



COMILLAS

UNIVERSIDAD PONTIFICIA

ICAI

ICADE

CIHS

Facultad de Ciencias Económicas y Empresariales

EL IMPACTO DEL RIESGO GEOPOLÍTICO EN
LOS MERCADOS FINANCIEROS:
UN ANÁLISIS RETROSPECTIVO DE LOS
ÚLTIMOS 25 AÑOS (2000 – 2025)

Autor: Alberto Sánchez Gómara

5º E-6 Analytics

Business Analytics

Tutora: Isabel Catalina Figuerola

Índice

| | |
|--|----|
| Resumen..... | 5 |
| Abstract..... | 6 |
| 1. Introducción | 7 |
| 2. Marco Teórico..... | 9 |
| 2.1. El Índice GPR de Caldara y Iacovello | 9 |
| 2.2. Alternativa al Índice GPR..... | 13 |
| 2.3. Estudios Previos sobre el Riesgo Geopolítico y los Mercados Financieros | 15 |
| 3. Metodología | 17 |
| 3.1. Horizonte y Frecuencia Temporal de los Datos..... | 17 |
| 3.2. Datos: índice GPR, activos financieros y variables de control..... | 17 |
| 3.2.1. Índice GPR..... | 17 |
| 3.2.2. Activos Financieros | 17 |
| 3.2.3. Variables de Control | 18 |
| 3.3. Regresión por Mínimos Cuadrados Ordinarios | 22 |
| 3.4. Análisis de Causalidad de Granger | 23 |
| 3.5. Variables | 24 |
| 3.6. Python como Herramienta para el Análisis de Datos | 25 |
| 4. Análisis Empírico y Resultados | 25 |
| 4.1. Ajuste Temporal del Índice GPR..... | 25 |
| 4.2. Tratamiento y Limpieza de los Datos | 26 |
| 4.3. Comparación Gráfica entre el Índice GPR y los Activos Financieros..... | 27 |
| 4.4. Análisis Preliminar de los Datos..... | 31 |
| 4.4.1. Prueba de Dickey-Fuller | 31 |
| 4.4.2. Estadísticas Descriptivas..... | 31 |
| 4.4.3. Matriz de Correlación | 32 |
| 4.5. Aplicación del Modelo de Regresión por Mínimos Cuadrados Ordinarios..... | 33 |

| | |
|---|----|
| 4.5.1. Modelo 1 | 33 |
| 4.5.2. Modelo 2 | 35 |
| 4.6. Análisis de Causalidad de Granger | 36 |
| 5. Conclusiones | 42 |
| 5.1. Implicaciones y Contribuciones de la Investigación | 44 |
| 5.2. Limitaciones y Líneas de Investigación Futuras..... | 45 |
| 6. Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado..... | 46 |
| 7. Bibliografía | 48 |
| 8. Anexos | 51 |

Índice de Figuras

| | |
|---|----|
| Figura 1: Componentes del índice GPR por tipo de evento geopolítico, 2000-2025 | 10 |
| Figura 2: Evolución histórica del índice GPR y sus repuntes asociados a eventos clave, 1985-2020..... | 11 |
| Figura 3: Evolución del índice GPR diario y mensual, 1985-2020 | 12 |
| Figura 4: Comparación entre la evolución del índice GPR y del índice EPU, 2000-2025..... | 14 |

Índice de Tablas

| | |
|--|----|
| Tabla 1: Clasificación de los activos financieros por mercado..... | 18 |
| Tabla 2: Variables de control empleadas en la investigación | 20 |
| Tabla 3: Comparación entre el índice GPR y el índice GPR ajustado durante los atentados del 11 de septiembre de 2001 | 26 |
| Table 4: Fragmento del Dataframe resultante tras el procesamiento inicial de los datos..... | 26 |

| | |
|--|----|
| Tabla 5: Resultads de la prueba de Dickey-Fuller aumentada (ADF) para evaluar la estacionariedad de las series temporales..... | 31 |
| Tabla 6: Estadísticas descriptivas del índice GPR y de los rendimientos de los activos financieros analizados..... | 32 |
| Tabla 7: Matriz de correlación entre el índice GPR y los rendimientos de los activos financieros analizados..... | 32 |
| Tabla 8: Resultados de modelo de regresión por mínimos cuadrados ordinarios (sin incluir las variables de control)..... | 33 |
| Tabla 9: Resultados del modelo de regresión por mínimos cuadrados ordinarios (incluyendo las variables de control)..... | 35 |
| Tabla 10: Resultados del análisis de causalidad de Granger para el mercado de renta variable..... | 37 |
| Tabla 11: Resultados del análisis de causalidad de Granger para el mercado de renta fija..... | 38 |
| Tabla 12: Resultados del análisis de causalidad de Granger para el mercado de commodities..... | 39 |
| Tabla 13: Resultados del análisis de causalidad de Granger para el mercado de divisas..... | 40 |
| Tabla 14: Resultados del análisis de causalidad de Granger para el mercado de criptomonedas..... | 41 |

Resumen

Este Trabajo de Fin de Grado examina el impacto del riesgo geopolítico sobre los mercados financieros en el período 2000–2025. Como indicador principal se emplea el índice de riesgo geopolítico (índice GPR, en adelante), desarrollado por Caldara e Iacovello, que cuantifica la incertidumbre geopolítica mediante el análisis de artículos de prensa. La investigación busca determinar en qué medida dicho riesgo afecta a los rendimientos de diversos activos, con el fin de identificar aquellos que puedan desempeñar un papel de refugio seguro en contextos de elevada incertidumbre geopolítica.

La metodología empleada combina un modelo de regresión por mínimos cuadrados ordinarios (OLS, por sus siglas en inglés) y un análisis de causalidad de Granger, lo que permite evaluar tanto el impacto inmediato como diferido del riesgo geopolítico sobre una variedad de activos.

Los resultados muestran que el mercado bursátil reacciona de forma inmediata y negativa ante el aumento en el riesgo geopolítico, mientras que el oro confirma su papel como un activo refugio, aunque su reacción no es instantánea, sino diferida en el tiempo. Los bonos del Tesoro de EE.UU. y los bonos corporativos de alta calificación no presentan una relación significativa con el riesgo geopolítico, ni inmediata ni con desfase, lo cual refuerza su papel tradicional como activos estables ante este tipo de incertidumbre. En el caso del petróleo, el gas natural o el Bitcoin, los resultados sugieren que su comportamiento está determinado por otros factores estructurales. Por último, en el mercado de divisas, el tipo de cambio USD/JPY muestra una respuesta diferida ante el riesgo geopolítico, confirmando su papel como refugio seguro.

Este Trabajo de Fin de Grado adopta un enfoque integral al analizar una amplia gama de activos procedentes de diversos mercados financieros. Como posibles líneas futuras de investigación, se plantea la aplicación de otros modelos econométricos y la incorporación de eventos geopolíticos concretos en el análisis, lo que permitiría profundizar en la comprensión del impacto de cada tipo de conflicto sobre los mercados financieros.

Conceptos clave: riesgo geopolítico, mercados financieros, índice GPR, activos refugio, regresión OLS, causalidad de Granger, análisis de series temporales.

Abstract

This Final Degree Project examines the impact of geopolitical risk on financial markets during the period 2000–2025. The main indicator used is the Geopolitical Risk Index (GPR Index, hereafter), developed by Caldara and Iacoviello, which quantifies geopolitical uncertainty through the analysis of newspaper articles. The research aims to determine the extent to which such risk affects the returns of various assets, in order to identify those that may serve as safe havens in contexts of heightened geopolitical uncertainty.

The methodology combines an Ordinary Least Squares (OLS) regression model with a Granger causality analysis, allowing for the assessment of both the immediate and lagged effects of geopolitical risk on a wide range of assets.

The results show that stock markets react immediately and negatively to increases in geopolitical risk, while gold confirms its role as a safe-haven asset, although its response is not immediate but rather delayed over time. U.S. Treasury bonds and high-grade corporate bonds do not exhibit a significant relationship with geopolitical risk, either contemporaneously or with lags, reinforcing their traditional role as stable assets in times of uncertainty. In the case of oil, natural gas, and Bitcoin, the findings suggest that their behavior is driven by other structural factors. Lastly, in the foreign exchange market, the USD/JPY exchange rate shows a lagged response to geopolitical risk, confirming its role as a safe-haven currency.

This Final Degree Project adopts a comprehensive approach by analyzing a wide range of assets from various financial markets. Future lines of research include the application of alternative econometric models and the incorporation of specific geopolitical events into the analysis, which would allow for a deeper understanding of how each type of conflict affects financial markets.

Key concepts: geopolitical risk, financial markets, GPR index, safe-haven assets, OLS regression, Granger causality, time series analysis.

1. Introducción

El objetivo principal de este Trabajo de Fin de Grado es analizar el impacto del riesgo geopolítico en diferentes mercados financieros, utilizando como indicador de referencia el índice GPR desarrollado por Caldara e Iacovello. El propósito es determinar si existe una relación significativa entre los niveles de incertidumbre geopolítica y el comportamiento de diversos activos financieros, con el fin de ofrecer a los inversores una mejor comprensión del papel que desempeña el riesgo geopolítico en los mercados.

En este escenario, se plantea la siguiente pregunta de investigación:

¿Cómo impacta el riesgo geopolítico, medido a través del índice GPR, en los retornos de una variedad de activos financieros?

A partir de esta pregunta principal, se plantean dos preguntas secundarias:

- ¿La reacción de los mercados financieros ante la incertidumbre geopolítica es inmediata o se manifiesta de forma diferida?
- ¿Qué activos financieros actúan como refugio seguro frente al riesgo geopolítico?

Este Trabajo de Fin de Grado, que aborda un tema de gran relevancia actual, se justifica tanto desde una perspectiva académica como práctica. La investigación se beneficia de mi formación académica en el doble grado de Business Analytics y Relaciones Internacionales. Mi conocimiento en Relaciones Internacionales me proporciona una comprensión profunda de los factores y eventos que generan tensiones geopolíticas, mientras que mi formación en Business Analytics, especialmente en el uso de herramientas como Python y técnicas de regresión lineal como el modelo de regresión por mínimos cuadrados ordinarios, me capacita para llevar a cabo un análisis riguroso de los datos y extraer conclusiones cuantitativas.

La relevancia de este estudio cobra especial importancia en el contexto actual. Recientemente, Donald Trump ha sido reelegido como presidente de Estados Unidos, y su nuevo mandato ha acelerado un cambio en el paradigma geopolítico. Sus amenazas de retirada de la OTAN si los países europeos no cumplen con los objetivos de gasto en defensa, su acercamiento a figuras como Vladimir Putin, así como sus políticas proteccionistas, como la imposición de nuevos aranceles, han aumentado significativamente la percepción de riesgo sistémico a nivel global. Este escenario ha provocado inquietud en las relaciones transatlánticas, generando dudas sobre

el compromiso estadounidense con la seguridad colectiva y reactivando los temores ante una política exterior más impredecible y unilateral. A estos cambios se suman los conflictos armados en curso, como la guerra entre Rusia y Ucrania o el conflicto entre Israel y Gaza. Todo ello ha contribuido a situar el riesgo geopolítico en niveles sin precedentes desde la Guerra Fría.

En este escenario de creciente volatilidad global, los inversores y analistas financieros enfrentan el reto de anticipar y mitigar el efecto de la incertidumbre geopolítica. Comprender la manera en que determinados activos responden ante un incremento del riesgo geopolítico, así como identificar cuáles de ellos pueden desempeñar un papel de refugio en contextos de incertidumbre, resulta esencial para diseñar estrategias de cobertura eficaces.

En el contexto de esta investigación es fundamental entender qué es el riesgo geopolítico. De acuerdo a la definición propuesta por Caldara e Iacovello (2022), el riesgo geopolítico es “la amenaza y la materialización de eventos negativos relacionados con conflictos bélicos, actos de terrorismo, y cualquier tipo de tensión entre naciones o actores políticos que perturbe las relaciones internacionales pacíficas” (Caldara e Iacoviello, 2022). Se trata de una definición concreta de la que se excluyen otros acontecimientos relevantes de carácter geopolítico ocurridos a lo largo de la historia: la disolución de la URSS en diciembre de 1991, el referéndum del Brexit en junio de 2016, o las elecciones presidenciales en EE. UU. son algunos ejemplos (Baur y Smales, 2020).

La literatura existente se ha centrado en el análisis del impacto del riesgo geopolítico sobre activos específicos. Sin embargo, a pesar del creciente interés por las implicaciones globales del riesgo geopolítico, se observa una carencia de investigaciones que adopten un enfoque más amplio e integrado, que considere simultáneamente diferentes mercados y tipos de activos. Este Trabajo de Fin de Grado tiene como objetivo contribuir a cubrir esta brecha, ofreciendo una visión general sobre cómo distintas clases de activos reaccionan ante la incertidumbre geopolítica. Además, a diferencia de otros estudios que se limitan al uso de una única metodología, este trabajo combina, de manera complementaria, un modelo de regresión por mínimos cuadrados ordinarios y un análisis de causalidad de Granger, con el fin de captar tanto el impacto inmediato como el efecto diferido del riesgo geopolítico sobre los mercados financieros.

Este Trabajo de Fin de Grado se estructura en varias secciones que abordan de forma progresiva los distintos aspectos del análisis. En primer lugar, el marco teórico presenta el índice GPR, una alternativa metodológica al mismo, y una revisión de los principales estudios previos sobre la relación entre el riesgo geopolítico y los mercados financieros. A continuación, la sección de metodología describe el horizonte y la frecuencia temporal de los datos utilizados, así como las variables seleccionadas. También se explican los modelos econométricos aplicados y se detalla el uso de Python como herramienta para el tratamiento y análisis de datos. Posteriormente, en el análisis empírico, se expone el proceso de recopilación, limpieza y ajuste temporal de los datos, incluyendo la comparación gráfica entre el índice GPR y los activos financieros analizados. Asimismo, se realiza un análisis preliminar que incluye la prueba de estacionariedad de Dickey-Fuller, estadísticas descriptivas y matriz de correlaciones. Posteriormente, se presentan los resultados de la regresión por mínimos cuadrados ordinarios y el análisis de causalidad de Granger. Por último, la sección de conclusiones recoge las principales evidencias extraídas del estudio, discute sus implicaciones prácticas, señala las limitaciones y propone posibles líneas de investigación futuras.

2. Marco Teórico

2.1. El Índice GPR de Caldara y Iacovello

En este Trabajo de Fin de Grado, se tomará como referencia el índice GPR, desarrollado por Caldara e Iacovello (2022), como herramienta principal para cuantificar el nivel de incertidumbre geopolítica (Baur & Smales, 2020).

Para construir el índice GPR, que cubre el periodo comprendido entre enero de 1985 y enero de 2025, Caldara e Iacovello (2022) emplean una técnica de procesamiento de lenguaje natural para identificar términos vinculados a la incertidumbre geopolítica. Con ello, se calcula la proporción de artículos periodísticos que contienen dichos términos. La lógica que sustenta el índice GPR es sencilla: cuanto mayor es la presencia de conceptos relacionados con el riesgo geopolítico en los periódicos, mayor es la percepción de dicho riesgo en un momento determinado (Baur & Smales, 2020).

En la elaboración del índice GPR, Caldara e Iacovello (2022) se basan en el análisis de los diez periódicos más relevantes de Estados Unidos, Reino Unido y Canadá: Chicago Tribune, Daily Telegraph, Financial Times, Globe and Mail, The Guardian, Los Angeles Times, New York

Times, USA Today, Wall Street Journal y Washington Post. Estos medios cubren acontecimientos geopolíticos de alcance global, generalmente con implicaciones directas para Estados Unidos (Caldara & Iacoviello, 2022).

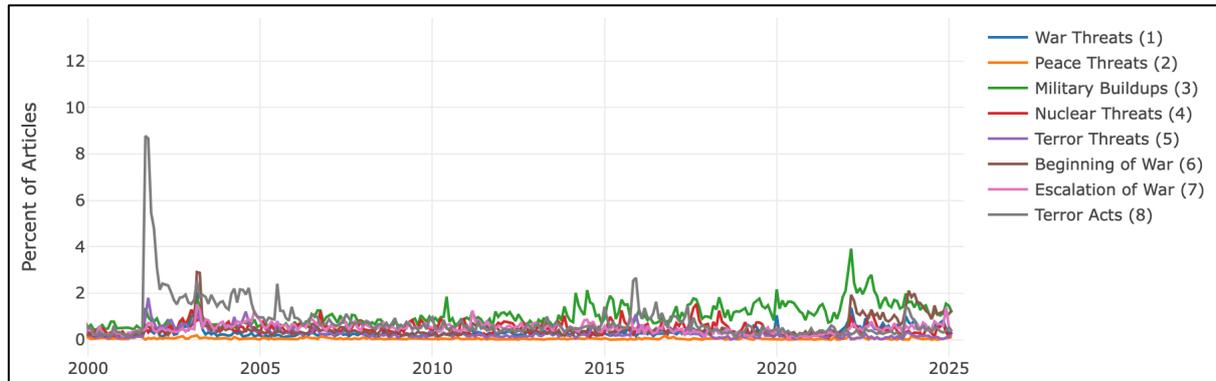


Figura 1: Componentes del índice GPR por tipo de evento geopolítico, 2000-2025

El gráfico muestra la evolución temporal de los componentes del índice GPR, desglosados en ocho categorías: amenazas de guerra, amenazas a la paz, acumulación militar, amenazas nucleares, amenazas terroristas, inicio de guerras, escaladas bélicas y actos terroristas. Se presenta el porcentaje de artículos que mencionan estos eventos en medios de prensa anglosajones.

Fuente: Caldara e Iacoviello (2022). Gráfico extraído de la página web oficial del índice GPR: <https://www.matteoiacoviello.com/gpr.htm>

Según Caldara e Iacovello (2022), la búsqueda automatizada identifica artículos que contienen términos agrupados en seis categorías principales: El Grupo 1 incluye menciones explícitas al riesgo geopolítico, así como referencias a conflictos militares que afectan a grandes regiones del mundo con participación de Estados Unidos. El Grupo 2 recoge términos vinculados específicamente a tensiones nucleares. Los Grupos 3 y 4 se refieren a amenazas de guerra y amenazas terroristas, respectivamente. Por último, los grupos 5 y 6 hacen referencia, respectivamente, a la cobertura mediática de eventos geopolíticos que ya se han materializado (GPR Acts) y a amenazas o riesgos potenciales que aún no se han concretado (GPR Threats) (Baur & Smales, 2020)

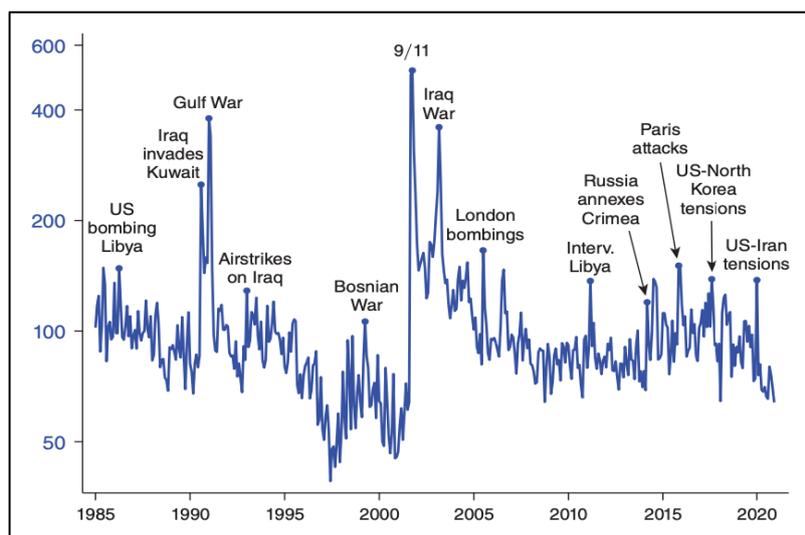


Figura 2: Evolución histórica del índice GPR y sus repuntes asociados a eventos clave, 1985-2020

El gráfico muestra la evolución del índice GPR desde 1985 hasta 2020, normalizado a un valor de 100 durante el período 1985–2019. Se destacan los principales eventos geopolíticos que generaron repuntes significativos en el índice, como los atentados del 11-S, la Guerra del Golfo o la anexión de Crimea.

