

**PONTIFICIA UNIVERSIDAD CATÓLICA DEL ECUADOR
FACULTAD DE ECONOMÍA**

**Trabajo de Integración Curricular
previo a la obtención del título de Economista**

Artículo Académico

**Factores macroeconómicos que incidieron en la cotización del
Bitcoin, periodo de estudio: 2013-2023**

Ricardo Emilio Gavilanes Valarezo
regavilanesv@puce.edu.ec

Director: Mateo Villalba
mpvillalba@puce.edu.ec

Quito, 25 de febrero de 2025

Resumen

El presente estudio analiza la relación de tres variables con la cotización del Bitcoin: el PIB per cápita, la tasa de inflación anual y el índice de percepción de la corrupción. Para este análisis se utiliza datos de panel con observaciones anuales en el periodo de 2013 a 2023, para lo cual fueron seleccionados 20 países por su mayor propensión a utilizar el Bitcoin. Se emplearon los siguientes modelos econométricos: regresión lineal múltiple; VAR (*Vector Autoregression*); VEC (*Vector Error Correction*); y, análisis de datos de panel con efectos fijos y aleatorios. Los modelos de regresión lineal múltiple, VAR y VEC no superaron la pruebas de validación y debieron descartarse. El Modelo de Efectos Fijos resultó el más adecuado al capturar de forma más robusta las heterogeneidades no observadas entre países, presentar significancia global, y revelar una relación significativa y positiva entre el PIB per cápita y la cotización del Bitcoin, lo que constituye evidencia a favor del uso de esta criptomoneda como activo especulativo. Aunque el Modelo de Efectos Aleatorios también presentó significancia global y aportó parámetros significativos para las tres variables mencionadas, su capacidad explicativa es menor y sus resultados son menos robustos. Sin embargo, ambos Modelos, el de Efectos Fijos y el de Efectos Aleatorios, presentan limitaciones por presencia de autocorrelación y endogeneidad que, aunque fueron mitigadas no se lograron eliminar. Esta limitación impide realizar afirmaciones causales con los presentes resultados. Finalmente, estos hallazgos aportan una base para futuras investigaciones que busquen indagar sobre la relación de la cotización del Bitcoin con variables macroeconómicas.

Palabras clave: Bitcoin, PIB per cápita, inflación, índice de percepción de la corrupción, datos de panel, efectos fijos, efectos aleatorios.

Abstract

This study analyzes the relationship of three variables with the Bitcoin price: GDP per capita, the annual inflation rate and the corruption perception index. For this analysis we use panel data with annual observations in the period from 2013 to 2023, for which 20 countries were selected for their higher propensity to use Bitcoin. The following econometric models were employed: multiple linear regression; VAR (*Vector Autoregression*); VEC (*Vector Error Correction*); and, panel data analysis with fixed and random effects. The multiple linear regression, VAR and VEC models did not pass the validation tests and had to be discarded. The fixed effects model was the most appropriate as it captured more robustly the unobserved heterogeneities between countries, presented global significance, and revealed a significant and positive relationship between GDP per capita and the Bitcoin price, which is evidence in favor of the use of this cryptocurrency as a speculative asset. Although the random effects model also presented global significance and provided significant parameters for the three variables mentioned, its explanatory capacity is lower and its results are less robust. However, both models, the fixed-effects and the random-effects models, present limitations due to the presence of autocorrelation and endogeneity which, although mitigated, could not be eliminated. This limitation prevents us from making causal statements with the present results. Nonetheless, these findings provide a basis for future research that seeks to investigate the relationship of the Bitcoin price with macroeconomic variables.

Keywords: Bitcoin, GDP per capita, inflation, Corruption Perception Index, panel data, fixed effects, random effects.

ÍNDICE

Resumen	2
Abstract.....	2
Introducción.....	1
Marco referencial teórico	2
Marco referencial empírico	8
Propuesta metodológica	11
Análisis Exploratorio	12
Interpretación de las pruebas	13
Métricas de evaluación.....	14
Regresión lineal múltiple por MCO.....	14
VAR	15
VEC	15
Modelos de Efectos Fijos y Aleatorios	15
Variable dependiente	15
Variables independientes	15
Modelos econométricos aplicados.....	16
Regresión lineal múltiple por MCO.....	16
Interpolación de datos mensuales a partir de una base de datos anuales.....	16
Vector AutoRegresivo (VAR) y Vector de corrección de error (VEC).....	17
Transformaciones.....	17
Modelo de Efectos Fijos	18
Modelo de Efectos Aleatorios	18
Prueba de Hausman.....	19
Limitaciones de la investigación	19
Resultados y discusión.....	20
Series de tiempo de las variables macroeconómicas	20
Modelo de regresión múltiple por MCO.....	23
Resultados	23
Pruebas de validación y problemas detectados.....	24
Modelo VAR.....	25
Modelo VEC.....	25
Modelos de Efectos Fijos y Aleatorios	26
Resultados Modelo de Efectos Fijos	27
PIB per cápita (PIB pc).....	27
Inflación (Infla)	28
Índice de percepción de la corrupción (IC)	28
Resultados Modelo de Efectos Aleatorios	28
PIB per cápita (PIB pc).....	29

Inflación (Infla)	29
Índice de percepción de la corrupción (IC)	29
Prueba de Hausman y validez de los modelos	30
Pruebas de validación y limitaciones	30
Discusión y comparación	32
Conclusiones y recomendaciones	32
Bibliografía	36
Anexos	41

Introducción

El Bitcoin es una criptomoneda digital cuyo origen se sitúa en el año 2009, según expertos de criptomonedas el creador de esta moneda alternativa es un individuo (o grupo de individuos) identificado bajo el nombre de Satoshi Nakamoto (Nakamoto, 2008). A partir de la primera transacción realizada con el Bitcoin en el año 2010, su cotización y popularidad ha ido incrementando al igual que su utilidad en diversos campos del intercambio económico y la especulación financiera (Chohan & Usman, 2022). Sin embargo, su cotización y usos revelan una gran volatilidad. A partir de la aparición del Bitcoin, muchas otras criptomonedas han sido creadas y han ganado espacio en el mercado de criptomonedas global, como es el caso de: *Ethereum*, *Tether*, *Binance Coin* y *Solana*, entre otras (CoinMarketCap, 2024). Pese a ello, el Bitcoin por ser la primera criptomoneda y la más utilizada no ha dejado de liderar este mercado global.

La aparición del Bitcoin se dio con el objetivo de presentar una alternativa descentralizada para transacciones digitales, originalmente focalizándose en ser una opción independiente al sistema financiero mundial que se basa en la gestión monetaria de monedas soberanas controladas por los estados nación a través de una autoridad monetaria o banco central (Nakamoto, 2008). Para aquellos que prefieren tener más de un método para realizar operaciones seguras, transparentes y privadas, sin la influencia o el control de las autoridades monetarias centralizadas, el mundo de las criptomonedas se abrió como una alternativa factible (Rodríguez Gómez, 2020). Las transacciones tradicionales controladas por instituciones centralizadas, como las autoridades monetarias o bancos centrales, son afectadas por las acciones de dicha autoridad para lograr objetivos de política económica y sus sistemas para supervisar operaciones que puedan ser ilícitas, dichas afectaciones se reflejan en el valor y los costos de transacción de utilizar las monedas soberanas. Quienes quieren evitar estos efectos pueden buscar una alternativa en el mundo de las criptomonedas, por ello las criptomonedas se han vuelto una alternativa a las monedas soberanas para el intercambio económico y la especulación financiera, en el mundo. Entre los objetivos del Bitcoin no está contemplado el reemplazar a las monedas tradicionales en el corto plazo (Chohan & Usman, 2022).

La tecnología que permite la creación del Bitcoin se conoce como *Blockchain*, la cual es un registro público de datos digitales transaccionales almacenados en múltiples servidores diferenciados en la red, todos estos nodos o servidores colaboran para verificar las transacciones y añadirlas a un bloque con una referencia criptográfica del bloque anterior, de esta manera se crea una cadena de bloques inalterable con información verificada, a diferencia de un registro o libro mayor tradicional que almacena datos en bases centralizadas, como en el caso de las monedas soberanas, las cuales tienen un acceso limitado a ciertos individuos (Algorand, 2023).

Para los economistas la definición de dinero es cualquier cosa aceptada generalmente para realizar pagos de deudas o de bienes y servicios en el día a día (Mishkin & Serletis , 2019). En el caso de sus funciones, las más conocidas son asociadas a la aproximación funcionalista del estudio del dinero que se desarrolló en el Siglo XIX, definiendo tres: medio de intercambio aceptado para bienes y servicios, unidad de cuenta como medida para determinar precios en numerarios y reserva de valor a lo largo del tiempo para almacenar riqueza (Mishkin & Serletis , 2019).

El Bitcoin, en la práctica, no cumple con todas las funciones del dinero. El uso del Bitcoin ha tomado fuerza como reserva de valor. Por ejemplo, en países como Argentina y Venezuela la compra de criptomonedas se utiliza para refugiarse de los problemas inflacionarios de la moneda soberana. Sin embargo, según Jordana de

Pozas Poole (2020), la volatilidad extrema del Bitcoin, la falta de regulación y la poca aceptación a nivel mundial como medio de pago han transformado la percepción de los inversores de una moneda digital funcional hacia un activo especulativo.

Los activos especulativos son instrumentos financieros que presentan fluctuaciones considerables en su cotización en periodos cortos de tiempo, su cotización está sujeta a la oferta y demanda, el comportamiento de los inversores y eventos externos (Jordana de Pozas Poole, 2020). La atracción de los inversores hacia el Bitcoin se fundamenta en su posible rendimiento elevado a corto y largo plazo, pero conlleva un alto riesgo por su naturaleza volátil (Rodríguez Gómez, 2020). Debido a estos factores al momento de invertir en activos especulativos como el Bitcoin es crucial poder anticipar movimientos en su cotización, para gestionar el riesgo de pérdidas significativas de manera informada y maximizar beneficios en el corto y largo plazo (Jay, y otros, 2020).

Para poder anticipar movimientos en la cotización del Bitcoin debemos analizar las variables o factores que tienen una relación directa en la cotización de esta criptomoneda. En esta investigación nos centraremos en los factores macroeconómicos. Al momento de investigarlos debemos seleccionarlos cuidadosamente, ya que deben tener relevancia para el mercado global de criptomonedas y tener relación con el comportamiento de los inversores. Si bien la finalidad del Bitcoin es benevolente por surgir como una alternativa para realizar transacciones rápidas y seguras en cualquier parte del mundo. Cuenta con una característica que no ha pasado desapercibida por las mentes criminales: el anonimato. Al ser una criptomoneda descentralizada sus transacciones no pueden asociarse fácilmente a una persona (natural o jurídica) por lo tanto podemos explorar factores globales que favorecerían el uso del Bitcoin para actividades ilícitas lo que incidiría en la demanda de la criptomoneda, como el índice de percepción de la corrupción (CPI). De igual manera existen otros indicadores como el volumen de transacciones de criptomonedas, la cantidad de secuestros de datos a cambio de un rescate pagado en Bitcoin (*ransomware*) que sirven para determinar crímenes en donde el Bitcoin es el principal protagonista (FinancialCrimeAcademy, 2024).

El objetivo de la presente investigación es el análisis de los siguientes factores macroeconómicos: PIB per cápita, tasa de inflación anual e índice de percepción de la corrupción, para determinar si incidieron en la cotización del Bitcoin de manera estadísticamente significativa en el periodo 2013 – 2023. Dicha investigación busca aportar conocimiento para una mejor gestión de portafolio a los inversionistas que han decidido incluir esta criptomoneda en su portafolio de inversiones. En este sentido, el aporte del presente estudio puede ser valioso para la gestión de beneficios y riesgos de inversionistas al momento de tomar una decisión informada y comprender mejor las oportunidades que brinda este mercado financiero de la criptomoneda líder a nivel mundial.

Marco referencial teórico

En el marco teórico exploramos la creación y las características del Bitcoin al igual que la relevancia de los factores macroeconómicos seleccionados para la cotización de esta criptomoneda. El Bitcoin y su origen están vinculados a los fundamentos de utilizar métodos criptográficos para crear una forma de dinero descentralizada y sin intermediarios. Bitcoin fue propuesto por un individuo o grupo de individuos bajo el seudónimo Satoshi

Nakamoto en 2008, mediante la publicación del documento titulado "*Bitcoin: A Peer-to-Peer Electronic Cash System*" (Chohan & Usman, 2022).

Bitcoin: esencia descentralizada y características

El primer desafío que presentó el Bitcoin fue la posibilidad de que una transacción con una criptomoneda Bitcoin sea replicada en un momento diferente gastando el mismo Bitcoin en ambas ocasiones. Este problema es conocido como el doble gasto en transacciones electrónicas. Al ser una moneda descentralizada la solución fue presentada a través de una metodología que se basa en una red servidor a servidor que utiliza la prueba de trabajo para validar las transacciones y registrar su orden en una cadena de bloques, también llamado *blockchain*. Esta estructura permite que la red sea descentralizada y controlada por nodos o servidores que apoyan en la validación y propagación de las transacciones. De esta manera el sistema propuesto representa una innovación significativa en las finanzas digitales al eliminar la necesidad de intermediarios, ofreciendo un mecanismo seguro, transparente y eficiente para transacciones globales (Nakamoto, 2008). El artículo de Davidson & Block (2015) afirma que el diseño técnico del Bitcoin le brinda una resistencia al fraude y derriba cualquier barrera fronteriza para transacciones. Lo que refuerza su atractivo para inversores y agentes económicos en todo el mundo.

La obtención de un bitcoin se lleva a cabo a través de un proceso conocido como minería de criptomonedas, el cual es fundamental para la operación de la red Bitcoin. Este proceso implica la validación de transacciones y la adición de nuevos bloques a la cadena de bloques (*blockchain*), un libro de contabilidad digital que registra todas las transacciones realizadas en la red (Algorand, 2023). La minería consiste en resolver problemas matemáticos complejos, utilizando algoritmos criptográficos (Kroll, Davey, & Felten, 2013). Los mineros, que son los participantes de la red que realizan este trabajo, emplean hardware especializado para llevar a cabo estas operaciones matemáticas. Cada vez que un minero resuelve el problema correspondiente a un bloque, verifica las transacciones contenidas en él, asegurando su validez y evitando el doble gasto. Es pertinente mencionar que la minería de Bitcoin consume grandes cantidades de energía, lo que tiene un impacto ambiental elevado. Una vez que un bloque es validado, se añade a la cadena de bloques, y el minero que realizó la validación recibe una recompensa en forma de nuevos bitcoins. Esta recompensa se reduce aproximadamente a la mitad cada cuatro años en un evento conocido como "*halving*", lo que contribuye a la escasez de la criptomoneda. Además de la recompensa por bloque, los mineros también reciben comisiones por las transacciones incluidas en el bloque que han validado. De este modo, la minería no solo asegura la integridad de la red, sino que también proporciona un incentivo económico para los mineros (Kroll, Davey, & Felten, 2013). En resumen, la minería de criptomonedas es un proceso crítico que no solo facilita la creación de nuevos bitcoins, sino que también mantiene la seguridad y el funcionamiento descentralizado de la red.

Según Meynkhart (2019) la regla del crecimiento de la emisión de Bitcoin establece un límite máximo de 21 millones de monedas y regula su emisión mediante el proceso de *halving*. Este diseño asegura una inflación decreciente que se aproxima a cero hacia el año 2140, creando escasez controlada. Además, la red ajusta la dificultad de minería cada 2016 bloques para mantener un ritmo constante de creación de bloques. Este sistema no solo limita la oferta, sino que, al combinarse con una demanda creciente, tiende a incrementar el valor del Bitcoin.

La tecnología Blockchain funciona como un libro distribuido que registra transacciones de manera segura, eliminando la necesidad de intermediarios (Algorand, 2023). Las transacciones se agrupan en bloques enlazados secuencialmente, formando una cadena inmutable, lo que detecta y complica las modificaciones. La unanimidad en la red asegura que todos los participantes estén de acuerdo en el estado del libro, manteniendo la integridad del sistema sin una autoridad central. Este enfoque permite transacciones verificables en una variedad de sectores (Tapscott, 2016). El Bitcoin ha pasado de ser una curiosidad tecnológica a un activo financiero aceptado, el cual sigue siendo un motor de transformación en la economía digital, con el potencial de generar nuevas innovaciones en el futuro (Chohan & Usman, 2022).

La teoría del dinero y el Bitcoin

Según Estévez (2023) al analizar las tres funciones del dinero más conocidas la criptomoneda Bitcoin no cumple en su totalidad con dichas funciones al no tener una adopción global como medio de intercambio y una limitada cantidad de comercios que la aceptan como forma de pago. La volatilidad de su cotización dificulta el uso del Bitcoin en operaciones económicas cotidianas y dificulta su uso como unidad de cuenta. Finalmente, respecto a la reserva de valor, cumple con las características al ser una opción de valor para almacenar riqueza en el corto y largo plazo, pero con la complicación de la volatilidad de su cotización.

Desde otro punto de vista de la teoría del dinero analizamos el teorema de regresión de Von Mises (1912). El teorema de regresión de Von Mises es una teoría económica que explica el origen y el valor del dinero. Propone que el dinero no tiene valor intrínseco por sí mismo, sino que su valor deriva de su uso en el intercambio. Según este teorema, el dinero es un medio de intercambio que surge cuando una mercancía, que ya tiene un valor en el mercado, es aceptada de manera generalizada para facilitar transacciones. La clave del teorema es que, para que una mercancía se convierta en dinero, debe haber una expectativa de que seguirá siendo aceptada en el futuro. Este proceso comienza con el uso de un bien (como el oro o la plata) en el comercio, y a medida que más personas lo aceptan, se establece una confianza en su uso continuado como medio de intercambio. Así, el valor del dinero se apoya en la creencia de que los demás también lo aceptarán, lo que crea un ciclo de confianza y aceptación. En resumen, el teorema de regresión de Von Mises destaca la importancia de la historia del dinero y cómo su aceptación social y su uso práctico determinan su valor en el tiempo.

Según la investigación de Šurda (2014) el Bitcoin no cumple completamente con los criterios clásicos del dinero de la teoría de Von Mises, introduciendo un nuevo concepto híbrido que combina características de dinero fiduciario y mercancía, por lo que Bitcoin debe considerarse un medio de intercambio con propiedades que no se alinean perfectamente con las definiciones económicas convencionales.

Factores macroeconómicos relevantes

Al no alinearse completamente con las características del dinero, el Bitcoin encuentra aplicaciones en otro campo económico, las inversiones, tal es el caso de Venezuela y Argentina en donde las criptomonedas, especialmente el Bitcoin ha ganado popularidad al comportarse como un refugio frente a la inflación creciente de la moneda local. El cual debe ser gestionado con supremo cuidado y bajo un exhaustivo análisis por su tendencia volátil (Villa Carranza, 2022).

Para determinar las variables macroeconómicas que puedan relacionarse con la cotización del Bitcoin analizamos características propias de los países respecto a la tenencia de Bitcoin: número de cajeros de Bitcoin y minería de Bitcoin. Según Dorta Martínez (2018), el uso del Bitcoin se ha expandido a nivel mundial, pero

existe una serie de países que presentan características favorables para la minería de criptomonedas, como tener un acceso a internet rápido, acceso a energía eléctrica a bajo costo y una aceptación legal del uso de esta criptomoneda, estos países son: Japón, Estados Unidos, Corea del Sur, Reino Unido, Dinamarca, entre otros (DortaMartinez, 2018). En el caso de las naciones con mayor tenencia de Bitcoin se incluyen países como: El Salvador, Ucrania, Bután, Venezuela, Finlandia, entre otros (Forbes, 2023). Finalmente, en relación con el número de cajeros de Bitcoin disponibles por país, los más destacados son: Canadá, Australia, España, Polonia, Suiza, entre otros (Fernandez, 2023).

PIB per cápita

Es la relación entre el valor total de los bienes y servicios finales que se han generado durante un año por el entorno económico de un país, y se puede medir como ingreso, consumo o producción de valor agregado. Es la representación del valor que sería asignado a cada habitante si el ingreso anual generado se distribuyera equitativamente. Por eso también se suele utilizar al PIB per cápita como una aproximación del ingreso nacional per cápita, aunque para obtener el ingreso nacional se deben considerar también el pago neto a factores desde el extranjero y el movimiento neto de transacciones sin contraprestación al exterior. De igual manera se comprende como una medida indirecta de la calidad de vida y del desarrollo económico de una región (INEE, 2009).

Las economías con alto PIB per cápita adoptan el Bitcoin principalmente como un activo especulativo o una herramienta de diversificación de portafolios, gracias a una mayor disponibilidad de ingreso, capacidad de ahorro e inversión, así como una mejor educación financiera, acceso a tecnología, y disponibilidad de acceso a capital. Comprendiendo este alcance, el PIB per cápita teóricamente debe mantener una relación positiva con la cotización del Bitcoin ya que a mayor *PIB per cápita*, *ceteris paribus*, se espera una mayor demanda de Bitcoins (Hassan Hoger, 2022).

Tasa de Inflación anual

Mide el incremento porcentual en los precios de bienes y servicios en un período anual, a través de la tasa de variación anual del Índice de Precios al Consumidor (IPC). Representa la pérdida de poder adquisitivo del dinero, donde un valor más alto indica que los precios están aumentando rápidamente, reduciendo el poder adquisitivo de la moneda. Este indicador es importante para evaluar la estabilidad a nivel macroeconómico de un país (BBVA, 2024).

Es importante denotar que, en periodos de inflación elevada, los agentes económicos suelen buscar opciones para mantener el poder adquisitivo de su dinero. De esta manera, los activos de refugio funcionan como instrumentos financieros que logran mantener o aumentar su valor durante este tipo de periodos. Entre las características de estos activos se encuentra la demanda estable ya que, debido al interés de los inversores, su valor aumenta o se mantiene igual en tiempos de incertidumbre. Asimismo, no tienen una relación con monedas fiduciarias o sus políticas monetarias ya que en periodos de inflación e inestabilidad estas monedas pierden poder adquisitivo (Mishkin & Serletis , 2019).

En países con este tipo de periodos, el oro se ha percibido tradicionalmente como el activo de refugio más reconocido por su escasez y uso histórico. Recientemente, el Bitcoin podría actuar como una herramienta para protegerse contra la creciente inflación. Al ser una moneda descentralizada y con una oferta limitada (21 millones de unidades), el Bitcoin se percibe como un refugio de valor alternativo, especialmente en economías

donde las monedas locales pierden rápidamente su poder adquisitivo. De esta forma, la tasa de inflación teóricamente debe mantener una relación positiva con la cotización del Bitcoin, por el hecho de que, al tener mayor inflación, *ceteris paribus*, se esperaría una mayor demanda de Bitcoins (Torre, 2023).

