entre ellos variables macroeconómicas, cambios regulatorios, indicadores de actividad en la red blockchain o medidas de sentimiento del mercado, los cuales podrían contribuir a explicar la evolución de la eficiencia informacional.

A partir de estas limitaciones, futuras investigaciones podrían ampliar la muestra de criptomonedas analizadas, incorporar períodos temporales más extensos o evaluar la robustez de los resultados mediante indicadores alternativos de eficiencia y metodologías econométricas adicionales. Del mismo modo, resultaría de interés profundizar el análisis del efecto de variables institucionales, regulatorias y macroeconómicas sobre la dinámica de la eficiencia en el mercado de cryptoactivos, contribuyendo así a una comprensión más integral de los factores que condicionan el comportamiento de estos mercados.

9. CONCLUSIONES

La presente investigación tuvo como objetivo analizar la evolución temporal del grado de eficiencia débil en el mercado de criptomonedas durante el período 2020–2025, considerando las diferencias existentes entre activos según su nivel de madurez relativa. A partir de la evidencia obtenida, se concluye que la eficiencia informacional constituye un fenómeno dinámico, que presenta variaciones a lo largo del tiempo y diferencias significativas entre criptomonedas con distintos niveles de desarrollo.

La evidencia obtenida permitió comprobar que Bitcoin y Ethereum exhibieron, en promedio, mayores niveles de eficiencia que el conjunto de las altcoins, resultado

consistente con su mayor madurez, liquidez y participación institucional. Complementariamente, la evolución temporal del indicador AMIM evidenció fluctuaciones compatibles con un proceso de adaptación del mercado. Finalmente, el modelo econométrico mostró que variables como la volatilidad, la capitalización de mercado y el rendimiento acumulado mantienen una relación estadísticamente significativa con el indicador AMIM.

En términos académicos, la investigación contribuye a la literatura sobre eficiencia en criptomonedas al analizar simultáneamente la evolución temporal del indicador AMIM, las diferencias entre activos con distinto nivel de madurez y la relación entre variables asociadas al desarrollo del mercado y la eficiencia informacional. En esta línea, el trabajo aporta evidencia empírica reciente correspondiente al período 2020–2025, caracterizado por una profunda transformación del ecosistema cripto.

Desde una perspectiva práctica, los resultados sugieren que el mercado de criptomonedas no debe interpretarse como un conjunto homogéneo de activos. Las diferencias observadas entre Bitcoin, Ethereum y las altcoins indican que el nivel de eficiencia depende tanto de las características propias de cada criptomoneda como de la evolución de las condiciones del mercado. En este sentido, los hallazgos de la investigación aportan evidencia útil para comprender el proceso de formación de precios en los cryptoactivos y constituyen un insumo de interés para investigadores, inversores y demás participantes del mercado.

En definitiva, los resultados obtenidos permiten aceptar la hipótesis de investigación planteada, confirmando que el grado de eficiencia débil presenta variaciones temporales y diferencias según el nivel de madurez de los activos analizados. Esta evidencia refuerza la importancia de analizar la eficiencia financiera desde la perspectiva evolutiva propuesta por la Hipótesis de Mercados Adaptativos, especialmente en mercados caracterizados por una rápida transformación estructural como el de las criptomonedas.

10. ANEXOS

ANEXO 1. Criptomonedas incluidas en la muestra

Las siguientes criptomonedas conforman la muestra analizada en la investigación. Bitcoin y Ethereum fueron consideradas criptomonedas de referencia debido a su mayor nivel de capitalización y madurez relativa, mientras que las restantes siete corresponden al grupo de altcoins utilizado para la comparación empírica.

Criptomoneda	Símbolo	Grupo
Bitcoin	BTC	Referencia
Ethereum	ETH	Referencia
Litecoin	LTC	Altcoin
Monero	XMR	Altcoin
Stellar	XLM	Altcoin
TRON	TRX	Altcoin
EOS	EOS	Altcoin
NEO	NEO	Altcoin
Ethereum Classic	ETC	Altcoin

ANEXO 2. Variables utilizadas

Variable	Definición	Fuente
AMIM	Indicador de eficiencia informacional	Elaboración propia
volatility_365	Desvío estándar anualizado	Elaboración propia
return_365	Rendimiento acumulado 365 días	Elaboración propia
ln_market_cap	Logaritmo natural de la capitalización	CoinGecko

ln_volume	Logaritmo natural del volumen negociado	CoinGecko
-----------	---	-----------

ANEXO 3. Construcción del indicador AMIM

Anexo 3.1 Selección del orden autorregresivo mediante AIC

Como primera etapa del procedimiento, se estiman modelos autorregresivos de distinto orden para cada ventana móvil. La siguiente función evalúa especificaciones desde AR(1) hasta AR(10), calcula el Criterio de Información de Akaike (AIC) para cada una de ellas y selecciona automáticamente el modelo que presenta el menor valor del criterio, el cual es posteriormente utilizado para la construcción del indicador.