Fuente: Caldara, D., & Iacoviello, M. (2022). Measuring Geopolitical Risk. *American Economic Review*, 112(4), 1194–1225. <https://doi.org/10.1257/aer.20191823>

El índice GPR registra varios picos significativos a lo largo del tiempo, coincidiendo con eventos geopolíticos de gran relevancia. Entre ellos se encuentran: el bombardeo de Libia por parte de EE. UU. en abril de 1986; la invasión de Kuwait por parte de Iraq y la posterior Guerra del Golfo en enero de 1991; la invasión de Iraq por parte de EE. UU. en marzo de 2003; la anexión de Crimea por parte de Rusia en agosto de 2014; o los ataques terroristas en París en noviembre de 2015 (Caldara & Iacoviello, 2022). No obstante, el valor máximo del índice GPR se alcanzó en septiembre de 2001, coincidiendo con los atentados terroristas en Estados Unidos. El 11-S supuso un punto de inflexión en la cobertura mediática de los eventos geopolíticos, lo que provocó un aumento notable en la media del índice. A partir de entonces, se inició la denominada guerra contra el terrorismo, y los medios de comunicación comenzaron a intensificar de forma sostenida la difusión de noticias relacionadas con amenazas terroristas (Caldara & Iacoviello, 2022).

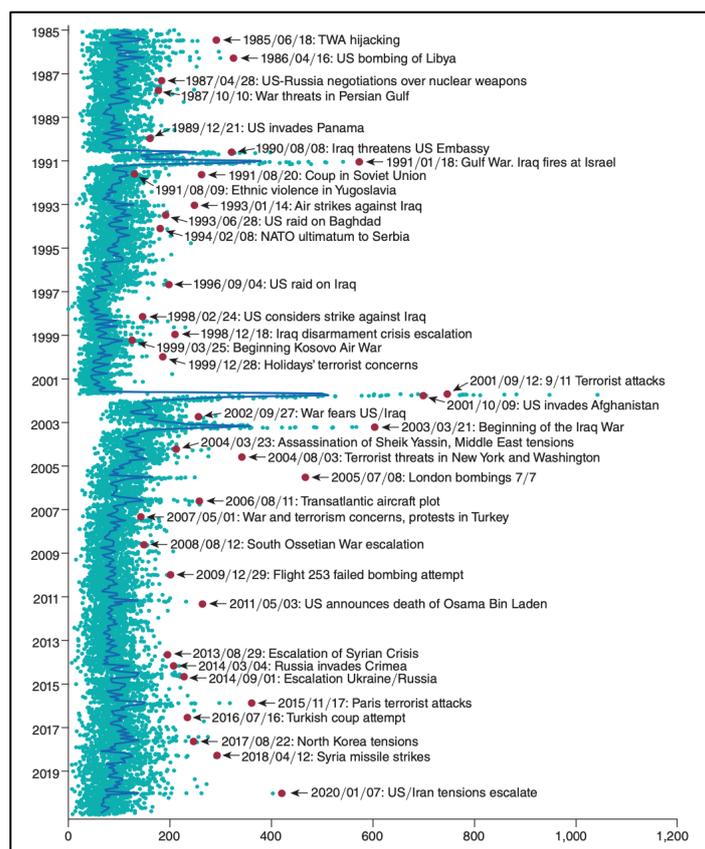


Figura 3: Evolución del índice GPR diario y mensual, 1985-2020

El gráfico presenta la evolución del índice GPR en frecuencia diaria y mensual entre 1985 y 2020. La línea azul sólida representa la serie mensual, los puntos verdes indican las observaciones diarias, y los puntos rojos destacan picos del índice asociados a eventos geopolíticos relevantes identificados por los medios de comunicación.

Fuente: Caldara e Iacoviello (2022). Gráfico extraído de la página web oficial del índice GPR: <https://www.matteoiacoviello.com/gpr.htm>

Aunque Caldara e Iacovello (2022) ofrecen el índice GPR en frecuencia diaria y mensual, el índice GPR diario proporciona una visión más precisa y detallada del riesgo geopolítico, al permitir identificar acontecimientos que, por su corta duración, pueden pasar desapercibidos en la versión mensual del índice. Esto se debe a que el índice GPR mensual se calcula como el promedio de los valores diarios, lo que suaviza el impacto de aquellos eventos que reciben una cobertura mediática limitada en el tiempo (Caldara & Iacoviello, 2022).

No obstante, cuando los medios de comunicación dedican una cobertura prolongada a un evento relevante durante varios días, el índice GPR mensual puede registrar valores elevados. Esto suele ocurrir en el caso de acontecimientos geopolíticos de gran magnitud que, por su importancia, son cubiertos durante días o incluso semanas. Un ejemplo claro se da en septiembre de 2001, cuando los atentados del 11-S ocuparon la agenda mediática durante semanas, lo que se tradujo en un valor excepcionalmente alto del índice GPR mensual.

Asimismo, las tensiones geopolíticas que se desarrollan de forma gradual pero sostenida, y que mantienen la atención constante de los medios, también pueden reflejarse en niveles elevados del índice mensual (Caldara & Iacoviello, 2022).

Dado que uno de los objetivos de este trabajo es determinar si el impacto del riesgo geopolítico en los mercados financieros se produce de forma inmediata o con cierto desfase temporal, en nuestra investigación nos centraremos en el índice GPR en su versión de frecuencia diaria. Esta versión del índice permite analizar con mayor detalle si los retornos de los activos reaccionan al riesgo geopolítico el mismo día del evento o en los días posteriores.

Aún así, a pesar de su mayor granularidad, el índice GPR diario presenta una limitación que debemos corregir: al basarse en noticias publicadas en la prensa escrita, introduce un desfase temporal respecto a la reacción real de los mercados. Esto se debe a que los periódicos tradicionales informan sobre los eventos geopolíticos con un día de retraso respecto a su ocurrencia. Por ejemplo, tras los atentados del 11-S, los mercados reaccionaron en cuestión de minutos, mientras que los periódicos reflejaron el suceso en sus ediciones del día siguiente. Por este motivo, y dado que se trata de un aspecto clave para evitar errores en la interpretación de los resultados, se empleará el índice GPR diario ajustando el análisis a dicho desfase entre el momento del evento y su cobertura mediática (Baur & Smales, 2020). Este aspecto será desarrollado más adelante.

2.2. Alternativa al Índice GPR

Baker, Bloom y Davis (2016) desarrollan, utilizando una metodología similar a la de Caldara e Iacoviello (2022), un índice alternativo al índice GPR: el índice EPU (Economic Policy Uncertainty). A diferencia del índice GPR, que se centra exclusivamente en eventos de naturaleza geopolítica como guerras, atentados terroristas o tensiones militares, el índice EPU adopta un enfoque más amplio, incluyendo acontecimientos como elecciones presidenciales o crisis financieras. Esta diferencia en el alcance de ambos índices se traduce en patrones distintos de comportamiento ante determinados eventos. Mientras que el índice EPU tiende a registrar picos en contextos de incertidumbre económica, el índice GPR muestra mayores fluctuaciones ante eventos de carácter geopolítico, como conflictos armados o ataques terroristas (Baur & Smales, 2020).

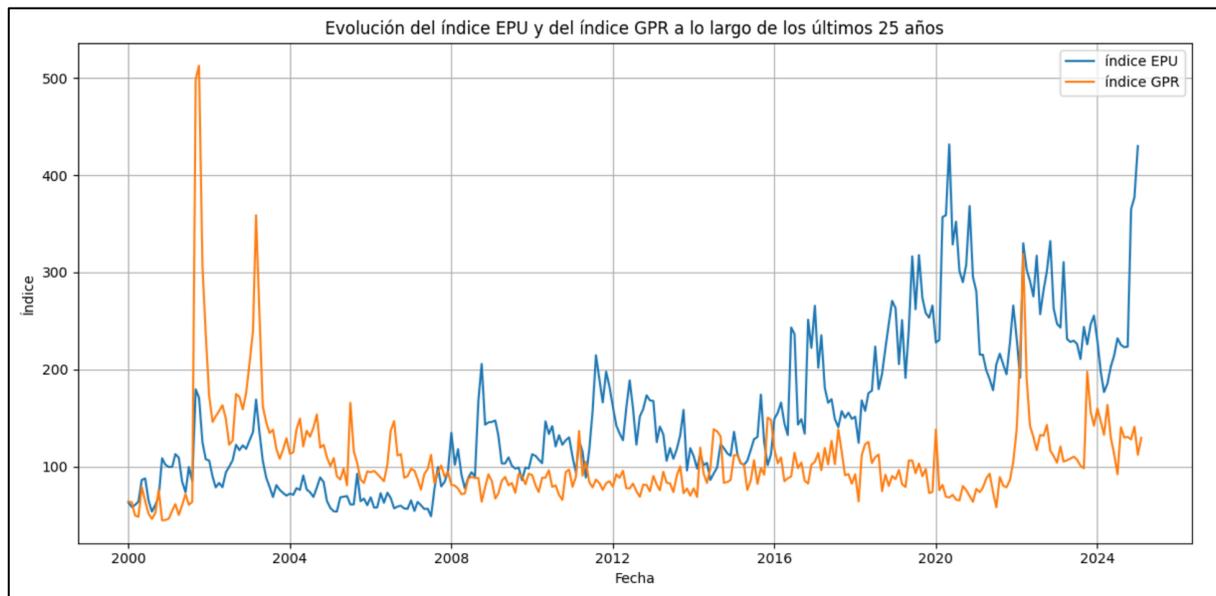


Figura 4: Comparación entre la evolución del índice GPR y del índice EPU, 2000-2025

El gráfico muestra la evolución conjunta del índice de Riesgo Geopolítico (GPR) y del índice de Incertidumbre en la Política Económica (EPU) durante el periodo 2000–2025. Ambos índices están normalizados y permiten observar las diferencias y similitudes en los patrones de comportamiento del riesgo geopolítico y la incertidumbre económica a lo largo del tiempo.

Fuente: Elaboración propia a partir de los datos de Caldara e Iacoviello (2022) para el GPR y de Baker, Bloom y Davis (2016) para el EPU.

El gráfico comparativo entre las series temporales del índice GPR y del índice EPU permite identificar la naturaleza de los sucesos captados por cada uno de los índices a lo largo del tiempo.

Entre los años 2000 y 2008, el índice GPR se mantuvo en niveles superiores al índice EPU, reflejando un contexto internacional marcado por los atentados del 11-S y el inicio de la “guerra contra el terrorismo”. No obstante, a partir de 2008, en gran parte como consecuencia de la Gran Recesión, esta tendencia comienza a revertirse: el índice EPU empieza a situarse por encima del índice GPR, y esta divergencia se hace especialmente pronunciada desde el año 2016.

En la última década, los mercados han estado expuestos a una sucesión de acontecimientos económicos que, si bien no son estrictamente geopolíticos, han generado un elevado nivel de incertidumbre global. Episodios como el Brexit, la guerra comercial entre Estados Unidos y China, los efectos económicos derivados de la pandemia de la COVID-19 o las respuestas monetarias agresivas adoptadas por los bancos centrales han contribuido a un aumento sostenido del índice EPU. Más recientemente, el inicio del segundo mandato de Donald Trump ha intensificado este contexto de incertidumbre. Su agenda política y económica, marcada por

un enfoque proteccionista y decisiones unilaterales en el ámbito comercial, ha provocado un repunte significativo del índice EPU.

Al mismo tiempo, el nuevo contexto geopolítico plantea un escenario especialmente volátil. El acercamiento diplomático entre Donald Trump y Vladímir Putin, junto con la creciente inestabilidad internacional derivada de conflictos activos como la guerra entre Rusia y Ucrania o el enfrentamiento entre Israel y Gaza, anticipan un posible repunte del índice GPR. En este nuevo paradigma global, marcado por la amenaza de nuevas guerras o escaladas bélicas, el índice GPR podría alcanzar niveles históricamente elevados.

2.3. Estudios Previos sobre el Riesgo Geopolítico y los Mercados Financieros

Los eventos geopolíticos pueden provocar un impacto significativo e inmediato en los mercados financieros. Por ejemplo, en la semana posterior a los atentados del 11-S, el índice S&P 500 registró una caída del 5,2 %, mientras que los contratos de futuros sobre el oro aumentaron un 6,2 % (Baur & Smales, 2020). Este tipo de reacciones subraya la importancia de que los inversores consideren el riesgo geopolítico como un factor clave en la toma de decisiones, e identifiquen activos refugio que les permitan proteger sus carteras frente a episodios de alta incertidumbre. (Caldara & Iacoviello, 2022).

Debido a su creciente relevancia en el contexto actual, el impacto del riesgo geopolítico sobre distintos activos financieros ha sido objeto de numerosos estudios.

Según Goel, Cagle y Shawky (2017), y Nikkinen y Vähämä (2010), los atentados terroristas provocan un aumento inmediato en la volatilidad de las acciones, acompañado de una caída en sus rendimientos. No obstante, la magnitud y duración de la reacción de los mercados financieros depende en gran medida de la naturaleza del ataque. En general, los mercados tienden a reaccionar de forma más intensa cuando los atentados se producen en países ricos, democráticos y políticamente estables, percibidos como menos vulnerables a este tipo de sucesos (Baur & Smales, 2020). En la misma línea, Caldara e Iacoviello (2022) hallaron que un incremento en el índice GPR mensual se asocia con una disminución en los rendimientos bursátiles. Complementando esta evidencia, Yilmazkuday (2024) analizó el impacto del riesgo geopolítico sobre los precios de las acciones en 29 economías entre 1985 y 2013, concluyendo que un aumento de una unidad en el índice GPR reduce significativamente el valor de los mercados bursátiles en la mayoría de los países analizados. Por su parte, Chesney, Karaman y Reshetar (2010) también constatan que los atentados terroristas generan caídas inmediatas y

significativas en los precios de las acciones, siendo este efecto aún más acusado en países con mercados financieros menos desarrollados.

El mercado de renta fija también evidencia los efectos del riesgo geopolítico. Chesney et al. (2010) hallaron que, en contextos de elevada incertidumbre geopolítica, los bonos del Tesoro de Estados Unidos tienden a funcionar como activos refugio, mostrando un comportamiento más estable. En contraste, los bonos emitidos por mercados emergentes presentan una mayor volatilidad y una caída en sus rendimientos, reflejando su mayor vulnerabilidad ante la incertidumbre geopolítica.

Los metales preciosos, en particular el oro y la plata, han sido históricamente considerados activos refugio en contextos de tensión geopolítica. Baur y Smales (2020) demostraron que, mientras las acciones y los bonos tienden a registrar caídas en sus rendimientos ante un aumento del riesgo geopolítico, el valor del oro y otros metales preciosos suele incrementarse. Esta dinámica fue corroborada por Ngo, Nguyen y Hoang (2024), quienes encontraron que los países tienden a aumentar sus reservas de oro en escenarios marcados por tensiones geopolíticas. Esta evidencia se refuerza con los hallazgos de Ramiah, Wallace, Veron, Reddy y Elliott (2019), quienes constataron que los atentados terroristas y las tensiones geopolíticas incrementan la demanda de oro como activo refugio, generando retornos anormales sostenidos hasta 120 días después del evento.

La incertidumbre geopolítica también tiene un impacto significativo en el mercado de divisas. Según Yilmazkuday (2025), los shocks derivados del riesgo geopolítico provocan movimientos heterogéneos en los tipos de cambio: mientras que monedas de países como China, Israel, o Filipinas tienden a depreciarse tras dichos eventos, otras divisas como las de Brasil, Australia o Sudáfrica muestran una apreciación. Además, se observa que las monedas de los países más conectados al comercio internacional tienden a depreciarse más rápidamente tras una crisis geopolítica.

En el caso de las criptomonedas, Patel y Richter (2020) analizaron el impacto de los atentados terroristas sobre los retornos de 1.178 criptomonedas entre 2014 y 2019. Los autores encontraron que un aumento en la tasa de éxito de estos ataques se asocia con una disminución significativa en sus rendimientos mensuales. Dado que se trata de activos relativamente nuevos, su comportamiento frente a eventos geopolíticos aún no está claramente definido, aunque la evidencia sugiere que tienden a reaccionar de forma volátil e impredecible.

3. Metodología

3.1. Horizonte y Frecuencia Temporal de los Datos

Para llevar a cabo esta investigación, se han recopilado datos correspondientes al periodo comprendido entre enero de 2000 y enero de 2025. Este horizonte temporal de 25 años resulta suficientemente amplio para incluir una variedad de episodios geopolíticos relevantes.

Respecto a la frecuencia temporal de los datos, se ha optado por una periodicidad diaria. Esta elección permite capturar con mayor precisión las variaciones de corto plazo asociadas al riesgo geopolítico, lo cual resulta fundamental para analizar su impacto tanto inmediato como con desfase en los mercados financieros.

3.2. Datos: índice GPR, activos financieros y variables de control

3.2.1. Índice GPR

Como indicador de referencia del nivel de riesgo geopolítico, se empleará el índice GPR desarrollado por Caldara e Iacoviello (2022), en su versión con frecuencia diaria. Los datos se obtendrán directamente desde la página web oficial de los autores, que ofrece la posibilidad de descargarlos en formato Excel.

3.2.2. Activos Financieros

Los datos correspondientes a los activos financieros analizados en este estudio se obtendrán a través de la plataforma Bloomberg. Los activos seleccionados son los siguientes:

| Mercado | Activo |
|----------------------------------|---|
| Renta variable | S&P500 |
| | EURO STOXX 50 |
| | MSCI Emerging Markets |
| Renta fija | ETF Bonos del Tesoro de EEUU a 10 años |
| | ETF Bonos corporativos de alta calificación |
| | ETF Bonos de mercados emergentes |
| Commodities (materias primas) | Oro (spot) |
| | Petróleo (WTI) |
| | Gas Natural |
| Divisas (Forex) | EUR/USD (Euro-Dólar) |
| | USD/JPY (Dólar-Yen) |
| Criptomonedas | Bitcoin (BTC/USD) |

Tabla 1: Clasificación de los activos financieros por mercado

La tabla presenta los activos financieros incluidos en el estudio, organizados según su categoría o mercado (renta variable, renta fija, materias primas, divisas y criptomonedas).

Fuente: Elaboración propia.

S&P 500: Índice de referencia del mercado bursátil estadounidense que recoge el desempeño de las 500 mayores empresas cotizadas del país (S&P Dow Jones Indices, n.d.).

EURO STOXX 50: Principal índice de la Eurozona, compuesto por 50 grandes empresas de distintos sectores económicos (STOXX, n.d.).

MSCI Emerging Markets: Índice que agrupa acciones de países en desarrollo como China, India o Brasil (MSCI, n.d.).

ETF de Bonos del Tesoro de EE. UU. a 10 años (iShares 7-10 Year Treasury Bond ETF): ETF que replica el rendimiento de los bonos soberanos estadounidenses a 10 años, considerados el activo refugio por excelencia (BlackRock, n.d.-a).

ETF de Bonos corporativos de alta calificación (iShares iBoxx \$ Investment Grade Corporate Bond ETF): ETF que sigue el comportamiento de una cesta de bonos emitidos por empresas con elevada solvencia crediticia. Actúa como indicador del desempeño del mercado de deuda

corporativa de bajo riesgo, mostrando la confianza de los inversores en el sector empresarial más sólido (BlackRock, n.d.-b).

ETF de Bonos de mercados emergentes (iShares J.P. Morgan USD Emerging Markets Bond ETF): ETF que refleja el rendimiento de una cartera diversificada de deuda soberana emitida por países en desarrollo. Su comportamiento ofrece una visión de la percepción del riesgo y las oportunidades en economías emergentes (BlackRock, n.d.-c).

Oro: Activo históricamente considerado como refugio frente a crisis económicas, inflación elevada y tensiones geopolíticas (Baur & Lucey, 2010).

Petróleo (WTI): Activo cuya cotización depende de la oferta y la demanda global, así como de factores geopolíticos, especialmente en regiones productoras clave (Hamilton, 2009).