Índice de percepción de la corrupción (CPI)

El CPI elaborado por *Transparency International* para cada país se construye en base a una encuesta realizada a 13 diferentes fuentes de 12 instituciones, entre las más importantes están: Banco Mundial, Foro Económico Mundial, *Economist Intelligence Unit*, *World Justice Project*, *Bertelsmann Stiftung*, *Freedom House*, *Global Insight Business Conditions and Risk Indicators*, *IMD World Competitiveness Center*, *African Development Bank Country Policy*, *Varieties of Democracy Project (V-Dem)* y *Political Risk Services Group*. Las preguntas se construyen detalladamente abarcando cuestiones esenciales para cada nación como: eficiencia del sistema judicial, integridad de contratación pública, corrupción en fuerzas del orden, uso de recursos públicos, control político y entorno empresarial. Dichas preguntas se realizan a expertos internacionales, ejecutivos, analistas regionales y a empresarios (Transparency, 2024).

Este índice se estima en una escala de 0 a 100, donde 0 indica máxima percepción de corrupción y 100 indica total ausencia de corrupción. Para estimar este índice se debe estandarizar las fuentes de datos al restar la media de cada fuente en el año base al puntaje de cada país y luego se lo tiene que dividir por la desviación estándar de esta fuente en el año base. Después de esto, los puntajes estandarizados se convierten a escala del CPI al multiplicarlos por el valor de la desviación estándar del CPI en el año inicial (2012) y sumando la media del año inicial (Transparency, 2024).

Es importante tomar en cuenta que el CPI incluye un error estándar y un intervalo de confianza del 90% asociado a cada puntaje, lo que captura la variación en los puntajes de las fuentes de datos disponibles. Estas instituciones analizan el nivel de corrupción en el sector público de cada país. Entre la información que analizan están sobornos, malversación de fondos públicos, captura del estado por intereses privados, funcionarios públicos que usan su cargo para lucro personal. Estas instituciones cumplen ciertos criterios como: utilizar una metodología adecuada, usar información certificada por profesionales y calificar el manejo del sector público de varios países representativos, entre otros (Transparency, 2024).

En los países con altos niveles de corrupción y bajos niveles de libertad económica, las personas tienden a buscar sistemas financieros alternativos, como el Bitcoin. Este análisis de otros métodos se debe a la desconfianza en las instituciones tradicionales y a la necesidad de proteger sus activos frente a la corrupción y la falta de transparencia gubernamental. Por otro lado, el anonimato que ofrece el Bitcoin lo hace atractivo para actividades ilícitas, lo que aumenta su demanda en economías con altos índices de corrupción (Johnson, 2020).

En base a la investigación de Johnson (2020), la facilidad para transferir Bitcoin a nivel global permite a las mentes criminales trasladar grandes capitales sin ser detectados por las autoridades. Asimismo, el Bitcoin puede ser utilizado para pagar sobornos que no deben ser rastreados. Para las naciones con altos niveles de corrupción y debilidad institucional, los movimientos de capital ilícitos a través del Bitcoin pueden ser un problema si no se toma las medidas necesarias.

De esta forma, el CPI teóricamente debe mantener una relación negativa con la cotización del Bitcoin, por el hecho de que, al tener un aumento de la percepción de corrupción (disminución del CPI), *ceteris paribus*, se esperaría una mayor demanda de Bitcoins para ser utilizados en actividades ilícitas. Por lo tanto, supondremos

que el Bitcoin es atractivo para actividades criminales que buscan anonimato en sus transacciones, por lo tanto, se espera que al tener mayor corrupción en un país (CPI bajo), *ceteris paribus*, existiría una mayor demanda de Bitcoins.

Hechos estilizados de Kaldor

En su estudio, Kaldor (1963), menciona 6 hechos que representan patrones de crecimiento económico, los cuales son: crecimiento de la relación capital/trabajo por el hecho de que el PIB per cápita crece constantemente a una tasa positiva, crecimiento de la productividad laboral, crecimiento del salario real por trabajador, crecimiento del consumo per cápita, constancia del coeficiente de capital y constancia de las variables distributivas. Aunque estos hechos son confirmados e identificados en varias economías, existen variaciones de crecimiento en algunas economías debido a diferencias estructurales o institucionales.

En el caso de las economías avanzadas, los hechos de Kaldor son fácilmente identificados. Para las economías emergentes y abiertas, pueden existir desviaciones en uno o varios hechos al enfrentar desafíos por falta de inversión o instituciones confiables por lo que se destaca la importancia de considerar todas las características de una economía para un correcto análisis macroeconómico. Estas herramientas son relevantes para identificar tendencias de crecimiento, siempre y cuando se analice individualmente cada macroeconomía y sus particularidades. Es de suma importancia para la investigación el tener en cuenta los hechos estilizados de Nicholas Kaldor y el argumento que soportan por que sirven como una base empírica para el desarrollo de modelos teóricos que explican el crecimiento económico de los países a largo plazo.

Los factores importantes como la acumulación de capital, el progreso técnico, la interacción entre trabajo y capital y la estabilidad institucional ayudan al crecimiento sostenible. Sin embargo, para las economías en desarrollo, la aplicación de estos principios necesita un ajuste para representar las particularidades de cada país, en las que se incluye: calidad de las instituciones, nivel de industrialización y acceso a recursos económicos. Comprendiendo esto, los hechos estilizados de Kaldor sirven como guía para la creación de políticas económicas pertinentes para cada país tomando en cuenta su estabilidad. (Kaldor, 1963).

La investigación de Ortiz y Winkelried (2022) examina las reformas macroeconómicas implementadas en Perú entre 1990 y 2020, destacando cómo éstas contribuyeron a la estabilidad económica y fortalecieron la confianza en las instituciones financieras. Bajo este contexto, los autores asocian los hechos estilizados de Kaldor, como el aumento de la productividad laboral, el crecimiento del PIB per cápita y el consumo, juegan un papel esencial para facilitar la adopción del Bitcoin. Estos cambios económicos percibidos incrementan la capacidad económica de los agentes para invertir en activos digitales, centrándose en países con una base macroeconómica sólida. En el caso de esta investigación, las reformas peruanas que incluyeron políticas monetarias orientadas a controlar la inflación redujeron los riesgos financieros. Ante esta nueva realidad, las condiciones para que las personas exploren tecnologías innovadoras como el Bitcoin eran favorables.

Tomando en cuenta los hechos estilizados de Kaldor (1963), para la presente investigación se analizan naciones con características macroeconómicas diversas, ya que se toman en cuenta países en vías de desarrollo, emergentes y economías industrializadas y desarrolladas. De esta manera, nos aseguramos un panorama completo al igual que resultados diferentes para cada macroeconomía en la que se explora que variable macroeconómica es la que más afectó a la cotización del Bitcoin en el periodo seleccionado. Enfatizando en la elección de diferentes países para nuestra base de datos, podemos acotar que, con estas características los datos no deberían estar sesgados por particularidades propias de regiones ya que se logra capturar la

heterogeneidad económica e institucional presente entre países. Este ajuste permite que las conclusiones sean aplicables a diferentes contextos económicos, lo que nos brinda solidez y eficiencia.

La conexión existente con los hechos estilizados radica en los patrones generales de crecimiento económico, tales como el PIB per cápita más estable y una productividad elevada que es común de las economías avanzadas. Asimismo, la desigualdad económica presente en mayor medida en los países en vías de desarrollo puede aumentar el uso del Bitcoin como alternativa financiera. De esta forma, al tener una diversidad de países aseguramos una gran cantidad de contextos macroeconómicos que brindan validez teórica a nuestra base de datos, al igual que capturamos relaciones complejas y diferenciadas entre las variables macroeconómicas y la cotización del Bitcoin.

Marco referencial empírico

A lo largo del marco empírico exploramos estudios e investigaciones que analizan las relaciones entre factores macroeconómicos y la cotización del Bitcoin. En base a esto, abordamos de manera más detallada los enfoques utilizados para identificar tendencias. El realizar esto nos permite situar nuestra investigación en un contexto aplicado a la realidad y que presenta relevancia en el avance del estado del arte del estudio de las fluctuaciones de valor del Bitcoin.

Macroeconomía y Bitcoin

Según la investigación de Wang, Sarker & Bouri (2023), respecto a la relación entre la cotización del Bitcoin, el índice de precios al consumidor (IPC) y el índice de incertidumbre de la política económica (EPU, por sus siglas en inglés) en Estados Unidos, se determinó que el IPC afecta de manera positiva al Bitcoin en un periodo corto de tiempo, y el EPU afecta de manera negativa a la cotización del Bitcoin en el corto y largo plazo. Estos resultados se lograron con la ayuda de datos mensuales de 2010 hasta 2020 aplicados a métodos econométricos como pruebas de causalidad no lineales y de *Granger*.

Según el artículo de Torre (2023), que examina variables macroeconómicas y tecnológicas en su búsqueda de entender la actividad de minería de las criptomonedas. El autor consideró: la dificultad de minería, el número de cajeros automáticos, la tasa de fondos federales (tasa referencial en EE. UU), oferta monetaria (M1) y tasa de inflación global. Su hallazgo, por medio del método de regresión lineal múltiple, fue que la dificultad de minería y la actividad minera tiene un impacto con signo positivo estadísticamente significativo en la cotización del Bitcoin. Lo que respalda el enfoque del autor respecto a la demostración de que la cotización del Bitcoin es influenciada en mayor medida por características intrínsecas de su ecosistema, en lugar de situaciones macroeconómicas externas. Para el caso de la tasa de inflación global, tiene un impacto positivo estadísticamente significativo, solo que en menor medida respecto a las otras variables. Lo que indica que en periodos de incertidumbre los inversionistas podrían buscar refugio en activos descentralizados como esta criptomoneda.

Las fuerzas de la oferta y demanda influyen en la determinación de la cotización del Bitcoin. La oferta representa a los agentes económicos que poseen Bitcoin y desean venderlo. Mientras que la demanda la conforman los agentes económicos que poseen divisas internacionales y desean adquirir Bitcoin. Debido a esta interacción, la cotización del Bitcoin y la cantidad estará determinados por el punto de equilibrio entre oferta y demanda en un

periodo determinado teniendo en cuenta la oferta limitada total de Bitcoin (21 millones) y la dificultad de los procesos de formación de nuevas criptomonedas Bitcoin. Por lo tanto, esta investigación estudia las relaciones de la cotización del Bitcoin con las variables macroeconómicas seleccionadas, buscando analizar la relación entre estas variables macroeconómicas y la cotización de esta criptomoneda.

La investigación de Hassan Hogger (2022) analiza el impacto de actos regulatorios sobre la cotización de Bitcoin utilizando modelos econométricos de series temporales y mínimos cuadrados ordinarios. Las variables explicativas que utilizó son: categorías de regulación (positiva o negativa) y PIB per cápita de algunos países del G20. El autor descubrió que, ante regulaciones negativas, como prohibiciones, se tiene un efecto significativo y negativo en la cotización de Bitcoin. Mientras que normativas positivas, como el reconocimiento de criptomonedas como moneda de curso legal, tienen un efecto positivo en la cotización. Además, las regulaciones provenientes de países con alto PIB per cápita generan un impacto más significativo en los mercados globales.

Regulación y economía del crimen

El artículo de Saldaña Taboada (2017) explora las determinantes del uso de criptomonedas en especial el Bitcoin para actividades criminales, la autora analiza casos reales como la operación “Tulipán Blanco” y llega a la conclusión de que el anonimato, la descentralización y el complicado rastreo de las transacciones del Bitcoin permiten a las mentes criminales blanquear capitales y evadir a las autoridades en sus operaciones, lo que presenta un desafío para los gobiernos y las instituciones de seguridad ante el fortalecimiento de una nueva forma de crimen digital. Entre las consecuencias a corto plazo que pueden tener estas operaciones criminales están: generar desconfianza en la población general respecto a la adopción de criptomonedas para usos digitales, la evasión de controles financieros internacionales por parte de criminales y finalmente una dificultad elevada para las autoridades gubernamentales sobre controlar las transacciones por su descentralización.

Según el artículo de Asthana (2024) en el que analiza si los niveles de corrupción, medidos por el Índice de Percepción de la Corrupción (CPI), están relacionados con la participación en el mercado de criptomonedas a nivel mundial utilizando datos de 56 países y aplicando modelos de regresión transversal, el autor descubre una relación inversa entre el CPI y la participación en criptomonedas, lo que sugiere que los países más corruptos tienen mayor adopción de criptomonedas. Este autor menciona que las criptomonedas son más populares en estos países debido a sus características esenciales que facilitan actividades como el lavado de dinero.

Bitcoin: refugio frente a la incertidumbre

Según la investigación de Ibrahim & AliBasah (2022), acerca de la relación de la cotización del Bitcoin con el oro y el dólar estadounidense utilizando pruebas de regresión, correlación y test de causalidad de Granger, se determinó que existe una relación significativa entre la cotización del Bitcoin y el del oro en el periodo comprendido entre 2015 y 2020. Por lo tanto, si el valor del oro aumenta la cotización del Bitcoin aumentará. Mientras que la relación del Bitcoin con el dólar estadounidense es insignificante. Pese a ello, los autores demostraron que existe una correlación negativa entre el Bitcoin y el dólar, por lo tanto, si el dólar estadounidense se aprecia el Bitcoin bajará de valor.

Por lo tanto, el oro y el Bitcoin se convierten en sustitutos del dólar y de otras divisas internacionales para mantener el valor del capital ante situaciones de crisis o eventos económicos adversos, en tiempos de incertidumbre (Jordana de Pozas Poole, 2020). Sin embargo, la estabilidad del precio del oro frente a la

volatilidad de la cotización del Bitcoin puede ocasionar grandes diferencias en el uso de estos activos como refugio de valor (Ibrahim & AliBasah, 2022). Estas investigaciones presumen al oro y al Bitcoin como activos de refugio ante crisis, los inversionistas convierten sus capitales a oro y a Bitcoin con la esperanza de que mantengan su poder adquisitivo y su valor de mercado.

La investigación de Arena (2021) explora cómo las condiciones económicas de Argentina, marcadas por una inflación promedio del 35 % anual y políticas que restringen el acceso a divisas internacionales, han impulsado el interés de los agentes económicos hacia el Bitcoin como alternativa financiera. La inestabilidad macroeconómica y la inflación han debilitado a la moneda local (peso argentino) y han generado desconfianza en el sistema bancario, lo que ha abierto un espacio para el uso del Bitcoin como un refugio frente a la devaluación y la inflación. Su emisión limitada y su facilidad para transferencias internacionales destacan el potencial del Bitcoin como una solución económica. Transformando el uso especulativo que se le ha dado a esta criptomoneda hacia una adaptación a las necesidades de economías inestables como la argentina.

Evolución de la cotización del Bitcoin

En el artículo de Uras, Marchesi, Marchesi & Tonelli (2020) se utilizan modelos de regresión simple y múltiple para explorar si es posible predecir con un grado aceptable de precisión los precios de cierre diario de diversas criptomonedas entre ellas el Bitcoin, los autores concluyeron que al dividir en regímenes de tiempo de 120 días en vez de analizar las series completas para Bitcoin, los modelos de regresión simple y múltiple son efectivos en términos de predicción ya que presentaron más distribución alrededor de la media, menor varianza y un error de desviación (MAPE) del 0,7% respecto a los valores reales.

La cotización del Bitcoin durante el periodo de análisis (2013 – 2023), mostró una amplia volatilidad, alcanzando máximos históricos en 2021. Bitcoin alcanzó este logro gracias a factores macroeconómicos, sociales y tecnológicos que impulsaron su cotización. La incorporación del Bitcoin en portafolios de inversión, el *halving* de 2020, la adopción del Bitcoin como moneda oficial de El Salvador y las políticas monetarias expansivas tras la pandemia del COVID-19 reforzaron la perspectiva del Bitcoin como un activo valioso y un refugio frente a la inflación (Jagati, 2022). Los detalles de la dinámica de la cotización del Bitcoin durante el período de estudio se pueden ver a continuación en el Gráfico 1.

Gráfico 1: Evolución de la cotización del Bitcoin (PB) (2013 - 2023)



Fuente: CoinMarketCap Elaboración: Emilio Gavilanes

Alcance de la investigación

Si bien los estudios analizados proporcionan un buen fundamento para explorar las relaciones macroeconómicas y la cotización del Bitcoin, también presentan limitaciones a considerar. La investigación de Torre (2023), se enfoca en variables tecnológicas relevantes, pero dada su naturaleza no son el objetivo de esta investigación. El artículo de Ibrahim & AliBasah (2022) destaca la relación del Bitcoin con el oro, pero no presenta una relación directa de las variables macroeconómicas con esta criptomoneda. Esta investigación se centró en explorar y profundizar el análisis de las variables macroeconómicas y su relación con la cotización del Bitcoin en un contexto global.

Las variables macroeconómicas, como la tasa de inflación, el PIB per cápita y el índice de percepción de la corrupción (CPI), juegan un papel crucial al momento de entender el comportamiento de la cotización del Bitcoin durante el periodo de 2013 a 2023. Estos factores nos permiten analizar fluctuaciones en su cotización y relacionarlas con la economía global y los factores vinculados a la economía del crimen. Sin embargo, no ha sido común que estas variables sean estudiadas dentro de un marco econométrico global que considera tanto economías desarrolladas como en vías de desarrollo.

Para solventar el objetivo de la presente investigación, se construye una base de datos que abarca 20 países de distinto nivel de desarrollo y ubicación geográfica, con la finalidad de tener datos diversos y confiables de todas las regiones. Se compiló datos anuales de los siguientes países: Alemania, Argentina, Australia, Austria, Brasil, Canadá, Corea del Sur, Dinamarca, El Salvador, España, Estados Unidos, Francia, India, Italia, Japón, Nigeria, Reino Unido, Rusia, Sudáfrica, Venezuela. Estos países tienen elementos clave para la economía de criptomonedas como: posesión de Bitcoins en reservas ya sea por adquisición propia del gobierno central o por haber recuperado grandes capitales de Bitcoin de organizaciones criminales, presencia de cajeros automáticos de esta criptomoneda y algunas políticas que favorecen las transacciones digitales. El objetivo de analizar esta base de datos de panel es identificar elementos que faciliten una comprensión más profunda de los factores que incidieron en la cotización del Bitcoin. Mediante la interpretación de los coeficientes obtenidos, presentamos las características principales del comportamiento de la cotización del Bitcoin durante el periodo de estudio.

Propuesta metodológica

Para la presente investigación, se escoge un enfoque cuantitativo porque permite analizar de manera precisa y objetiva cómo las variables macroeconómicas seleccionadas se relacionaron con la cotización del Bitcoin. Mediante el uso de modelos econométricos, como regresión múltiple por mínimos cuadrados ordinarios (MCO), modelo de Vector AutoRegresivo (VAR), Vector de Corrección de Error (VEC) y Modelos de Efectos Fijos y Aleatorios se trata estas variables para analizar cómo se relacionaron con la cotización del Bitcoin. Estos métodos econométricos son seleccionados como herramientas porque facilitan la interpretación de las relaciones entre más de una variable (Wooldridge, 2010). Este enfoque cuantitativo nos brinda resultados concretos y medibles, permitiendo responder la pregunta de investigación de manera robusta.

Para la obtención de los datos de las variables macroeconómicas seleccionadas, así como las cotizaciones del Bitcoin, utilizamos fuentes confiables como el Banco Mundial, FMI, *Transparency.org*, Statista y *CoinMarketCap*. Una vez agrupados los datos, comenzamos la fase de análisis, en el que se exploran las características de los factores macroeconómicos de cada país respectivamente. Posteriormente, elaboramos una regresión lineal múltiple, como punto de referencia de partida para determinar las relaciones entre las variables y su significancia estadística. Esta regresión se corre para cada país. A su vez, se aplicaron modelos VAR y VEC para analizar dinámicas temporales a corto y largo plazo. Finalmente se aplica el Modelo de Efectos Fijos y el Modelo de Efectos Aleatorios en el análisis de datos de panel y se validan los resultados con la prueba de Hausman para garantizar cuál es el mejor resultado (Wooldridge, 2010).

Los métodos de aprendizaje supervisados constan de variables predictoras (X) y una variable de respuesta (Y), las cuales predicen o infieren nuevas observaciones (Verbeek, 2012). Este enfoque econométrico nos brinda resultados concretos, permitiendo responder a la pregunta de investigación de manera sólida y precisa, como se expone más adelante.

Análisis Exploratorio

Durante el proceso de construcción de los modelos econométricos de regresión lineal múltiple, modelo VAR y VEC nos encontramos con problemas comunes de los mismos. El haber generado datos interpolados, nos ayuda a solucionar los valores faltantes de la base de datos, lo que hubiera disminuido la calidad de la predicción y aumentado el sesgo para el caso de la regresión lineal múltiple. De igual forma, los nuevos datos son continuos, lo que nos ayuda a captar tendencias con mayor precisión, identificar coeficientes más estables y reducir la autocorrelación (Atkinson, 2004).

Los problemas que pueden existir en uno o varios de nuestros modelos y las pruebas que podemos realizar para identificarlos son:

Regresión múltiple por MCO

- **Multicolinealidad:** Puede causar que los coeficientes individuales tengan intervalos de confianza amplios, lo que dificultaría la determinación del efecto real de cada variable. Se utiliza una prueba VIF para determinar la relación entre variables.
- **No normalidad de los residuos:** El posible hecho de que los residuos no siguen una distribución normal puede generar dificultades al interpretar si los coeficientes son significativos. Esto debido a pruebas de significancia menos fiables. Podemos identificar este problema con la prueba de Shapiro-Wilk.
- **Autocorrelación de los errores:** valores cercanos a 0 podrían indicar que los errores están correlacionados en el tiempo y sugeriría que el modelo no captura relaciones dinámicas entre las variables. La prueba de Durbin-Watson nos indica si existe este problema.
- **Heterocedasticidad:** Es común que se perciba cuando la varianza de los errores no es constante a lo largo de los valores, lo que podría afectar a los intervalos de confianza y a los valores p. La identificamos con una prueba de Breusch-Pagan.

VAR y VEC

- Estacionariedad: Las series de tiempo de las variables deben ser estacionarias, de lo contrario podrían causar regresiones espurias. Se comprueba con una prueba Dickey-Fuller Aumentada (ADF).
- Estabilidad: Si uno o más valores propios del modelo están fuera del círculo unitario, no se puede garantizar de forma robusta que las dinámicas de las series tengan coherencia a lo largo del periodo estudiado. Se realiza una prueba de estabilidad para identificar si el modelo es estable o no.
- Rezagos: Si se selecciona un número o muy alto o bajo puede llevar a omisión de información o un sobreajuste del modelo. Podemos usar criterios de información como AIC (Akaike), BIC (*Bayesian*) o HQIC (Hannan-Quinn).
- Autocorrelación: Se evalúa si los residuos del modelo están libres de autocorrelación, en caso de que exista puede indicar problemas en la especificación del modelo y comprometer los resultados y su validez. Se realiza una prueba de Ljung-Box para determinarla.
- Rango de cointegración: Una elección incorrecta de este rango puede afectar los resultados finales, ya que inicialmente se debe verificar que las variables estén cointegradas. Verificamos a través de una prueba de Johansen.