Figura A3.1. Función para la selección automática del modelo autorregresivo mediante el criterio AIC.

```
def seleccionar_ar_aic(returns, max_lags=10):

    # Eliminamos valores faltantes.
    returns = returns.dropna()

    # Lista donde se guardará el AIC de cada modelo.
    resultados = []

    # Probamos modelos AR(1), AR(2), ..., AR(max_lags).
    for q in range(1, max_lags + 1):
        try:
            # Estimamos el modelo AR(q).
            modelo = AutoReg(returns, lags=q).fit()

            # Guardamos el número de rezagos y su AIC.
            resultados.append((q, modelo.aic))

        except:
            # Si algún modelo falla, lo salteamos.
            continue

    # Convertimos los resultados en una tabla.
    tabla = pd.DataFrame(resultados, columns=["q", "AIC"])

    # Elegimos el q con menor AIC.
    q_optimo = int(tabla.loc[tabla["AIC"].idxmin(), "q"])

    return q_optimo, tabla
```

Fuente: Elaboración propia.

Anexo 3.2 Cálculo del indicador AMIM

A continuación se implementa la función encargada de calcular el indicador Adjusted

Market Inefficiency Magnitude (AMIM) a partir del modelo autorregresivo previamente seleccionado. La función estima el Market Inefficiency Magnitude (MIM), calcula el Reference Critical Interval (RCI) correspondiente y obtiene el valor final del indicador para cada ventana de observaciones.

Figura A3.2. Función para el cálculo del indicador AMIM.

```
def calcular_amim(returns, max_lags=10):
    returns = returns.dropna()

    q_optimo, tabla_aic = seleccionar_ar_aic(returns, max_lags=max_lags)

    modelo = AutoReg(returns, lags=q_optimo).fit()

    beta_names = [name for name in modelo.params.index if name != "const"]
    beta_hat = modelo.params[beta_names].values

    cov_beta = modelo.cov_params().loc[beta_names, beta_names].values

    L = np.linalg.cholesky(cov_beta)
    beta_standard = np.linalg.inv(L) @ beta_hat

    suma_abs = np.sum(np.abs(beta_standard))
    mim = suma_abs / (1 + suma_abs)

    rci = RCI_TABLE[q_optimo]
    amim = (mim - rci) / (1 - rci)

    beta_hat = modelo.params[beta_names].values
    beta1 = beta_hat[0]

    return {
        "q": q_optimo,
        "MIM": mim,
        "AMIM": amim,
        "beta1": beta1,
        "modelo": modelo,
        "tabla_aic": tabla_aic
    }
```

Fuente: Elaboración propia.

Anexo 3.3 Estimación mediante ventanas móviles

Por último, se implementa un procedimiento de ventanas móviles de 365 observaciones diarias. Para cada ventana se selecciona el modelo autorregresivo óptimo, se calcula el indicador AMIM y posteriormente la ventana se desplaza una observación, repitiendo el proceso hasta completar toda la serie temporal de cada criptomoneda analizada.

Figura A3.3. Función para la estimación del indicador mediante ventanas móviles.

```
def rolling_amim(df, ventana=365, max_lags=10):

    resultados = []

    for i in range(ventana, len(df) + 1):

        muestra = df.iloc[i-ventana:i].copy()
        fecha_final = muestra["date"].iloc[-1]
        returns_window = muestra["returns"].dropna()

        try:
            resultado = calcular_amim(
                returns_window,
                max_lags=max_lags
            )

            resultados.append({
                "date": fecha_final,
                "q": resultado["q"],
                "MIM": resultado["MIM"],
                "AMIM": resultado["AMIM"],
                "beta1": resultado["beta1"]
            })

        except:
            continue

    return pd.DataFrame(resultados)
```

Fuente: Elaboración propia.

NOTA: Las funciones presentadas corresponden a las principales rutinas desarrolladas para la implementación del indicador AMIM. El código completo incluye además procedimientos de carga de datos, depuración de la base, construcción del panel y estimación de los modelos econométricos utilizados en la investigación.