Gas Natural: Activo particularmente sensible a interrupciones en el suministro y conflictos en zonas estratégicas como Europa del Este (Ritz, 2014).

EUR/USD (Euro-Dólar): Tipo de cambio más negociado a nivel mundial. Refleja la fortaleza relativa entre las economías de la Eurozona y Estados Unidos, siendo especialmente sensible a las decisiones de política monetaria del BCE y la Reserva Federal (Fratzscher, Juvenal, & Sarno, 2010).

USD/JPY (Dólar-Yen): El yen japonés ha sido históricamente considerado un activo refugio. En momentos de elevada incertidumbre, tiende a apreciarse frente al dólar, reflejando una mayor aversión al riesgo por parte de los inversores (Fatum & Yamamoto, 2016).

Bitcoin (BTC/USD): Criptomoneda más relevante y capitalizada del mercado. Su comportamiento ante eventos de riesgo geopolítico aún es objeto de debate académico, si bien algunos estudios le atribuyen propiedades similares a los activos refugio (Bouri, Molnár, Azzi, Roubaud, y Hagfors, 2017).

3.2.3. Variables de Control

Las variables de control se incorporan con el objetivo de aislar el impacto específico del riesgo geopolítico sobre los retornos de los activos financieros, teniendo en cuenta que estos factores también pueden influir de forma significativa en su comportamiento.

Los datos correspondientes a las variables de control se obtendrán a través de la plataforma Bloomberg. Las variables de control seleccionadas son las siguientes:

| Categoría | Variable de control |
|--|---|
| Volatilidad y percepción del riesgo | Índice VIX Índice MOVE |
| Factores macroeconómicos | Tasa de interés (rendimiento de bonos del Tesoro de EE. UU. a 2 años) Inflación esperada |
| Condiciones de crédito y estructura de tasas | Diferencial de crédito Prima por término |

Tabla 2: Variables de control empleadas en la investigación

La tabla muestra las variables de control empleadas en el modelo econométrico. Cada variable se clasifica según su categoría.

Fuente: Elaboración propia.

Índice VIX (Volatility Index): mide la volatilidad del S&P 500 y se utiliza como barómetro del nivel de incertidumbre en los mercados financieros. Un aumento en el VIX refleja una mayor aversión al riesgo por parte de los inversores, lo que suele coincidir con caídas en activos de mayor riesgo, como las acciones, y con una revalorización de activos refugio como el oro (Whaley, 2000). De acuerdo con Whaley (2000), el VIX se ha consolidado como una medida de la percepción del riesgo del mercado, y estudios posteriores como el de Caldara e Iacovello (2022) o el de Baur y Smales (2020) han confirmado su utilidad como variable explicativa de movimientos en los precios de los activos.

Índice MOVE (Merrill Option Volatility Estimate): mide la volatilidad en el mercado de bonos del Tesoro de Estados Unidos, actuando como un indicador de la incertidumbre en el mercado de renta fija. Un aumento en el índice MOVE refleja un incremento en la percepción de riesgo dentro de este mercado, lo que puede afectar también a otros mercados financieros. Dado que los movimientos en la deuda soberana están vinculados a la política monetaria, las expectativas macroeconómicas y el sentimiento de los inversores, el índice MOVE se considera una medida relevante del nivel de estrés financiero general (Charles Schwab, 2024).

Rendimiento de los bonos del Tesoro de EE. UU. a 2 años: es un indicador fundamental de las expectativas del mercado respecto a la política monetaria de la Reserva Federal. A diferencia

del tipo de interés oficial, este rendimiento fluctúa de forma continua, incorporando de manera inmediata las expectativas del mercado sobre futuras decisiones de política monetaria, inflación y crecimiento económico (Crump, Eusepi, y Moench, 2016). Un incremento en el rendimiento de estos bonos suele interpretarse como una señal de que los inversores anticipan una política monetaria más restrictiva por parte de la Reserva Federal (Hanson y Stein, 2015), lo que tiende a ejercer presión a la baja sobre los precios de activos sensibles a los tipos de interés, como las acciones y los bonos de mayor duración. Por el contrario, una caída en el rendimiento se asocia con expectativas de recortes en los tipos de interés, favoreciendo a los mercados de renta variable, a los bonos de largo plazo y a activos refugio como el oro (Bauer y Rudebusch, 2014).

Inflación esperada: representa la expectativa del mercado sobre el comportamiento de la inflación y se calcula como la diferencia entre el rendimiento de los bonos del Tesoro de EE. UU. a 10 años y el rendimiento de los bonos indexados a la inflación (Gürkaynak, Sack, y Wright, 2010). Un aumento en la inflación esperada se traduce en mayores rendimientos nominales, lo que reduce el precio de los bonos ya emitidos (Haubrich, Pennacchi, y Ritchken, 2012). Además, la inflación esperada aumenta la incertidumbre sobre los beneficios reales de las empresas, disminuyendo el atractivo de la renta variable e incentivando la búsqueda de activos refugio como el oro (Baur y Smales, 2020).

Diferencial de crédito: refleja la prima de riesgo que los inversores exigen por adquirir bonos corporativos en lugar de bonos soberanos libres de riesgo y se calcula como la diferencia entre el rendimiento de los bonos con calificación crediticia más baja (Baa) y los de calificación crediticia más alta (Aaa) (Gilchrist y Zakrajšek, 2012). Su evolución constituye una medida del nivel de riesgo percibido: en contextos de incertidumbre económica, el diferencial tiende a ampliarse, evidenciando un aumento en la percepción de riesgo de impago de las empresas emisoras (Longstaff, Pan, Pedersen, y Singleton, 2011). Por el contrario, en entornos de estabilidad económica, el diferencial se reduce, reflejando una mayor confianza en la solvencia corporativa.

Prima por término: refleja las expectativas del mercado sobre la evolución futura de la economía y se calcula como la diferencia entre el rendimiento de los bonos del Tesoro de Estados Unidos a 10 años y el rendimiento de los bonos a 3 meses. Una prima positiva suele interpretarse como una señal de confianza en el crecimiento económico, lo que incentiva a los inversores a asumir mayores niveles de riesgo, favoreciendo así la apreciación de activos como las acciones y los bonos corporativos. En cambio, una prima por término negativa se asocia

comúnmente con una desaceleración económica o una recesión inminente (Wright, 2006), lo que tiende a provocar caídas en los mercados bursátiles y un desplazamiento hacia activos refugio (Rudebusch y Williams, 2009).

3.3. Regresión por Mínimos Cuadrados Ordinarios

En primer lugar, se empleará un modelo de regresión por mínimos cuadrados ordinarios. Este modelo, que se basa en la estimación de una relación lineal entre una variable dependiente y una o más variables independientes, permite evaluar el impacto inmediato del riesgo geopolítico (variable independiente) sobre los retornos de los activos financieros (variable dependiente).

Los modelos econométricos que se utilizarán son los siguientes:

$$1) \quad R_t = \beta_0 + \beta_1 \Delta \log(GPR_t) + \varepsilon_t$$

El primer modelo econométrico tiene como objetivo analizar el impacto del riesgo geopolítico sobre los rendimientos de los activos financieros sin incluir aún variables de control. En este enfoque inicial, la variable dependiente es el rendimiento del activo financiero en el periodo t (R_t), mientras que la variable independiente o explicativa es la primera diferencia logarítmica del índice GPR ($\Delta \log(GPR_t)$). El parámetro β_1 representa el cambio esperado en los rendimientos del activo ante un incremento de una unidad en la variación logarítmica del índice GPR, β_0 representa el término constante, y ε_t es el término de error aleatorio que recoge los factores no explicados por el modelo.

$$2) \quad R_t = \beta_0 + \beta_1 \Delta \log(GPR_t) + \beta_2 M_t + \varepsilon_t$$

En el segundo modelo econométrico se incorporan las variables de control con el objetivo de capturar otros factores que también pueden influir en los rendimientos de los activos financieros y aislar el efecto específico del riesgo geopolítico. Aunque en la notación se utiliza M_t para representar el conjunto de variables de control, en la estimación econométrica estas se introducen de forma desagregada, cada una con su propio coeficiente. De este modo, el modelo permite estimar el impacto individual de cada variable de control sobre los rendimientos, mejorando la precisión del análisis.

Se plantean las siguientes hipótesis estadísticas:

- Hipótesis nula (H_0): la variación del índice GPR no tiene un efecto significativo sobre los rendimientos del activo financiero, es decir, el coeficiente asociado al índice GPR es igual a cero ($\beta_1=0$).
- Hipótesis alternativa (H_1): la variación del índice GPR sí tiene un efecto significativo sobre los rendimientos del activo financiero, es decir, el coeficiente asociado al índice GPR es distinto de cero ($\beta_1 \neq 0$)

3.4. Análisis de Causalidad de Granger

En segundo lugar, se aplicará un análisis de causalidad de Granger, una metodología econométrica ampliamente utilizada que permite analizar relaciones predictivas entre series temporales (Granger, 1969). En este caso, se evaluará si los valores pasados del índice GPR contienen información estadísticamente significativa para predecir los rendimientos futuros de los activos financieros analizados.

Esta metodología complementa al modelo de regresión por mínimos cuadrados ordinarios. Mientras que dicha metodología permite identificar efectos inmediatos, el análisis de causalidad de Granger ofrece una perspectiva adicional al detectar posibles efectos diferidos, manifestados días después de los eventos geopolíticos.

La causalidad de Granger se basa en el siguiente modelo econométrico:

$$Y_t = \alpha + \sum_{i=1}^p \beta_i Y_{t-i} + \sum_{j=1}^p \gamma_j X_{t-j} + \varepsilon_t$$

En este modelo, Y_t representa los retornos del activo financiero en el periodo t , mientras que X_t corresponde al valor del índice GPR en ese mismo periodo. El parámetro p indica el número de rezagos incluidos en la estimación. Los coeficientes β_i capturan el efecto de los valores pasados del propio rendimiento del activo sobre su valor actual, mientras que los coeficientes γ_j permiten evaluar si los valores pasados del índice GPR aportan información relevante para predecir los rendimientos futuros. Por último, ε_t representa el término de error, que recoge la parte de la variación en Y_t no explicada por los valores pasados de Y e X (Granger, 1969).

Se plantean las siguientes hipótesis estadísticas:

- Hipótesis nula (H_0): el índice GPR no causa, en el sentido de Granger, los rendimientos del activo. Es decir, los valores pasados del índice GPR no contienen información predictiva significativa para explicar los rendimientos futuros del activo; en términos estadísticos, esto implica que los coeficientes asociados a los rezagos del índice GPR ($\gamma_1, \gamma_2, \dots, \gamma_p$) son conjuntamente iguales a cero.
- Hipótesis alternativa (H_1): el índice GPR sí causa, en el sentido de Granger, los rendimientos del activo. Es decir, al menos uno de los coeficientes γ_j es estadísticamente distinto de cero, lo que sugiere que el índice GPR tiene poder predictivo sobre el comportamiento futuro del activo.

3.5. Variables

Las variables empleadas en esta investigación se pueden clasificar en tres grupos principales: el rendimiento del activo financiero, la variación del índice GPR y las variables de control.

En primer lugar, la variable dependiente es el rendimiento logarítmico diario del activo. Este se calcula a partir de los precios de cierre del activo en los días t y $t-1$, utilizando la siguiente fórmula:

$$R_t = 100 \times \ln\left(\frac{P_t}{P_{t-1}}\right)$$

donde P_t y P_{t-1} representan los precios de cierre del activo en los días t y $t-1$, respectivamente. La multiplicación por 100 permite expresar el resultado en términos porcentuales, facilitando su interpretación.

En segundo lugar, la variable explicativa principal es la primera diferencia logarítmica del índice GPR, denotada como $\Delta \log(\text{GPR}_t)$. Esta variable mide el cambio relativo en el índice GPR entre dos días consecutivos, es decir, cómo varía el nivel de riesgo de un día al siguiente. Se calcula mediante la siguiente expresión:

$$\Delta \log(\text{GPR}_t) = \log(\text{GPR}_t) - \log(\text{GPR}_{t-1})$$

El uso de diferencias logarítmicas permite estandarizar los cambios en el índice GPR, eliminando el efecto del nivel absoluto de los valores y facilitando comparaciones consistentes a lo largo del tiempo.

Por último, se incluyen las variables de control, que tienen como finalidad aislar el efecto específico del riesgo geopolítico. Estas variables permiten capturar otros factores macroeconómicos relevantes que también pueden influir en el comportamiento de los mercados. Son las siguientes: Índice VIX, Índice MOVE, Rendimiento de los bonos del Tesoro de EE. UU. a 2 años, Inflación esperada, Diferencial de crédito y Prima por término.

3.6. Python como Herramienta para el Análisis de Datos

Para llevar a cabo el análisis empírico se empleará Python, un lenguaje de programación ampliamente utilizado en el análisis de datos y en el ámbito de la economía financiera. Su implementación permitirá organizar y gestionar de manera eficiente la información recopilada, así como facilitar su tratamiento, visualización y análisis. Asimismo, Python cuenta con un conjunto de bibliotecas especializadas (como pandas, numpy y statsmodels) que resultan esenciales para procesar los datos, realizar análisis estadísticos, aplicar modelos de regresión lineal y ejecutar pruebas econométricas, como el análisis de causalidad de Granger.

4. Análisis Empírico y Resultados

4.1. Ajuste Temporal del Índice GPR

Dado que el índice GPR se construye a partir de noticias publicadas en periódicos tradicionales, existe un desfase temporal entre la ocurrencia del evento geopolítico y su posterior cobertura en los medios. Este desfase implica que el valor del índice GPR correspondiente al día t refleja, en realidad, acontecimientos ocurridos el día $t-1$. Para corregir esta discrepancia temporal y lograr una mayor precisión en el análisis, se ajustará el índice GPR de manera que la observación asignada al día t represente los eventos sucedidos en ese mismo día.

Un ejemplo ilustrativo de este desfase se dio el 11 de septiembre de 2001, fecha de los atentados contra las Torres Gemelas en Nueva York. Ese día, el valor del índice GPR fue de 154,07; sin embargo, el 12 de septiembre, cuando los periódicos reflejaron ampliamente el suceso, el índice se disparó a 725,51. Aplicando el ajuste mencionado, el valor de 725,51 se reasigna al 11 de septiembre, lo que permite una representación más coherente y precisa de la evolución del riesgo geopolítico.

| Índice GPR | | Índice GPR ajustado | |
|------------|--------|---------------------|--------|
| 10/9/01 | 38,24 | 10/9/01 | 154,07 |
| 11/9/01 | 154,07 | 11/9/01 | 725,51 |
| 12/9/01 | 725,51 | 12/9/01 | 633,48 |
| 13/9/01 | 633,48 | 13/9/01 | 667,81 |

Tabla 3: Comparación entre el índice GPR y el índice GPR ajustado durante los atentados del 11 de septiembre de 2001

La tabla muestra cómo el valor del índice GPR cambia al aplicar un ajuste temporal que traslada la información registrada por los medios al día en que ocurrieron los atentados. El índice original refleja un incremento el 12/9/01 (día de la publicación), mientras que el índice ajustado asigna correctamente ese valor al 11/9/01, fecha real del evento.

Fuente: Elaboración propia a partir del índice GPR de Caldara e Iacoviello (2019).

4.2. Tratamiento y Limpieza de los Datos

Antes de proceder con el análisis empírico, es fundamental llevar a cabo un proceso de tratamiento previo de los datos. Una vez recopilada la información desde la terminal de Bloomberg, los datos deben ser procesados correctamente para eliminar errores, inconsistencias o valores atípicos que puedan distorsionar los resultados.

| Fecha | GPR | Activos financieros | | | | | | | | | | | Variables de control | | | | | | | |
|---------|-----------|---------------------|---------------|-----------------------|-----------------------------------|---|----------------------------------|-------|----------------|-------------|---------|---------|----------------------|------------|-------------|---|--------------------|------------------------|-------------------|--|
| | | S&P 500 | EURO STOXX 50 | MSCI Emerging markets | ETF Bonos Tesoro EE.UU. a 10 años | ETF Bonos corporativos de alta calificación | ETF Bonos de mercados emergentes | Oro | Petróleo (WTI) | Gas natural | EUR/USD | USD/JPY | Bitcoin | Índice VIX | Índice MOVE | Tasa de interés (rendimiento bonos Tesoro de EE.UU. 2 años) | Inflación esperada | Diferencial de crédito | Prima por término | |
| 1/1/00 | 123,07842 | | | | | | | | | | | | | | | | | | | |
| 2/1/00 | 50,317482 | | | | | | | | | | | | | | | | | | | |
| 3/1/00 | 101,01859 | 1455,22 | 4849,22 | 496,22 | | | 289 | | | 1,0243 | 101,45 | | 24,21 | 102,95 | 6,384 | | | 6,592 | 5,411 | |
| 4/1/00 | 93,751915 | 1399,42 | 4657,83 | 500,38 | | | 282,25 | 25,55 | 2,176 | 1,0296 | 103,22 | | 27,01 | 101,3 | 6,299 | | | 6,497 | 5,447 | |
| 5/1/00 | 47,565075 | 1402,11 | 4541,75 | 491,09 | | | 280 | 24,91 | 2,168 | 1,0321 | 104,14 | | 26,41 | 106,69 | 6,358 | | | 6,594 | 5,425 | |
| 6/1/00 | 52,01284 | 1403,45 | 4500,69 | 486,04 | | | 281,1 | 24,78 | 2,196 | 1,0328 | 105,23 | | 25,73 | 105,21 | 6,299 | | | 6,524 | 5,383 | |
| 7/1/00 | 41,667515 | 1441,47 | 4648,27 | 492,1 | | | 281,75 | 24,22 | 2,173 | 1,0295 | 105,34 | | 21,72 | 97,81 | 6,308 | | | 6,515 | 5,38 | |
| 8/1/00 | 77,942772 | | | | | | | | | | | | | | | | | | | |
| 9/1/00 | 57,643288 | | | | | | | | | | | | | | | | | | | |
| 10/1/00 | 65,595398 | 1457,6 | 4714,03 | 506,69 | | | 281,48 | 24,67 | 2,216 | 1,0256 | 105,16 | | 21,71 | 97,13 | 6,359 | | | 6,552 | 5,39 | |
| 11/1/00 | 55,517899 | 1438,56 | 4671,5 | 498,12 | | | 283,25 | 25,77 | 2,26 | 1,0336 | 105,95 | | 22,5 | 101,03 | 6,428 | | | 6,657 | 5,426 | |
| 12/1/00 | 50,74572 | 1432,25 | 4649,3 | 500,59 | | | 282,35 | 26,28 | 2,244 | 1,0309 | 105,79 | | 22,84 | 104,11 | 6,472 | | | 6,703 | 5,446 | |
| 13/1/00 | 65,703819 | 1449,68 | 4688,35 | 508,08 | | | 284,25 | 26,69 | 2,252 | 1,0258 | 106,17 | | 21,71 | 100,44 | 6,394 | | | 6,63 | 5,403 | |
| 14/1/00 | 59,253769 | 1465,15 | 4829,36 | 515,63 | | | 284,2 | 28,02 | 2,322 | 1,0122 | 105,87 | | 19,66 | 94,61 | 6,43 | | | 6,679 | 5,4 | |
| 15/1/00 | 52,719913 | | | | | | | | | | | | | | | | | | | |
| 16/1/00 | 51,449677 | | | | | | | | | | | | | | | | | | | |
| 17/1/00 | 54,126926 | 4884,5 | 524,38 | | | | 285,5 | | | 1,0122 | 104,9 | | | 94,61 | 6,43 | | | 6,681 | 5,399 | |
| 18/1/00 | 66,321167 | 1455,14 | 4761 | 522,65 | | | 288,65 | 28,85 | 2,383 | 1,0137 | 105,67 | | 21,5 | 95,91 | 6,465 | | | 6,748 | 5,378 | |
| 19/1/00 | 82,592964 | 1455,9 | 4768,37 | 511,54 | | | 289,63 | 29,54 | 2,417 | 1,0133 | 105,32 | | 21,72 | 96,67 | 6,448 | | | 6,732 | 5,326 | |
| 20/1/00 | 61,08675 | 1445,57 | 4778,71 | 510,7 | | | 288,5 | 28,66 | 2,559 | 1,0168 | 105,47 | | 21,75 | 95,25 | 6,492 | | | 6,788 | 5,456 | |
| 21/1/00 | 75,088715 | 1441,36 | 4719,29 | 507,49 | | | 289,1 | 28,2 | 2,485 | 1,0098 | 104,78 | | 20,82 | 96,6 | 6,458 | 2,3944 | | 6,765 | 5,464 | |
| 22/1/00 | 74,161964 | | | | | | | | | | | | | | | | | | | |
| 23/1/00 | 54,947807 | | | | | | | | | | | | | | | | | | | |
| 24/1/00 | 90,75528 | 1401,53 | 4718,76 | 507,63 | | | 287,6 | 27,83 | 2,528 | 1,0072 | 105,57 | | 24,07 | 94,16 | 6,406 | 2,3234 | | 6,685 | 5,452 | |
| 25/1/00 | 60,576313 | 1410,03 | 4653,61 | 499,7 | | | 287,05 | 28,28 | 2,616 | 1,0009 | 106,04 | | 23,02 | 96,28 | 6,432 | 2,3559 | | 6,692 | 5,562 | |
| 26/1/00 | 74,375435 | 1404,09 | 4721,03 | 501,02 | | | 286 | 27,84 | 2,523 | 1,0019 | 105,66 | | 23,03 | 95,45 | 6,442 | 2,344 | | 6,664 | 5,561 | |
| 27/1/00 | 66,864273 | 1398,56 | 4786,82 | 502,55 | | | 286,85 | 27,32 | 2,61 | 0,9882 | 105,12 | | 23,54 | 95,03 | 6,506 | 2,3719 | | 6,692 | 5,602 | |

Table 4: Fragmento del Dataframe resultante tras el procesamiento inicial de los datos

La tabla muestra una porción del DataFrame que integra el índice GPR, los activos financieros seleccionados y las variables de control utilizadas en el análisis. Se observan valores en blanco correspondientes a fines de semana y festivos, en los que los mercados financieros permanecen cerrados y no se registran precios de cierre.