Datos de Panel (Efectos fijos y aleatorios)

- Prueba de Hausman: Nos indica si utilizar Modelos de Efectos Fijos o Aleatorios es más adecuado, en base a efectos individuales y su correlación con la variable explicativa.
- Prueba de *poolability*: Evalúa si es apropiado estimar un modelo agrupado sin efectos específicos o si es necesario considerar efectos individuales. Es decir, identifica si es más adecuado evaluar individualmente por países o como un grupo sin diferenciar.
- Autocorrelación: A través de una prueba de Woolridge, se determina si los errores de un periodo están correlacionados con los del periodo anterior.
- Para el caso de Modelos de Efectos Fijos y Aleatorios, utilizamos las mismas pruebas de validación que en el modelo de regresión lineal múltiple.

Interpretación de las pruebas

Para confirmar que el modelo cumple con los supuestos básicos de los modelos por analizar, debemos entender las pruebas que realizamos. Comenzando con la regresión lineal múltiple. Al verificar la multicolinealidad utilizando el Factor de Inflación de la Varianza (VIF), detectamos si las variables independientes están demasiado relacionadas entre sí. Si los resultados son mayores a 10 (>10) significa que existe multicolinealidad problemática. Como siguiente paso, aplicamos la prueba de Breusch-Pagan para identificar posibles problemas de heterocedasticidad. En la cual la hipótesis nula (H_0) sería que los residuos son homocedásticos y la hipótesis alternativa (H_1) es que los residuos presentan heterocedasticidad. En el caso de un p-valor menor a 0.05 se rechaza la hipótesis nula y se concluye en la presencia de heterocedasticidad en los residuos. Asimismo, corremos la prueba de Shapiro-Wilk para verificar la normalidad de los residuos, si el p-valor es mayor a 0.05 los residuos son normales y si el p-valor es menor o igual a 0.05 los residuos no son normales. Finalmente, corremos la prueba de Durbin-Watson para comprobar si existe autocorrelación en los errores. Si el resultado de la prueba es cercano a 2, no hay evidencia de autocorrelación, si el valor es alejado de 2, existe autocorrelación positiva o negativa (Stock & Watson, 2012).

Para validar los modelos VAR y VEC comenzamos con la prueba de estacionariedad ADF, en la cual, la hipótesis nula (H_0) es que la serie no es estacionaria y la hipótesis alternativa (H_1) es que la serie es estacionaria. En el caso de un p-valor menor a 0.05 se rechaza la hipótesis nula y se concluye que la serie es estacionaria. A continuación, realizamos una prueba de rezagos de los tres criterios de información (AIC, BIC, HQIC) para lograr capturar relaciones dinámicas entre variables al escoger un número óptimo de rezagos. Para la prueba de estabilidad, si los valores propios son menores a 1, el modelo es estable. En el caso de que algún valor propio sea mayor o igual a 1 el modelo no será estable. Asimismo, se corre una prueba Ljung-Box para determinar si hay autocorrelación, la hipótesis nula (H_0) sería que los residuos no están autocorrelacionados y la hipótesis alternativa (H_1) es que los residuos están autocorrelacionados. En el caso de un p-valor mayor a 0.05 no se rechaza la hipótesis nula y se concluye que no hay autocorrelación significativa en los residuos. Habiendo realizado estas pruebas anteriores, finalmente llegamos a una prueba de cointegración de Johansen, en la cual la hipótesis nula (H_0) es que no existe cointegración y la hipótesis alternativa (H_1) es que existe al menos una relación cointegrada de largo plazo entre las variables (Enders, 2014).

Finalmente, para la confirmación y validación del Modelo de Efectos Fijos y el Modelo de Efectos Aleatorios se realiza una prueba de Hausman. A través de una evaluación de la significancia de cada modelo, la hipótesis nula (H_0) viene a comprobar que el Modelo de Efectos Aleatorios es más adecuado, mientras que la hipótesis alternativa (H_1) presenta al Modelo de Efectos Fijos como el más adecuado. Si el p-valor es menor a 0.05, se rechaza la hipótesis nula y se concluye que el Modelo de Efectos Fijos es el más adecuado. Asimismo, se deben correr las mismas pruebas del modelo de regresión lineal múltiple para estos dos Modelos (Efectos Fijos y Aleatorios). De igual forma, la prueba de *poolability* tiene una hipótesis nula (H_0), que viene a comprobar si las diferencias entre países no son significativas, mientras que la hipótesis alternativa (H_1) presenta las diferencias entre países como significativas. Si el p-valor es menor a 0.05, se rechaza la hipótesis nula y se concluye que el Modelo de Efectos Fijos es más adecuado que el modelo agrupado (Wooldridge, 2010), por último, se realiza una prueba de Wooldridge para determinar si existe autocorrelación en los errores, la hipótesis nula (H_0) indica que no existe autocorrelación, mientras que la hipótesis alternativa (H_1) indica que existe autocorrelación en los residuos. Si el p-valor es menor a 0.05, se rechaza la hipótesis nula y se concluye que existe autocorrelación en los errores del modelo (Wooldridge, 2010).

Métricas de evaluación

Regresión lineal múltiple por MCO

- Significancia del modelo global (*Prob F-statistic*): Evalúa si al menos una de las variables independientes tiene un efecto significativo sobre la variable dependiente. El valor p debe ser menor a 0.05 para que exista significancia global.
- R-cuadrado (R^2): Es una medida de que porcentaje de la variación de la variable dependiente se puede explicar con las variables contenidas en el modelo. Un valor de 0 indica que el modelo no explica nada, mientras que los valores más cercanos a 1 explican un alto grado de la variabilidad de la variable independiente por al menos una de las variables explicativas del modelo.
- Valor p de cada coeficiente: Evalúa si cada variable independiente del modelo tiene una relación significativa en la variable dependiente. Valores p menores a 0.05 ($p < 0.05$) tienen un efecto estadísticamente significativo, mientras que valores p mayores a 0.05 ($p > 0.05$) indican que no hay evidencia para que la variable tenga una relación significativa.

VAR

- Valor p de los coeficientes: Para que el coeficiente tenga una significancia estadística debe tener un p-valor menor a 0.05 ($p < 0.05$)
- Criterios de información: El AIC, BIC y HQIC indicaran valores. Los valores más bajos indican un modelo con mejor ajuste.
- Estabilidad del modelo: Las raíces del polinomio deben estar dentro del círculo unitario para que el modelo sea adecuado y las interpretaciones sean apropiadas.

VEC

- Coeficientes de integración: Representan relaciones de equilibrio a largo plazo entre las variables.
- Significancia valores p: Evaluar si los rezagos son estadísticamente significativos ($p < 0.05$)
- Velocidad de ajuste: Indica la velocidad con la que desviaciones del equilibrio se corrigen.
- Rango de cointegración: Determina cuantas relaciones de equilibrio a largo plazo existen.

Modelos de Efectos Fijos y Aleatorios

- Prueba F de significancia global: Evalúa si la estimación de los parámetros del Modelo, por Efectos Fijos, es significativa de manera global. Esta prueba indica si las variables independientes de nuestro modelo tienen algún tipo de efecto estadísticamente significativo sobre la variable dependiente de forma unificada.
- R-cuadrado (R^2): Al igual que en el modelo de regresión múltiple, un valor de 0 indica que el modelo no explica nada, mientras que los valores más cercanos a 1 explican un alto grado de la variabilidad de la variable independiente por al menos una de las variables explicativas del modelo.
- Valores p de los coeficientes: Indica si las variables explicativas o independientes tienen un efecto significativo ($p < 0.05$) sobre la variable dependiente.
- Varianza de los efectos aleatorios: Mide la proporción de variabilidad total que se debe a las diferencias entre las unidades.
- Prueba de Hausman: Evalúa cuál de los dos modelos es el más adecuado. Un $p < 0.05$ indica que el Modelo de Efectos Fijos es preferible.

Variable dependiente

La investigación tiene como variable dependiente o de respuesta a la cotización promedio anual del Bitcoin (PB) durante el periodo de tiempo comprendido entre 2013 a 2023.

Variables independientes

PIB per cápita (PIB pc), Tasa de inflación anual (infla) e Índice de percepción de la corrupción (IC) de los países seleccionados en el periodo de tiempo entre 2013 a 2023.

Tabla 1: Diccionario de variables

	Detalle	Unidad
Fecha	Día/mes/año	Numeros enteros
Pais	Nombre	Objeto de texto
PIB pc	Producto Interno Bruto per cápita	Dolares de Estados Unidos (con decimales)
Infla	Tasa de variación del IPC	Porcentajes (con decimales)
IC	Índice de corrupción	Numeros enteros (rango 0-100), para 0 máxima corrupción y 100 mínima corrupción (con decimales)
PB	Precio del Bitcoin (cotización Spot)	Dolares de Estados Unidos (con decimales)

Elaboración: Emilio Gavilanes

Modelos econométricos aplicados

La presente investigación analiza más de una variable o factor macroeconómico, por lo tanto, los modelos elegidos son los adecuados. Para construir la base de datos, se obtiene la información anual de las variables para cada país de fuentes confiables. Los valores para el PIB per cápita y la tasa de inflación los recopilamos del Banco Mundial, FMI y Statista, mientras que, los valores del índice de percepción de la corrupción los recopilamos de *Transparency International*. Para la variable dependiente PB, utilizamos la cotización promedio anual para todos los años dentro del periodo seleccionado en cotización de cierre mensual en *Spot*, ya que captura una visión más estable de la cotización del Bitcoin a lo largo del periodo. Los datos se obtienen de *CoinMarketCap*.

Regresión lineal múltiple por MCO

Al utilizar el modelo de regresión lineal múltiple, se observa una mejora inicial en la precisión del modelo como resultado del conjunto de variables independientes interactuando simultáneamente. Este modelo permite, a través de la estimación de los coeficientes de regresión, identificar relaciones parciales entre cada variable independiente y la dependiente, de igual manera, es el modelo base para desarrollar modelos econométricos más avanzados, como los de efectos fijos y aleatorios (Stock & Watson, 2012). Sin embargo, en este caso, el modelo presenta limitaciones debido a problemas de micronumerosidad ya que el tamaño de la base de datos no es lo suficientemente grande como para garantizar que las estimaciones obtenidas sean confiables. Esto nos lleva a la necesidad de recurrir a la interpolación *spline* cúbica como solución adecuada para tratar de obtener resultados precisos y sólidos. Esta técnica es complementaria y se utiliza para abordar los problemas presentes en el modelo, lo que nos permite superar las restricciones de la micronumerosidad y poder avanzar de manera adecuada con el análisis econométrico.

Interpolación de datos mensuales a partir de una base de datos anuales

Ante la limitada cantidad de datos por país a nivel anual, se utiliza un mecanismo de interpolación de datos a nivel mensual, respetando la tendencia de datos anuales para las variables explicativas (PIB pc, Infla, CPI). Mientras que para la variable de respuesta (PB), los datos de corte mensual en el periodo comprendido si están disponibles. El interpolar los datos a nivel mensual nos brinda una mejora en la robustez del modelo ya que se incrementa el número de observaciones. De igual manera, la estimación de parámetros y la significancia estadística de las variables mejora. Al tener más de una variable explicativa, este proceso redujo la varianza de las estimaciones (Atkinson, 2004).

Se aplica una interpolación *spline* cúbica para las variables macroeconómicas. Este proceso nos permite generar datos mensuales respetando la tendencia de los datos anuales conocidos sin introducir cambios poco realistas en la serie de tiempo, de igual manera este método minimiza los errores al mejorar el equilibrio de los

datos. Debido a las características de las variables macroeconómicas, realizar este proceso mejora la precisión del modelo. Para la validación de los datos interpolados generados, visualizamos las series temporales por país para verificar si las tendencias generadas son concordantes y continúan de forma natural. Este proceso nos permite asegurar el mantenimiento de las características de los datos originales (Atkinson, 2004).

Sin embargo, a pesar de la aplicación de esta técnica, la autocorrelación en los modelos de regresión múltiple para cada país persiste. Invalidando la significancia de los resultados obtenidos debido a que pueden ser relaciones espurias entre las variables. Esta situación nos lleva a la aplicación de modelos VAR y VEC que se ajustan especialmente para capturar dinámicas temporales entre variables para un análisis más robusto.

Vector AutoRegresivo (VAR) y Vector de corrección de error (VEC)

Una de las características de los modelos VAR y VEC es que no requieren diferenciar entre variables independientes y dependiente porque cada variable depende de sus rezagos propios y de los rezagos de las otras variables incluidas en el modelo. Por esta razón, estos modelos pueden ser útiles para analizar variables interactuando entre ellas a lo largo del periodo de estudio siempre y cuando estas relaciones existan y los resultados sean verificados por las pruebas de validación.

Se realiza la construcción de un modelo VAR porque nos permite analizar la dinámica de varias variables interrelacionadas en el tiempo. El modelo VAR modela una función lineal de sus propios rezagos y de las demás variables del modelo (Enders, 2014). Para la presente investigación, se ajustan de manera adecuada ya que nos sirven para estudiar la interacción entre variables macroeconómicas en la cotización del Bitcoin a lo largo del periodo de estudio seleccionado.

Para el caso del modelo VEC, es una variante del modelo anterior, solo que maneja la cointegración de las series temporales o las relaciones de equilibrio a largo plazo que existan en el modelo. El modelo VEC utiliza las mismas series de tiempo estacionarias de los modelos VAR y solamente se añade el término de corrección. Esto facilita el análisis de los resultados ya que, de existir coeficientes significativos, estarían respaldados por conexiones reales y no por tendencias presentes entre variables. La utilidad de este modelo radica en su capacidad para modelar relaciones a corto y largo plazo al mismo tiempo. Además, el término de corrección cuantifica la rapidez de ajuste de vuelta hacia el equilibrio que tienen las variables tras un evento inesperado (*shock*) (Enders, 2014).

Transformaciones

Para el análisis de las series de tiempo un factor clave es la estacionariedad de las variables independientes y dependiente. Según Enders (2014), las series no estacionarias pueden variar con el tiempo en sus propiedades estadísticas, lo que podría conducir a resultados espurios por que podría existir una tendencia en las variables macroeconómicas y la relación entre las mismas podría no tener un vínculo real. Si es que contamos con variables no estacionarias, aplicar transformaciones como la primera diferencia podría ser lo más adecuado para brindar validez a nuestros modelos.

Este método es justificado ya que elimina las tendencias determinísticas al tomar la diferencia entre valores consecutivos. La fórmula aplicada para las series temporales consta de seleccionar la variable específica, tomar el valor de la serie en el periodo actual (t) y restar el valor de la serie del periodo anterior (t-1). Es importante tomar en cuenta que al trabajar con variables macroeconómicas como el PIB per cápita o la inflación a través

de un periodo de tiempo específico, pueden presentar tendencias, las cuales se corrigen con el método de primera diferencia. Esta técnica preserva las dinámicas de corto plazo, facilita la interpretación de los modelos y brinda robustez a los resultados obtenidos (Enders, 2014).

Modelo de Efectos Fijos

En el caso de los Modelos de Efectos Fijos, son útiles para analizar datos de panel en casos particulares donde se debe controlar las diferencias específicas para cada país. Este modelo elimina patrones temporales que pueden causar autocorrelación y mejora la calidad de las estimaciones a través de las transformaciones internas (Wooldridge, 2010). Asimismo, es adecuado cuando existe heterogeneidad no observada que podría afectar resultados y que varía entre países. El enfoque de este modelo elimina las influencias de características de cada país que son constantes en el tiempo y que podrían afectar a los resultados (Wooldridge, 2010). Para la presente investigación es útil al estudiar las variaciones dentro de cada país a lo largo del tiempo. La fórmula para este modelo es la siguiente:

Ecuación 1: Fórmula para Modelo de Efectos Fijos

$$PBit = \alpha_i + \beta_1(PIB_{pc})_{it} + \beta_2(Infla)_{it} + \beta_3(IC)_{it} + u_{it}$$

Elaboración: Emilio Gavilanes

En la cual ***PBit*** es la cotización del Bitcoin en el país *i* en el año *t*, α_i es el efecto fijo para cada país, el cual atrapa características constantes en el tiempo, $(PIB_{pc})_{it}$, $(Infla)_{it}$, $(IC)_{it}$, son las variables independientes para el país *i* en el año *t*. $\beta_1, \beta_2, \beta_3$ son los coeficientes que miden el efecto de las variables independientes sobre la variable dependiente y finalmente ***uit*** es el término de error que captura la variación no explicada del modelo.

En los modelos econométricos es común que contemos con problemas de autocorrelación en las variables, por lo tanto, al aplicar Modelos de Efectos Fijos podemos mitigar en parte este problema. Las transformaciones internas que realiza este modelo se basan en la eliminación de cualquier característica constante en el tiempo para cada país, lo que rompe las tendencias que dan lugar a la autocorrelación. Asimismo, permite que los estimadores capturen las variaciones de manera adecuada al reducir los patrones temporales no explicativos (Stock & Watson, 2012). Sin embargo, debemos tener en cuenta que, si existen problemas de autocorrelación significativa en nuestro modelo, esta transformación no la elimina por completo. En este caso, el uso de errores robustos ayuda a capturar ciertas dinámicas temporales y a reducir la autocorrelación (Stock & Watson, 2012).

Modelo de Efectos Aleatorios

Este modelo asume que las diferencias no observadas entre países no están correlacionadas con las variables explicativas y son tratadas como una fracción del término de error, lo que nos ayuda a reducir la autocorrelación (Stock & Watson, 2012). Para el caso de nuestra investigación, el modelo asume que las diferencias específicas entre los países son aleatorias y es pertinente para analizar un panel grande de datos lo que da como resultado una estimación adecuada (Wooldridge, 2010). La fórmula para este modelo es:

Ecuación 2: Fórmula para Modelo de Efectos Aleatorios

$$PBit = \alpha + \beta_1(PIB_{pc})_{it} + \beta_2(Infla)_{it} + \beta_3(IC)_{it} + \mu_i + u_{it}$$

Elaboración: Emilio Gavilanes

En esta ecuación, los términos son iguales al Modelo de Efectos Fijos a excepción de μ_i , el cual es un componente aleatorio específico del país i que captura las diferencias entre los países. La elección entre los modelos depende de la estructura de la base de datos y las características propias de las variables independientes y recae en la prueba de Hausman, la cual evalúa las especificaciones de cada modelo y emite un resultado sobre el que más se ajusta al modelo y es más adecuado (Wooldridge, 2010).

Prueba de Hausman

La prueba de Hausman es importante porque nos permite visualizar si las características no observadas propias de cada país tienen algún tipo de correlación con nuestras variables macroeconómicas. Por este motivo, la hipótesis nula propone que no existe tal correlación, y el Modelo de Efectos Aleatorios sería el más adecuado al tener estimadores consistentes. En cambio, si se rechaza la hipótesis nula, es porque en nuestro modelo existe una correlación y debemos optar por usar un Modelo de Efectos Fijos al tener mayor pertinencia y solidez para tratar estas características de nuestros datos (Wooldridge, 2010).

Limitaciones de la investigación

La presente sección recopila las limitaciones que están presentes a lo largo de la investigación, las cuales surgen desde las características de la base de datos hasta los modelos econométricos usados. Un factor clave de toda investigación es tener en cuenta las limitaciones ya que resaltan las complejidades del análisis económico en el mercado de criptomonedas.

La primera de ellas se encuentra en las pruebas de validación de los modelos econométricos que se utilizan (regresión múltiple, VAR, VEC, Modelo de Efectos Fijos y Modelo de Efectos Aleatorios) en este estudio. La presencia de endogeneidad afecta a todos los modelos al generar estimaciones sesgadas, ya que puede surgir por diversos motivos. Entre ellos se encuentra la omisión de variables relevantes, en la cual el modelo puede producir sesgos en los coeficientes si no se toma en cuenta características que afectan a la variable dependiente y a las independientes. Asimismo, los errores de medición en las variables independientes pueden generar una correlación entre estas y el término de error, lo que distorsiona los resultados. Finalmente, la simultaneidad puede generar autocorrelación en los errores e incrementar la posibilidad de obtener resultados espurios, al tener variables explicativas que se afectan entre ellas. Debido a estas implicaciones, en la presente investigación no es posible realizar afirmaciones causales y nuestro análisis se verá limitado a estudiar la relación entre las variables estudiadas y la cotización del Bitcoin.

Para el caso del modelo VAR, la estabilidad del modelo es un problema central debido a los valores propios fuera del círculo unitario, lo que invalida la representación de las series de tiempo. Por otro lado, para el modelo

VEC, los problemas se encuentran en la estacionariedad y autocorrelación de las variables. Estos resultados de las pruebas sugieren que los datos tienen características particulares y los modelos pueden no capturar de los movimientos macroeconómicos y su relación con la cotización del Bitcoin.

En los Modelos de Efectos Fijos y Aleatorios, las relaciones pueden estar sujetas a factores no tomados en cuenta en el modelo o variables centrales omitidas, lo cual explica el porcentaje moderado de explicatividad de las variables independientes sobre la dependiente. Asimismo, características como la adopción tecnológica o políticas propias de cada país no han sido capturadas por las variables seleccionadas. El recopilar las limitaciones presentes en la investigación es acertado ya que debemos considerarlas al analizar los resultados, de igual manera, se evidencia la necesidad de incluir otros métodos, como los cuasi-experimentales, para validar de forma precisa las inferencias causales. Entre los métodos que se podrían utilizar están las variables instrumentales y la *regression discontinuity*.


Resultados y discusión

Esta sección busca explorar la relación que existe entre la cotización del Bitcoin y las variables macroeconómicas: PIB per cápita, tasa de inflación e índice de percepción de la corrupción presentes en la base de datos, con el objetivo de aportar para una mejor comprensión de las relaciones entre estas variables y cómo se relacionan con la cotización del Bitcoin en el periodo 2013 – 2023.

Series de tiempo de las variables macroeconómicas

El PIB per cápita en el periodo de análisis (2013 – 2023) revela dos grandes grupos: los países de alto PIB per cápita, entre los que se cuentan, de mayor a menor, Estados Unidos y España; y, los de menor PIB per cápita, entre los que se cuentan, de mayor a menor, Argentina y Nigeria. Recordemos que éste es un grupo de países heterogéneo pero que comparte la característica de una mayor propensión al uso del Bitcoin por las razones expuestas anteriormente. Como se puede observar hay países que mantienen una tendencia creciente del PIB per cápita y otros que muestran estancamiento, reflejando el desempeño del PIB per cápita como *proxy* del ingreso de las personas estos países.