ANEXO 4. Evolución anual de la eficiencia por criptomoneda.

Anexo 4.1. Ranking promedio de eficiencia informacional (2020–2025)

La siguiente tabla presenta el ranking promedio obtenido por cada criptomoneda durante el período de estudio. Un menor ranking promedio indica una posición relativamente más eficiente dentro del conjunto de activos analizados.

Tabla A4.1. Ranking promedio de eficiencia informacional (2020–2025).

Ranking_promedio	
ETC	3.166667
LTC	3.333333
BTC	4.000000
ETH	4.333333
NEO	5.166667
EOS	5.500000
XLM	5.666667
TRX	6.333333
XMR	7.500000

Fuente: Elaboración propia.

Anexo 4.2 Valores promedio anuales del indicador AMIM

Con el objetivo de complementar el análisis presentado en el Capítulo 4, se presentan los valores promedio anuales del indicador AMIM para cada una de las criptomonedas incluidas en la muestra. Dado que valores menores del indicador representan un menor grado de ineficiencia informacional, esta información permite observar la evolución relativa de la eficiencia de cada activo durante el período analizado.

Tabla A4.2. Valores promedio anuales del indicador AMIM por criptomoneda (2020–2025).

crypto	AMIM promedio anual por criptomoneda								
	BTC	ETH	LTC	XMR	XLM	TRX	EOS	NEO	ETC
year									
2020	0.152	0.222	-0.005	0.133	-0.187	-0.154	0.259	-0.645	-0.108
2021	-0.239	-0.039	-0.396	0.478	-0.773	0.000	0.319	0.070	-0.236
2022	-0.953	-0.857	-0.286	-0.087	-0.137	0.288	-0.027	-0.277	-0.736
2023	-1.214	-0.586	-0.667	0.023	0.142	0.300	-0.155	-0.035	-0.563
2024	-0.278	-0.419	-0.411	0.527	0.193	-0.484	-1.239	0.061	-1.560
2025	-0.504	-0.848	-1.129	-0.070	0.429	0.308	-1.142	-0.832	-0.937

Fuente: Elaboración propia.

Anexo 4.3. Ranking anual de eficiencia

A partir de los valores promedio anuales del indicador AMIM se construyó un ranking de eficiencia para cada año del período analizado. La posición 1 corresponde a la criptomoneda que registró el menor valor promedio anual del indicador AMIM, mientras que la posición 9 representa la de mayor ineficiencia relativa.

Tabla A4.3. Ranking anual de eficiencia informacional por criptomoneda.

	2020	2021	2022	2023	2024	2025
1	NEO	XLM	BTC	BTC	ETC	EOS
2	XLM	LTC	ETH	LTC	EOS	LTC
3	TRX	BTC	ETC	ETH	TRX	ETC
4	ETC	ETC	LTC	ETC	ETH	ETH
5	LTC	ETH	NEO	EOS	LTC	NEO
6	XMR	TRX	XLM	NEO	BTC	BTC
7	BTC	NEO	XMR	XMR	NEO	XMR
8	ETH	EOS	EOS	XLM	XLM	TRX
9	EOS	XMR	TRX	TRX	XMR	XLM

Fuente: Elaboración propia.

NOTA: El ranking anual tiene un carácter descriptivo y complementa el análisis desarrollado en el cuerpo principal de la investigación. Debido a que la discusión central se basa en el comportamiento promedio del período 2020–2025 y en la comparación entre Bitcoin, Ethereum y el conjunto de las altcoins, las variaciones observadas en años particulares no modifican las conclusiones generales obtenidas.

ANEXO 5. Resultados completos de las estimaciones econométricas

Con el propósito de complementar la información presentada en la Tabla 4.3, se exponen a continuación los resultados completos de las tres especificaciones econométricas estimadas en la investigación. Se incluyen los coeficientes, errores estándar robustos (HC3), estadísticos de prueba y medidas de ajuste reportadas por el software utilizado para la estimación.

Anexo 5.1 Modelo base (OLS)

Figura A5.1. Resultados completos del modelo base (OLS).