Fuente: Elaboración propia.

El DataFrame resultante, tras el procesamiento inicial, incorpora tanto el índice GPR como los datos correspondientes a los activos financieros y a las variables de control. No obstante, es

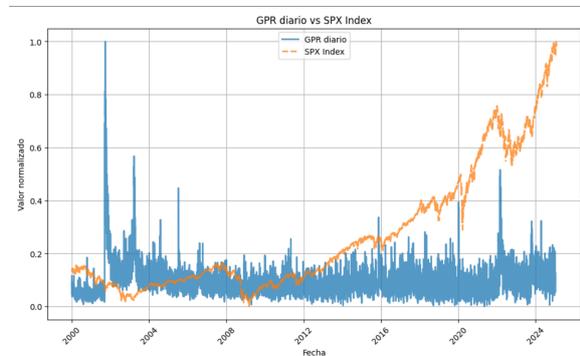
importante señalar que tanto en los activos financieros como en las variables de control pueden encontrarse valores ausentes. Esta situación se debe a que los mercados financieros no operan durante los fines de semana ni en días festivos, por lo que los precios de cierre únicamente se registran en días hábiles. Por este motivo, con el objetivo de garantizar la precisión del análisis y evitar sesgos o distorsiones en los resultados, se eliminan las observaciones que contienen datos faltantes.

4.3. Comparación Gráfica entre el Índice GPR y los Activos Financieros

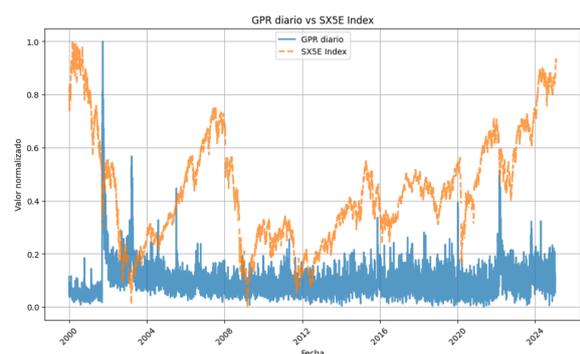
Los gráficos siguientes muestran la evolución temporal del índice GPR junto con los precios cada uno de los activos analizados. En la primera columna, las series temporales se presentan en su forma original, sin normalizar, lo que genera discrepancias visuales debido a las diferencias de escala entre las variables.

Para resolver este problema, en la segunda columna se muestran las series temporales tras haber sido normalizadas, lo que permite ajustar todas las variables a una escala común. Este procedimiento facilita una comparación visual más clara y coherente.

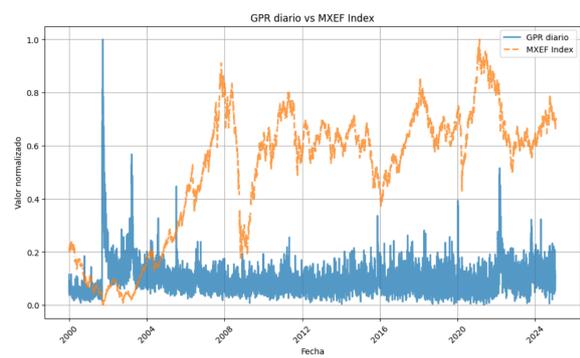
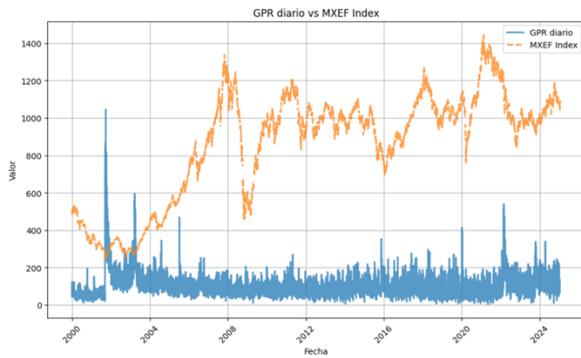
- Índice GPR vs S&P 500



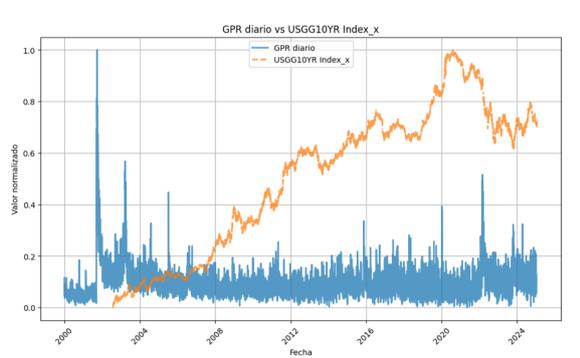
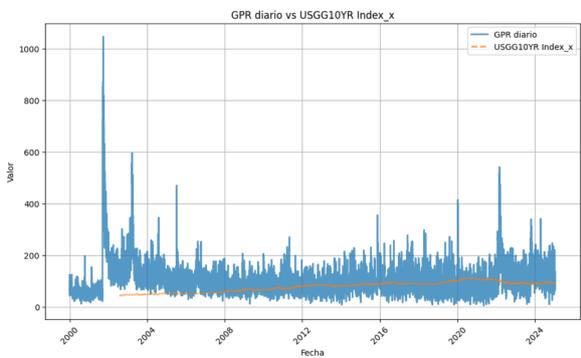
- Índice GPR vs EURO STOXX 50



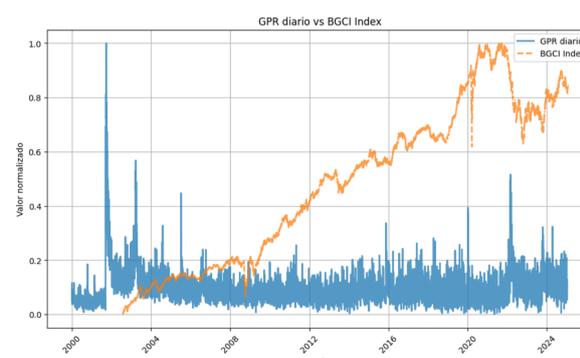
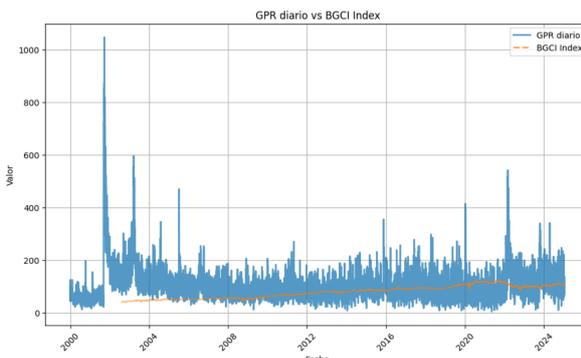
- Índice GPR vs MSCI Emerging Markets



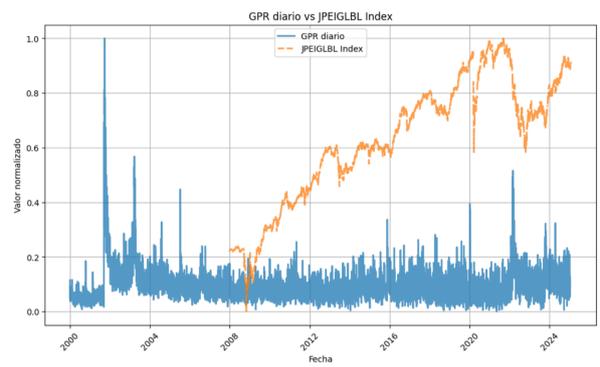
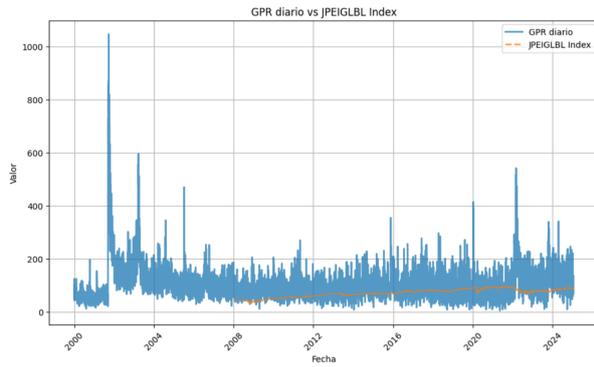
- Índice GPR vs ETF de Bonos del tesoro de EE. UU. a 10 años



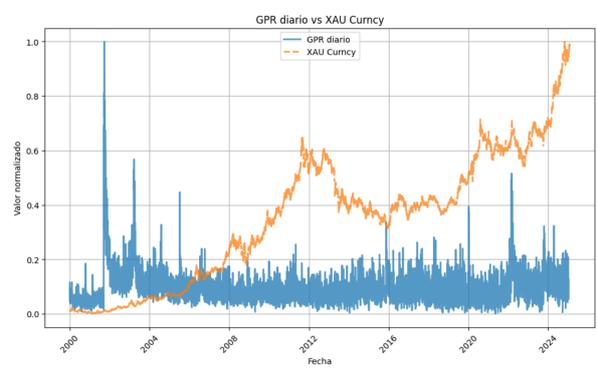
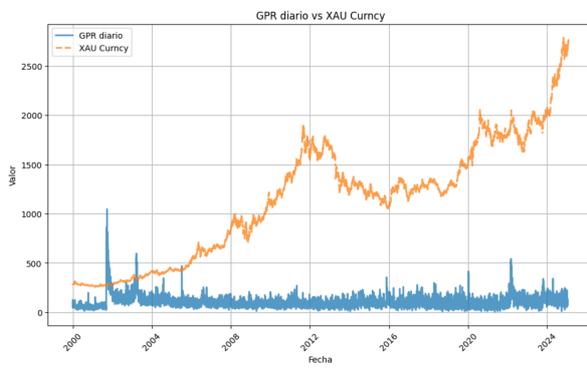
- Índice GPR vs ETF de Bonos corporativos de alta calificación



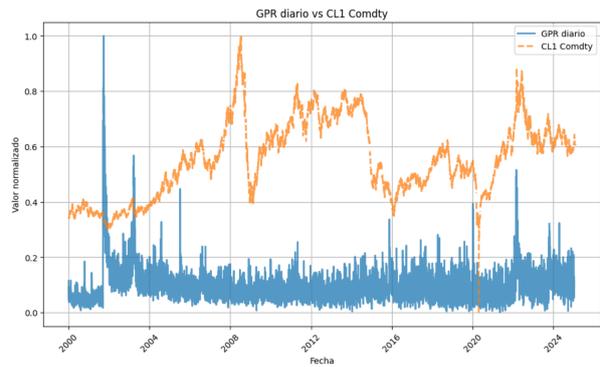
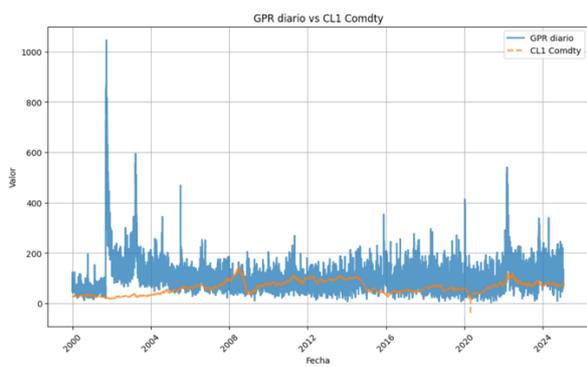
- Índice GPR vs ETF de Bonos de mercados emergentes



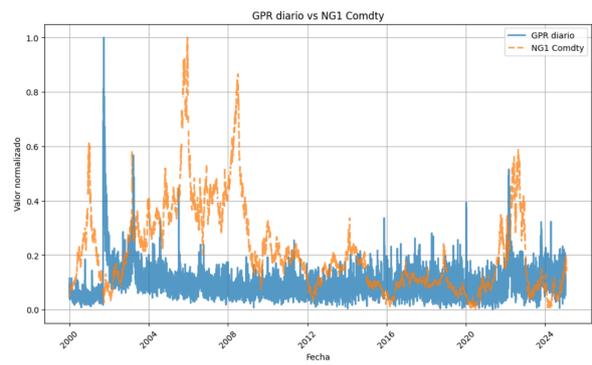
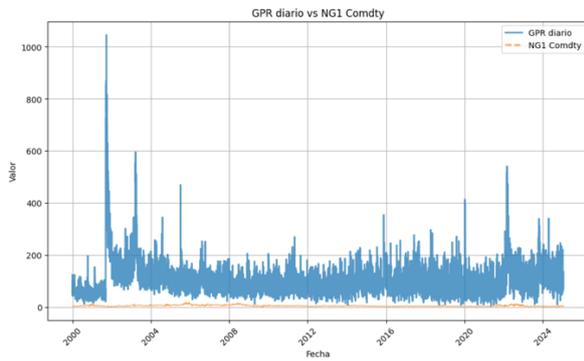
- Índice GPR vs Oro



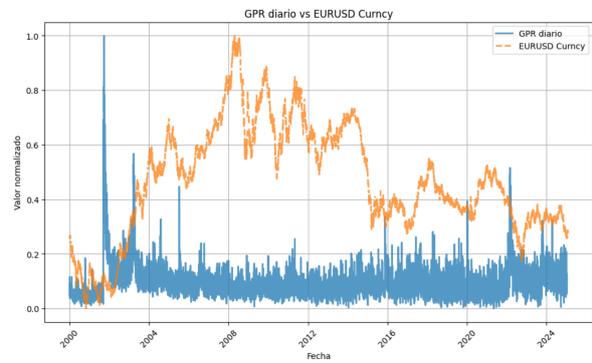
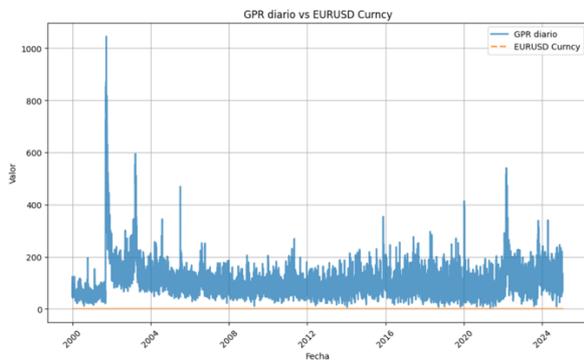
- Índice GPR vs Petróleo



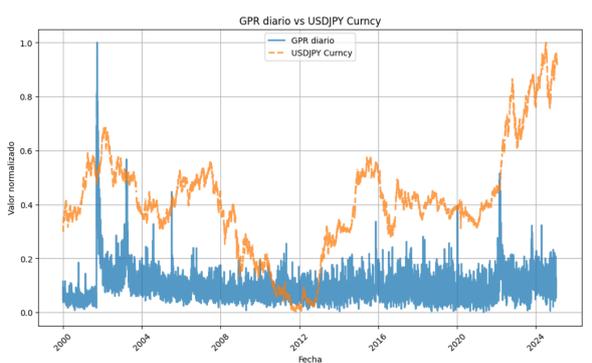
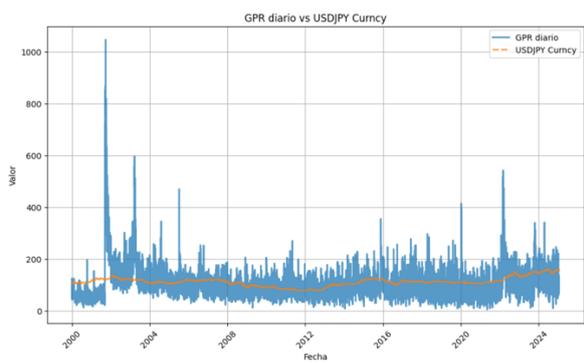
- Índice GPR vs Gas natural



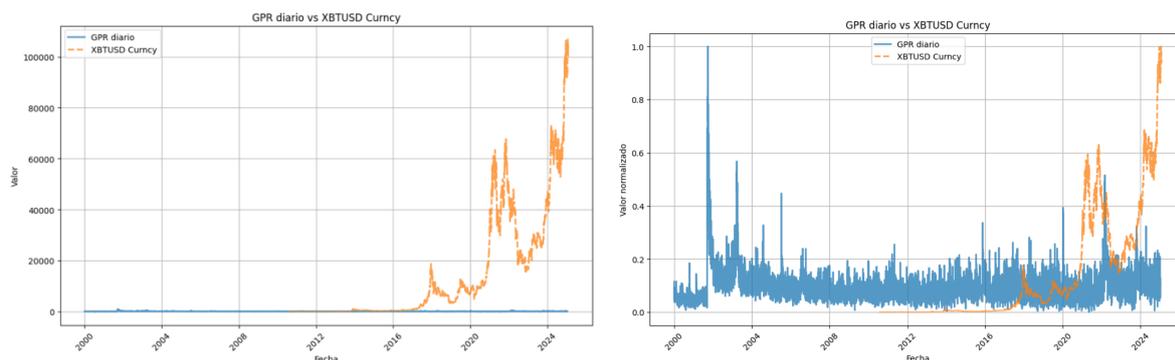
- Índice GPR vs EUR/USD



- Índice GPR vs USD/JPY



- Índice GPR vs Bitcoin



4.4. Análisis Preliminar de los Datos

4.4.1. Prueba de Dickey-Fuller

| Prueba de Dickey-Fuller | | | | | | | | | | | | | |
|-------------------------|-----------|------------|------------------|--------------------------|--------------------------------------|--|-------------------------------------|--------|-------------------|----------------|------------|------------|------------|
| | Alog(GPR) | Rt S&P 500 | Rt EURO STOXX 50 | Rt MSCI Emerging markets | Rt ETF Bonos Tesoro EE.UU. a 10 años | Rt ETF Bonos corporativos de alta calificación | Rt ETF Bonos de mercados emergentes | Rt Oro | Rt Petróleo (WTI) | Rt Gas natural | Rt EUR/USD | Rt USD/JPY | Rt XBT/USD |
| Estadístico ADF | -19,78 | -14,69 | -34,13 | -74,41 | -22,84 | -17,02 | -11,07 | -74,41 | -14,59 | -17,67 | -73,97 | -21,92 | -12,4 |
| P-valor | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 | 0,000 |

Tabla 5: Resultados de la prueba de Dickey-Fuller aumentada (ADF) para evaluar la estacionariedad de las series temporales

La tabla presenta los estadísticos y p-valores correspondientes a la prueba de Dickey-Fuller aumentada (ADF) aplicada a las series temporales utilizadas en el análisis. Dado que todos los p-valores son inferiores al umbral de significancia del 5%, se rechaza la hipótesis nula de la presencia de una raíz unitaria, concluyéndose que las series son estacionarias.