Gráfico 2: Evolución del PIB per cápita (PIB pc) en todos los países (2013-2023)

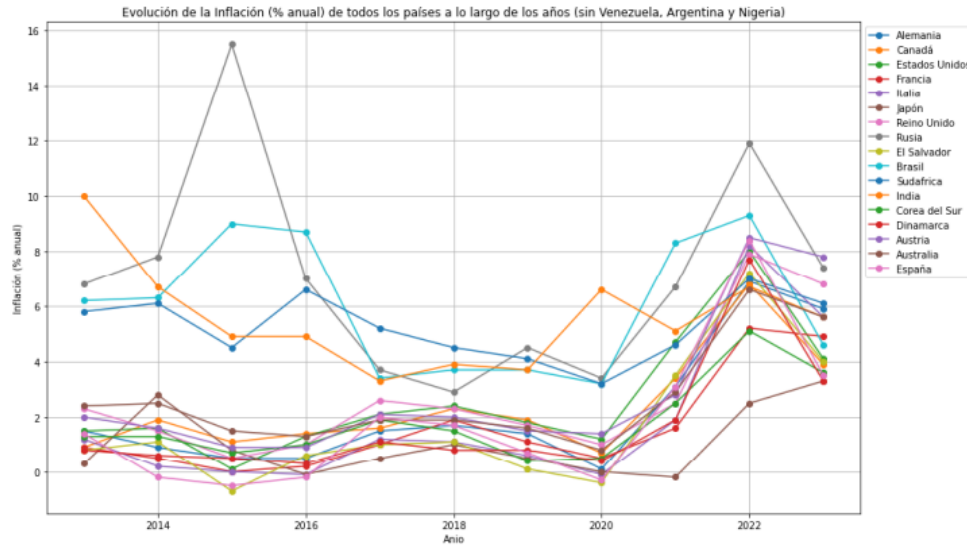


Fuente: Banco Mundial

Elaboración: Emilio Gavilanes

Para el caso de la tasa de inflación anual en el periodo seleccionado, se elaboran gráficos separados para ilustrar la evolución de esta variable macroeconómica en los países seleccionados. El primero, que se puede observar en el Anexo 1, considera a países como Venezuela, Argentina y Nigeria, los cuales son conocidos por presentar tasas extremadamente altas de inflación, lo que dificulta su comparación con el resto de las economías que mantienen niveles de inflación más moderados. Por lo tanto, en el Gráfico 3 se excluye a los países de gran inflación para que se pueda observar una tendencia estable de la inflación, entre ellos se incluye a países desarrollados como Dinamarca y Francia donde la inflación oscila entre 0% y 2%. Mientras que, en países como Japón, en donde la inflación tiene valores extremadamente bajos, incluso en ciertos años la economía presenta deflación que dificulta en mantener un crecimiento sostenido en los precios. Por otro lado, se incluye en el análisis países como Sudáfrica y Brasil que presentan una mayor volatilidad en sus tasas de inflación durante el periodo de estudio, dejando en evidencia problemas estructurales internos que se agudizan ante eventos imprevistos, los cuales repercuten en la correcta fluctuación de sus mercados.

Gráfico 3: Evolución de la Inflación (% anual) de todos los países a lo largo de los años (sin Venezuela, Argentina y Nigeria)

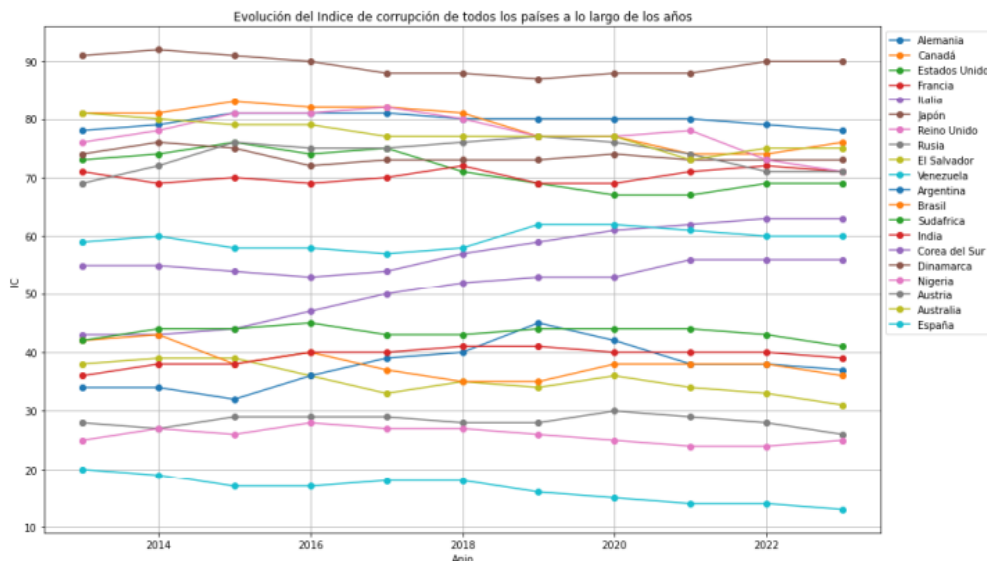


Fuente: Banco Mundial y Statista

Elaboración: Emilio Gavilanes

Como tercera variable macroeconómica encontramos al índice de percepción de corrupción que se puede observar en el gráfico 4. Al estudiar su evolución notamos que países como Dinamarca, Alemania y Australia tienen niveles bajos de corrupción percibida, lo que puede deberse a controles gubernamentales sólidos e instituciones transparentes que minimizan las oportunidades para actividades corruptas. Esto debido a que sus puntuaciones son superiores a 70 puntos. Por otro lado, naciones como Nigeria y Venezuela muestran altos niveles de corrupción percibida, al no tener transparencia en la gestión pública, por lo que sus puntuaciones constantemente caen debajo de 20 puntos. Países como Rusia y Argentina presentan un estancamiento al no tener mejoras notables con el pasar de los años, lo que puede deberse a problemas estructurales en su sociedad y modelo de gobierno.

Gráfico 4: Evolución del Índice de corrupción de todos los países a lo largo de los años



Fuente: *Transparency International*

Elaboración: Emilio Gavilanes

El análisis de la evolución de las variables por país refleja la necesidad de utilizar modelos que capturen diferencias estructurales y dinámicas temporales, por el hecho de que, las economías de la muestra de países seleccionados son heterogéneas.

Modelo de regresión múltiple por MCO

La presente investigación parte del método de regresión lineal porque dicho método es el referente más usual de todo trabajo econométrico. Así que nuestro punto de partida o de referencia inicial son las regresiones lineales múltiples corridas para cada país de la base de datos. Una ventaja adicional de utilizar la regresión lineal múltiple por país es que además permitiría evidenciar las diferencias entre países para identificar cómo las particularidades macroeconómicas de cada país pueden relacionarse de diferente manera con la cotización del Bitcoin. Sin embargo, al partir de una base de datos de panel en la que las variables de cada país constituyen series de tiempo, sabemos que la estructura temporal de los datos podría ocasionar problemas de autocorrelación lo que invalidaría los resultados de las regresiones lineales al identificar correlaciones espurias que solo reflejan coincidencias en la estructura temporal de los datos (tendencias en el tiempo) más no la relación real entre las variables. Con esta limitación, a continuación, presentamos los resultados obtenidos al correr un modelo de regresión lineal múltiple para cada uno de los países de nuestra base de datos y posteriormente pondremos a prueba la validez de los resultados al realizar distintas pruebas de validación.

Resultados

A partir del modelo econométrico de regresión lineal múltiple, se destaca cómo las variables macroeconómicas seleccionadas, el PIB per cápita, la inflación y el índice de percepción de la corrupción, se relacionaron con la cotización del Bitcoin en distintos países. Inicialmente se realizó una primera regresión para cada uno de los 20 países con los datos anuales, pero nos encontramos con un problema de micronumerosidad. El tamaño de la base de datos no es lo suficientemente grande a comparación de la cantidad de parámetros que el modelo estima, por lo que las regresiones no presentaron significancia global. Por este motivo recurrimos a la técnica de interpolación *spline* cúbica que nos permite trabajar con una muestra de datos más grande, este método genera sintéticamente más observaciones, pero mantiene la estructura de los datos y además suaviza las series temporales evitando generar valores extremos.

Con este nuevo ajuste se volvió a correr las regresiones para cada país y en este caso todas las regresiones obtuvieron significancia global, la cual es medida a través del estadístico F que demuestra que en todos los países al menos una variable independiente explica la cotización del Bitcoin. Por su parte el coeficiente de determinación (R^2) también es representativo y presenta variaciones en cada país, tal es el caso de Australia, Estados Unidos, Corea del Sur, Alemania y Canadá, que presentan un coeficiente superior al 70%, indicando una alta capacidad explicativa del modelo. Mientras que, en países como Brasil y Sudáfrica, los coeficientes de 24.7% y 28.2% respectivamente, demuestran una menor capacidad explicativa.

Un segundo hallazgo consiste en que al menos el coeficiente de una variable macroeconómica en todas las regresiones por país resultó significativo (véase Anexos 2 - 21). En Alemania, España y El Salvador todos los coeficientes de las variables son estadísticamente significativos, al 95% de confianza. En contraste, en Argentina, Japón y Francia solo presentan un coeficiente estadísticamente significativo, al 95% de confianza. Estos resultados revelan las diferencias entre países que esperábamos observar. Con el objetivo de facilitar la interpretación de todos los resultados, los hemos dividido en una guía de colores que clasifica la cantidad de variables con coeficientes estadísticamente significativos, los resultados de las métricas de evaluación y los

coeficientes para cada país. Estos resultados se pueden analizar con mayor detalle y profundidad a través de tablas de resumen en la sección de anexos, donde también está incluido un resumen de las métricas de evaluación para cada país, incluyendo el estadístico F, su probabilidad asociada ($prob(F)$) y el coeficiente de determinación (R^2) (véase Anexos 22 - 24).

En la mayoría de los países, el modelo de regresión indica que el PIB per cápita tiene una relación estadísticamente significativa con la cotización del Bitcoin y además cuenta con el signo positivo teóricamente esperado. Este resultado refuerza la hipótesis planteada de que, ante un mayor ingreso y capacidad de ahorro, la demanda del Bitcoin aumentaría, *ceteris paribus*, impulsando su cotización al alza, lo que refuerza la evidencia del uso del Bitcoin como activo especulativo.

Para el caso de la tasa de inflación, todos los países que tienen una relación estadísticamente significativa con la cotización del Bitcoin presentan un coeficiente con signo positivo, lo que respalda la hipótesis planteada de que el Bitcoin se utiliza como un activo de refugio para protegerse de las pérdidas de poder adquisitivo de las tenencias monetarias ante escenarios de alta inflación. Por ejemplo, en el caso de Argentina, el coeficiente de la inflación tuvo signo positivo, e indica que un incremento de un punto porcentual en la inflación está relacionado con un incremento de la cotización del Bitcoin de 214.71 dólares, lo que implica un crecimiento de la cotización del Bitcoin de 0.72% por cada punto porcentual que aumente la inflación para el año 2023.

Para el caso del índice de percepción de la corrupción, los resultados fueron mixtos porque ciertos países presentan coeficientes positivos y otros países coeficientes negativos, (estadísticamente significativos). Por ejemplo, en el caso de Brasil, Canadá, Nigeria, Sudáfrica y Venezuela, el coeficiente es de signo negativo. Recordemos que el índice de percepción de la corrupción utilizado reduce su valor cuando la percepción de corrupción aumenta. Por lo tanto, en el caso de estos cinco países un aumento de la percepción de corrupción estaría relacionado con un aumento de la cotización del Bitcoin. Lo que quiere decir que una mayor corrupción, *ceteris paribus*, estaría asociada con una mayor demanda de Bitcoins utilizados para ocultar actividades económicas ilícitas lo que presiona al alza la cotización del Bitcoin. En este caso se confirmaría la hipótesis del uso del Bitcoin para ocultar corrupción e ilícitos. Mientras que Italia, Rusia y El Salvador, por ejemplo, sucede lo contrario, pues el coeficiente es positivo y se rechazaría la hipótesis del uso del Bitcoin para ocultar actividades económicas ilícitas y corrupción en este segundo grupo de países.

Sin embargo, aunque los resultados presentados anteriormente muestran hallazgos interesantes, sabemos que estos resultados pueden obedecer a correlaciones espurias producto de la autocorrelación presente en el modelo ocasionada por la tendencia de las series de tiempo. Por lo que no podemos confiar plenamente en estos resultados. Este problema podría restar validez a nuestras interpretaciones de los coeficientes al no respetar un supuesto fundamental de la regresión: la ausencia de autocorrelación. Esto es típico en series de tiempo, donde los valores presentes dependen de valores pasados. Por lo tanto, las regresiones lineales por país no resultan adecuadas para cumplir el objetivo de esta investigación. Esto se confirmó con las pruebas de validación que se describen a continuación.

Pruebas de validación y problemas detectados

Las pruebas de validación revelaron que las regresiones lineales anteriores no evidencian problemas de multicolinealidad, tal como se muestra en las pruebas VIF que se pueden observar en los anexos 25 – 27. Por el contrario, las pruebas de heterocedasticidad revelaron este problema (véase Anexo 28) que fue corregido utilizando errores estándar robustos. De igual forma, la prueba de normalidad de residuos Shapiro-Wilk revela

que existe una distribución no normal de los residuos (véase Anexo 29) y finalmente la prueba de Durbin-Watson revela la presencia de autocorrelación en el modelo (véase Anexo 30).

Al confirmar la presencia de autocorrelación y de no normalidad de los residuos en nuestro modelo de regresión lineal por país sabemos que los resultados obtenidos anteriormente no son confiables porque pueden obedecer a correlaciones espurias. Para confirmar esta posibilidad procedimos a estacionalizar las series de tiempo utilizando la primera diferencia (todas las series se vuelven estacionaria en primera diferencia, véase el anexo 31) y corrimos el mismo modelo de regresión por país con las series estacionalizadas. El resultado de este ejercicio fue que ningún país mostró significancia global ni coeficientes significativos, por lo que se confirma que los resultados anteriores pese a ser interesantes son espurios y se deben descartar.

Por lo expuesto anteriormente, decidimos pasar a construir modelos VAR y VEC debido a su pertinencia en capturar relaciones dinámicas de equilibrio a largo plazo en nuestras series de tiempo para cada país, lo que podría ayudar a superar el problema de correlación y mejorar el análisis al evitar sesgos propios de la estructura temporal de los datos.

Modelo VAR

El primer requisito para construir un modelo VAR para cada país de nuestra base de datos es la estacionariedad de todas las variables, por lo tanto, la aplicación de la primera diferencia es fundamental para transformar las series de tiempo de nuestras variables y tratar de que éstas presenten estacionariedad. La importancia de aplicar esta técnica radica en que, al diferenciar las series, se puede eliminar tendencias que podrían influir en los resultados. Para verificar la estacionariedad de nuestras variables después de haber realizado la primera diferencia corremos una prueba *Augmented Dickey-Fuller (ADF)* que nos confirma la estacionariedad de todas las variables en primera diferencia (véase Anexo 31). El segundo requisito es la determinación del número óptimo de rezagos para cada país con la ayuda de criterios de información como: AIC(Akaike), BIC (*Bayesian*) y HQIC (Hannan-Quinn). Al modelar estos criterios, nos dan una alta cantidad de rezagos para cada país (véase Anexo 32 y 33) lo que sugiere la presencia de relaciones complejas entre las variables.

Con ambos requisitos aprobados, se construye un modelo VAR para cada país. Sin embargo, ninguno de los modelos VAR por país logro superar la prueba de estabilidad. Los resultados de las pruebas de estabilidad de los modelos VAR evidencian que todos los países tienen valores propios fuera del círculo unitario (véase Anexo 34). Por lo tanto, se descarta este tipo de modelos para cumplir los objetivos de la presente investigación. Esto sugiere que las variables estudiadas no tienen una relación en el corto plazo con la cotización del Bitcoin.

Teniendo en cuenta la inexistencia de relaciones en el corto plazo, es pertinente realizar una prueba de cointegración de Johansen para determinar si existen relaciones de largo plazo. De ser el caso, deberíamos construir un modelo VEC para identificar si existen relaciones a largo plazo y analizar si pueden reflejar relaciones significativas entre las variables analizadas en la presente investigación.

Modelo VEC

Se aplica una prueba de cointegración de Johansen para evaluar si existen relaciones de largo plazo entre las variables e identificar si comparten una relación de equilibrio a lo largo del periodo de estudio. El resultado de la prueba indica la existencia de diferentes rangos que varían de 1 a 4 por cada país (véase Anexo 35). Se construye un modelo VEC para cada país de nuestra base de datos tomando en cuenta los rangos de la prueba

de cointegración de Johansen. Los resultados de los modelos VEC por país en todos los casos a excepción de uno (Venezuela) revelaron inestabilidad en el VAR subyacente (véase los Anexos 36 - 55) por lo que no resultan válidos. En el caso de Venezuela pese a que el VAR subyacente supera la prueba de estabilidad ninguna variable refleja un coeficiente estadísticamente significativo (véase Anexo 56).

Por lo expuesto, debemos descartar el modelo VEC. Aprovechando la riqueza de la base de datos de panel se puede recurrir a métodos que ayudan a corregir las limitaciones que genera la autocorrelación y la endogeneidad como son los Modelos de Efectos Fijos y Aleatorios. Estos modelos al capturar las heterogeneidades no observadas y aprovechar la riqueza de los datos de panel (como diferentes tendencias temporales por país), con particularidades propias de cada país, podrían ser una alternativa para superar los problemas de autocorrelación y endogeneidad que hasta el momento no han permitido obtener resultados válidos e interpretables.

Modelos de Efectos Fijos y Aleatorios

Al tener un panel de datos, empleamos Modelo de Efectos Fijos y Modelo de Efectos Aleatorios para identificar relaciones entre variables explicativas y la cotización del Bitcoin. Estos modelos tienen la ventaja de no estar restringidos a solo realizar regresiones individuales por país, sino que pueden controlar toda la información disponible en el panel de datos a través de efectos constantes y efectos variables. Dada la estructura de la base de datos y al observar los resultados sin validez ni significancia estadística de los modelos anteriores, ahora hemos confirmado que no es una opción realizar modelos individuales para cada país. Por este motivo, se construye un Modelo de Efectos Fijos que captura la dinámica temporal de los datos y controla características no observables pero constantes a lo largo del periodo. Por su parte, también se construye un Modelo de Efectos Aleatorios que trabaja con el supuesto de que las diferencias entre cada país son aleatorias y no tienen ningún tipo de relación con el desempeño de las variables independientes.

El Modelo de Efectos Fijos es efectivo para abordar endogeneidad por variables omitidas constantes y atenuar patrones sistemáticos de autocorrelación. Los efectos fijos controlan por factores no observados específicos de cada entidad que son constantes en el tiempo, como cultura, políticas iniciales o características estructurales. Esto elimina una fuente importante de endogeneidad derivada de variables omitidas que afectan tanto las variables explicativas como la dependiente. Al incluir efectos fijos, el modelo aborda correlaciones entre los factores no observados constantes (efecto no aleatorio) y las variables explicativas, permitiendo identificar posibles efectos causales dentro de cada entidad a lo largo del tiempo.

El Modelo de Efectos Aleatorios asume que los errores son independientes entre sí y no tienen correlación serial, pero no corrige la autocorrelación por defecto. Sin embargo, al modelar las diferencias entre países como un término aleatorio, puede reducir parcialmente la variación persistente entre las observaciones dentro de un país. Si bien la presencia de autocorrelación es un problema que este método no corrige directamente, utilizar errores estándar robustos nos permite mitigar este problema en el caso del Modelo de Efectos Aleatorios.

Por lo expuesto, la elección de estos modelos nos permite aprovechar la riqueza del panel de datos para mitigar la endogeneidad y la autocorrelación, presentes, y superar las correlaciones espurias que se han identificado hasta el momento. A continuación, se presentan los resultados de los Modelos de Efectos Fijos y Aleatorios, incluyendo un análisis de la capacidad explicativa de los modelos, los coeficientes y su significancia estadística. Además, para proporcionar una interpretación detallada y confiable de las relaciones durante el período 2013-2023, los resultados se evalúan a través de pruebas de validación.

Resultados Modelo de Efectos Fijos

Tabla 11: Resultados Modelo de Efectos Fijos

PanelOLS Estimation Summary			
Dep. Variable:	PB	R-squared:	0.2582
Estimator:	PanelOLS	R-squared (Between):	0.0000
No. Observations:	220	R-squared (Within):	0.2582
Date:	Tue, Dec 24 2024	R-squared (Overall):	5.9352
Cov. Estimator:	Clustered	Log-likelihood:	-2393.0
Entities:	20	F-statistic:	22.859
Avg. Obs:	11.00	P-value:	0.0000
Min. Obs:	11.00	Distribution:	F (3,197)
Max. Obs:	11.00		
Time periods:	11		
Avg Obs:	20.00		
Min Obs:	20.00		
Max Obs:	20.00		

Parameter Estimates						
	Parameter	Std. Err.	T-stat	P-value	Lower CI	Upper CI
const	-4.259e+04	2.794e+04	-1.5244	0.1290	-9.769e+04	1.251e+04
PIB pc	1.8334	0.2328	7.8764	0.0000	1.3744	2.2925
Infla	-0.0533	1.5051	-0.0354	0.9718	-3.0216	2.9149
IC	-35.970	418.49	-0.0860	0.9316	-861.27	789.32

F-test for Poolability	2.8981
P-value	0.0001
Distribution	F (19,197)
Included effects	Entity

Elaboración: Emilio Gavilanes

En nuestro Modelo de Efectos Fijos, el *F-statistic* robusto confirma la existencia de significancia estadística global al revelar un valor de 29.578 y un p-valor de 0.0000 indicando que al menos una de las variables del modelo presenta un efecto significativo sobre la cotización del Bitcoin. Por otro lado, el valor del coeficiente de determinación ajustado (R^2) revela una capacidad explicativa moderada con un valor de 0.2582. Este resultado implica que el 25.82% de la variabilidad de la cotización del Bitcoin es explicada por al menos una de las variables macroeconómicas del modelo.

PIB per cápita (PIB pc)

Al tener un coeficiente positivo (1.8334) y estadísticamente significativo ($p = 0.0000$) nos refleja que un aumento de un dólar en el PIB per cápita se relaciona con un incremento de 1.83 dólares en la cotización del Bitcoin. El signo del coeficiente respalda la hipótesis propuesta: un aumento del PIB per cápita está relacionado con una

mayor cotización del Bitcoin. Es decir que, ante un mayor ingreso y capacidad de ahorro, la demanda del Bitcoin aumentaría, *ceteris paribus*, impulsando su cotización al alza, lo que refuerza la evidencia del uso del Bitcoin como activo especulativo.

Inflación (Infla)

El parámetro de la inflación no es estadísticamente significativo ($p = 0.9718$), lo que nos indica que no hay evidencia estadística suficiente para suponer que dicho coeficiente es distinto de cero. Por lo tanto, se descarta que la inflación tenga una relación directa con un incremento en la cotización del Bitcoin en el Modelo de Efectos Fijos para el conjunto de países seleccionados en el periodo 2013 – 2023.

Índice de percepción de la corrupción (IC)

El parámetro del índice de percepción de la corrupción no es estadísticamente significativo ($p = 0.9316$), por lo tanto, no hay evidencia estadística suficiente para suponer que dicho coeficiente es distinto de cero. Dado esto, se descarta que el índice de percepción de la corrupción tenga una relación con la cotización del Bitcoin en el Modelo de Efectos Fijos para el conjunto de países seleccionados en el periodo 2013 - 2023.