OLS Regression Results

Dep. Variable:	AMIM	R-squared:	0.078
Model:	OLS	Adj. R-squared:	0.078
Method:	Least Squares	F-statistic:	376.6
Date:	Mon, 29 Jun 2026	Prob (F-statistic):	3.95e-311
Time:	00:41:24	Log-Likelihood:	-15086.
No. Observations:	16769	AIC:	3.018e+04
Df Residuals:	16764	BIC:	3.022e+04
Df Model:	4		
Covariance Type:	HC3		

	coef	std err	z	P> z	[0.025	0.975]
Intercept	1.0784	0.067	16.190	0.000	0.948	1.209
volatility_365	2.4872	0.490	5.072	0.000	1.526	3.448
ln_volume	-0.0386	0.006	-6.517	0.000	-0.050	-0.027
ln_market_cap	-0.0303	0.006	-5.037	0.000	-0.042	-0.019
return_365	0.1317	0.006	23.825	0.000	0.121	0.143

Omnibus:	2095.754	Durbin-Watson:	0.046
Prob(Omnibus):	0.000	Jarque-Bera (JB):	2969.487
Skew:	-1.016	Prob(JB):	0.00
Kurtosis:	3.346	Cond. No.	3.35e+03

Notes:

[1] Standard Errors are heteroscedasticity robust (HC3)

[2] The condition number is large, 3.35e+03. This might indicate that there are strong multicollinearity or other numerical problems.

Fuente: Elaboración propia.

Anexo 5.2 Modelo con efectos fijos

Figura A5.2. Resultados completos del modelo con efectos fijos por criptomoneda.

```

=====
                        OLS Regression Results
=====
Dep. Variable:            AMIM      R-squared:                0.273
Model:                    OLS      Adj. R-squared:           0.273
Method:                    Least Squares      F-statistic:             696.1
Date:                      Mon, 29 Jun 2026    Prob (F-statistic):       0.00
Time:                      00:41:24      Log-Likelihood:          -13092.
No. Observations:          16769      AIC:                    2.621e+04
Df Residuals:              16757      BIC:                    2.630e+04
Df Model:                  11
Covariance Type:           HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
Intercept                3.0041      0.197      15.215      0.000      2.617      3.391
C(crypto)[T.ETC]        -0.9971      0.046     -21.533      0.000     -1.088     -0.906
C(crypto)[T.ETH]         -0.1263      0.020      -6.193      0.000     -0.166     -0.086
C(crypto)[T.LTC]         -0.6221      0.039     -15.869      0.000     -0.699     -0.545
C(crypto)[T.NEO]         -0.6304      0.059     -10.761      0.000     -0.745     -0.516
C(crypto)[T.TRX]         -0.1504      0.041      -3.710      0.000     -0.230     -0.071
C(crypto)[T.XLM]         -0.2652      0.051      -5.168      0.000     -0.366     -0.165
C(crypto)[T.XMR]         0.0221      0.053      0.416      0.677     -0.082      0.126
volatility_365           2.6957      0.662      4.074      0.000      1.399      3.992
ln_volume                0.0605      0.011      5.651      0.000      0.039      0.081
ln_market_cap            -0.1883      0.007     -26.913      0.000     -0.202     -0.175
return_365               0.0750      0.005     13.711      0.000      0.064      0.086
=====
Omnibus:                 2024.800      Durbin-Watson:           0.058
Prob(Omnibus):            0.000      Jarque-Bera (JB):        2837.186
Skew:                     -0.961      Prob(JB):                 0.00
Kurtosis:                 3.603      Cond. No.                 4.81e+03
=====

Notes:
[1] Standard Errors are heteroscedasticity robust (HC3)
[2] The condition number is large, 4.81e+03. This might indicate that there are
strong multicollinearity or other numerical problems.

```

Fuente: Elaboración propia.

Anexo 5.3 Modelo final

Figura A5.3. Resultados completos del modelo final.

OLS Regression Results						
=====						
Dep. Variable:	AMIM	R-squared:	0.271			
Model:	OLS	Adj. R-squared:	0.271			
Method:	Least Squares	F-statistic:	762.2			
Date:	Mon, 29 Jun 2026	Prob (F-statistic):	0.00			
Time:	00:41:24	Log-Likelihood:	-13113.			
No. Observations:	16769	AIC:	2.625e+04			
Df Residuals:	16758	BIC:	2.633e+04			
Df Model:	10					
Covariance Type:	HC3					
=====						
	coef	std err	z	P> z	[0.025	0.975]