Fuente: Elaboración propia.

Como parte del análisis exploratorio de los datos, se ha aplicado la prueba de Dickey-Fuller Aumentada (ADF) para evaluar la estacionariedad de las series temporales.

La estacionariedad es una propiedad esencial en el análisis de series temporales, ya que garantiza que la media, la varianza y la relación entre los datos se mantengan constantes a lo largo del tiempo. Esta condición es necesaria para que los resultados de los modelos econométricos sean fiables. En particular, el análisis de causalidad de Granger requiere que las series sean estacionarias (Granger, 1969). Si las series presentan una raíz unitaria, es decir, si no son estacionarias, es necesario transformarlas antes de aplicar el test (Lütkepohl, 2005).

Los resultados de la prueba de Dickey-Fuller indican que, en todas las series temporales analizadas, los p-valores asociados al estadístico ADF son inferiores al umbral de significancia

del 5 %. Esto permite rechazar la hipótesis nula de presencia de raíz unitaria en cada caso. Por tanto, se concluye que todas las series temporales son estacionarias.

4.4.2. Estadísticas Descriptivas

| | GPR | ΔGPR | Alog(GPR) | Rt S&P 500 | Rt EURO STOXX 50 | Rt MSCI Emerging markets | Rt ETF Bonos Tesoro EE.UU. a 10 años | Rt ETF Bonos corporativos de alta calificación | Rt ETF Bonos de mercados emergentes | Rt Oro | Rt Petróleo (WTI) | Rt Gas natural | Rt EUR/USD | Rt USD/JPY | Rt XBT/USD |
|-------|---------|---------|-----------|------------|------------------|--------------------------|--------------------------------------|--|-------------------------------------|--------|-------------------|----------------|------------|------------|------------|
| count | 9144 | 9143 | 9143 | 6294 | 6422 | 6529 | 5650 | 5650 | 4292 | 6514 | 6288 | 6289 | 6529 | 6529 | 4591 |
| mean | 105,52 | 0,01 | 0,00 | 0,02 | 0,00 | 0,01 | 0,01 | 0,02 | 0,02 | 0,03 | 0,03 | 0,01 | 0,00 | 0,01 | 0,31 |
| std | 65,27 | 44,37 | 0,46 | 1,22 | 1,40 | 1,15 | 0,43 | 0,53 | 0,70 | 1,05 | 2,60 | 3,68 | 0,58 | 0,61 | 5,19 |
| min | 3,57 | -286,36 | -3,00 | -12,77 | -13,24 | -9,99 | -2,54 | -9,55 | -10,66 | -9,51 | -28,22 | -30,05 | -2,52 | -3,86 | -60,09 |
| 25% | 67,38 | -25,97 | -0,28 | -0,48 | -0,64 | -0,55 | -0,25 | -0,22 | -0,22 | -0,48 | -1,27 | -1,98 | -0,33 | -0,31 | -1,29 |
| 50% | 93,00 | -1,27 | -0,01 | 0,06 | 0,03 | 0,07 | 0,02 | 0,04 | 0,04 | 0,04 | 0,11 | 0,00 | 0,01 | 0,01 | 0,14 |
| 75% | 126,60 | 24,52 | 0,26 | 0,59 | 0,68 | 0,63 | 0,27 | 0,27 | 0,27 | 0,58 | 1,36 | 1,92 | 0,32 | 0,33 | 1,94 |
| max | 1045,60 | 571,44 | 2,87 | 10,96 | 10,44 | 10,07 | 3,37 | 9,32 | 6,51 | 10,25 | 31,96 | 38,17 | 3,45 | 5,50 | 51,70 |

Tabla 6: Estadísticas descriptivas del índice GPR y de los rendimientos de los activos financieros analizados

La tabla recoge medidas estadísticas (número de observaciones, media, desviación estándar, mínimo, percentiles y máximo) del índice GPR, de su primera diferencia en niveles y en logaritmos, así como de los rendimientos diarios de los activos financieros incluidos en el estudio para el periodo 2000–2025.

Fuente: Elaboración propia.

4.4.3. Matriz de Correlación

| | GPR | ΔGPR | Alog(GPR) | Rt S&P 500 | Rt EURO STOXX 50 | Rt MSCI Emerging markets | Rt ETF Bonos Tesoro EE.UU. a 10 años | Rt ETF Bonos corporativos de alta calificación | Rt ETF Bonos de mercados emergentes | Rt Oro | Rt Petróleo (WTI) | Rt Gas natural | Rt EUR/USD | Rt USD/JPY | Rt XBT/USD |
|--|-----|--------|-----------|------------|------------------|--------------------------|--------------------------------------|--|-------------------------------------|---------|-------------------|----------------|------------|------------|------------|
| GPR | 1 | 0,3398 | 0,3033 | -0,0054 | -0,0038 | -0,0118 | -0,0134 | -0,0152 | -0,0348 | 0,0068 | -0,0250 | 0,0062 | 0,0008 | 0,0199 | -0,0147 |
| ΔGPR | | 1 | 0,8766 | -0,0303 | -0,0414 | -0,0282 | 0,0078 | -0,0104 | -0,0212 | 0,0256 | 0,0058 | -0,0122 | 0,0036 | -0,0011 | -0,0105 |
| Alog(GPR) | | | 1 | -0,0330 | -0,0293 | -0,0233 | 0,0096 | -0,0128 | -0,0203 | 0,0110 | 0,0048 | -0,0090 | -0,0062 | 0,0085 | -0,0124 |
| Rt S&P 500 | | | | 1 | 0,5844 | 0,4364 | -0,3181 | 0,1486 | 0,3825 | 0,0141 | 0,2120 | 0,0552 | 0,1209 | 0,2528 | 0,1298 |
| Rt EURO STOXX 50 | | | | | 1 | 0,5725 | -0,2857 | 0,0783 | 0,3667 | -0,0112 | 0,2074 | 0,0374 | 0,0626 | 0,2284 | 0,0840 |
| Rt MSCI Emerging markets | | | | | | 1 | -0,1744 | 0,1389 | 0,4013 | 0,1435 | 0,2408 | 0,0527 | 0,1900 | 0,1304 | 0,0399 |
| Rt ETF Bonos Tesoro EE.UU. a 10 años | | | | | | | 1 | 0,5874 | 0,1889 | 0,2185 | -0,1530 | -0,0169 | 0,1184 | -0,4672 | -0,0141 |
| Rt ETF Bonos corporativos de alta calificación | | | | | | | | 1 | 0,4437 | 0,1572 | 0,0218 | 0,0134 | 0,1766 | -0,2220 | 0,0517 |
| Rt ETF Bonos de mercados emergentes | | | | | | | | | 1 | 0,1728 | 0,1963 | 0,0634 | 0,1991 | -0,0210 | 0,0862 |
| Rt Oro | | | | | | | | | | 1 | 0,1888 | 0,0567 | 0,3842 | -0,2758 | 0,0371 |
| Rt Petróleo (WTI) | | | | | | | | | | | 1 | 0,1879 | 0,1280 | 0,0723 | 0,0477 |
| Rt Gas natural | | | | | | | | | | | | 1 | 0,0606 | 0,0197 | 0,0059 |
| Rt EUR/USD | | | | | | | | | | | | | 1 | -0,3058 | 0,0551 |
| Rt USD/JPY | | | | | | | | | | | | | | 1 | -0,0190 |
| Rt XBT/USD | | | | | | | | | | | | | | | 1 |

Tabla 7: Matriz de correlación entre el índice GPR y los rendimientos de los activos financieros analizados

La tabla muestra los coeficientes de correlación de Pearson entre el índice de riesgo geopolítico, sus transformaciones, y los rendimientos diarios de los activos financieros considerados en el estudio.

Fuente: Elaboración propia.

4.5. Aplicación del Modelo de Regresión por Mínimos Cuadrados Ordinarios

4.5.1. Modelo 1: $R_t = \beta_0 + \beta_1 \Delta \log(GPR_t) + \varepsilon_t$

| | Rt S&P 500 | Rt EURO STOXX 50 | Rt MSCI Emerging markets | Rt ETF Bonos Tesoro EE.UU. a 10 años | Rt ETF Bonos corporativos de alta calificación | Rt ETF Bonos de mercados emergentes | Rt Oro | Rt Petróleo (WTI) | Rt Gas natural | Rt EUR/USD | Rt USD/JPY | Rt XBT/USD |
|--------------------------|------------|------------------|--------------------------|--------------------------------------|--|-------------------------------------|--------|-------------------|----------------|------------|------------|------------|
| coef. $\Delta \log(GPR)$ | -0,0957 | -0,0969 | -0,0715 | 0,0033 | -0,0219 | -0,0412 | 0,0051 | 0,0208 | -0,1006 | -0,0144 | 0,0154 | -0,0763 |
| P-valor | 0,005 | 0,013 | 0,024 | 0,793 | 0,159 | 0,061 | 0,861 | 0,777 | 0,333 | 0,366 | 0,360 | 0,614 |

Tabla 8: Resultados de modelo de regresión por mínimos cuadrados ordinarios (sin incluir las variables de control)

La tabla presenta los coeficientes estimados y sus respectivos p-valores en un modelo de regresión por mínimos cuadrados ordinarios (OLS), en el que la única variable explicativa es la primera diferencia logarítmica del índice GPR. Se adopta un nivel de significancia del 5% para evaluar la significatividad estadística de los coeficientes estimados.

Fuente: Elaboración propia.

El aumento en el riesgo geopolítico está asociado a una caída inmediata en los retornos del mercado bursátil. En concreto, los resultados del modelo de regresión por mínimos cuadrados muestran que, por cada aumento unitario en el logaritmo de la primera diferencia del índice GPR, los índices S&P 500, EURO STOXX 50 y MSCI Emerging Markets experimentan, en promedio, descensos de -0,0957, -0,0969 y -0,0206 puntos porcentuales, respectivamente, lo que permite rechazar la hipótesis nula y confirman la existencia de una relación negativa e inmediata entre el riesgo geopolítico y los rendimientos bursátiles.

En el mercado de renta fija, la única relación que se aproxima a un nivel de significancia estadística ocurre en los bonos de mercados emergentes. En este caso, el coeficiente asociado al índice GPR presenta un p-valor cercano al umbral convencional del 5% (concretamente, 6,1%), lo que sugiere una posible relación entre el riesgo geopolítico y el comportamiento de este activo, aunque no puede considerarse concluyente desde el punto de vista estadístico. Según los resultados, un aumento unitario en la primera diferencia logarítmica del índice GPR se asocia con una caída promedio de 0,0284 puntos porcentuales en el rendimiento de estos bonos. No obstante, dado que el p-valor no alcanza el nivel de significancia requerido, no es posible rechazar con certeza la hipótesis nula ni afirmar una relación causal inmediata. Por otro lado, no se encuentra evidencia estadísticamente significativa de que el riesgo geopolítico afecte de forma inmediata a los rendimientos de los bonos del Tesoro de EE. UU. a 10 años ni a los de los bonos corporativos de alta calificación. Los p-valores asociados a estos activos son

considerablemente altos (0,760 y 0,922, respectivamente), lo que refuerza la conclusión de que, al menos en el corto plazo, estos activos parecen estar menos expuestos a las variaciones del riesgo geopolítico global.

En el mercado de commodities o materias primas, los resultados obtenidos resultan, en apariencia, contrarios a lo esperado. Aunque el oro suele considerarse un activo refugio en contextos de incertidumbre, el análisis mediante regresión por mínimos cuadrados ordinarios no confirma esta hipótesis. Si bien el coeficiente asociado al índice GPR es positivo, el p-valor correspondiente (0,861) está muy por encima del umbral de significancia del 5%, lo que impide afirmar que dicha relación sea estadísticamente significativa. Una situación similar se observa en el caso del gas natural y del petróleo. En ambos activos, los coeficientes estimados también son positivos, pero los p-valores asociados (0,777 y 0,333, respectivamente) no permiten rechazar la hipótesis nula. En consecuencia, los resultados no evidencian una relación inmediata y significativa entre el aumento del riesgo geopolítico y los retornos de estos commodities. No obstante, la ausencia de significancia estadística en el corto plazo no implica necesariamente que no exista relación alguna; es posible que el impacto del riesgo geopolítico sobre estos activos se manifieste con cierto desfase temporal, aspecto que se abordará en el análisis de causalidad de Granger.

En el mercado de divisas, los resultados tampoco muestran una relación estadísticamente significativa entre el riesgo geopolítico y el comportamiento de los pares de divisas analizados. Para ambos pares, los p-valores asociados a los coeficientes del índice GPR son de 0,366 y 0,360, respectivamente, valores claramente superiores al umbral de significancia estándar del 5%. Por tanto, no es posible rechazar la hipótesis nula, lo que impide concluir que exista un efecto inmediato del riesgo geopolítico sobre los retornos de estas divisas.

Por último, en el mercado de criptomonedas, los resultados tampoco indican una relación estadísticamente significativa entre el riesgo geopolítico y el comportamiento del Bitcoin. El p-valor asociado al coeficiente del índice GPR es de 0,614, claramente superior al nivel de significancia del 5%, lo que impide rechazar la hipótesis nula. En consecuencia, no se encuentra evidencia suficiente para afirmar que las variaciones en el riesgo geopolítico tengan un efecto inmediato sobre los rendimientos del Bitcoin.

4.5.2. Modelo 2: $R_t = \beta_0 + \beta_1 \Delta \log(GPR_t) + \beta_2 M_t + \varepsilon_t$

| | Rt S&P 500 | Rt EURO STOXX 50 | Rt MSCI Emerging markets | Rt ETF Bonos Tesoro EE.UU. a 10 años | Rt ETF Bonos corporativos de alta calificación | Rt ETF Bonos de mercados emergentes | Rt Oro | Rt Petróleo (WTI) | Rt Gas natural | Rt EUR/USD | Rt USD/JPY | Rt XBT/USD |
|---|------------|------------------|--------------------------|--------------------------------------|--|-------------------------------------|---------|-------------------|----------------|------------|------------|------------|
| coef. Alog(GPR) | -0,0963 | -0,1100 | -0,1006 | 0,0045 | -0,0191 | -0,0351 | 0,0068 | -0,0115 | -0,0595 | -0,0075 | 0,0112 | 0,1023 |
| P-valor Alog(GPR) | 0,006 | 0,007 | 0,003 | 0,725 | 0,224 | 0,111 | 0,827 | 0,885 | 0,583 | 0,662 | 0,543 | 0,605 |
| coef. índice VIX | -0,0535 | -0,0475 | -0,0495 | 0,0040 | -0,0095 | -0,0205 | -0,0062 | -0,0475 | -0,0077 | -0,0067 | -0,0059 | -0,0837 |
| coef. índice MOVE | 0,0018 | 0,0012 | 0,0007 | -0,0009 | -0,0008 | -0,0020 | 0,0005 | -0,0009 | -0,0009 | 0,0001 | 0,0003 | -0,0040 |
| coef. rendimientos bonos Tesoro EE. UU a 2 años | -0,0649 | -0,0402 | -0,0331 | 0,0004 | -0,0093 | -0,0163 | 0,0051 | -0,0203 | 0,0095 | -0,0057 | -0,0010 | -0,2001 |
| coef. inflación esperada | 0,1375 | 0,1170 | 0,0665 | -0,0016 | 0,0393 | 0,1497 | 0,0000 | 0,2977 | 0,1212 | 0,0121 | 0,0500 | 0,9384 |
| coef. diferencial de crédito | 0,1494 | 0,1275 | 0,1374 | 0,0063 | 0,0526 | 0,1084 | 0,0233 | 0,1481 | 0,0111 | 0,0239 | 0,0122 | 0,3452 |
| coef. prima por término | -0,0883 | -0,0635 | -0,0495 | -0,0119 | -0,0317 | -0,0703 | -0,0242 | -0,0274 | 0,0292 | -0,0129 | -0,0030 | -0,1951 |

Tabla 9: Resultados del modelo de regresión por mínimos cuadrados ordinarios (incluyendo las variables de control)

La tabla presenta los coeficientes estimados de un modelo de regresión por mínimos cuadrados ordinarios (OLS) que incluye un conjunto de variables de control: índice VIX, índice MOVE, rendimiento de los bonos del Tesoro de EE. UU. a 2 años, inflación esperada, diferencial de crédito y prima por término. Se muestran los coeficientes de todas las variables, pero únicamente se incluye el p-valor correspondiente al coeficiente del GPR. Se adopta un nivel de significancia del 5 % para evaluar la relevancia estadística.

Fuente: Elaboración propia.

La inclusión de las variables de control permite aislar el efecto específico del riesgo geopolítico sobre los mercados financieros. De este modo, se puede identificar con mayor precisión el impacto real que tienen las variaciones en el índice GPR sobre los retornos de los activos analizados.

Los resultados obtenidos tras la incorporación de las variables de control son coherentes con los del modelo inicial. Se confirma que un aumento en el índice GPR se asocia con una caída inmediata en los retornos del mercado bursátil. Esta relación es estadísticamente significativa al nivel de significancia estándar del 5%, ya que los p-valores correspondientes a los coeficientes del índice GPR son inferiores a 0,05 en los tres índices bursátiles analizados. En consecuencia, se mantiene el rechazo de la hipótesis nula, lo que refuerza la conclusión de que el riesgo geopolítico tiene un impacto negativo e inmediato sobre los rendimientos de la renta variable. En particular, por cada incremento unitario en la primera diferencia logarítmica del índice GPR, los retornos del S&P 500, EURO STOXX 50 y MSCI Emerging Markets disminuyen, en promedio, 0,0963, 0,1100 y 0,1006 puntos porcentuales, respectivamente.

En el mercado de renta fija, los resultados obtenidos se mantienen en línea con los del modelo inicial. En el caso de los bonos de mercados emergentes, aunque en el modelo previo el p-valor se aproximaba al umbral convencional de significancia del 5%, en este nuevo modelo el p-valor asciende a 0,111, lo que impide considerarlo cercano a dicho umbral. Por otro lado, se continúa sin observar un efecto estadísticamente significativo en los bonos del Tesoro de EE.

UU. y en los bonos corporativos de alta calificación, cuyos p-valores son de 0,725 y 0,224, respectivamente. En conjunto, los resultados sugieren que el riesgo geopolítico no tiene un impacto inmediato sobre los rendimientos de estos instrumentos de renta fija.

De manera similar, los resultados no muestran evidencia estadísticamente significativa que indique que el aumento en el riesgo geopolítico afecte de forma inmediata los rendimientos en los mercados de materias primas, divisas o criptomonedas. Los p-valores asociados a los coeficientes del índice GPR para estos activos superan el umbral convencional de significancia del 5%, lo que impide rechazar la hipótesis nula y sugiere que, en el corto plazo, el riesgo geopolítico no ejerce un efecto inmediato sobre sus rendimientos.

No obstante, la ausencia de una relación inmediata no implica necesariamente que estos activos sean insensibles al riesgo geopolítico. Es posible que su respuesta ante eventos de esta naturaleza se produzca con cierto desfase temporal. Por esta razón, se llevará a cabo un análisis de causalidad de Granger con el objetivo de evaluar la existencia de relaciones diferidas en el tiempo. En caso de que tampoco se encuentren efectos rezagados estadísticamente significativos, podrá concluirse que estos activos son relativamente insensibles al riesgo geopolítico, y que su evolución responde principalmente a otros factores o tipos de riesgo con mayor capacidad explicativa.

4.6. Análisis de Causalidad de Granger

El análisis previo, basado en un modelo de regresión por mínimos cuadrados ordinarios, ha permitido determinar si existe una relación inmediata entre el índice GPR y los retornos de varios activos financieros. Los resultados indican que el mercado bursátil reacciona de manera instantánea ante un aumento en el riesgo geopolítico. Sin embargo, no se ha encontrado evidencia de una respuesta inmediata para el resto de activos financieros.