Resultados Modelo de Efectos Aleatorios

Tabla 12: Resultados Modelo de Efectos Aleatorios

RandomEffects Estimation Summary						
Dep. Variable:	PB		R-squared:	0.0509		
Estimator:	RandomEffects		R-squared (Between):	0.0000		
No. Observations:	220		R-squared (Within):	0.0886		
Date:	Tue, Dec 24 2024		R-squared (Overall):	0.0509		
Cov. Estimator:	Clustered		Log-likelihood:	2420.1		
Entities:	20		F-statistic:	3.8597		
Avg. Obs:	11.00		P-value:	0.0102		
Min. Obs:	11.00		Distribution:	F (3,216)		
Max. Obs:	11.00					
Time periods:	11		F-statistic:	3.8597		
Avg Obs:	20.00		P-value:	0.0102		
Min Obs:	20.00		Distribution:	F(3,216)		
Max Obs:	20.00					
Parameter Estimates						
	Parameter	Std. Err.	T-stat	P-value	Lower CI	Upper CI
const	1.858e+04	3246.4	5.7237	0.0000	1.218e+04	2.498e+04
PIB pc	0.3134	0.0897	3.4916	0.0006	0.1365	0.4902
Infla	-1.2131	0.4904	-2.4736	0.0141	-2.1796	-0.2465
IC	-280.76	85.975	-3.2656	0.0013	-450.22	-111.30

Elaboración: Emilio Gavilanes

En nuestro Modelo de Efectos Aleatorios, el *F-statistic* robusto confirma la existencia de significancia estadística global al mostrar un valor de 5.8759 y un *p*-valor de 0.0007 indicando que al menos una de las variables del

modelo tiene un efecto significativo sobre la cotización del Bitcoin. Por otro lado, el valor del coeficiente de determinación ajustado (R^2) revela una baja capacidad explicativa con un valor de 0.0509. Este resultado expone que el 5.09% de la variabilidad de la cotización del Bitcoin es explicada por al menos una de las variables macroeconómicas del modelo.

PIB per cápita (PIB pc)

El PIB per cápita presenta un coeficiente positivo (0.3134) y estadísticamente significativo ($p = 0.0006$), por lo tanto, existe una relación entre el PIB per cápita y la cotización del Bitcoin. Ante un aumento de un dólar en el PIB per cápita, la cotización del Bitcoin tendrá un incremento de 0.3134 dólares (31 centavos de dólar). Para esta variable el signo del coeficiente respalda la hipótesis propuesta: un aumento del PIB per cápita está relacionado con una mayor cotización del Bitcoin. Es decir que, ante un mayor ingreso y capacidad de ahorro de los agentes económicos, la demanda del Bitcoin aumentaría, *ceteris paribus*, impulsando su cotización al alza. Este resultado refuerza la evidencia del uso del Bitcoin como activo especulativo. A pesar de que existe una relación, esta tiene una menor relevancia a comparación del Modelo de Efectos Fijos porque el valor del coeficiente de efectos aleatorios, aunque mantiene el mismo signo, es menor.

Inflación (Infla)

Presenta un coeficiente negativo (-1.2131) y estadísticamente significativo ($p = 0.0141$), lo que nos indica la existencia de una relación negativa entre las variables. De esta manera, un aumento de un punto porcentual en la tasa de inflación anual está asociado a una disminución de 1.21 dólares en la cotización del Bitcoin. Para el caso de la tasa de inflación, el signo negativo del coeficiente rechaza la hipótesis planteada respecto de que el Bitcoin se utiliza como un activo de refugio para protegerse de la inflación. Esta evidencia muestra que el Bitcoin no sería utilizado como un activo de refugio, ya que ante un aumento de la inflación su cotización bajaría en lugar de aumentar como era esperado teóricamente. Cabe señalar que este resultado es pertinente para el conjunto de países del panel de datos en el periodo de estudio analizado, por lo que debemos considerar que podría haber excepciones puntuales para ciertos países en los cuales, bajo características económicas específicas y periodos de tiempo particulares, el Bitcoin si cumple esta función de activo de refugio ante la inflación como lo sugiera alguna de la literatura especializada revisada en el marco teórico.

Índice de percepción de la corrupción (IC)

Al presentar un coeficiente negativo (-280.76) y ser estadísticamente significativo ($p = 0.0013$), el modelo sugiere que existe una relación entre un aumento de la percepción de la corrupción y un incremento del precio del Bitcoin. Recordemos que un aumento en este índice (IC) evidencia una caída en la percepción de la corrupción. Por lo tanto, el signo negativo del coeficiente sugiere que, ante un aumento de un punto en el índice de percepción de la corrupción, es decir una reducción de la percepción corrupción en un punto, la cotización del Bitcoin disminuye en 280.76 dólares. Esta relación significativa con un coeficiente negativo respalda la hipótesis planteada con anterioridad al presentar el signo esperado sobre la utilización de Bitcoins para ocultar actividades ilícitas.

Esta evidencia indica que, ante una reducción de la corrupción, la demanda del Bitcoin, *ceteris paribus*, debería disminuir para respaldar una caída en su cotización; y, por el contrario, ante un aumento de la corrupción, la demanda del Bitcoin, *ceteris paribus*, debería aumentar para respaldar un incremento en su cotización. Esto constituye evidencia estadística de una posible utilización del Bitcoin para ocultar actividades ilícitas de la

economía del crimen, como lo sugiere parte de la literatura especializada revisada en este artículo. La hipótesis planteada sugiere que, ante un aumento de la percepción de la corrupción o mayor corrupción, la demanda del Bitcoin aumentaría, *ceteris paribus*, y por ende eso presionaría al alza su cotización, lo que suma evidencia que respalda el posible uso del Bitcoin para ocultar actividades ilícitas relacionadas con la corrupción.

Prueba de Hausman y validez de los modelos

Inicialmente, se sospecha que son más robustos los resultados del Modelo de Efectos Fijos que los del Modelo de Efectos Aleatorios porque tiene mayor significancia global ($F = 22.859$) y un coeficiente de determinación ajustado con mayor capacidad explicativa ($R^2 = 0.2582$). Además, sabemos que el Modelo de Efectos Fijos tiene la capacidad directa de mitigar y corregir los problemas de autocorrelación que se han presentado como uno de los principales obstáculos para el análisis. Para confirmar nuestra sospecha realizamos la prueba de Hausman, cuyos resultados muestran un valor del estadístico de 46.9535 y un p-valor estadísticamente significativo de 0.0000. En base al resultado obtenido, se rechaza la hipótesis nula y se concluye que el Modelo de Efectos Fijos es más pertinente para nuestro análisis por su capacidad de identificar la heterogeneidad entre países.

Este resultado confirma nuestra sospecha inicial y asegura la elección de un modelo más acorde a nuestros supuestos. Para el Modelo de Efectos Fijos, las características particulares de cada país resultan relevantes para identificar una relación entre las variables macroeconómicas y la cotización del Bitcoin. Además, se encuentra un respaldo a través de la prueba de Hausman que nos permite interpretar adecuadamente las relaciones existentes. Sin embargo, a pesar de que los resultados del Modelo de Efectos Fijos son preferibles, los resultados del Modelo de Efectos Aleatorios al tener significancia global también son válidos, pero de manera menos robusta.

Tabla 13: Prueba del estadístico de Hausman

Test de Hausman	
Estadístico de Hausman	46.9535
p-valor	0.0000
Conclusión: Se rechaza H0. El Modelo de EFECTOS FIJOS es preferible	

Elaboración: Emilio Gavilanes

Pruebas de validación y limitaciones

La primera prueba realizada es el factor de inflación de la varianza (VIF por sus siglas en inglés) para determinar si existe multicolinealidad en el Modelo de Efectos Fijos. Los resultados muestran que la multicolinealidad no es significativa ni preocupante al tener a todas las variables macroeconómicas por debajo de un valor crítico de 10 (véase Anexo 57).

La segunda validación es la prueba de heterocedasticidad (Breusch-Pagan), cuyos resultados confirman la presencia de heterocedasticidad en los dos modelos porque la varianza de los residuos tiende a modificarse dependiendo de las variables independientes y no es constante (véase Anexos 58 - 59). Para mitigar este problema se aplicaron errores estándar robustos (*clustered*), en ambos modelos, lo que permite que la varianza de los errores varíe entre cada grupo o clúster ajustando las inferencias para que sean válidas. En el Modelo de Efectos Fijos, los resultados de correr el modelo con y sin errores estándar robustos no presenta diferencias en la inferencia estadística pues en ambos casos solo el PIB per cápita evidencia un coeficiente significativo,

por lo tanto, la heterocedasticidad no tiene un impacto considerable en los estimadores del Modelo de Efectos Fijos, a diferencia de lo que sucede con el Modelo de Efectos Aleatorios. En el Modelo de Efectos Aleatorios, al correr con errores estándar robustos el coeficiente de la inflación pasa a ser significativo, pese a no ser significativo al correr el modelo con errores estándar no ajustados (véase Anexos 60 – 63). Finalmente, cabe anotar que, por lo expuesto en este párrafo, los resultados reportados en las tablas anteriores corresponden a los Modelos de Efectos Fijos y Aleatorios ajustados con errores estándar robustos para superar el problema de heterocedasticidad.

La tercera prueba de validación fue la normalidad de los residuos (Shapiro-Wilk). En los anexos 64 y 65 se muestra una desviación de la normalidad al tener un p-valor significativamente bajo en ambos modelos. Tomando en cuenta este resultado, el usar errores estándar robustos nos ayuda a mitigar esta desviación y garantizar que las relaciones sean válidas a pesar de no tener una normalidad en los residuos. Asimismo, el Modelo de Efectos Fijos internamente soluciona el problema de variable omitida propio de la endogeneidad al eliminar cualquier característica no observada que afecta a los países de panel y sea constante en el tiempo. Aunque no corrige completamente otros problemas de la endogeneidad como son: simultaneidad y errores de medición, esto da como resultado que solo podamos identificar relaciones estadísticamente significativas entre las variables, pero no podamos hacer afirmaciones causales.

La limitación de nuestros resultados, mencionada en el párrafo anterior, se confirma con las pruebas de Durbin-Watson, Ljung-Box y Woolridge, pues éstas indican la persistencia de autocorrelación positiva en ambos modelos por el hecho de que los residuos no presentan independencia entre ellos (véase Anexos 66 – 68). Si bien la estructura del Modelo de Efectos Fijos y la utilización de errores estándar robustos ayudan a mitigar la autocorrelación estas pruebas revelan que no la han eliminado por completo. Por este motivo, se ratifica que nuestros resultados no son robustos para afirmar efectos o relaciones causales y solo podemos identificar de manera más débil asociaciones estadísticamente significativas entre las variables.

Finalmente, se realiza una prueba de *poolability* para identificar cómo tratar el panel de datos en nuestros modelos. Es importante acotar que el estimador utilizado es un panel de mínimos cuadrados ordinarios (MCO) pero sus siglas en inglés son *PanelOLS*. Los resultados presentados en el anexo 69 muestran que el Modelo de Efectos Fijos es superior al modelo agrupado (*Pooled*) al explicar de manera más precisa la variabilidad dentro de los países. Por otro lado, para el Modelo de Efectos Aleatorios, los resultados presentados en el anexo 70 sugieren que este modelo también es adecuado. Sin embargo, al comparar los dos resultados observamos que el Modelo de Efectos Fijos demuestra ser más adecuado porque captura mejor la variabilidad dentro los países y ofrece una mayor capacidad explicativa de la variable dependiente.

En conclusión, es importante reconocer que la autocorrelación y la endogeneidad no se eliminaron completamente, solamente se mitigaron con los ajustes descritos en esta sección. Esta situación puede afectar la validez de nuestras relaciones estadísticas. Sin embargo, al trabajar con un panel de datos de tamaño razonable (220 observaciones) y al utilizar errores estándar robustos para corregir posibles correlaciones existentes en nuestra muestra de datos, hemos logrado reducir los efectos de estas limitaciones sobre la significancia de los coeficientes. A pesar de que los ajustes no eliminan por completo los problemas detectados, y por lo tanto no nos permiten realizar afirmaciones causales robustas, sí nos permiten interpretar los resultados de la relación entre variables para cumplir el objetivo de esta investigación. En este sentido, los presentes resultados revelan que sí existen relaciones entre las variables macroeconómicas y la cotización del Bitcoin, en especial en el caso del PIB per cápita.

Discusión y comparación

Cada modelo tiene características específicas que deben ser tomadas en cuenta para interpretar sus resultados. Una primera diferencia es que el Modelo de Efectos Fijos obtuvo un solo coeficiente estadísticamente significativo, que es el del PIB per cápita. Mientras que, en el Modelo de Efectos Aleatorios las tres variables macroeconómicas: PIB per cápita, tasa de inflación anual e índice de percepción de la corrupción resultaron significativas. Además, al comparar el Modelo de Efectos Fijos con el Modelo de Efectos Aleatorios en función de la significancia global, el coeficiente de determinación (R^2) y la prueba de Hausman, sabemos que los resultados del Modelo de Efectos Fijos son más robustos.

La significancia del PIB per cápita en ambos modelos refuerza la hipótesis inicialmente planteada de que un aumento del PIB per cápita tiene una relación directa con la cotización del Bitcoin. Por lo tanto, se puede inferir que un mayor PIB per cápita, *ceteris paribus*, impulsa la demanda de esta criptomoneda y presiona su cotización al alza. De aquí se puede concluir que los agentes económicos al tener mayores ingresos, acceso a recursos y tecnologías financieras, por contar con un mayor PIB per cápita, tienen mayor capacidad para invertir en Bitcoins como un activo especulativo.

Para el caso de la inflación y la percepción de la corrupción, la discrepancia en los resultados de ambos modelos no permite asegurar de manera robusta una relación de la cotización del Bitcoin con estas variables. Sin embargo, queda para consideración de los lectores la evidencia más débil del Modelo de Efectos Aleatorios que se describió arriba y que podría servir como referencia para futuros trabajos de investigación.

Conclusiones y recomendaciones

Tras haber realizado un detallado análisis de diferentes enfoques metodológicos aplicados a datos de panel de 20 países durante el periodo 2013 – 2023, se evaluó la hipótesis de que el PIB per cápita, la inflación y el índice de percepción de la corrupción tienen una relación con la cotización del Bitcoin. A partir de este análisis podemos concluir lo siguiente:

Los modelos de regresión lineal múltiple aplicados para cada uno de los veinte países no fueron adecuados al no tener validez estadística y presentar problemas de endogeneidad y autocorrelación. Estos problemas pueden ser ocasionados por características propias de los datos en nuestra base, como pueden ser las tendencias en las series de tiempo que pueden guiarnos a interpretar resultados que obedecen a correlaciones espurias. Para confirmar estas limitaciones se realizaron pruebas de validación, las cuales evidenciaron la presencia de estos problemas que respaldan las críticas de Woolridge (2010) acerca de las limitaciones de los modelos lineales al abordar fenómenos económicos complejos como es la cotización del Bitcoin.

Por lo mencionado anteriormente, se realizó el análisis a través de modelos VAR y VEC para capturar relaciones dinámicas de equilibrio a corto y largo plazo en nuestras series de tiempo de cada país. Sin embargo, ninguno de los modelos por país presentó coeficientes estadísticamente significativos ni logró superar adecuadamente las pruebas de estabilidad y de ausencia de autocorrelación. Dado que en nuestra investigación tenemos un

panel de datos con dinámicas temporales y estructuras particulares que no fueron capturadas, se confirma que los modelos VAR y VEC resultan inadecuados para procesar la información disponible en nuestro panel de datos. Este hallazgo es corroborado por las limitaciones de estos modelos que señala Enders (2014).

En vista de lo expuesto hasta ahora, se determina que los Modelos de Efectos Fijos y Aleatorios son los más adecuados para el análisis del panel de datos puesto que permiten identificar relaciones entre variables explicativas y la cotización del Bitcoin al tener la ventaja de no estar restringidos a regresiones individuales por país. Estos modelos pueden controlar toda la información disponible en el panel de datos a través de efectos constantes y variables, capturando la dinámica temporal de los datos y las características no observables pero constantes a lo largo del período.

El Modelo de Efectos Fijos destaca como el más robusto al capturar las heterogeneidades no observadas entre los países, al tener mayor capacidad explicativa sobre la variable dependiente y por ser el modelo respaldado por la prueba de Hausman. Al aplicar este modelo se revela un coeficiente estadísticamente significativo para el PIB per cápita en donde se obtiene el signo positivo teóricamente esperado que refleja una variación de 1.83 dólares en la cotización del Bitcoin por cada dólar que aumente el PIB per cápita.

Este coeficiente positivo indica que a medida que aumenta el PIB per cápita por habitante en los países de nuestra muestra, la cotización del Bitcoin también aumenta. Asimismo, para que la cotización aumente, *ceteris paribus* la demanda debe aumentar, especialmente en los países con mayor avance económico que tienen un PIB per cápita mayor. El hecho de tener un PIB per cápita mayor implica que los agentes económicos tengan una mayor disponibilidad para ahorrar y aumentar su riqueza. Por este motivo, este hallazgo refuerza la investigación de Hassan Hoger (2022) que destaca el papel del PIB per cápita, en la adopción del Bitcoin al demostrar que, teniendo acceso a más información, mayor riqueza, más recursos financieros y tecnológicos se incrementa la demanda de activos especulativos como esta criptomoneda.

La relación se ve fortalecida al correr el Modelo de Efectos Aleatorios y obtener el mismo signo del coeficiente positivo para el PIB per cápita, confirmando de esta manera en ambos modelos la hipótesis planteada del Bitcoin como activo especulativo. Esto quiere decir que ante un mayor PIB per cápita de la población, la demanda del Bitcoin y su cotización aumentan. Dicho de otra manera, al crecer el valor del PIB per cápita, existe una relación con el crecimiento de la demanda de Bitcoins al incrementar la cantidad de inversionistas con condiciones económicas para especular en los mercados de criptomonedas como el Bitcoin. Esta dinámica de la cotización del Bitcoin según Jordana de Pozas Poole (2020) sugiere que la cotización está ampliamente arraigada a interacciones entre la oferta y demanda, lo que encasilla al Bitcoin principalmente como un activo financiero especulativo.

Adicionalmente, nuestros hallazgos se conectan con uno de los hechos estilizados de Kaldor expuestos en el marco teórico. Estos hechos estilizados explican los principios de niveles de crecimiento, por esta razón, la relación positiva entre el PIB per cápita y la cotización del Bitcoin refuerza el principio de crecimiento del ingreso y acumulación de capital presentado por Kaldor (1963). En este sentido, los países con mayor PIB per cápita como *proxys* del ingreso, tienen una mayor capacidad de invertir en activos especulativos como el Bitcoin.

Con respecto a la tasa de inflación, los resultados del Modelo de Efectos Fijos no arrojan una relación estadísticamente significativa. Solamente bajo el enfoque del Modelo de Efectos Aleatorios, se comprueba la existencia de una débil relación con signo negativo entre la tasa de inflación y la cotización del Bitcoin. El signo

presentado no corresponde con el signo esperado de la hipótesis planteada por lo que este hallazgo rechaza la creencia acerca del Bitcoin como un activo de refugio que propone el estudio de Torre (2023).

Finalmente, en el análisis del Índice de Percepción de la Corrupción, se puede evidenciar que bajo el enfoque del Modelo de Efectos Fijos no existe una relación significativa con la cotización del Bitcoin. Sin embargo, al evaluar con el Modelo de Efectos Aleatorios se comprueba que tiene una débil, pero estadísticamente significativa relación con signo negativo con la cotización del Bitcoin. Este signo obtenido en el modelo al ser negativo respalda débilmente la hipótesis planteada sobre el uso de Bitcoins para la economía del crimen.

Recordando la teoría, el índice de percepción de la corrupción revela la percepción de corrupción en el sector público, en donde puntajes bajos indican mayor corrupción. En economías altamente corruptas y con instituciones débiles, el Bitcoin se postula como una herramienta para evadir controles legales por su naturaleza anónima y descentralizada. Por esta razón, en economías con niveles significativos de corrupción, la demanda y cotización de Bitcoin aumenta al usar esta criptomoneda para operaciones que promueven el crecimiento de la economía del crimen. Este hallazgo respalda parcialmente la investigación de Asthana (2024) en donde señala que, en economías altamente corruptas, el Bitcoin es utilizado para movimientos anónimos de capitales ilícitos.

El hallazgo de la inconsistencia de las variables de tasa de inflación e índice de corrupción en el Modelo de Efectos Fijos robustece a la variable PIB per cápita al ser la única que tiene una relación positiva con la cotización del Bitcoin tanto en el Modelo de Efectos Fijos como en el Modelo de Efectos Aleatorios. Este resultado enfatiza el uso del Bitcoin sobre todo como activo especulativo, más que como activo de refugio o como herramienta para operaciones ilícitas en economías altamente corruptas. Estos hallazgos respaldan a los argumentos presentados por Ibrahim & Ali Basah (2022) en su investigación, lo cuales mencionan el uso del Bitcoin principalmente como activo de inversión especulativo, en economías donde los agentes buscar diversificar sus inversiones, antes que servir como un activo de refugio frente a la inflación por su significativa volatilidad o una herramienta para actividades criminales. Estos hallazgos sugieren que el Índice de Corrupción a pesar de confirmar el signo esperado e influir en cierta medida en la demanda de Bitcoins, tiene una débil relación con la cotización del Bitcoin a comparación de la relación robusta y positiva del PIB per cápita.

A pesar de la pertinencia metodológica de los Modelos de Efectos Fijos y Efectos Aleatorios, los problemas de autocorrelación y endogeneidad siguen presentes y restringen el análisis a identificar relaciones sin la posibilidad de afirmar causalidades. Estos problemas afianzan las limitaciones que tienen los modelos tradicionales, respaldando lo destacado por Stock y Watson (2012).

Teniendo en cuenta los hallazgos de la investigación, una primera recomendación para futuras investigaciones, que busquen profundizar sobre el objetivo de estudio de la presente investigación, sugiere la ampliación del periodo de estudio y de los países. Realizar esto podría permitir evaluar si las relaciones identificadas son estables a lo largo del tiempo y una base de datos con más diversidad de países ayudaría a capturar características económicas propias de cada región o país. Asimismo, el incluir variables macroeconómicas adicionales como índices de volatilidad financiera, flujos de capital, entre otras, podrían exponer relaciones significativas y elevar el coeficiente de determinación (R^2) de las variables independientes sobre la dependiente.