Intercept	3.8696	0.155	24.936	0.000	3.565	4.174
C(crypto)[T.ETC]	-1.1958	0.037	-32.182	0.000	-1.269	-1.123
C(crypto)[T.ETH]	-0.1736	0.019	-9.204	0.000	-0.211	-0.137
C(crypto)[T.LTC]	-0.7725	0.032	-24.385	0.000	-0.835	-0.710
C(crypto)[T.NEO]	-0.9052	0.040	-22.856	0.000	-0.983	-0.828
C(crypto)[T.TRX]	-0.3176	0.031	-10.094	0.000	-0.379	-0.256
C(crypto)[T.XLM]	-0.5131	0.035	-14.781	0.000	-0.581	-0.445
C(crypto)[T.XMR]	-0.2408	0.035	-6.977	0.000	-0.308	-0.173
volatility_365	5.8817	0.351	16.764	0.000	5.194	6.569
ln_market_cap	-0.1703	0.006	-30.090	0.000	-0.181	-0.159
return_365	0.0798	0.005	14.592	0.000	0.069	0.091
=====						
Omnibus:	1962.641	Durbin-Watson:	0.058			
Prob(Omnibus):	0.000	Jarque-Bera (JB):	2719.488			
Skew:	-0.948	Prob(JB):	0.00			
Kurtosis:	3.544	Cond. No.	2.07e+03			
=====						
Notes:						
[1] Standard Errors are heteroscedasticity robust (HC3)						
[2] The condition number is large, 2.07e+03. This might indicate that there are strong multicollinearity or other numerical problems.						

Fuente: Elaboración propia.

Nota: Los resultados corresponden a estimaciones realizadas mediante Mínimos Cuadrados Ordinarios (OLS) con errores estándar robustos HC3. La Tabla 4.3 del cuerpo principal presenta una versión resumida de estas estimaciones.

11. BIBLIOGRAFÍA

Teoría

Bachelier, L. (1900). *Théorie de la spéculation. Annales Scientifiques de l'École Normale Supérieure*

Samuelson, P. A. (1965). Proof That Properly Anticipated Prices Fluctuate Randomly. *Industrial Management Review*

Fama, E. F. (1970). *Efficient capital markets: A review of theory and empirical work*. *The Journal of Finance*, 25(2), 383–417.

Fama, E. F. (1976). *Foundations of Finance*. Basic Books.

Lo, A. W. (2004). *The Adaptive Markets Hypothesis: Market efficiency from an evolutionary perspective*. *The Journal of Portfolio Management*, 30(5), 15–29.

Lo, A. W. (2005). *Reconciling Efficient Markets with Behavioral Finance: The Adaptive Markets Hypothesis*. *Journal of Investment Consulting*, 7(2), 21–44.

Shiller, R. J. (1981). *Do Stock Prices Move Too Much to be Justified by Subsequent Changes in Dividends?* *American Economic Review*, 71(3), 421–436.

Metodología

Tran, V. L., & Leirvik, T. (2019). *A simple but powerful measure of market efficiency*. *Finance Research Letters*, 29, 141–151.

Lo, A. W., & MacKinlay, A. C. (1988). *Stock market prices do not follow random walks: Evidence from a simple specification test*. *The Review of Financial Studies*, 1(1), 41–66.

Evidencia

Urquhart, A. (2016). *The inefficiency of Bitcoin*. *Economics Letters*, 148, 80–82.

Urquhart, A., & Hudson, R. (2013). *Efficient or adaptive markets? Evidence from major stock markets using very long run historic data*. *International Review of Financial Analysis*, 28, 130–142.

Cheah, E.-T., & Fry, J. (2015). *Speculative bubbles in Bitcoin markets? An empirical investigation into the fundamental value of Bitcoin*

Bariviera, A. F. (2017). *The inefficiency of Bitcoin revisited: A dynamic approach*. *Economics Letters*, 161, 1–4.

Miller, J. L. (2019). Price efficiency of cryptocurrencies. *Journal of Risk and Financial Management*, 12(4), 171.

Sensoy, A. (2019). *The inefficiency of Bitcoin revisited: A high-frequency analysis with*

- alternative currencies*. Finance Research Letters, 28, 68–73.
- Noda, A. (2020). *On the Evolution of Cryptocurrency Market Efficiency*. Economics Letters, 193, 109342
- Wei, W. C. (2018). *Liquidity and market efficiency in cryptocurrencies*. Economics Letters, 168, 21–24. .
- Tran & Leirvik (2019). *Efficiency in the Markets of Crypto-Currencies*.
- Kristoufek, L. (2018). *On Bitcoin markets (in)efficiency and its evolution*. Physica A: Statistical Mechanics and its Applications, 503, 257–262.
- Hu, Y., Valera, H. G. A., & Oxley, L. (2019). Market efficiency of the top market-cap cryptocurrencies: Further evidence from a panel framework.