Un hallazgo aparentemente sorprendente es la ausencia de una relación estadísticamente significativa entre el riesgo geopolítico y los retornos del oro. La literatura financiera ha considerado históricamente al oro como un activo refugio en tiempos de incertidumbre geopolítica. No obstante, los resultados sugieren que, al menos bajo la metodología de regresión por mínimos cuadrados ordinarios, el incremento en el riesgo geopolítico no se traduce automáticamente en un aumento en los retornos del oro. Esto no implica que el oro sea insensible a las variaciones en el índice GPR, sino que su reacción podría producirse con cierto retraso en el tiempo, en lugar de manifestarse de manera inmediata.

Para evaluar esta posible respuesta diferida, en esta sección se llevará a cabo un análisis de causalidad de Granger. Este método permitirá determinar si los valores pasados del índice GPR tienen capacidad predictiva sobre los retornos futuros de los activos financieros. En otras palabras, se examinará si los mercados reaccionan al riesgo geopolítico con un desfase temporal de varios días.

La literatura financiera sostiene de manera consistente que el mercado bursátil responde de forma inmediata a la incertidumbre geopolítica, pero no suele hacer la misma afirmación para otros activos financieros. Los resultados obtenidos hasta ahora refuerzan esta observación, al encontrar que el impacto inmediato del riesgo geopolítico se limita principalmente a la renta variable. El análisis de causalidad de Granger permitirá encontrar si activos como el oro, que no han mostrado una respuesta instantánea en el modelo de regresión por mínimos cuadrados, reaccionan con cierto retraso ante aumentos en el riesgo geopolítico.

En el análisis de series temporales, el número de rezagos representa la cantidad de observaciones pasadas de una variable que se utilizan para evaluar su posible influencia sobre otra (Lütkepohl, 2005). En esta investigación, se ha establecido un máximo de 10 rezagos para realizar la prueba de causalidad de Granger, lo que equivale a analizar un horizonte de hasta diez días, dado que los datos utilizados son de frecuencia diaria. Este umbral se considera adecuado para capturar tanto efectos inmediatos como posibles reacciones retardadas de los activos financieros frente a variaciones en el índice GPR. Así, se busca identificar si la influencia del riesgo geopolítico sobre el comportamiento del mercado se manifiesta de forma diferida, proporcionando una visión más completa de la dinámica temporal entre las variables analizadas.

- Resultados para el mercado de renta variable:

| Rezagos | P-valores | | | | | | | | | |
|-----------------------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| S&P 500 | 0,0742 | 0,1128 | 0,0878 | 0,0743 | 0,0782 | 0,1128 | 0,1480 | 0,1064 | 0,0970 | 0,1126 |
| EURO STOXX 50 | 0,1788 | 0,0313 | 0,0570 | 0,0697 | 0,1336 | 0,1942 | 0,0134 | 0,0007 | 0,0003 | 0,0005 |
| MSCI Emerging Markets | 0,5610 | 0,3915 | 0,2678 | 0,2810 | 0,4275 | 0,4737 | 0,1273 | 0,1582 | 0,1081 | 0,2023 |

Tabla 10: Resultados del análisis de causalidad de Granger para el mercado de renta variable

La tabla muestra los p-valores obtenidos del test de causalidad de Granger aplicado a los índices S&P 500, EURO STOXX 50 y MSCI Emerging Markets. Se presentan los resultados para diferentes rezagos (de 1 a 10), utilizando un nivel de significancia del 5 % para evaluar la existencia de causalidad estadísticamente significativa entre la primera diferencia logarítmica del índice GPR y los retornos de cada índice bursátil.

Fuente: Elaboración propia.

En el caso de los índices bursátiles S&P 500 y MSCI Emerging Markets, los p-valores asociados a los coeficientes de los rezagos del índice GPR ($\gamma_1, \gamma_2, \dots, \gamma_p$) son superiores al umbral convencional de significancia del 5% en todos los casos. Por tanto, no se puede rechazar la hipótesis nula de la prueba de causalidad de Granger, lo que indica que los valores pasados del índice GPR no tienen poder predictivo sobre los rendimientos futuros de estos índices bursátiles. En otras palabras, los retornos del S&P 500 y del MSCI Emerging Markets no parecen responder de manera diferida ante variaciones en el riesgo geopolítico. Sin embargo, esta ausencia de causalidad en el tiempo no implica que estos mercados sean ajenos a la incertidumbre geopolítica. De hecho, como se evidenció en el modelo de regresión por mínimos cuadrados ordinarios, tanto el S&P 500 como el MSCI Emerging Markets mostraron una relación estadísticamente significativa con el índice GPR, indicando que sus rendimientos tienden a disminuir de forma inmediata cuando aumenta el riesgo geopolítico.

Por otro lado, el índice EURO STOXX 50 muestra un comportamiento particular. Si bien el modelo de regresión por mínimos cuadrados ordinarios identifica una relación inmediata entre el índice GPR y los rendimientos de este índice bursátil, el análisis de causalidad de Granger revela además una relación estadísticamente significativa en los rezagos 8, 9 y 10. En estos casos, los p-valores asociados a los coeficientes del índice GPR son inferiores al umbral convencional del 5%, lo que permite rechazar la hipótesis nula y concluir que el índice GPR causa, en el sentido de Granger, los retornos del EURO STOXX 50. Este hallazgo sugiere que, además de una respuesta inmediata, el mercado bursátil europeo podría experimentar un efecto diferido, reflejado en ajustes adicionales en los precios de los activos financieros entre una y dos semanas después de un incremento en la incertidumbre geopolítica.

- Resultados para el mercado de renta fija:

| Rezagos | P-valores | | | | | | | | | |
|---|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| ETF Bonos del Tesoro de EE. UU. A 10 años | 0,3842 | 0,3458 | 0,1783 | 0,1133 | 0,1916 | 0,2636 | 0,3563 | 0,3709 | 0,3535 | 0,4233 |
| ETF Bonos corporativos de alta calificación | 0,8641 | 0,8538 | 0,5699 | 0,3945 | 0,4697 | 0,3576 | 0,3826 | 0,3510 | 0,2390 | 0,3166 |
| ETF Bonos de mercados emergentes | 0,6762 | 0,9078 | 0,9141 | 0,4653 | 0,5898 | 0,6433 | 0,4927 | 0,4265 | 0,6055 | 0,5830 |

Tabla 11: Resultados del análisis de causalidad de Granger para el mercado de renta fija

La tabla muestra los p-valores obtenidos del test de causalidad de Granger aplicado a los bonos del Tesoro de EE. UU. a 10 años, al índice de bonos corporativos de alta calificación y al índice de bonos de mercados emergentes. Se presentan los resultados para distintos rezagos (de 1 a 10), utilizando un nivel de significancia del 5 % para evaluar la existencia de causalidad estadísticamente significativa entre la primera diferencia logarítmica del índice GPR y los retornos de cada activo de renta fija.

Fuente: Elaboración propia.

Los resultados del análisis de causalidad de Granger para los activos de renta fija analizados refuerzan las conclusiones previamente obtenidas mediante el modelo de regresión por mínimos cuadrados. En particular, para los bonos del Tesoro de EE. UU. a 10 años, los bonos corporativos de alta calificación y los bonos de mercados emergentes, los p-valores asociados a los rezagos del índice GPR superan consistentemente el umbral de significancia del 5 % en todos los casos. Esto impide rechazar la hipótesis nula y sugiere que los valores pasados del índice GPR no tienen capacidad predictiva sobre los rendimientos futuros de estos instrumentos. En consecuencia, puede concluirse que ninguno de estos activos presenta una reacción diferida ante aumentos en la incertidumbre geopolítica. Esta conclusión resulta coherente con los resultados del modelo de regresión por mínimos cuadrados ordinarios, en el que tampoco se identificó una relación inmediata y estadísticamente significativa entre el índice GPR y los retornos de estos activos.

- Resultados para el mercado de commodities:

| Rezagos | P-valores | | | | | | | | | |
|----------------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| Oro | 0,1054 | 0,0633 | 0,0916 | 0,0302 | 0,0025 | 0,0026 | 0,0036 | 0,0059 | 0,0204 | 0,0297 |
| Petróleo (WTI) | 0,8200 | 0,1921 | 0,0215 | 0,0391 | 0,0548 | 0,0964 | 0,1490 | 0,2021 | 0,1819 | 0,2414 |
| Gas natural | 0,4496 | 0,3526 | 0,6812 | 0,2228 | 0,2812 | 0,2739 | 0,2389 | 0,2566 | 0,3118 | 0,4173 |

Tabla 12: Resultados del análisis de causalidad de Granger para el mercado de commodities

La tabla muestra los p-valores obtenidos del test de causalidad de Granger aplicado al oro, al petróleo (WTI) y al gas natural. Se presentan los resultados para diferentes rezagos (de 1 a 10), utilizando un nivel de significancia del 5 % para evaluar la existencia de causalidad estadísticamente significativa entre la primera diferencia logarítmica del índice GPR y los retornos de estos activos de materias primas.

Fuente: Elaboración propia.

En el mercado de commodities, los resultados muestran diferencias en la forma en que cada activo responde al riesgo geopolítico. Según el modelo de regresión por mínimos cuadrados, no se encontró evidencia estadísticamente significativa de una relación inmediata entre el índice GPR y los rendimientos del oro, el petróleo o el gas natural. No obstante, el análisis de causalidad de Granger revela que el oro sí presenta una respuesta diferida ante variaciones en

el índice GPR, mientras que en el caso del petróleo y el gas natural no se observa evidencia significativa de efectos rezagados.

En el caso del oro, los resultados del análisis de causalidad de Granger muestran que los p-valores asociados a los rezagos del índice GPR son inferiores al umbral de significancia del 5% desde el rezago 4 hasta el rezago 10. Esto permite rechazar la hipótesis nula y concluir que el índice GPR tiene capacidad predictiva sobre los rendimientos del oro con un desfase de entre 4 y 10 días. Este hallazgo sugiere que, si bien el modelo de regresión por mínimos cuadrados ordinarios no identificó una relación inmediata significativa, el oro sí reacciona de manera diferida ante aumentos en la incertidumbre geopolítica. Este comportamiento es coherente con la literatura financiera, que considera al oro un activo refugio frente a episodios de inestabilidad global.

En el caso del petróleo, los resultados del análisis de causalidad de Granger no muestran una relación consistente con el índice GPR. Aunque en los rezagos 3 y 4 los p-valores asociados a los coeficientes de los rezagos del índice GPR son de 0.0215 y 0.0391 respectivamente, lo que sugiere una posible relación significativa en esos puntos, los p-valores correspondientes al resto de los rezagos superan el umbral del 5 %. Esta falta de consistencia sugiere que los resultados podrían no ser robustos, por lo que no es posible concluir que el petróleo reaccione de forma sistemática ante variaciones en el riesgo geopolítico.

Por su parte, el gas natural tampoco muestra evidencia de una relación diferida con el índice GPR. En todos los rezagos considerados, los p-valores son superiores al umbral del 5 %, lo que impide rechazar la hipótesis nula. En consecuencia, no se identifica capacidad predictiva del riesgo geopolítico sobre los rendimientos del gas natural, ni de forma inmediata ni con desfase temporal.

- Resultados para el mercado de divisas:

| Rezagos | P-valores | | | | | | | | | |
|---------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| EUR/USD | 0,7099 | 0,5734 | 0,7819 | 0,9359 | 0,9629 | 0,9591 | 0,9376 | 0,9309 | 0,9385 | 0,8132 |
| USD/JPY | 0,0717 | 0,0158 | 0,0411 | 0,0403 | 0,0638 | 0,0203 | 0,0269 | 0,0301 | 0,0264 | 0,0158 |

Tabla 13: Resultados del análisis de causalidad de Granger para el mercado de divisas

La tabla muestra los p-valores obtenidos del test de causalidad de Granger aplicado a los pares EUR/USD y USD/JPY. Se presentan los resultados para diferentes rezagos (de 1 a 10), utilizando un nivel de significancia del 5% para evaluar la existencia de causalidad estadísticamente significativa entre la primera diferencia logarítmica del índice GPR y los retornos de estas divisas.

Fuente: Elaboración propia.

En el mercado de divisas, el modelo de regresión por mínimos cuadrados ordinarios no encontró evidencia de que ni el EUR/USD ni el USD/JPY reaccionaran de forma inmediata ante variaciones en el índice GPR. No obstante, aunque los resultados del análisis de causalidad de Granger refuerzan esta conclusión para el EUR/USD, no lo hacen para el USD/JPY.

En el caso del EUR/USD, los p-valores asociados a todos los rezagos considerados son consistentemente superiores al umbral del 5 %, por lo que no se puede rechazar la hipótesis nula. Esto indica que los valores pasados del índice GPR no poseen capacidad predictiva sobre los rendimientos futuros de este tipo de cambio. En consecuencia, el par euro/dólar no parece responder de forma sistemática a variaciones en la incertidumbre geopolítica, ni de manera inmediata ni con desfase.

En contraste, el USD/JPY sí presenta una relación significativa con el índice GPR en la mayoría de los rezagos analizados. En concreto, los p-valores son inferiores al umbral del 5 % en los rezagos comprendidos entre el día 2 y el día 10, lo que permite rechazar la hipótesis nula y concluir que el índice GPR causa, en el sentido de Granger, los rendimientos del tipo de cambio USD/JPY. Este resultado sugiere que el riesgo geopolítico tiene capacidad predictiva sobre este par de divisas, y que el yen japonés tiende a apreciarse frente al dólar con un desfase de entre 2 y 10 días tras un aumento en la incertidumbre geopolítica.

- Resultados para el mercado de criptomonedas:

| Rezagos | P-valores | | | | | | | | | |
|--------------------|-----------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 | 10 |
| Bitcoin (BTC(USD)) | 0,0368 | 0,0746 | 0,0528 | 0,0604 | 0,1483 | 0,2937 | 0,1511 | 0,1973 | 0,2932 | 0,3579 |

Tabla 14: Resultados del análisis de causalidad de Granger para el mercado de criptomonedas

La tabla presenta los p-valores obtenidos del test de causalidad de Granger aplicado al retorno de Bitcoin frente al dólar estadounidense. Se muestran los resultados para distintos rezagos (de 1 a 10), utilizando un nivel de significancia del 5 % para evaluar la existencia de causalidad estadísticamente significativa entre la primera diferencia logarítmica del índice GPR y el retorno de este activo digital.

Fuente: Elaboración propia.

Los resultados del análisis de causalidad de Granger para el Bitcoin (BTC/USD) coinciden con los obtenidos a través del modelo de regresión por mínimos cuadrados, al no encontrarse evidencia estadísticamente significativa de una relación sistemática entre el índice GPR y esta criptomoneda. Los p-valores asociados a los rezagos del GPR en la prueba de Granger son superiores al 5 % en todos los casos, salvo en el rezago 1, donde se registra un valor de 0,0368. Si bien este dato sugiere una posible relación puntual en el muy corto plazo, no constituye evidencia robusta, ya que no se observa persistencia en los rezagos posteriores, cuyos p-valores superan nuevamente el umbral de significancia. En consecuencia, no puede concluirse que el riesgo geopolítico tenga un impacto predictivo consistente sobre los rendimientos del Bitcoin.

5. Conclusiones

En este Trabajo de Fin de Grado se ha analizado el impacto del riesgo geopolítico en los mercados financieros mediante un enfoque empírico basado en modelos de regresión por mínimos cuadrados ordinarios y análisis de causalidad de Granger. A través de este enfoque, se ha podido determinar cómo diferentes activos reaccionan ante variaciones en el índice GPR, diferenciando entre respuestas inmediatas y diferidas.

Los resultados obtenidos confirman que el mercado bursátil tiende a reaccionar de forma inmediata ante aumentos en el riesgo geopolítico. El modelo de regresión por mínimos cuadrados ordinarios reveló una relación negativa e inmediata entre el índice GPR y los rendimientos de los índices bursátiles analizados (S&P 500, EURO STOXX 50 y MSCI Emerging Markets). El análisis de causalidad de Granger respaldó estos hallazgos en el caso del S&P 500 y del MSCI Emerging Markets, al mostrar que los valores pasados del GPR no poseen capacidad predictiva sobre los retornos futuros, lo que indica que su respuesta es puramente instantánea. Sin embargo, el EURO STOXX 50 mostró una dinámica diferente: se identificó una relación predictiva en rezagos de hasta 10 días, lo que sugiere que el impacto del riesgo geopolítico en los mercados europeos podría prolongarse en el tiempo. Este resultado implica que, en contextos de elevada incertidumbre geopolítica, los inversores deben adoptar estrategias defensivas, deshacerse de activos de renta variable y redirigir su capital hacia instrumentos considerados más seguros. Estos hallazgos son coherentes con la literatura existente, donde Goel et al. (2017), Nikkinen y Vähämma (2010) y Chesney et al. (2010) establecen que el mercado bursátil tiende a experimentar caídas en los rendimientos de manera inmediata cuando aumenta la incertidumbre geopolítica.

En el mercado de bonos, los resultados indican que ni los bonos del Tesoro de EE. UU. a 10 años ni los bonos corporativos de alta calificación presentan una relación estadísticamente significativa con el riesgo geopolítico, tanto en el modelo de regresión por mínimos cuadrados como en el análisis de causalidad de Granger. Este comportamiento refuerza la percepción de estos activos como refugios seguros, al no registrar variaciones relevantes en sus rendimientos ante episodios de incertidumbre geopolítica. Este hallazgo es coherente con estudios previos, como el de Chesney et al. (2010), que señalan que los bonos del Tesoro estadounidense suelen actuar como activos refugio en contextos de tensión geopolítica. En cambio, en el caso de los bonos de mercados emergentes, aunque no se ha identificado una relación estadísticamente significativa con el riesgo geopolítico, los resultados obtenidos se sitúan cerca del umbral de significancia convencional del 5%, lo que sugiere una posible relación entre el riesgo geopolítico y los rendimientos de estos bonos. El modelo de regresión por mínimos cuadrados apunta a que estos bonos podrían experimentar una caída inmediata en sus rendimientos ante un aumento en el riesgo geopolítico. No obstante, dado que la evidencia no alcanza significancia estadística, estos resultados deben interpretarse con cautela. Este comportamiento podría deberse a la mayor vulnerabilidad de los mercados emergentes ante episodios de incertidumbre global, ya que los inversores tienden a retirar capital de estos mercados y redirigirlo hacia activos considerados más seguros en contextos de crisis.

El mercado de materias primas presentó hallazgos mixtos en cuanto a su relación con el riesgo geopolítico. En cuanto al oro, a pesar de que la regresión por mínimos cuadrados no encontró evidencia de una relación inmediata entre el riesgo geopolítico y sus retornos, la prueba de causalidad de Granger reveló una relación predictiva en rezagos de 4 a 10 días. Esto indica que, aunque el oro no reacciona de manera instantánea ante aumentos en el índice GPR, su precio tiende a incrementarse en los días posteriores a un evento geopolítico significativo. Este resultado es coherente con la literatura financiera, donde Baur y Smales (2020), Ngo et al. (2024) y Ramiah et al. (2019) concluyen que el oro es un activo refugio en tiempos de incertidumbre geopolítica. Respecto al petróleo y al gas natural, no se encontró evidencia concluyente de que el riesgo geopolítico tenga un impacto inmediato o diferido en los retornos de estos activos. Si bien algunos rezagos mostraron cierta significancia estadística, los resultados no fueron consistentes a lo largo del análisis. Esto sugiere que otros factores, como la oferta y demanda global o la política de producción de los países exportadores, tienen un peso mayor en la determinación de los precios de estos activos que el propio riesgo geopolítico.