Una segunda recomendación para futuras investigaciones es la inclusión de errores estándar *Discroll-Kraay* para controlar problemas de autocorrelación y heterocedasticidad simultáneamente. De igual manera, se podría incluir modelos dinámicos o técnicas de *machine learning* que podrían ser de utilidad para identificar patrones

ocultos en los datos que los modelos tradicionales no perciben. Con la finalidad de enriquecer la relación entre variables, una tercera recomendación recae en la inclusión de eventos económicos y financieros externos para identificar cómo reacciona la cotización del Bitcoin a estos cambios, lo que podría ofrecer una visión dinámica de como afectarían estos eventos al mercado mismo de las criptomonedas. Finalmente, para investigaciones futuras se podría incluir criptomonedas alternativas y evaluar si los hallazgos del presente estudio constituyen una base de entendimiento para otras criptomonedas que también se utilizan como activos especulativos.

A pesar de las limitaciones detectadas, los resultados del estudio pueden complementar la teoría de que el Bitcoin actúa principalmente como un activo especulativo en el cual su cotización está relacionada con la variable del PIB per cápita con coeficiente positivo. Este hallazgo establece una base para futuras investigaciones que busquen explorar las relaciones de variables macroeconómicas con criptomonedas en diferentes temporalidades y contextos económicos.

Bibliografía

- Algorand. (2023). *What is Blockchain*. Obtenido de https://developer.algorand.org/docs/get-started/basics/what_is_blockchain/
- Arena, L. (2021). *Las criptomonedas como atractivo beneficio compensatorio en Argentina*. Recuperado el 2024, de Universidad del CEMA: <https://ucema.edu.ar/sites/default/files/2023-07/Arena%2CLEonardo%20Dario%20-%20MBA%20-%202021.pdf>
- Asthana, V. (2024). *Corruption and crypto participation: Cross-country evidence*. *Economics Bulletin*, 44(2). Recuperado el 2024, de <https://www.accessecon.com/Pubs/EB/2024/Volume44/EB-24-V44-I2-P55.pdf>
- Atkinson, K. (2004). *An Introduction to Numerical Analysis* (2da ed.). Wiley. Obtenido de <https://www.wiley.com/en-us/An+Introduction+to+Numerical+Analysis%2C+2nd+Edition-p-9780471624899>
- BBVA. (2024). *¿Que es la inflación y como se calcula?* Recuperado el 2024, de <https://www.bbva.es/finanzas-vistazo/ef/finanzas-personales/que-es-la-inflacion-y-como-se-calcula.html>
- Chohan, & Usman. (Febrero de 2022). *A history of Bitcoin*. SSRN, 24. doi:<http://dx.doi.org/10.2139/ssrn.3047875>
- CoinMarketCap. (2024). *CoinMarketCap*. Obtenido de <https://coinmarketcap.com/es/>
- Davidson, L., & Block, W. E. (2015). *Bitcoin, the Regression Theorem, and the emergence of a new medium of exchange*. *The quarterly journal of austrian economics*, 18(3), 28. Recuperado el 2024, de <https://cothinktank.com/upload/Bitcoin%20the%20Regression%20Theorem%20and%20the%20Emergence%20of%20a%20New%20Medium%20of%20Exchange.pdf>
- DortaMartinez. (2018). *Ranking de los paises donde mas se utiliza el Bitcoin*. Obtenido de <https://dortamartinez.com/ranking-de-los-paises-donde-mas-utilizan-bitcoin/>
- Enders, W. (2014). *Applied Econometric Time Series* (4ta ed.). Wiley. Recuperado el 2024, de <https://www.wiley.com/en-au/Applied+Econometric+Time+Series%2C+4th+Edition-p-9781118808566>

- Estévez, S. (2023). *Análisis del uso de criptomonedas como dinero en Latinoamérica*. Obtenido de <https://repositorio.puce.edu.ec/server/api/core/bitstreams/29f8dded-92d2-4c97-8d08-9caf6456f77b/content>
- Fernandez, R. (2023). *Ranking de los países con más cajeros Bitcoin instalados a mayo de 2023*. STATISTA. Obtenido de <https://es.statista.com/estadisticas/658296/paises-con-mas-cajeros-bitcoin-instalados-a-nivel-mundial/>
- FinancialCrimeAcademy. (2024). *Comprender los métodos de lavado de dinero criptográfico: el delito de criptomonedas*. Obtenido de <https://financialcrimeacademy.org/es/metodos-de-lavado-de-dinero-en-criptodivisas-la-clave-de-los-delitos-de-criptodivisas/#:~:text=Con%2>
- Forbes. (2023). *Estos son los países que más poseen Bitcoin*. Obtenido de <https://forbes.do/economia-digital/2023-06-20/estos-son-los-paises-que-poseen-mas-bitcoin>
- Hassan Hoger, J. (2022). *Cómo afecta la regulación y prohibición de las criptomonedas en ciertos países en la cotización del mercado de las criptomonedas*. Repositorio Universidad Pontificia Comillas. Recuperado el 2024, de <https://repositorio.comillas.edu/xmlui/bitstream/handle/11531/56595/TFG%20-%20Hassan%20Hoger%2c%20Janira.pdf?sequence=2&isAllowed=y>
- Ibrahim, J., & AliBasah, M. Y. (2022). *A study on relationship between crypto currency, commodity and foreign exchange rate*. *The Journal of Muamalat and islamic finance research*. Obtenido de <https://doi.org/10.33102/jmifr.v19i2.457>
- INEE. (2009). *Producto Interno Bruto per cápita*. Instituto Nacional para la Evaluación de la Educación *Panorama educativo de México*. Recuperado el 2024, de <https://www.inee.edu.mx/wp-content/uploads/2019/03/CS07-2009.pdf>
- Jagati, S. (2022). *El año de Bitcoin: Un resumen de 2021 para la criptomoneda estrella*. Recuperado el 2024, de Cointelegraph: <https://es.cointelegraph.com/news/the-year-for-bitcoin-a-2021-roundup-of-the-flagship-crypto>
- Jay, Kalariya, Parmar, Tanwar, Kumar, & Alazab. (2020). *Stochastic Neural Networks for Cryptocurrency Price Prediction (Vol. 8)*. IEEE Access. Obtenido de <https://doi.org/10.1109/ACCESS.2020.2990659>

- Johnson, J. (2020). *Bitcoin, corruption and economic freedom*. *Journal of Financial Crime*, 27(1). Recuperado el 2024, de <https://www.emerald.com/insight/content/doi/10.1108/jfc-11-2018-0122/full/pdf?title=bitcoin-corruption-and-economic-freedom>
- Jordana de Pozas Poole, J. A. (2020). *El inversor de bitcoin en la actualidad: de moneda virtual a activo especulativo*. Obtenido de <http://hdl.handle.net/11531/37181>
- Kaldor, N. (1963). *Capital Accumulation and Economic Growth*. En *The Theory of Capital*. Cambridge . Obtenido de <http://gesd.free.fr/kaldor61.pdf>
- Kroll, J. A., Davey, I. C., & Felten, E. W. (June de 2013). *The economics of Bitcoin mining, or Bitcoin in the presence of adversaries*. *The Twelfth Workshop on the Economics of Information Security (WEIS)*. Recuperado el 2024, de <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=7bf78054192d98e999edcdf08971a5eed42518d2>
- Meynkhhard, A. (2019). *Fair market value of bitcoin: halving effect*. *Business Perspectives*, 16. doi:[http://dx.doi.org/10.21511/imfi.16\(4\).2019.07](http://dx.doi.org/10.21511/imfi.16(4).2019.07)
- Mises, L. v. (1912). *Money, Method, and the Market Process*. Libro. Obtenido de <https://cdn.mises.org/Theory%20of%20Money%20and%20Credit.pdf>
- Mishkin, F., & Serletis, A. (2019). *The economics of money, banking, and financial markets*. Libro, 4th Edition. Obtenido de [file:///C:/Users/User/Downloads/THE_ECONOMICS_OF_MONEYS_BANKING_AND_FINANCIAL_MARKETS%20\(1\).pdf](file:///C:/Users/User/Downloads/THE_ECONOMICS_OF_MONEYS_BANKING_AND_FINANCIAL_MARKETS%20(1).pdf)
- Nakamoto, S. (2008). *Bitcoin: A peer-to-peer electronic cash system*. Obtenido de https://www.usssc.gov/sites/default/files/pdf/training/annual-national-training-seminar/2018/Emerging_Tech_Bitcoin_Crypto.pdf
- Ortiz, M., & Winkelried, D. (2022). *Hitos de la reforma macroeconómica en el Perú 1990-2020: La recompensa de los tamíás*. Recuperado el 2024, de Universidad del Pacífico: <https://doi.org/10.21678/978-9972-57-486-3>

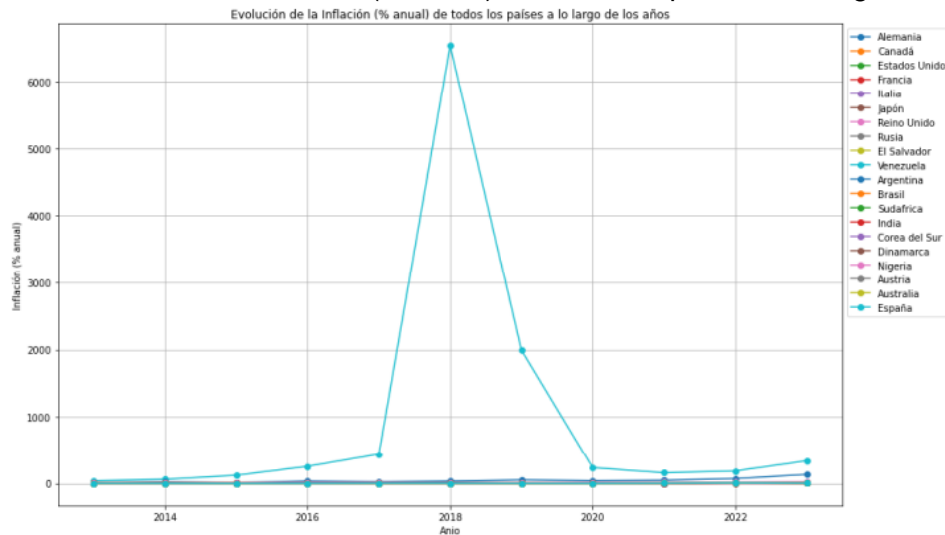
- Rodríguez Gómez, J. L. (2020). *Bitcoin, un activo de inversión alternativo*. Obtenido de <https://ruc.udc.es/dspace/handle/2183/26065>
- Saldaña Taboada, P. (2017). *¿Por qué las organizaciones criminales utilizan criptomonedas? Los bitcoins en el crimen organizado (Vol. 6)*. Granada: Instituto Andaluz Interuniversitario de Criminología. Obtenido de <https://revistaseug.ugr.es/index.php/cridi/article/download/20883/20268>
- Stock, J., & Watson, M. (2012). *Introducción a la econometría (3 ed.)*. Pearson Educación, S.A. Obtenido de https://www.academia.edu/92785065/Econometr%C3%ADa_Stock_and_Watson.
- Šurda, P. (2014). *The origin, classification and utility of Bitcoin*. Obtenido de <https://ssrn.com/abstract=2436823>
- Tapscott, D. (2016). *La revolución Blockchain: Descubre como esta nueva tecnología transformará la economía global*. New York, Estados Unidos: DEUSTO. Recuperado el 2024, de https://static0planetadelibroscommx.cdnstatics.com/libros_contenido_extra/35/34781_La_revolucion_blockchain.pdf
- Torre, J. (2023). *Análisis de Factores de Correlación en el Precio del Bitcoin*. Recuperado el 2024, de Repositorio abierto de la universidad de Cantabria: <https://hdl.handle.net/10902/30852>
- Transparency, I. (2024). *Transparency.org, CC-BYND 4.0*. Recuperado el 2024, de <https://www.transparency.org/es/news/how-cpi-scores-are-calculated>
- Uras, N., Marchesi, L., Marchesi, M., & Tonelli, R. (2020). *Forecasting Bitcoin closing price series using linear regression and neural networks models*. *PeerJ Computer Science*. Obtenido de <https://doi.org/10.7717/peerj-cs.279>
- Verbeek, M. (2012). *A guide to modern econometrics (4ta ed.)*. Wiley. Obtenido de <https://www.wiley.com/en-ca/A+Guide+to+Modern+Econometrics%2C+5th+Edition-p-9781119401155>
- Villa Carranza, D. N. (2022). *Criptomonedas como alternativas de inversión, una revisión literaria en américa latina*. Biblioteca PUCE. Obtenido de <https://repositorio.puce.edu.ec/server/api/core/bitstreams/e8d071e2-f8e4-42fe-b9b7-2f590bee6a0a/content>

Wang, L., Sarker, P., & Bouri, E. (2023). *Short- and Long-Term Interactions Between Bitcoin and Economic Variables: Evidence from the US. Computational Economics*. Obtenido de <https://doi.org/10.1007/s10614-022-10247-5>

Wooldridge, J. (2010). *Econometric analysis of cross section and panel data (2da ed.)*. MIT Press. Recuperado el 2024, de <https://mitpress.mit.edu/9780262232586/econometric-analysis-of-cross-section-and-panel-data/>

Anexos

Anexo 1: Evolución de la inflación (% anual) de todos los países a lo largo de los años



Elaboración: Emilio Gavilanes

Anexo 2: regresión lineal múltiple Alemania

```

=====
OLS Regression Results
=====
Dep. Variable:                PB      R-squared:                0.765
Model:                      OLS      Adj. R-squared:           0.759
Method:                     Least Squares      F-statistic:              92.64
Date:                       mi., 13 nov. 2024      Prob (F-statistic):       1.27e-31
Time:                       16:46:46      Log-Likelihood:           -1336.8
No. Observations:           129      AIC:                      2682.
Df Residuals:               125      BIC:                      2693.
Df Model:                   3
Covariance Type:           HC3
=====
               coef      std err          z      P>|z|      [0.025      0.975]
-----+-----
const        -5.485e+05    1.35e+05     -4.054    0.000     -8.14e+05    -2.83e+05
PIB pc         1.8308           0.414        4.425    0.000         1.020         2.642
Infla         5757.7631       605.313      9.512    0.000     4571.371     6944.155
IC            5778.9835       1486.242     3.888    0.000     2866.003     8691.964
=====
Omnibus:                21.199      Durbin-Watson:           0.272
Prob(Omnibus):          0.000      Jarque-Bera (JB):        35.487
Skew:                   0.768      Prob(JB):                1.97e-08
Kurtosis:               5.059      Cond. No.                8.12e+06
=====
    
```

Elaboración: Emilio Gavilanes

Anexo 3: regresión lineal múltiple Argentina

```

=====
OLS Regression Results
=====
Dep. Variable:                PB      R-squared:                0.365
Model:                      OLS      Adj. R-squared:           0.349
Method:                     Least Squares      F-statistic:              59.60
Date:                       mi., 13 nov. 2024      Prob (F-statistic):       5.44e-24
Time:                       16:46:20      Log-Likelihood:           -1400.9
No. Observations:           129      AIC:                      2810.
Df Residuals:               125      BIC:                      2821.
Df Model:                   3
Covariance Type:           HC3
=====
               coef      std err          z      P>|z|      [0.025      0.975]
-----+-----
const        -6257.9210    1.77e+04     -0.353    0.724     -4.1e+04     2.85e+04
PIB pc         0.1008           0.667        0.151    0.880         -1.207         1.408
Infla         214.7082       17.162     12.511    0.000     181.072     248.344
IC            161.7150       281.553        0.574    0.566     -390.120     713.550
=====
Omnibus:                69.020      Durbin-Watson:           0.105
Prob(Omnibus):          0.000      Jarque-Bera (JB):        194.676
Skew:                   2.200      Prob(JB):                5.33e-43
Kurtosis:               7.106      Cond. No.                2.73e+05
=====
    
```

Elaboración: Emilio Gavilanes

Anexo 4: regresión lineal múltiple Canadá

```
=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.741
Model:                 OLS      Adj. R-squared:           0.734
Method:                Least Squares      F-statistic:              96.73
Date:                  mi., 13 nov. 2024    Prob (F-statistic):       1.96e-32
Time:                  17:31:40           Log-Likelihood:          -1343.1
No. Observations:     129              AIC:                     2694.
Df Residuals:         125              BIC:                     2706.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const                1.372e+05    2.82e+04     4.865    0.000    8.19e+04    1.93e+05
PIB pc                0.8234         0.386       2.133    0.033    0.067       1.580
Infla                 2777.1621     1114.246    2.492    0.013    593.281     4961.043
IC                   -2170.7026     261.539    -8.300    0.000   -2683.309   -1658.096
=====
Omnibus:              25.393      Durbin-Watson:           0.249
Prob(Omnibus):        0.000      Jarque-Bera (JB):        38.113
Skew:                 0.978      Prob(JB):                5.30e-09
Kurtosis:             4.806      Cond. No.:               2.22e+06
=====
```

Elaboración: Emilio Gavilanes

Anexo 5: regresión lineal múltiple Estados Unidos

```
=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.791
Model:                 OLS      Adj. R-squared:           0.786
Method:                Least Squares      F-statistic:              94.00
Date:                  mi., 13 nov. 2024    Prob (F-statistic):       6.80e-32
Time:                  16:45:41           Log-Likelihood:          -1329.1
No. Observations:     129              AIC:                     2666.
Df Residuals:         125              BIC:                     2678.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const               -4.449e+04    2.41e+04    -1.848    0.065   -9.17e+04    2708.246
PIB pc                0.9165         0.144       6.352    0.000    0.634       1.199
Infla                 3218.2426     572.862    5.618    0.000   2095.453     4341.032
IC                   -164.4386     237.857    -0.691    0.489   -630.630     301.753
=====
Omnibus:              28.552      Durbin-Watson:           0.303
Prob(Omnibus):        0.000      Jarque-Bera (JB):        77.462
Skew:                 0.809      Prob(JB):                1.51e-17
Kurtosis:             6.434      Cond. No.:               2.63e+06
=====
```

Elaboración: Emilio Gavilanes

Anexo 6: regresión lineal múltiple Francia

```
=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.654
Model:                 OLS      Adj. R-squared:           0.646
Method:                Least Squares      F-statistic:              75.03
Date:                  mi., 13 nov. 2024    Prob (F-statistic):       8.03e-28
Time:                  16:45:23           Log-Likelihood:          -1361.7
No. Observations:     129              AIC:                     2731.
Df Residuals:         125              BIC:                     2743.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const               -1.679e+05    9.34e+04    -1.797    0.072   -3.51e+05    1.53e+04
PIB pc                0.4248         0.359       1.182    0.237   -0.280       1.129
Infla                 5686.6042     980.967    5.797    0.000   3763.945     7609.263
IC                   2179.3169     1251.616    1.741    0.082   -273.806     4632.440
=====
Omnibus:              41.730      Durbin-Watson:           0.184
Prob(Omnibus):        0.000      Jarque-Bera (JB):        100.322
Skew:                 1.290      Prob(JB):                1.64e-22
Kurtosis:             6.466      Cond. No.:               3.87e+06
=====
```

Elaboración: Emilio Gavilanes

Anexo 7: regresión lineal múltiple Italia

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.745
Model:                 OLS      Adj. R-squared:           0.739
Method:                Least Squares      F-statistic:              83.60
Date:                  lu., 25 nov. 2024    Prob (F-statistic):       9.77e-30
Time:                  22:28:09           Log-Likelihood:           -1342.1
No. Observations:     129      AIC:                      2692.
Df Residuals:         125      BIC:                      2704.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -7.649e+04    1.12e+04    -6.815    0.000    -9.85e+04    -5.45e+04
PIB pc      0.8454         0.260       3.246    0.001     0.335     1.356
Infla      3228.1601      508.798     6.345    0.000    2230.934    4225.386
IC         1060.1859      120.269     8.815    0.000     824.462    1295.909
=====
Omnibus:                36.339      Durbin-Watson:           0.249
Prob(Omnibus):          0.000      Jarque-Bera (JB):        103.248
Skew:                   1.037      Prob(JB):                 3.80e-23
Kurtosis:               6.861      Cond. No.                 5.81e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 8: regresión lineal múltiple Japón

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.573
Model:                 OLS      Adj. R-squared:           0.563
Method:                Least Squares      F-statistic:              55.19
Date:                  lu., 25 nov. 2024    Prob (F-statistic):       8.64e-23
Time:                  22:28:58           Log-Likelihood:           -1375.2
No. Observations:     129      AIC:                      2758.
Df Residuals:         125      BIC:                      2770.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -2.006e+05    6.73e+04    -2.981    0.003    -3.32e+05    -6.87e+04
PIB pc      3.6916        0.397       9.299    0.000     2.913     4.470
Infla     -1867.1087     1194.520    -1.563    0.118    -4208.325    474.108
IC         746.1765       756.142     0.987    0.324    -735.834    2228.187
=====
Omnibus:                63.143      Durbin-Watson:           0.154
Prob(Omnibus):          0.000      Jarque-Bera (JB):        175.497
Skew:                   1.972      Prob(JB):                 7.78e-39
Kurtosis:               7.135      Cond. No.                 5.21e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 9: regresión lineal múltiple Reino Unido

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.700
Model:                 OLS      Adj. R-squared:           0.693
Method:                Least Squares      F-statistic:              81.23
Date:                  mi., 13 nov. 2024    Prob (F-statistic):       3.20e-29
Time:                  16:44:21           Log-Likelihood:           -1352.4
No. Observations:     129      AIC:                      2713.
Df Residuals:         125      BIC:                      2724.
Df Model:              3
Covariance Type:      HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -1.029e+05    3.98e+04    -2.585    0.010    -1.81e+05    -2.49e+04
PIB pc      1.5177         0.266       5.716    0.000     0.997     2.038
Infla      2497.8594      706.051     3.538    0.000    1114.025    3881.693
IC         436.9045       390.019     1.120    0.263    -327.519    1201.328
=====
Omnibus:                46.018      Durbin-Watson:           0.213
Prob(Omnibus):          0.000      Jarque-Bera (JB):        131.618
Skew:                   1.345      Prob(JB):                 2.63e-29
Kurtosis:               7.154      Cond. No.                 2.66e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 10: regresión lineal múltiple Rusia

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.766
Model:                  OLS      Adj. R-squared:           0.760
Method:                 Least Squares      F-statistic:              99.29
Date:                   mi., 13 nov. 2024   Prob (F-statistic):      6.28e-33
Time:                   16:43:57          Log-Likelihood:          -1336.5
No. Observations:      129      AIC:                     2681.
Df Residuals:          125      BIC:                     2693.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -1.149e+05   2.26e+04     -5.095   0.000   -1.59e+05   -7.07e+04
PIB pc      1.9816        0.144       13.758   0.000    1.699       2.264
Infla      856.2124     183.619     4.663   0.000    496.326    1216.099
IC         2071.1272    677.222     3.058   0.002    743.796    3398.459
=====
Omnibus:                28.878      Durbin-Watson:           0.274
Prob(Omnibus):          0.000      Jarque-Bera (JB):        58.489
Skew:                   0.944      Prob(JB):                1.99e-13
Kurtosis:               5.705      Cond. No.:               9.33e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 11: regresión lineal múltiple El Salvador