Los resultados obtenidos para el mercado de divisas reflejan que la relación entre el índice GPR y los tipos de cambio no es homogénea. En el caso del EUR/USD, no se encontró evidencia estadísticamente significativa de una relación entre el riesgo geopolítico y los movimientos de este par, ni de forma inmediata ni con desfase temporal. Esto sugiere que su evolución está más influenciada por otros factores, como la política monetaria de la Reserva Federal y del Banco Central Europeo. Por el contrario, para el USD/JPY, la prueba de causalidad de Granger identificó una relación predictiva en los rezagos comprendidos entre 2 y 10 días. Este resultado indica que el yen japonés tiende a apreciarse frente al dólar tras un aumento en la incertidumbre geopolítica. Este comportamiento es coherente con la literatura, que considera al yen un activo refugio en tiempos de crisis, respaldado por la estabilidad macroeconómica y política de Japón (Fatum & Yamamoto, 2016).

Tanto el análisis de regresión por mínimos cuadrados ordinarios como la prueba de causalidad de Granger indican que Bitcoin no presenta una relación estadísticamente significativa y consistente con el riesgo geopolítico. Aunque se observó un p-valor inferior al 5 % en uno de los rezagos de la prueba de Granger, la falta de persistencia en los resultados a lo largo del tiempo sugiere que cualquier efecto del índice GPR sobre el comportamiento de Bitcoin es puntual y no sistemático. En consecuencia, los resultados sugieren que Bitcoin, al menos por el momento, no parece reaccionar de manera clara ante episodios de incertidumbre geopolítica.

5.1. Implicaciones y Contribuciones de la Investigación

Los resultados de esta investigación ofrecen implicaciones prácticas relevantes para los inversores. En términos de estrategia de inversión, los hallazgos refuerzan el papel de ciertos activos como refugios seguros ante episodios de alta incertidumbre geopolítica. En particular, los bonos del Tesoro de EE. UU. y el oro destacan como los más fiables en estos contextos: los primeros por su baja sensibilidad al riesgo geopolítico, y el segundo por su reacción positiva, aunque con cierto desfase temporal. Por ello, los inversores que buscan proteger sus carteras ante tensiones geopolíticas pueden considerar aumentar su exposición a estos activos.

Desde la perspectiva de la gestión del riesgo, la investigación también resalta la elevada sensibilidad del mercado bursátil a los cambios en el riesgo geopolítico. La reacción negativa e inmediata de la renta variable ante aumentos en la incertidumbre geopolítica subraya la necesidad de aplicar estrategias de cobertura y diversificación en carteras expuestas a este tipo de activos. Así, los resultados no solo aportan evidencia empírica sobre la reacción de distintos

mercados ante eventos geopolíticos, sino que también ofrecen recomendaciones útiles para diseñar carteras más resistentes en escenarios de inestabilidad global.

5.2. Limitaciones y Líneas de Investigación Futuras

A pesar de que esta investigación ha proporcionado evidencia relevante sobre la relación entre el riesgo geopolítico y los mercados financieros, existen ciertas limitaciones que conviene considerar y que abren la puerta a futuras líneas de investigación.

En primer lugar, la incorporación de un enfoque basado en eventos geopolíticos específicos permitiría analizar de forma más detallada cómo distintos tipos de crisis impactan de manera diferenciada a los activos financieros. En segundo lugar, el uso de metodologías econométricas más sofisticadas, como modelos VAR (Vectores Autorregresivos), modelos no lineales o enfoques basados en técnicas de machine learning, podría mejorar la capacidad de capturar dinámicas complejas y no lineales en la relación entre el riesgo geopolítico y los mercados financieros. Por último, debe tenerse en cuenta una limitación inherente al índice GPR: al estar construido a partir de noticias publicadas en medios de comunicación estadounidenses, su medición del riesgo geopolítico puede reflejar un sesgo hacia la perspectiva de Estados Unidos. Esto puede limitar su utilidad en contextos donde los eventos no involucran directamente a este país. Por ello, futuras investigaciones podrían complementar el análisis con indicadores alternativos.

En conjunto, estas posibles líneas de mejora abren nuevas oportunidades para seguir profundizando en el estudio de la relación entre el riesgo geopolítico y los mercados financieros.

6. Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

Por la presente, yo, Alberto Sánchez Gómara, estudiante del doble grado en Business Analytics y Relaciones Internacionales (E6-Analytics) de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado “El impacto del riesgo geopolítico en los mercados financieros: un análisis retrospectivo de los últimos 25 años (2000 – 2025)”, declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. Brainstorming de ideas de investigación: Utilizado para idear y esbozar posibles áreas de investigación.
2. Crítico: Para encontrar contra-argumentos a una tesis específica que pretendo defender.
3. Referencias: Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
4. Interpretador de código: Para realizar análisis de datos preliminares.
5. Corrector de estilo literario y de lenguaje: Para mejorar la calidad lingüística y estilística del texto.
6. Sintetizador y divulgador de libros complicados: Para resumir y comprender literatura compleja.
7. Revisor: Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
8. Traductor: Para traducir textos de un lenguaje a otro.

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las

implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 2 de marzo de 2025

Firma: Alberto Sánchez Gómara

7. Bibliografía

Baker, S. R., Bloom, N., y Davis, S. J. (2016). Measuring economic policy uncertainty. *Quarterly Journal of Economics*, 131(4), 1593–1636. <https://doi.org/10.1093/qje/qjw024>

Baur, D. G., y Lucey, B. M. (2010). Is gold a hedge or a safe haven? An analysis of stocks, bonds and gold. *The Financial Review*, 45(2), 217–229. <https://doi.org/10.1111/j.1540-6288.2010.00244.x>

Baur, D. G., y Smales, L. A. (2020). Hedging geopolitical risk with precious metals. *Journal of Banking and Finance*, 117, 105823. <https://doi.org/10.1016/j.jbankfin.2020.105823>

Bauer, M. D., y Rudebusch, G. D. (2014). *Monetary policy expectations at the zero lower bound*. Federal Reserve Bank of San Francisco Working Paper Series, 2014-18. Recuperado de <https://www.sciencedirect.com/science/article/abs/pii/S0304405X19301230>

BlackRock. (n.d.-a). *iShares 7-10 Year Treasury Bond ETF (IEF)*. Retrieved April 9, 2025, from <https://www.ishares.com/us/products/239458/ishares-710-year-treasury-bond-etf>

BlackRock. (n.d.-b). *iShares iBoxx \$ Investment Grade Corporate Bond ETF (LQD)*. Retrieved April 9, 2025, from <https://www.ishares.com/us/products/239726/ishares-iboxx-investment-grade-corporate-bond-etf>

BlackRock. (n.d.-c). *iShares J.P. Morgan USD Emerging Markets Bond ETF (EMB)*. Retrieved April 9, 2025, from <https://www.ishares.com/us/products/239572/ishares-jpmorgan-usd-emerging-markets-bond-etf>

Bouri, E., Molnár, P., Azzi, G., Roubaud, D., y Hagfors, L. I. (2017). On the hedge and safe haven properties of Bitcoin: Is it really more than a diversifier? *Finance Research Letters*, 20, 192–198. <https://doi.org/10.1016/j.frl.2016.09.025>

Caldara, D., e Iacoviello, M. (2022). Measuring geopolitical risk. *American Economic Review*, 112(4), 1194–1225. <https://doi.org/10.1257/aer.20191823>

Charles Schwab. (2024). *What's the MOVE Index and why it might matter?* Charles Schwab & Co. Inc. Recuperado de <https://www.schwab.com/learn/story/whats-move-index-and-why-it-might-matter>

Chesney, M., Karaman, M., y Reshetar, G. (2010). The impact of terrorism on financial markets: An empirical study. *Microeconomics: General Equilibrium & Disequilibrium Models of Financial Markets eJournal*. <https://doi.org/10.2139/ssrn.1579674>

Crump, R. K., Eusepi, S., y Moench, E. (2016). *The term structure of expectations and bond yields*. Federal Reserve Bank of New York Staff Reports, No. 775. Recuperado de https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2786193

Fatum, R., y Yamamoto, Y. (2016). Intra-safe haven currency behavior during the global financial crisis. *Journal of International Money and Finance*, 66, 49–64. <https://doi.org/10.1016/j.jimonfin.2016.02.003>

Fratzscher, M., Juvenal, L., y Sarno, L. (2010). Asset prices, exchange rates and the current account. *European Economic Review*, 54(5), 643–658. <https://doi.org/10.1016/j.euroecorev.2009.12.003>

Gilchrist, S., y Zakrajšek, E. (2012). *Credit Spreads and Business Cycle Fluctuations*. *American Economic Review*, 102(4), 1692–1720. <https://doi.org/10.1257/aer.102.4.1692>

Goel, S., Cagle, S., y Shawky, H. (2017). How vulnerable are international financial markets to terrorism? An empirical study based on terrorist incidents worldwide. *Journal of Financial Stability*, 33, 120–132. <https://doi.org/10.1016/j.jfs.2017.11.001>

Granger, C. W. J. (1969). Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3), 424–438. <https://doi.org/10.2307/1912791>

Gürkaynak, R. S., Sack, B. P., y Wright, J. H. (2010). *The TIPS Yield Curve and Inflation Compensation*. *American Economic Journal: Macroeconomics*, 2(1), 70–92. <https://doi.org/10.1257/mac.2.1.70>

Hamilton, J. D. (2009). Causes and consequences of the oil shock of 2007–08. *Brookings Papers on Economic Activity*, 2009(1), 215–283. <https://doi.org/10.2139/ssrn.1386205>

Hanson, S. G., y Stein, J. C. (2015). *Monetary policy and long-term real rates*. *Journal of Financial Economics*, 115(3), 429–448. <https://doi.org/10.1016/j.jfineco.2014.09.002>

Haubrich, J. G., Pennacchi, G. G., y Ritchken, P. H. (2012). *Inflation Expectations, Real Rates, and Risk Premia: Evidence from Inflation Swaps*. *Review of Financial Studies*, 25(5), 1588–1629. <https://doi.org/10.1093/rfs/hhs004>

Longstaff, F. A., Pan, J., Pedersen, L. H., y Singleton, K. J. (2011). *How Sovereign Is Sovereign Credit Risk?* *American Economic Journal: Macroeconomics*, 3(2), 75–103. <https://doi.org/10.1257/mac.3.2.75>

Lütkepohl, H. (2005). *New introduction to multiple time series analysis*. Springer. <https://doi.org/10.1007-3-540-27752-4>

MSCI. (n.d.). *MSCI Emerging Markets Index*. Retrieved April 9, 2025, from <https://www.msci.com/our-solutions/indexes/emerging-markets>

Ngo, V. M., Nguyen, P. V., y Hoang, Y. H. (2024). The impacts of geopolitical risks on gold, oil, and financial reserve management. *Resources Policy*, 90, 104688. <https://doi.org/10.1016/j.resourpol.2024.104688>

Nikkinen, J., y Vähämaa, S. (2010). Terrorism and stock market sentiment. *The Financial Review*, 45(2), 263–275. <https://doi.org/10.1111/j.1540-6288.2010.00246.x>

Patel, P., y Richter, J. (2020). The relationship between terrorist attacks and cryptocurrency returns. *Applied Economics*, 53, 940–961. <https://doi.org/10.1080/00036846.2020.1819952>

Ritz, R. A. (2014). Price and volume effects of Russian gas supply shocks to Europe: A case study. *Energy Economics*, 43, 85–96. <https://doi.org/10.1016/j.eneco.2014.02.013>

Rudebusch, G. D., y Williams, J. C. (2009). *Forecasting Recessions: The Puzzle of the Enduring Power of the Yield Curve*. *Journal of Business & Economic Statistics*, 27(4), 492–503. <https://doi.org/10.1198/jbes.2009.07213>

STOXX. (n.d.). *EURO STOXX 50 Index*. Retrieved April 9, 2025, from <https://www.stoxx.com/index-details?symbol=SX5E>

S&P Dow Jones Indices. (n.d.). *S&P 500*. Retrieved April 9, 2025, from <https://www.spglobal.com/spdji/en/indices/equity/sp-500>

Whaley, R. E. (2000). The investor fear gauge. *Journal of Portfolio Management*, 26(3), 12–17.

Wright, J. H. (2006). *The Yield Curve and Predicting Recessions*. Finance and Economics Discussion Series 2006-07, Board of Governors of the Federal Reserve System. <https://doi.org/10.17016/FEDS.2006.07>

Yilmazkuday, H. (2024). Geopolitical risk and stock prices. *European Journal of Political Economy*, 83, 102553. <https://doi.org/10.1016/j.ejpoleco.2024.102553>

Yilmazkuday, H. (2025). Geopolitical risks and exchange rates. *Finance Research Letters*, 74, 106769. <https://doi.org/10.1016/j.frl.2025.106769>

8. Anexos

✓ Código en Python para el análisis preliminar y la estimación del modelo econométrico de regresión por Mínimos Cuadrados Ordinarios (sin variables de control)

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import statsmodels.formula.api as smf
import sklearn as sk
import plotly.express as px
import statsmodels.api as sm
from sklearn.preprocessing import MinMaxScaler

df = pd.read_excel('df2.xlsx')

df.head()

# Excluir las columnas 'GPR diario - Act' y 'GPR diario - Threat'
df = df.drop(columns=['GPR diario - Act', 'GPR diario - Threat'])

GRÁFICAS

# Variables a graficar junto con "GPR diario"
gpr_column = "GPR diario"
excluded_columns = ["Dates", gpr_column, 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'USGG

for column in df.columns:
    if column not in excluded_columns: # Excluye "Date" y "GPR diario"
        plt.figure(figsize=(10, 6))
        plt.plot(df["Dates"], df[gpr_column], label=gpr_column, alpha=0.75, linestyle='-', linewidth=2)
        plt.plot(df["Dates"], df[column], label=column, alpha=0.75, linestyle='--', linewidth=2)
        plt.title(f"GPR diario vs {column}")
        plt.xlabel("Fecha")
        plt.ylabel("Valor")
        plt.legend()
        plt.grid(True)
        plt.tight_layout()
        plt.xticks(rotation=45) # Rotar las fechas para mejor visualización
        plt.show()

GRÁFICAS (VALORES NORMALIZADOS)

# Excluir las columnas de la normalización
columns_to_exclude = ["Dates", 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'USGG10YR Index

# Normalización de las columnas restantes
normalized_df = df.copy()
for column in df.columns:
    if column not in columns_to_exclude:
        normalized_df[column] = (df[column] - df[column].min()) / (df[column].max() - df[column].min())

# Mantener "Date" sin cambios
normalized_df["Dates"] = df["Dates"]

# Mostrar un vistazo al DataFrame normalizado
print(normalized_df.head())

# Variables a graficar junto con "GPR diario"
gpr_column = "GPR diario"
excluded_columns = ["Dates", gpr_column, 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'USC

for column in df.columns:
    if column not in excluded_columns: # Excluye "Date" y "GPR diario"
        plt.figure(figsize=(10, 6))
        plt.plot(normalized_df["Dates"], normalized_df[gpr_column], label=gpr_column, alpha=0.75, linestyle='-', linewidth=2)
        plt.plot(normalized_df["Dates"], normalized_df[column], label=column, alpha=0.75, linestyle='--', linewidth=2)
        plt.title(f"GPR diario vs {column}")
        plt.xlabel("Fecha")
        plt.ylabel("Valor normalizado")
        plt.legend()
        plt.grid(True)
        plt.tight_layout()
```

```

plt.xticks(rotation=45) # Rotar las fechas para mejor visualización
plt.show()

df.head()

AJUSTE TEMPORAL GPR DIARIO

# Desplazar las columnas 'GPR diario' 'GPR diario - Act ajustado' y 'GPR diario - Threat ajustado' una fila hacia arriba
df['GPR diario ajustado'] = df['GPR diario'].shift(-1)

df = df[df["GPR diario"] != 0]

#Calcular la primera diferencia de los índices GPR
df['delta GPR diario'] = df['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df['log GPR diario'] = np.log(df['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df['delta log GPR diario'] = df['log GPR diario'].diff()

df.head()

CREAMOS UN DATAFRAME PARA CADA ACTIVO/ÍNDICE

df_sp500 = df[['GPR diario ajustado', 'SPX Index']]
df_eurostoxx50 = df[['GPR diario ajustado', 'SX5E Index']]
df_emerging = df[['GPR diario ajustado', 'MXEF Index']]
df_tesoro = df[['GPR diario ajustado', 'USGG10YR Index_x']]
df_corporativos = df[['GPR diario ajustado', 'BHCI Index']]
df_emergentes = df[['GPR diario ajustado', 'JPEIGLBL Index']]
df_oro = df[['Dates', 'GPR diario ajustado', 'XAU Curncy']]
df_petroleo = df[['GPR diario ajustado', 'CL1 Comdty']]
df_gas = df[['GPR diario ajustado', 'NG1 Comdty']]
df_eurusd = df[['GPR diario ajustado', 'EURUSD Curncy']]
df_usdjpy = df[['GPR diario ajustado', 'USDJPY Curncy']]
df_bitcoin = df[['GPR diario ajustado', 'XBTUSD Curncy']]

```

✓ 1. S&P500

ELIMINAMOS LOS VALORES NULOS

```

df_sp500.head()

df_sp500_nan = df_sp500.dropna()

df_sp500_nan.head()

```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```

#Calcular la primera diferencia de los índice GPR
df_sp500_nan['delta GPR diario'] = df_sp500_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_sp500_nan['log GPR diario'] = np.log(df_sp500_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_sp500_nan['delta log GPR diario'] = df_sp500_nan['log GPR diario'].diff()

```

CALCULAMOS EL RETORNO DEL S&P500

```

df_sp500_nan['Rt SPX Index'] = 100 * np.log(df_sp500_nan['SPX Index'] / df_sp500_nan['SPX Index'].shift(1))

df_sp500_nan.head()

```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_sp500_nan = df_sp500_nan.dropna()
```

```
df_sp500_nan
```

✓ 2. EURO STOXX 50

ELIMINAMOS LOS VALORES NULOS

```
df_eurostoxx50_nan = df_eurostoxx50.dropna(subset=['GPR diario ajustado', 'SX5E Index'])
```

```
df_eurostoxx50_nan.head()
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_eurostoxx50_nan['delta GPR diario'] = df_eurostoxx50_nan['GPR diario ajustado'].diff()
```

```
# Calculamos el logaritmo de los índice GPR
df_eurostoxx50_nan['log GPR diario'] = np.log(df_eurostoxx50_nan['GPR diario ajustado'])
```

```
# Luego calculamos la diferencia entre los logaritmos consecutivos
df_eurostoxx50_nan['delta log GPR diario'] = df_eurostoxx50_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL EUROSTOXX50

```
df_eurostoxx50_nan['Rt SX5E Index'] = 100 * np.log(df_eurostoxx50_nan['SX5E Index'] / df_eurostoxx50_nan['SX5E Index'].shift
```

```
df_eurostoxx50_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_eurostoxx50_nan = df_eurostoxx50_nan.dropna(subset=['GPR diario ajustado', 'SX5E Index', 'delta GPR diario', 'Rt SX5E Inc
```

```
df_eurostoxx50_nan.head()
```

✓ 3. MSCI Emerging Markets

ELIMINAMOS LOS VALORES NULOS

```
df_emerging_nan = df_emerging.dropna(subset=['GPR diario ajustado', 'MXEF Index'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_emerging_nan['delta GPR diario'] = df_emerging_nan['GPR diario ajustado'].diff()
```

```
# Calculamos el logaritmo de los índice GPR
df_emerging_nan['log GPR diario'] = np.log(df_emerging_nan['GPR diario ajustado'])
```

```
# Luego calculamos la diferencia entre los logaritmos consecutivos
df_emerging_nan['delta log GPR diario'] = df_emerging_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL MSCI Emerging Markets

```
df_emerging_nan['Rt MXEF Index'] = 100 * np.log(df_emerging_nan['MXEF Index'] / df_emerging_nan['MXEF Index'].shift(1))
```

```
df_emerging_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_emerging_nan = df_emerging_nan.dropna(subset=['GPR diario ajustado', 'MXEF Index', 'delta GPR diario', 'Rt MXEF Index'])
```

```
df_emerging_nan.head()
```

✓ 4. ETF Bonos del Tesoro de EEUU a 10 años

ELIMINAMOS LOS VALORES NULOS