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.786
Model:                  OLS      Adj. R-squared:           0.781
Method:                 Least Squares      F-statistic:              76.91
Date:                   lu., 25 nov. 2024   Prob (F-statistic):      2.96e-28
Time:                   22:29:38          Log-Likelihood:          -1330.8
No. Observations:      129      AIC:                     2670.
Df Residuals:          125      BIC:                     2681.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -1.171e+05   1.24e+04     -9.471   0.000   -1.41e+05   -9.29e+04
PIB pc      18.6258      1.949       9.558   0.000    14.806     22.445
Infla      3059.9243    550.575     5.558   0.000   1980.817   4139.032
IC         1275.0038    166.730     7.647   0.000    948.220    1601.788
=====
Omnibus:                29.376      Durbin-Watson:           0.294
Prob(Omnibus):          0.000      Jarque-Bera (JB):        102.338
Skew:                   0.733      Prob(JB):                5.99e-23
Kurtosis:               7.109      Cond. No.:               1.91e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 12: regresión lineal múltiple Venezuela

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.618
Model:                  OLS      Adj. R-squared:           0.609
Method:                 Least Squares      F-statistic:              85.67
Date:                   mi., 13 nov. 2024   Prob (F-statistic):      3.51e-30
Time:                   16:17:50          Log-Likelihood:          -1368.0
No. Observations:      129      AIC:                     2744.
Df Residuals:          125      BIC:                     2756.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      1.215e+05   8227.774    14.761   0.000    1.05e+05    1.38e+05
PIB pc      1.1747       0.142       8.280   0.000    0.897       1.453
Infla      1.6845       0.260       6.467   0.000    1.174       2.195
IC         -7244.8078   500.864    -14.465   0.000   -8226.484   -6263.132
=====
Omnibus:                56.347      Durbin-Watson:           0.172
Prob(Omnibus):          0.000      Jarque-Bera (JB):        140.784
Skew:                   1.789      Prob(JB):                2.69e-31
Kurtosis:               6.660      Cond. No.:               5.63e+04
=====

```

Elaboración: Emilio Gavilanes

Anexo 13: regresión lineal múltiple Brasil

```

=====
                    OLS Regression Results
=====
Dep. Variable:                PB      R-squared:                0.247
Model:                      OLS      Adj. R-squared:           0.229
Method:                     Least Squares      F-statistic:              22.66
Date:                       mi., 13 nov. 2024      Prob (F-statistic):      8.84e-12
Time:                       16:20:05      Log-Likelihood:          -1411.8
No. Observations:           129      AIC:                    2832.
Df Residuals:                125      BIC:                    2843.
Df Model:                    3
Covariance Type:            HC3
=====
                    coef      std err      z      P>|z|      [0.025      0.975]
-----
const      1.362e+05      1.62e+04      8.430      0.000      1.05e+05      1.68e+05
PIB pc      2.2403      0.783      2.860      0.004      0.705      3.776
Infla      3228.9638      766.181      4.214      0.000      1727.276      4730.652
IC      -4313.5697      599.376      -7.197      0.000      -5488.325      -3138.814
=====
Omnibus:                9.763      Durbin-Watson:           0.088
Prob(Omnibus):          0.008      Jarque-Bera (JB):        10.359
Skew:                   0.694      Prob(JB):                0.00563
Kurtosis:               3.009      Cond. No.:               1.67e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 14: regresión lineal múltiple Sudáfrica

```

=====
                    OLS Regression Results
=====
Dep. Variable:                PB      R-squared:                0.282
Model:                      OLS      Adj. R-squared:           0.265
Method:                     Least Squares      F-statistic:              50.90
Date:                       mi., 13 nov. 2024      Prob (F-statistic):      1.45e-21
Time:                       16:21:51      Log-Likelihood:          -1408.8
No. Observations:           129      AIC:                    2826.
Df Residuals:                125      BIC:                    2837.
Df Model:                    3
Covariance Type:            HC3
=====
                    coef      std err      z      P>|z|      [0.025      0.975]
-----
const      1.87e+05      3.24e+04      5.779      0.000      1.24e+05      2.5e+05
PIB pc      4.7727      2.594      1.840      0.066      -0.312      9.857
Infla      2977.1402      1113.554      2.674      0.008      794.614      5159.666
IC      -5101.9052      487.293      -10.470      0.000      -6056.982      -4146.828
=====
Omnibus:                32.140      Durbin-Watson:           0.091
Prob(Omnibus):          0.000      Jarque-Bera (JB):        40.200
Skew:                   1.255      Prob(JB):                3.28e-11
Kurtosis:               4.638      Cond. No.:               2.33e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 15: regresión lineal múltiple India

```

=====
                    OLS Regression Results
=====
Dep. Variable:                PB      R-squared:                0.721
Model:                      OLS      Adj. R-squared:           0.715
Method:                     Least Squares      F-statistic:              82.52
Date:                       mi., 13 nov. 2024      Prob (F-statistic):      1.67e-29
Time:                       16:23:51      Log-Likelihood:          -1347.7
No. Observations:           129      AIC:                    2703.
Df Residuals:                125      BIC:                    2715.
Df Model:                    3
Covariance Type:            HC3
=====
                    coef      std err      z      P>|z|      [0.025      0.975]
-----
const      -1.088e+05      3.13e+04      -3.481      0.001      -1.7e+05      -4.75e+04
PIB pc      39.7850      2.541      15.659      0.000      34.805      44.765
Infla      4077.8764      716.938      5.688      0.000      2672.704      5483.048
IC      522.2544      696.418      0.750      0.453      -842.700      1887.209
=====
Omnibus:                44.966      Durbin-Watson:           0.231
Prob(Omnibus):          0.000      Jarque-Bera (JB):        113.261
Skew:                   1.374      Prob(JB):                2.54e-25
Kurtosis:               6.676      Cond. No.:               9.30e+04
=====

```

Elaboración: Emilio Gavilanes

Anexo 16: regresión lineal múltiple Corea del Sur

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.789
Model:                  OLS      Adj. R-squared:           0.784
Method:                 Least Squares      F-statistic:              93.67
Date:                   mi., 13 nov. 2024   Prob (F-statistic):       7.92e-32
Time:                   16:24:30           Log-Likelihood:           -1329.9
No. Observations:      129              AIC:                      2668.
Df Residuals:          125              BIC:                      2679.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -1.233e+05   1.04e+04    -11.832   0.000   -1.44e+05   -1.03e+05
PIB pc      0.6728        0.497       1.353    0.176    -0.302       1.647
Infla      5687.1575     684.749     8.305    0.000    4345.074    7029.241
IC         1789.3598     225.994     7.918    0.000    1346.419    2232.300
=====
Omnibus:                27.936      Durbin-Watson:           0.301
Prob(Omnibus):           0.000      Jarque-Bera (JB):        72.604
Skew:                    0.807      Prob(JB):                 1.71e-16
Kurtosis:                6.302      Cond. No.                 6.08e+05
=====

```

Elaboración: Emilio Gavilanes

Anexo 17: regresión lineal múltiple Dinamarca

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.747
Model:                  OLS      Adj. R-squared:           0.741
Method:                 Least Squares      F-statistic:              80.93
Date:                   mi., 13 nov. 2024   Prob (F-statistic):       3.72e-29
Time:                   16:28:18           Log-Likelihood:           -1341.5
No. Observations:      129              AIC:                      2691.
Df Residuals:          125              BIC:                      2702.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      -4.299e+04   4.43e+04    -0.970    0.332   -1.3e+05    4.38e+04
PIB pc      1.6916        0.211       8.021    0.000    1.278       2.105
Infla      3091.6404     572.921     5.396    0.000    1968.737    4214.544
IC         -603.4633     443.239    -1.361    0.173   -1472.196    265.270
=====
Omnibus:                17.646      Durbin-Watson:           0.254
Prob(Omnibus):           0.000      Jarque-Bera (JB):        21.700
Skew:                    0.803      Prob(JB):                 1.94e-05
Kurtosis:                4.207      Cond. No.                 3.96e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 18: regresión lineal múltiple Nigeria

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.730
Model:                  OLS      Adj. R-squared:           0.724
Method:                 Least Squares      F-statistic:              95.46
Date:                   mi., 13 nov. 2024   Prob (F-statistic):       3.49e-32
Time:                   16:30:04           Log-Likelihood:           -1345.6
No. Observations:      129              AIC:                      2699.
Df Residuals:          125              BIC:                      2711.
Df Model:               3
Covariance Type:       HC3
=====
                        coef      std err          z      P>|z|      [0.025      0.975]
-----
const      1.531e+05   2.22e+04     6.908    0.000    1.1e+05    1.97e+05
PIB pc      9.7881        2.852       3.432    0.001    4.199       15.377
Infla      1915.1315     275.750     6.945    0.000    1374.672    2455.591
IC         -7381.1335     786.901    -9.380    0.000   -8923.432   -5838.835
=====
Omnibus:                25.819      Durbin-Watson:           0.244
Prob(Omnibus):           0.000      Jarque-Bera (JB):        39.276
Skew:                    0.986      Prob(JB):                 2.96e-09
Kurtosis:                4.849      Cond. No.                 6.93e+04
=====

```

Elaboración: Emilio Gavilanes

Anexo 19: regresión lineal múltiple Austria

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.668
Model:                 OLS      Adj. R-squared:           0.660
Method:                Least Squares      F-statistic:              99.87
Date:                  mi., 13 nov. 2024   Prob (F-statistic):       4.86e-33
Time:                  16:31:49           Log-Likelihood:           -1359.0
No. Observations:     129      AIC:                      2726.
Df Residuals:          125      BIC:                      2737.
Df Model:              3
Covariance Type:      HC3
=====
                coef      std err          z      P>|z|      [0.025      0.975]
-----+-----
const          -1.422e+05    2.06e+04    -6.901    0.000    -1.83e+05    -1.02e+05
PIB pc          0.6497          0.256       2.537    0.011         0.148         1.152
Infla          4937.8454        573.601     8.609    0.000    3813.608    6062.083
IC             1441.1218        185.400     7.773    0.000    1077.744    1804.500
=====
Omnibus:                57.608      Durbin-Watson:           0.193
Prob(Omnibus):          0.000      Jarque-Bera (JB):        206.995
Skew:                   1.616      Prob(JB):                 1.13e-45
Kurtosis:               8.298      Cond. No.                 3.15e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 20: regresión lineal múltiple Australia

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.797
Model:                 OLS      Adj. R-squared:           0.792
Method:                Least Squares      F-statistic:              105.1
Date:                  mi., 13 nov. 2024   Prob (F-statistic):       5.02e-34
Time:                  16:33:24           Log-Likelihood:           -1327.2
No. Observations:     129      AIC:                      2662.
Df Residuals:          125      BIC:                      2674.
Df Model:              3
Covariance Type:      HC3
=====
                coef      std err          z      P>|z|      [0.025      0.975]
-----+-----
const          3.067e+05    6.97e+04    4.403    0.000     1.7e+05     4.43e+05
PIB pc         -0.0890        0.253     -0.351    0.725     -0.585         0.407
Infla          4808.7310        839.743     5.726    0.000    3162.865    6454.597
IC             -3932.1720        756.477     -5.198    0.000    -5414.840    -2449.504
=====
Omnibus:                19.724      Durbin-Watson:           0.315
Prob(Omnibus):          0.000      Jarque-Bera (JB):        39.048
Skew:                   0.644      Prob(JB):                 3.32e-09
Kurtosis:               5.368      Cond. No.                 4.02e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 21: regresión lineal múltiple España

```

=====
                        OLS Regression Results
=====
Dep. Variable:          PB      R-squared:                0.707
Model:                 OLS      Adj. R-squared:           0.700
Method:                Least Squares      F-statistic:              71.12
Date:                  lu., 25 nov. 2024   Prob (F-statistic):       6.71e-27
Time:                  22:30:21           Log-Likelihood:           -1351.0
No. Observations:     129      AIC:                      2710.
Df Residuals:          125      BIC:                      2721.
Df Model:              3
Covariance Type:      HC3
=====
                coef      std err          z      P>|z|      [0.025      0.975]
-----+-----
const          -1.824e+05    2.2e+04    -8.279    0.000    -2.26e+05    -1.39e+05
PIB pc          2.4682          0.492       5.012    0.000         1.503         3.433
Infla          3695.9560        450.827     8.198    0.000    2812.350    4579.562
IC             1958.6048        358.917     5.457    0.000    1255.140    2662.070
=====
Omnibus:                17.626      Durbin-Watson:           0.220
Prob(Omnibus):          0.000      Jarque-Bera (JB):        20.853
Skew:                   0.838      Prob(JB):                 2.96e-05
Kurtosis:               4.036      Cond. No.                 1.09e+06
=====

```

Elaboración: Emilio Gavilanes

Anexo 22: Guía de colores

Guía de colores
Tres variables significativas
Dos variables significativas
Una variable significativa

Elaboración: Emilio Gavilanes

Anexo 23: Métricas de evaluación

Pais	R²	SigniGlob
Alemania	0.765 76.50%	F-statistic: 92.64 prob (F): 1.27e-31
Argentina	0.365 36.50%	F-statistic: 59.60 prob (F): 5.44e-24
Australia	0.797 79.70%	F-statistic: 105.1 prob (F): 5.02e-34
Austria	0.668 66.80%	F-statistic: 99.87 prob (F): 4.86e-33
Brasil	0.247 24.70%	F-statistic: 22.66 prob (F): 8.84e-12
Canadá	0.741 74.10%	F-statistic: 96.73 prob (F): 1.96e-32
Corea del Sur	0.789 78.90%	F-statistic: 93.67 prob (F): 7.92e-32
Dinamarca	0.747 74.70%	F-statistic: 80.93 prob (F): 3.72e-29
El Salvador	0.786 78.60%	F-statistic: 76.91 prob (F): 2.96e-28
España	0.707 70.70%	F-statistic: 71.12 prob (F): 6.71e-27
Estados Unidos	0.791 79.10%	F-statistic: 94.00 prob (F): 6.80e-32
Francia	0.654 65.40%	F-statistic: 75.03 prob (F): 8.03e-28
India	0.721 72.10%	F-statistic: 82.52 prob (F): 1.67e-29
Italia	0.745 74.50%	F-statistic: 83.60 prob (F): 9.77e-30
Japón	0.573 57.30%	F-statistic: 55.19 prob (F): 8.64e-23
Nigeria	0.73 73.00%	F-statistic: 95.46 prob (F): 3.49e-32
Reino Unido	0.7 70.00%	F-statistic: 81.23 prob (F): 3.20e-29
Rusia	0.766 76.60%	F-statistic: 99.29 prob (F): 6.28e-33
Sudafrica	0.282 28.20%	F-statistic: 50.90 prob (F): 1.45e-21
Venezuela	0.618 61.80%	F-statistic: 85.67 prob (F): 3.51e-30

Elaboración: Emilio Gavilanes

Anexo 24: Resultados regresión múltiple (MCO) por país

<i>Pais</i>	<i>PIB pc</i>	<i>Infla</i>	<i>IC</i>
Alemania	Significativo (95%) P-value: 0.000 coeficiente: +1.83	Significativo (95%) P-value: 0.000 coeficiente: +5757.76	Significativo (95%) P-value: 0.000 coeficiente: +5778.98
Argentina	No significativo (95%) P-value: 0.880 coeficiente: +0.1008	Significativo (95%) P-value: 0.000 coeficiente: +214.71	No significativo (95%) P-value: 0.566 coeficiente: +161.71
Australia	No significativo (95%) P-value: 0.725 coeficiente: -0.09	Significativo (95%) P-value: 0.000 coeficiente: +4808.73	Significativo (95%) P-value: 0.000 coeficiente: -3932.17
Austria	Significativo (95%) P-value: 0.011 coeficiente: +0.65	Significativo (95%) P-value: 0.000 coeficiente: +4937.85	Significativo (95%) P-value: 0.000 coeficiente: +1441.12
Brasil	Significativo (95%) P-value: 0.004 coeficiente: +2.24	Significativo (95%) P-value: 0.000 coeficiente: +3228.96	Significativo (95%) P-value: 0.000 coeficiente: -4313.57
Canadá	Significativo (95%) P-value: 0.033 coeficiente: +0.8234	Significativo (95%) P-value: 0.013 coeficiente: +2777.16	Significativo (95%) P-value: 0.000 coeficiente: -2170.70
Corea del Sur	No significativo (95%) P-value: 0.176 coeficiente: +0.67	Significativo (95%) P-value: 0.000 coeficiente: +5687.16	Significativo (95%) P-value: 0.000 coeficiente: +1789.36
Dinamarca	Significativo (95%) P-value: 0.000 coeficiente: +1.69	Significativo (95%) P-value: 0.000 coeficiente: +3091.64	No significativo (95%) P-value: 0.173 coeficiente: -603.46
El Salvador	Significativo (95%) P-value: 0.000 coeficiente: +17.16	Significativo (95%) P-value: 0.000 coeficiente: +3326.22	Significativo (95%) P-value: 0.000 coeficiente: +961.74
España	Significativo (95%) P-value: 0.000 coeficiente: +2.35	Significativo (95%) P-value: 0.000 coeficiente: +4117.29	Significativo (95%) P-value: 0.000 coeficiente: +2000.00
Estados Unidos	Significativo (95%) P-value: 0.000 coeficiente: +0.916	Significativo (95%) P-value: 0.000 coeficiente: +3218.24	No significativo (95%) P-value: 0.489 coeficiente: -164.44
Francia	No significativo (95%) P-value: 0.237 coeficiente: +0.4248	Significativo (95%) P-value: 0.000 coeficiente: +5686.60	No significativo (95%) P-value: 0.082 coeficiente: +2179.32
India	Significativo (95%) P-value: 0.000 coeficiente: +39.76	Significativo (95%) P-value: 0.000 coeficiente: +4077.88	No significativo (95%) P-value: 0.453 coeficiente: +522.25
Italia	Significativo (95%) P-value: 0.001 coeficiente: +0.877	Significativo (95%) P-value: 0.000 coeficiente: +3249.30	Significativo (95%) P-value: 0.000 coeficiente: +1051.28
Japón	Significativo (95%) P-value: 0.000 coeficiente: +3.67	No significativo (95%) P-value: 0.151 coeficiente: -1796.61	No significativo (95%) P-value: 0.390 coeficiente: +659.64
Nigeria	Significativo (95%) P-value: 0.001 coeficiente: +9.79	Significativo (95%) P-value: 0.000 coeficiente: +1915.13	Significativo (95%) P-value: 0.000 coeficiente: -7381.13
Reino Unido	Significativo (95%) P-value: 0.000 coeficiente: +1.52	Significativo (95%) P-value: 0.000 coeficiente: +2497.86	No significativo (95%) P-value: 0.263 coeficiente: +436.90
Rusia	Significativo (95%) P-value: 0.000 coeficiente: +1.98	Significativo (95%) P-value: 0.000 coeficiente: +856.21	Significativo (95%) P-value: 0.002 coeficiente: +2071.13
Sudafrica	No significativo (95%) P-value: 0.066 coeficiente: +4.77	Significativo (95%) P-value: 0.008 coeficiente: +2977.14	Significativo (95%) P-value: 0.000 coeficiente: -5101.91
Venezuela	Significativo (95%) P-value: 0.000 coeficiente: +1.17	Significativo (95%) P-value: 0.000 coeficiente: +1.68	Significativo (95%) P-value: 0.000 coeficiente: -7244.81

Elaboración: Emilio Gavilanes

Anexo 25: Prueba de Multicolinealidad (VIF)

```

--- Prueba de Multicolinealidad (VIF) ---
Variable      VIF
0  const      10.679406
1  PIB pc     3.731449
2  Infla      1.046695
3  IC         3.808273

```

Elaboración: Emilio Gavilanes

Anexo 26: Prueba de Multicolinealidad (VIF) para Sudáfrica

```

Prueba VIF para Sudafrica:
Variable          VIF
0    const    1299.218187
1    PIB pc    1.020604
2    Infla    1.057994
3     IC    1.041052

```

Elaboración: Emilio Gavilanes

Anexo 27: Prueba de Multicolinealidad (VIF) para Estados Unidos

```

Prueba VIF para Estados Unidos:
Variable          VIF
0    const    1570.114727
1    PIB pc    2.288208
2    Infla    1.499626
3     IC    1.994155

```

Elaboración: Emilio Gavilanes

Anexo 28: Prueba de Heterocedasticidad (Breusch-Pagan)

```

--- Prueba de Heterocedasticidad (Breusch-Pagan) ---
LM Statistic: 40.54388930546652
LM-Test p-value: 8.170524995284645e-09
F-Statistic: 13.704622256622047
F-Test p-value: 7.1951052283184444e-09

```

Elaboración: Emilio Gavilanes

Anexo 29: Prueba de Shapiro-Wilk para no normalidad de los residuos

```

--- Prueba de Shapiro-Wilk para los residuos ---
Estadístico de Shapiro-Wilk: 0.7893
p-valor: 0.0000
Los residuos NO siguen una distribución normal (se rechaza H0).

```

Elaboración: Emilio Gavilanes

Anexo 30: Prueba de Autocorrelación (Durbin-Watson)

```

--- Prueba de Autocorrelación (Durbin-Watson) ---
Estadístico de Durbin-Watson: 0.15604501046053798

```

Elaboración: Emilio Gavilanes

Anexo 31: Prueba de Augmented Dickey-Fuller para variables a primera diferencia

```

--- Prueba de Dickey-Fuller para PIB_pc_diff ---
Estadístico ADF: -50.316837638579244
p-valor: 0.0
Valores críticos: {'1%': -3.4329089813516065, '5%': -2.8626705556366505, '10%': -2.56737183663938}
La serie PIB_pc_diff es estacionaria (rechazamos H0).

--- Prueba de Dickey-Fuller para Infla_diff ---
Estadístico ADF: -10.809233716914347
p-valor: 1.9277020477625856e-19
Valores críticos: {'1%': -3.432936307610058, '5%': -2.8626826231161626, '10%': -2.567378261492694}
La serie Infla_diff es estacionaria (rechazamos H0).

--- Prueba de Dickey-Fuller para IC_diff ---
Estadístico ADF: -50.41377380901705
p-valor: 0.0
Valores críticos: {'1%': -3.4329089813516065, '5%': -2.8626705556366505, '10%': -2.56737183663938}
La serie IC_diff es estacionaria (rechazamos H0).

```

```

--- Prueba de Dickey-Fuller para PB_diff ---
Estadístico ADF: -13.814857711261867
p-valor: 8.104337597670578e-26
Valores críticos: {'1%': '1%', '5%': '5%', '10%': '10%'}
La serie PB_diff es estacionaria (rechazamos H0).

```

Elaboración: Emilio Gavilanes

Anexo 32: Resumen de rezagos óptimos por país según criterio AIC

```

--- Resumen del número óptimo de rezagos según AIC por país ---
Alemania: 15 rezagos
Argentina: 15 rezagos
Australia: 15 rezagos
Austria: 14 rezagos
Brasil: 7 rezagos
Canadá: 7 rezagos
Corea del Sur: 14 rezagos
Dinamarca: 15 rezagos
El Salvador: 7 rezagos
España: 7 rezagos
Estados Unidos: 15 rezagos
Francia: 15 rezagos
India: 14 rezagos
Italia: 14 rezagos
Japón: 15 rezagos
Nigeria: 7 rezagos
Reino Unido : 15 rezagos
Rusia: 15 rezagos
Sudafrica: 15 rezagos
Venezuela: 7 rezagos

```

Elaboración: Emilio Gavilanes

Anexo 33: Resumen de rezagos óptimos según criterio BIC y HQIC

```

--- Resultados de la selección de rezagos ---
Criterios de selección de rezagos:
BIC: 5
HQIC: 7

--- Sugerencias según los criterios ---
Rezagos sugeridos por BIC: 5
Rezagos sugeridos por HQIC: 7

```

Elaboración: Emilio Gavilanes

Anexo 34: Resumen de estabilidad del modelo VAR por país

```
##### Resumen final de estabilidad por país #####
País: Alemania, Estado: NO ESTABLE
País: Argentina, Estado: NO ESTABLE
País: Australia, Estado: NO ESTABLE
País: Austria, Estado: NO ESTABLE
País: Brasil, Estado: NO ESTABLE
País: Canadá, Estado: NO ESTABLE
País: Corea del Sur, Estado: NO ESTABLE
País: Dinamarca, Estado: NO ESTABLE
País: El Salvador, Estado: NO ESTABLE
País: España, Estado: NO ESTABLE
País: Estados Unidos, Estado: NO ESTABLE
País: Francia, Estado: NO ESTABLE
País: India, Estado: NO ESTABLE
País: Italia, Estado: NO ESTABLE
País: Japón, Estado: NO ESTABLE
País: Nigeria, Estado: NO ESTABLE
País: Reino Unido , Estado: NO ESTABLE
País: Rusia, Estado: NO ESTABLE
País: Sudafrica, Estado: NO ESTABLE
País: Venezuela, Estado: NO ESTABLE
```

Elaboración: Emilio Gavilanes

Anexo 35: Resumen de prueba de Johansen para rango de cointegración por país

```
##### Resumen final de VEC por país #####
País: Alemania, Rango de cointegración: 2
País: Argentina, Rango de cointegración: 2
País: Australia, Rango de cointegración: 3
País: Austria, Rango de cointegración: 4
País: Brasil, Rango de cointegración: 3
País: Canadá, Rango de cointegración: 1
País: Corea del Sur, Rango de cointegración: 1
País: Dinamarca, Rango de cointegración: 1
País: El Salvador, Rango de cointegración: 1
País: España, Rango de cointegración: 2
País: Estados Unidos, Rango de cointegración: 1
País: Francia, Rango de cointegración: 2
País: India, Rango de cointegración: 4
País: Italia, Rango de cointegración: 2
País: Japón, Rango de cointegración: 2
País: Nigeria, Rango de cointegración: 2
País: Reino Unido , Rango de cointegración: 2
País: Rusia, Rango de cointegración: 4
País: Sudafrica, Rango de cointegración: 1
País: Venezuela, Rango de cointegración: 3
```

Elaboración: Emilio Gavilanes

Anexo 36: Pruebas de validación del modelo VEC para Alemania

```
--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0585
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.16236548e+00 4.04775885e-02 4.28064376e-18 1.61030811e-17]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).
```

Elaboración: Emilio Gavilanes

Anexo 37: Pruebas de validación del modelo VEC para Argentina

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0475
-> Hay autocorrelación (rechazamos H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.05597844e+00 3.29297847e-02 8.02622271e-19 7.36993289e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 38: Pruebas de validación del modelo VEC para Austria

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0573
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.1509367 0.02911583 0.05162808 0.05162808]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 39: Pruebas de validación del modelo VEC para Australia

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1050
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.11508153e+00 2.09796300e-17 1.43949320e-02 4.60969288e-02]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 40: Pruebas de validación del modelo VEC para Brasil

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1540
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.02654863e+00 6.70472025e-17 2.92589734e-04 3.49207997e-02]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 41: Pruebas de validación del modelo VEC para Canadá

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0398
-> Hay autocorrelación (rechazamos H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.15980726e+00 0.00000000e+00 6.91425974e-20 2.94160738e-20]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 42: Pruebas de validación del modelo VEC para Corea del Sur

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0573
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.17230098e+00 2.71050543e-20 8.66780028e-20 8.66780028e-20]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 43: Pruebas de validación del modelo VEC para Dinamarca

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0368
-> Hay autocorrelación (rechazamos H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.17955664e+00 2.02512535e-20 8.70363431e-19 0.00000000e+00]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 44: Pruebas de validación del modelo VEC para El Salvador

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0721
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.10668036e+00 0.00000000e+00 2.71050543e-20 2.16840434e-19]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 45: Pruebas de validación del modelo VEC para España

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0796
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.16302322e+00 3.11581728e-03 2.07468322e-18 3.55777045e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 46: Pruebas de validación del modelo VEC para Estados Unidos

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0731
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.11760894e+00 1.48630897e-19 1.48630897e-19 0.00000000e+00]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 47: Pruebas de validación del modelo VEC para Francia

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0963
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.12419101e+00 3.57763866e-02 2.26552715e-18 2.57401236e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 48: Pruebas de validación del modelo VEC para India

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1835
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.07171115 0.02833737 0.02833737 0.04461104]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 49: Pruebas de validación del modelo VEC para Italia

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.0574
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.15468585e+00 1.56294142e-03 1.44825409e-19 8.00331574e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 50: Pruebas de validación del modelo VEC para Japón

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.2340
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.02156879e+00 5.46869386e-02 1.16839415e-17 1.90994675e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 51: Pruebas de validación del modelo VEC para Nigeria

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1883
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.04092298e+00 4.55623717e-02 2.64428378e-18 2.64428378e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 52: Pruebas de validación del modelo VEC para Reino Unido

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1950
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.05367259e+00 4.61461388e-02 5.02351986e-18 1.30520037e-18]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 53: Pruebas de validación del modelo VEC para Rusia

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1549
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.05766649 0.04601717 0.04601717 0.02601214]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 54: Pruebas de validación del modelo VEC para Sudáfrica

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.1549
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [1.03751231e+00 2.16840434e-19 2.32661212e-19 1.09037040e-20]
El modelo VAR subyacente NO es estable (algunos valores propios están fuera del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 55: Pruebas de validación del modelo VEC para Venezuela

```

--- Prueba de autocorrelación (Ljung-Box) en los residuos ---
Variable: PB_diff, p-valor Ljung-Box: 0.2441
-> No hay autocorrelación (no se rechaza H0).
Variable: PIB_pc_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: Infla_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).
Variable: IC_diff, p-valor Ljung-Box: 0.0000
-> Hay autocorrelación (rechazamos H0).

--- Prueba de estabilidad del VAR subyacente ---
Valores propios (módulos): [9.58160234e-01 3.38553043e-17 1.91941798e-02 2.80222576e-02]
El modelo VAR subyacente es ESTABLE (todos los valores propios están dentro del círculo unitario).

```

Elaboración: Emilio Gavilanes

Anexo 56: Resultados modelo VEC para Venezuela

```

--- Ajustando modelo VEC para Venezuela con rango de cointegración = 3 ---
C:\Users\User\Documents\ANACONDA\lib\site-packages\statsmodels\tsa\base\tsa_model.py:471: ValueWarning:
A date index has been provided, but it has no associated frequency information and so will be ignored
when e.g. forecasting.
  self._init_dates(dates, freq)
Det. terms outside the coint. relation & lagged endog. parameters for equation PB_diff
=====
      coef      std err          z      P>|z|      [0.025      0.975]
-----
L1.PB_diff      0.1902      0.088      2.158      0.031      0.017      0.363
L1.PIB_pc_diff      1.3653      5.338      0.256      0.798     -9.097     11.828
L1.Infla_diff     -0.8341      8.524     -0.098      0.922    -17.541     15.873
L1.IC_diff      649.8663     2629.365      0.247      0.805    -4503.595     5803.328
Det. terms outside the coint. relation & lagged endog. parameters for equation PIB_pc_diff
=====
      coef      std err          z      P>|z|      [0.025      0.975]
-----
L1.PB_diff      0.0001      0.001      0.220      0.826     -0.001      0.001
L1.PIB_pc_diff      0.8244      0.039     21.296      0.000      0.749      0.900
L1.Infla_diff     -0.0318      0.062     -0.514      0.607     -0.153      0.089
L1.IC_diff      401.0946     19.069     21.034      0.000     363.720     438.470
Det. terms outside the coint. relation & lagged endog. parameters for equation Infla_diff
=====
      coef      std err          z      P>|z|      [0.025      0.975]
-----
L1.PB_diff     -0.0001      0.000     -0.276      0.782     -0.001      0.001
L1.PIB_pc_diff     -0.0113      0.025     -0.458      0.647     -0.060      0.037
L1.Infla_diff      0.8739      0.040     22.097      0.000      0.796      0.951
L1.IC_diff     -2.9597     12.200     -0.243      0.808    -26.871     20.951
Det. terms outside the coint. relation & lagged endog. parameters for equation IC_diff
=====

```

	coef	std err	z	P> z	[0.025	0.975]
L1.PB_diff	-2.723e-07	1.81e-07	-1.502	0.133	-6.28e-07	8.3e-08
L1.PIB_pc_diff	8.451e-05	1.1e-05	7.695	0.000	6.3e-05	0.000
L1.Infla_diff	6.327e-05	1.75e-05	3.608	0.000	2.89e-05	9.76e-05
L1.IC_diff	0.0414	0.005	7.652	0.000	0.031	0.052
Loading coefficients (alpha) for equation PB_diff						
	coef	std err	z	P> z	[0.025	0.975]
ec1	-0.9573	0.112	-8.549	0.000	-1.177	-0.738
ec2	0.3238	1.157	0.280	0.779	-1.943	2.591
ec3	0.7935	1.770	0.448	0.654	-2.676	4.263
Loading coefficients (alpha) for equation PIB_pc_diff						
	coef	std err	z	P> z	[0.025	0.975]
ec1	-0.0002	0.001	-0.210	0.834	-0.002	0.001
ec2	-0.0317	0.008	-3.779	0.000	-0.048	-0.015
ec3	0.0079	0.013	0.614	0.539	-0.017	0.033
Loading coefficients (alpha) for equation Infla_diff						
	coef	std err	z	P> z	[0.025	0.975]
ec1	-0.0001	0.001	-0.273	0.785	-0.001	0.001
ec2	-0.0062	0.005	-1.152	0.250	-0.017	0.004
ec3	-0.0402	0.008	-4.891	0.000	-0.056	-0.024

	coef	std err	z	P> z	[0.025	0.975]
ec1	6.004e-07	2.3e-07	2.606	0.009	1.49e-07	1.05e-06
ec2	-8.137e-06	2.38e-06	-3.420	0.001	-1.28e-05	-3.47e-06
ec3	-2.634e-05	3.64e-06	-7.231	0.000	-3.35e-05	-1.92e-05
Cointegration relations for loading-coefficients-column 1						
	coef	std err	z	P> z	[0.025	0.975]
beta.1	1.0000	0	0	0.000	1.000	1.000
beta.2	2.275e-16	0	0	0.000	2.27e-16	2.27e-16
beta.3	9.456e-16	0	0	0.000	9.46e-16	9.46e-16
beta.4	-2705.2081	4732.046	-0.572	0.568	-1.2e+04	6569.431
const	-452.2697	1027.999	-0.440	0.660	-2467.110	1562.570
Cointegration relations for loading-coefficients-column 2						
	coef	std err	z	P> z	[0.025	0.975]
beta.1	-3.043e-19	0	0	0.000	-3.04e-19	-3.04e-19
beta.2	1.0000	0	0	0.000	1.000	1.000
beta.3	-4.888e-18	0	0	0.000	-4.89e-18	-4.89e-18
beta.4	-515.4406	357.354	-1.442	0.149	-1215.841	184.959
const	53.8357	457.417	0.118	0.906	-842.685	950.356
Cointegration relations for loading-coefficients-column 3						
	coef	std err	z	P> z	[0.025	0.975]
beta.1	-1.232e-17	0	0	0.000	-1.23e-17	-1.23e-17
beta.2	3.384e-18	0	0	0.000	3.38e-18	3.38e-18
beta.3	1.0000	0	0	0.000	1.000	1.000
beta.4	-805.0145	99.370	-8.101	0.000	-999.776	-610.253
const	-67.1644	34.543	-1.944	0.052	-134.868	0.539

Elaboración: Emilio Gavilanes

Anexo 57: Prueba VIF de multicolinealidad para Modelo de Efectos Fijos

Prueba de Multicolinealidad (VIF)	
Variable	VIF
Const	10.821628
PIB pc	3.901294
Infla	1.041527

IC	3.971546
----	----------

Elaboración: Emilio Gavilanes

Anexo 58: Prueba de heterocedasticidad (Breusch-Pagan) para Modelo de Efectos Fijos

Prueba de Heterocedasticidad (Breusch-Pagan)
--

LM Statistic	10.089544591361008
LM-Test p-value	0.01782011013186673
F-Statistic	3.4607481040608308
F-Test p-value	0.017224022068364535

Elaboración: Emilio Gavilanes

Anexo 59: Prueba de heterocedasticidad (Breusch-Pagan) para Modelo de Efectos Aleatorios

Prueba de Heterocedasticidad (Breusch-Pagan)
--

LM Statistic	8.753756482262845
LM-Test p-value	0.03328432306294897
F-Statistic	2.9662846427395463
F-Test p-value	0.03627264197352826

Elaboración: Emilio Gavilanes

Anexo 60: Modelo de Efectos Fijos original

```

PanelOLS Estimation Summary
=====
Dep. Variable:          PB      R-squared:              0.2582
Estimator:             PanelOLS R-squared (Between):   0.0000
No. Observations:     220     R-squared (Within):    0.2582
Date:                 Tue, Dec 24 2024 R-squared (Overall):   -5.9352
Time:                 19:27:10  Log-likelihood         -2393.0
Cov. Estimator:       Unadjusted

                          F-statistic:      22.859
                          P-value          0.0000
Entities:              20
Avg Obs:               11.000  Distribution:          F(3,197)
Min Obs:               11.000
Max Obs:               11.000  F-statistic (robust): 22.859
                          P-value          0.0000
Time periods:         11
Avg Obs:               20.000  Distribution:          F(3,197)
Min Obs:               20.000
Max Obs:               20.000

Parameter Estimates
=====
Parameter  Std. Err.  T-stat  P-value  Lower CI  Upper CI
-----
const     -4.259e+04  2.392e+04  -1.7807  0.0765  -8.976e+04  4577.5
PIB pc     1.8334    0.2290    8.0059  0.0000  1.3818    2.2851
Infla     -0.0533    2.2153   -0.0241  0.9808  -4.4220    4.3154
IC        -35.970    376.61   -0.0955  0.9240  -778.67    706.73
=====
F-test for Poolability: 2.8981
P-value: 0.0001
Distribution: F(19,197)

```

Elaboración: Emilio Gavilanes

Anexo 61: Modelo de Efectos Fijos con errores estándar robustos

```

--- Resultados del Modelo de Efectos Fijos ---
PanelOLS Estimation Summary
=====
Dep. Variable:          PB      R-squared:              0.2582
Estimator:             PanelOLS R-squared (Between):   0.0000
No. Observations:     220     R-squared (Within):    0.2582
Date:                 Wed, Dec 25 2024 R-squared (Overall):   -5.9352
Time:                 13:23:26  Log-likelihood         -2393.0
Cov. Estimator:       Clustered

                          F-statistic:      22.859
                          P-value          0.0000
Entities:              20
Avg Obs:               11.000  Distribution:          F(3,197)
Min Obs:               11.000
Max Obs:               11.000  F-statistic (robust): 29.578
                          P-value          0.0000
Time periods:         11
Avg Obs:               20.000  Distribution:          F(3,197)
Min Obs:               20.000
Max Obs:               20.000

Parameter Estimates
=====
Parameter  Std. Err.  T-stat  P-value  Lower CI  Upper CI
-----
const     -4.259e+04  2.794e+04  -1.5244  0.1290  -9.769e+04  1.251e+04
PIB pc     1.8334    0.2328    7.8764  0.0000  1.3744    2.2925
Infla     -0.0533    1.5051   -0.0354  0.9718  -3.0216    2.9149
IC        -35.970    418.49   -0.0860  0.9316  -861.27    789.32
=====

```

Elaboración: Emilio Gavilanes

Anexo 62: Modelo de Efectos Aleatorios original

```

--- Resultados del Modelo de Efectos Aleatorios ---
RandomEffects Estimation Summary
=====
Dep. Variable:                PB      R-squared:                0.0509
Estimator:                    RandomEffects  R-squared (Between):    0.0000
No. Observations:            220    R-squared (Within):     0.0886
Date:                        Wed, Dec 25 2024  R-squared (Overall):    0.0509
Time:                        13:16:15    Log-likelihood          -2420.1
Cov. Estimator:              Unadjusted
                               F-statistic:            3.8597
                               P-value                 0.0102
Entities:                    20      Distribution:            F(3,216)
Avg Obs:                     11.000
Min Obs:                     11.000
Max Obs:                     11.000
                               F-statistic (robust):    3.8597
                               P-value                 0.0102
Time periods:                11      Distribution:            F(3,216)
Avg Obs:                     20.000
Min Obs:                     20.000
Max Obs:                     20.000

Parameter Estimates
=====
Parameter  Std. Err.  T-stat  P-value  Lower CI  Upper CI
-----
const      1.858e+04  3243.8  5.7283  0.0000  1.219e+04  2.497e+04
PIB pc     0.3134    0.0929  3.3732  0.0009  0.1303    0.4964
Infla     -1.2131   2.1857  -0.5550  0.5795  -5.5210   3.0949
IC        -280.76   92.036  -3.0506  0.0026  -462.16   -99.358
=====

```

Elaboración: Emilio Gavilanes

Anexo 63: Modelo de Efectos Aleatorios con errores robustos (Clustered)

```

--- Resultados del Modelo de Efectos Aleatorios ---
RandomEffects Estimation Summary
=====
Dep. Variable:                PB      R-squared:                0.0509
Estimator:                    RandomEffects  R-squared (Between):    0.0000
No. Observations:            220    R-squared (Within):     0.0886
Date:                        Wed, Dec 25 2024  R-squared (Overall):    0.0509
Time:                        13:15:42    Log-likelihood          -2420.1
Cov. Estimator:              Clustered
                               F-statistic:            3.8597
                               P-value                 0.0102
Entities:                    20      Distribution:            F(3,216)
Avg Obs:                     11.000
Min Obs:                     11.000
Max Obs:                     11.000
                               F-statistic (robust):    5.8759
                               P-value                 0.0007
Time periods:                11      Distribution:            F(3,216)
Avg Obs:                     20.000
Min Obs:                     20.000
Max Obs:                     20.000

Parameter Estimates
=====
Parameter  Std. Err.  T-stat  P-value  Lower CI  Upper CI
-----
const      1.858e+04  3246.4  5.7237  0.0000  1.218e+04  2.498e+04
PIB pc     0.3134    0.0897  3.4916  0.0006  0.1365    0.4902
Infla     -1.2131   0.4904  -2.4736  0.0141  -2.1796   -0.2465
IC        -280.76   85.975  -3.2656  0.0013  -450.22   -111.30
=====

```

Elaboración: Emilio Gavilanes

Anexo 64: Prueba de normalidad de residuos (Shapiro-Wilk) para Modelo de Efectos Fijos

Prueba de Normalidad de los Residuos (Shapiro-Wilk)	
Shapiro-Wilk Statistic	0.9058117866516113
p-value	1.468937e-10

Elaboración: Emilio Gavilanes

Anexo 65: Prueba de normalidad de residuos (Shapiro-Wilk) para Modelo de Efectos Aleatorios

Prueba de Normalidad de los Residuos (Shapiro-Wilk)	
Shapiro-Wilk Statistic	0.8498
p-value	0.0000

Elaboración: Emilio Gavilanes

Anexo 66: Pruebas de autocorrelación Durbin-Watson y Ljung-Box para Modelo de Efectos Fijos

Prueba de Durbin – Watson		
Durbin-Watson Statistic	1.0702271394845193	
Prueba de Ljung – Box		
Lags	lb_stat	lb_pvalue
10	198.226915	3.708987e-37

Se rechaza la hipótesis nula: Hay evidencia de autocorrelación.

Elaboración: Emilio Gavilanes

Anexo 67: Prueba de autocorrelación de Woolridge para Modelo de Efectos Fijos

Prueba de Woolridge	
Estadístico F	59.26470014
P-valor	4.814679e-13

Se rechaza la hipótesis nula: Existe autocorrelación en los errores

Elaboración: Emilio Gavilanes

Anexo 68: Pruebas de autocorrelación Durbin-Watson y Ljung-Box para Modelo de Efectos Aleatorios

Prueba de Durbin – Watson	
Durbin-Watson Statistic	0.9970

Prueba de Ljung – Box

Lags	lb_stat	lb_pvalue
10	285.865701	1.505245e-55

Se rechaza la hipótesis nula: Hay evidencia de autocorrelación.

Elaboración: Emilio Gavilanes

Anexo 69: Prueba de poolability para datos de panel en Modelo de Efectos Fijos

Model Comparison

	Fixed Effects	Pooled
Dep. Variable	PB	PB
Estimator	PanelOLS	PanelOLS
No. Observations	220	220
Cov. Est.	Clustered	Unadjusted
R-squared	0.2582	0.0509
R-squared (Within)	0.2582	0.0886
R-squared (Between)	0.0000	0.0000
R-squared (Overall)	-5.9352	0.0509
F-statistic	22.859	3.8597
P-value (F-stat)	0.0000	0.0102
const	-4.259e+04	1.858e+04
	(-1.5244)	(5.7283)
PIB pc	1.8334	0.3134
	(7.8764)	(3.3732)
Infla	-0.0533	-1.2131
	(-0.0354)	(-0.5550)
IC	-35.970	-280.76
	(-0.0860)	(-3.0506)
	Effects	Entity

Elaboración: Emilio Gavilanes

Anexo 70: Prueba de poolability para datos de panel en Modelo de Efectos Aleatorios

Model Comparison

	Pooled	RandomEffects
Dep. Variable	PB	PB
Estimator	PooledOLS	RandomEffects
No. Observations	220	220
Cov. Est.	Unadjusted	Clustered
R-squared	0.0509	0.0509
R-squared (Within)	0.0886	0.0886

R-squared (Between)	0.0000	0.0000
R-squared (Overall)	0.0509	0.0509
F-statistic	3.8597	3.8597
P-value (F-stat)	0.0102	0.0102
const	1.858e+04	1.858e+04
	(5.7283)	(5.7237)
PIB pc	0.3134	0.3134
	(3.3732)	(3.4916)
Infla	-1.2131	-1.2131
	(-0.5550)	(-2.4736)
IC	-280.76	-280.76
	(-3.0506)	(-3.2656)

Elaboración: Emilio Gavilanes