```
df_tesoro_nan = df_tesoro.dropna(subset=['GPR diario ajustado', 'USGG10YR Index_x'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_tesoro_nan['delta GPR diario'] = df_tesoro_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_tesoro_nan['log GPR diario'] = np.log(df_tesoro_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_tesoro_nan['delta log GPR diario'] = df_tesoro_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL ETF DE LOS BONOS DEL TESORO DE EE. UU. A 10 AÑOS

```
df_tesoro_nan['Rt USGG10YR Index_x'] = 100 * np.log(df_tesoro_nan['USGG10YR Index_x'] / df_tesoro_nan['USGG10YR Index_x'].shift(1))

df_tesoro_nan.head()
df_tesoro_nan.to_excel('df_tesoro_nan.xlsx', index=True)
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_tesoro_nan = df_tesoro_nan.dropna(subset=['GPR diario ajustado', 'USGG10YR Index_x', 'delta GPR diario', 'Rt USGG10YR Inc'])

df_tesoro_nan.head()
```

✓ 5. ETF Bonos corporativos de alta calificación

ELIMINAMOS LOS VALORES NULOS

```
df_corporativos_nan = df_corporativos.dropna(subset=['GPR diario ajustado', 'BGCI Index'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_corporativos_nan['delta GPR diario'] = df_corporativos_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_corporativos_nan['log GPR diario'] = np.log(df_corporativos_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_corporativos_nan['delta log GPR diario'] = df_corporativos_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL ETF DE LOS BONOS CORPORATIVOS DE ALTA CALIFICACIÓN

```
df_corporativos_nan['Rt BGCI Index'] = 100 * np.log(df_corporativos_nan['BGCI Index'] / df_corporativos_nan['BGCI Index'].shift(1))

df_corporativos_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_corporativos_nan = df_corporativos_nan.dropna(subset=['GPR diario ajustado', 'BGCI Index', 'delta GPR diario', 'Rt BGCI Index'])

df_corporativos_nan.head()
```

✓ 6. ETF Bonos de mercados emergentes

ELIMINAMOS LOS VALORES NULOS

```
df_emergentes_nan = df_emergentes.dropna(subset=['GPR diario ajustado', 'JPEIGLBL Index'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_emergentes_nan['delta GPR diario'] = df_emergentes_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_emergentes_nan['log GPR diario'] = np.log(df_emergentes_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_emergentes_nan['delta log GPR diario'] = df_emergentes_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL ETF DE LOS BONOS DE MERCADOS EMERGENTES

```
df_emergentes_nan['Rt JPEIGLBL Index'] = 100 * np.log(df_emergentes_nan['JPEIGLBL Index'] / df_emergentes_nan['JPEIGLBL Inde

df_emergentes_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_emergentes_nan = df_emergentes_nan.dropna(subset=['GPR diario ajustado', 'JPEIGLBL Index', 'delta GPR diario', 'Rt JPEIGL

df_emergentes_nan.head()
```

✓ 7. Oro

ELIMINAMOS LOS VALORES NULOS

```
df_oro_nan = df_oro.dropna(subset=['Dates', 'GPR diario ajustado', 'XAU Curncy'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_oro_nan['delta GPR diario'] = df_oro_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_oro_nan['log GPR diario'] = np.log(df_oro_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_oro_nan['delta log GPR diario'] = df_oro_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL ORO

```
df_oro_nan['Rt XAU Curncy'] = 100 * np.log(df_oro_nan['XAU Curncy'] / df_oro_nan['XAU Curncy'].shift(1))

df_oro_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_oro_nan = df_oro_nan.dropna(subset=['GPR diario ajustado', 'XAU Curncy', 'delta GPR diario', 'Rt XAU Curncy'])

df_oro_nan.head()
```

✓ 8. Petróleo (WTI - West Texas Intermediate)

ELIMINAMOS LOS VALORES NULOS

```
df_petroleo_nan = df_petroleo.dropna(subset=['GPR diario ajustado', 'CL1 Comdty'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_petroleo_nan['delta GPR diario'] = df_petroleo_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_petroleo_nan['log GPR diario'] = np.log(df_petroleo_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_petroleo_nan['delta log GPR diario'] = df_petroleo_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL PETRÓLEO (WTI - West Texas Intermediate)

```
df_petroleo_nan['Rt CL1 Comdty'] = 100 * np.log(df_petroleo_nan['CL1 Comdty'] / df_petroleo_nan['CL1 Comdty'].shift(1))
```

```
df_petroleo_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_petroleo_nan= df_petroleo_nan.dropna(subset=['GPR diario ajustado', 'CL1 Comdty', 'delta GPR diario', 'Rt CL1 Comdty'])
```

```
df_petroleo_nan.head()
```

✓ 9. Gas Natural

ELIMINAMOS LOS VALORES NULOS

```
df_gas_nan = df_gas.dropna(subset=['GPR diario ajustado', 'NG1 Comdty'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_gas_nan['delta GPR diario'] = df_gas_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_gas_nan['log GPR diario'] = np.log(df_gas_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_gas_nan['delta log GPR diario'] = df_gas_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL GAS NATURAL

```
df_gas_nan['Rt NG1 Comdty'] = 100 * np.log(df_gas_nan['NG1 Comdty'] / df_gas_nan['NG1 Comdty'].shift(1))
```

```
df_gas_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_gas_nan = df_gas_nan.dropna(subset=['GPR diario ajustado', 'NG1 Comdty', 'delta GPR diario', 'Rt NG1 Comdty'])
```

```
df_gas_nan.head()
```

✓ 10. EUR/USD (Euro-Dólar)

ELIMINAMOS LOS VALORES NULOS

```
df_eurusd_nan = df_eurusd.dropna(subset=['GPR diario ajustado', 'EURUSD Curncy'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_eurusd_nan['delta GPR diario'] = df_eurusd_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_eurusd_nan['log GPR diario'] = np.log(df_eurusd_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_eurusd_nan['delta log GPR diario'] = df_eurusd_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL EUR/USD (Euro-Dólar)

```
df_eurusd_nan['Rt EURUSD Curncy'] = 100 * np.log(df_eurusd_nan['EURUSD Curncy'] / df_eurusd_nan['EURUSD Curncy'].shift(1))

df_eurusd_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_eurusd_nan = df_eurusd_nan.dropna(subset=['GPR diario ajustado', 'EURUSD Curncy', 'delta GPR diario', 'Rt EURUSD Curncy'])

df_eurusd_nan.head()
```

✓ 11. USD/JPY (Dólar-Yen)

ELIMINAMOS LOS VALORES NULOS

```
df_usdjpy_nan = df_usdjpy.dropna(subset=['GPR diario ajustado', 'USDJPY Curncy'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_usdjpy_nan['delta GPR diario'] = df_usdjpy_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_usdjpy_nan['log GPR diario'] = np.log(df_usdjpy_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_usdjpy_nan['delta log GPR diario'] = df_usdjpy_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL USD/JPY (Dólar-Yen)

```
df_usdjpy_nan['Rt USDJPY Curncy'] = 100 * np.log(df_usdjpy_nan['USDJPY Curncy'] / df_usdjpy_nan['USDJPY Curncy'].shift(1))

df_usdjpy_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_usdjpy_nan = df_usdjpy_nan.dropna(subset=['GPR diario ajustado', 'USDJPY Curncy', 'delta GPR diario', 'Rt USDJPY Curncy'])

df_usdjpy_nan.head()
```

✓ 12. Bitcoin (BTC/USD)

ELIMINAMOS LOS VALORES NULOS

```
df_bitcoin_nan = df_bitcoin.dropna(subset=['GPR diario ajustado', 'XBTUSD Curncy'])
```

CALCULAMOS LA PRIMERA DIFERENCIA DEL GPR DIARIO, EL LOGARITMO DEL GPR DIARIO, Y LA DIFERENCIA ENTRE LOS LOGARITMOS DEL GPR DIARIO

```
#Calcular la primera diferencia de los índice GPR
df_bitcoin_nan['delta GPR diario'] = df_bitcoin_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_bitcoin_nan['log GPR diario'] = np.log(df_bitcoin_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_bitcoin_nan['delta log GPR diario'] = df_bitcoin_nan['log GPR diario'].diff()
```

CALCULAMOS EL RETORNO DEL Bitcoin (BTC/USD)

```
df_bitcoin_nan['Rt XBTUSD Curncy'] = 100 * np.log(df_bitcoin_nan['XBTUSD Curncy'] / df_bitcoin_nan['XBTUSD Curncy'].shift(1))

df_bitcoin_nan.head()
```

VOLVEMOS A ELIMINAR LOS VALORES NULOS

```
df_bitcoin_nan = df_bitcoin_nan.dropna(subset=['GPR diario ajustado', 'XBTUSD Curncy', 'delta GPR diario', 'Rt XBTUSD Curncy'])

df_bitcoin_nan.head()
```

IMPLEMENTACIÓN DE LOS MODELOS

1. S&P500

```
# Variables independientes
X = df_sp500_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_sp500_nan['Rt SPX Index']
modelo_sp500 = sm.OLS(y, X).fit()
print("Modelo para Rt SPX Index:")
print(modelo_sp500.summary())
```

2. EURO STOXX 50

```
# Variables independientes
X = df_eurostoxx50_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_eurostoxx50_nan['Rt SX5E Index']
modelo_eurostoxx50 = sm.OLS(y, X).fit()
print("Modelo para Rt SX5E Index:")
print(modelo_eurostoxx50.summary())
```

3. MSCI Emerging Markets

```
# Variables independientes
X = df_emerging_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_emerging_nan['Rt MXEF Index']
modelo_emerging = sm.OLS(y, X).fit()
print("Modelo para Rt MXEF Index:")
print(modelo_emerging.summary())
```

4. Bonos del Tesoro de EEUU a 10 años

```
# Variables independientes
X = df_tesoro_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_tesoro_nan['Rt USGG10YR Index_x']
modelo_tesoro = sm.OLS(y, X).fit()
print("Modelo para Rt USGG10YR Index:")
print(modelo_tesoro.summary())
```

5. Índice de bonos corporativos de alta calificación (Bloomberg Global Aggregate Corporate Index)

```

# Variables independientes
X = df_corporativos_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_corporativos_nan['Rt BGCIndex']
modelo_corporativos = sm.OLS(y, X).fit()
print("Modelo para Rt BGCIndex:")
print(modelo_corporativos.summary())

```

6. Índice de bonos de mercados emergentes (J.P. Morgan EMBI Global Index)

```

# Variables independientes
X = df_emergentes_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_emergentes_nan['Rt JPEIGLBL Index']
modelo_emergentes = sm.OLS(y, X).fit()
print("Modelo para Rt JPEIGLBL Index:")
print(modelo_emergentes.summary())

```

7. Oro (spot)

```

# Variables independientes
X = df_oro_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_oro_nan['Rt XAU Curncy']
modelo_oro = sm.OLS(y, X).fit()
print("Modelo para Rt XAU Curncy:")
print(modelo_oro.summary())

```

8. Petróleo (WTI - West Texas Intermediate)

```

# Variables independientes
X = df_petroleo_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_petroleo_nan['Rt CL1 Comdty']
modelo_petroleo = sm.OLS(y, X).fit()
print("Modelo para Rt CL1 Comdty:")
print(modelo_petroleo.summary())

```

9. Gas Natural (Henry Hub)

```

# Variables independientes
X = df_gas_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_gas_nan['Rt NG1 Comdty']
modelo_gas = sm.OLS(y, X).fit()
print("Modelo para Rt NG1 Comdty:")
print(modelo_gas.summary())

```

10. EUR/USD (Euro-Dólar)

```

# Variables independientes
X = df_eurUSD_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_eurUSD_nan['Rt EURUSD Curncy']
modelo_eurUSD = sm.OLS(y, X).fit()
print("Modelo para Rt EURUSD Curncy:")
print(modelo_eurUSD.summary())

```

11. USD/JPY (Dólar-Yen)

```

# Variables independientes
X = df_usdJPY_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_usdJPY_nan['Rt USDJPY Curncy']
modelo_usdJPY = sm.OLS(y, X).fit()

```

```
print("Modelo para Rt USDJPY Curncy:")
print(modelo_usdjpy.summary())
```

12. Bitcoin (BTC/USD)

```
# Variables independientes
X = df_bitcoin_nan[['delta log GPR diario']] # Variables independientes
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_bitcoin_nan['Rt XBTUSD Curncy']
modelo_bitcoin = sm.OLS(y, X).fit()
print("Modelo para Rt XBTUSD Curncy:")
print(modelo_bitcoin.summary())

# Crear un diccionario con las columnas extraídas de cada dataframe
datos = {
    "GPR diario ajustado": df["GPR diario ajustado"],
    "delta GPR diario": df["delta GPR diario"],
    "delta log GPR diario": df["delta log GPR diario"],
    "Rt SPX Index": df_sp500_nan["Rt SPX Index"],
    "Rt SX5E Index": df_eurostoxx50_nan["Rt SX5E Index"],
    "Rt MXEF Index": df_emerging_nan["Rt MXEF Index"],
    "Rt USGG10YR Index_x": df_tesoro_nan["Rt USGG10YR Index_x"],
    "Rt BGCI Index": df_corporativos_nan["Rt BGCI Index"],
    "Rt JPEIGLBL Index": df_emergentes_nan["Rt JPEIGLBL Index"],
    "Rt XAU Curncy": df_oro_nan["Rt XAU Curncy"],
    "Rt CL1 Comdty": df_petroleo_nan["Rt CL1 Comdty"],
    "Rt NG1 Comdty": df_gas_nan["Rt NG1 Comdty"],
    "Rt EURUSD Curncy": df_eurusd_nan["Rt EURUSD Curncy"],
    "Rt USDJPY Curncy": df_usdjpy_nan["Rt USDJPY Curncy"],
    "Rt XBTUSD Curncy": df_bitcoin_nan["Rt XBTUSD Curncy"]
}

# Combinar las columnas en un nuevo dataframe
df_combinado = pd.DataFrame(datos)

# Calcular las estadísticas descriptivas
summary_stats = df_combinado.describe()
print(summary_stats)

# Exportar las estadísticas descriptivas a un archivo Excel
summary_stats.to_excel('summary_stats.xlsx', index=True)

# Calcular la matriz de correlación
corr_matrix = df_combinado.corr()
print(corr_matrix)

# Exportar las estadísticas descriptivas a un archivo Excel
corr_matrix.to_excel('corr_matrix.xlsx', index=True)
```

✓ Código en Python para la estimación del modelo econométrico de regresión por Mínimos Cuadrados Ordinarios (incluyendo las variables de control)

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import statsmodels.formula.api as smf
import sklearn as sk
import plotly.express as px
import statsmodels.api as sm
from sklearn.preprocessing import MinMaxScaler
```

```
df = pd.read_excel('df2.xlsx')
```

```
df.head()
```

QUITAR LOS VALORES 0 DEL ÍNDICE GPR

```
df = df[df["GPR diario"] != 0]
df = df[df["GPR diario - Act"] != 0]
df = df[df["GPR diario - Threat"] != 0]
```

✓ AJUSTE TEMPORAL DEL ÍNDICE GPR

```
#Desplazar las columnas 'GPR diario' 'GPR diario - Act ajustado' y 'GPR diario - Threat ajustado' una fila hacia arriba
df['GPR diario ajustado'] = df['GPR diario'].shift(-1)
df['GPR diario Act ajustado'] = df['GPR diario - Act'].shift(-1)
df['GPR diario Threat ajustado'] = df['GPR diario - Threat'].shift(-1)
```

```
# Calcular el valor del decil más alto (percentil 90) de la columna 'GPR diario'
decil_alto = df['GPR diario'].quantile(0.9)
```

```
# Crear una nueva columna con 1 para los valores en el decil más alto y 0 para el resto
df['GPR decil alto'] = (df['GPR diario'] >= decil_alto).astype(int)
```

```
df
```

✓ CREAMOS UN DATAFRAME PARA CADA ACTIVO/ÍNDICE

```
df_sp500 = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'SP
df_eurostoxx50 = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto
df_emerging = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto',
df_tesoro = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'U
df_corporativos = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alt
df_emergentes = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto',
df_oro = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'XAU
df_petroleo = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto',
df_gas = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'NG1
df_eurusd = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'E
df_usdjpy = df[['Dates', 'GPR diario ajustado', 'Dates', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil
df_bitcoin = df[['Dates', 'GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR decil alto', 'I
```

✓ CALCULAR LA PRIMA POR TÉRMINO

```
df['Prima por término'] = df['USGG10YR Index_y'] - df['USGG3M Index']
```

✓ 1. S&P500

ELIMINAMOS LOS VALORES NULOS

```

df_sp500_nan = df_sp500.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_sp500_nan = df_sp500_nan.join(df[cols_to_add])

df_sp500_nan = df_sp500_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '

df_sp500_nan['Rt SPX Index'] = 100 * np.log(df_sp500_nan['SPX Index'] / df_sp500_nan['SPX Index'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_sp500_nan['delta GPR Act diario'] = df_sp500_nan['GPR diario Act ajustado'].diff()
df_sp500_nan['delta GPR Threat diario'] = df_sp500_nan['GPR diario Threat ajustado'].diff()
df_sp500_nan['delta GPR diario'] = df_sp500_nan['GPR diario ajustado'].diff()

# Calculamos el logaritmo de los índice GPR
df_sp500_nan['log GPR diario Act'] = np.log(df_sp500_nan['GPR diario Act ajustado'])
df_sp500_nan['log GPR diario Threat'] = np.log(df_sp500_nan['GPR diario Threat ajustado'])
df_sp500_nan['log GPR diario'] = np.log(df_sp500_nan['GPR diario ajustado'])

# Luego calculamos la diferencia entre los logaritmos consecutivos
df_sp500_nan['delta log GPR diario Act'] = df_sp500_nan['log GPR diario Act'].diff()
df_sp500_nan['delta log GPR diario Threat'] = df_sp500_nan['log GPR diario Threat'].diff()
df_sp500_nan['delta log GPR diario'] = df_sp500_nan['log GPR diario'].diff()

df_sp500_nan = df_sp500_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '

df_sp500_nan

```

✓ **2. EURO STOXX 50**

```

df_eurostoxx50_nan = df_eurostoxx50.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajus

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_eurostoxx50_nan = df_eurostoxx50_nan.join(df[cols_to_add])

df_eurostoxx50_nan = df_eurostoxx50_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat

df_eurostoxx50_nan['Rt SX5E Index'] = 100 * np.log(df_eurostoxx50_nan['SX5E Index'] / df_eurostoxx50_nan['SX5E Index'].shift

#Calcular la primera diferencia de los índices GPR
df_eurostoxx50_nan['delta GPR Act diario'] = df_eurostoxx50_nan['GPR diario Act ajustado'].diff()
df_eurostoxx50_nan['delta GPR Threat diario'] = df_eurostoxx50_nan['GPR diario Threat ajustado'].diff()
df_eurostoxx50_nan['delta GPR diario'] = df_eurostoxx50_nan['GPR diario ajustado'].diff()

df_eurostoxx50_nan['log GPR diario Act'] = np.log(df_eurostoxx50_nan['GPR diario Act ajustado'])
df_eurostoxx50_nan['log GPR diario Threat'] = np.log(df_eurostoxx50_nan['GPR diario Threat ajustado'])
df_eurostoxx50_nan['log GPR diario'] = np.log(df_eurostoxx50_nan['GPR diario ajustado'])

df_eurostoxx50_nan['delta log GPR diario Act'] = df_eurostoxx50_nan['log GPR diario Act'].diff()
df_eurostoxx50_nan['delta log GPR diario Threat'] = df_eurostoxx50_nan['log GPR diario Threat'].diff()
df_eurostoxx50_nan['delta log GPR diario'] = df_eurostoxx50_nan['log GPR diario'].diff()

df_eurostoxx50_nan = df_eurostoxx50_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat

df_eurostoxx50_nan

```

✓ **3. MSCI Emerging Markets**

```

df_emerging_nan = df_emerging.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

```

```

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_emerging_nan = df_emerging_nan.join(df[cols_to_add])

df_emerging_nan = df_emerging_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajusta

df_emerging_nan['Rt MXEF Index'] = 100 * np.log(df_emerging_nan['MXEF Index'] / df_emerging_nan['MXEF Index'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_emerging_nan['delta GPR Act diario'] = df_emerging_nan['GPR diario Act ajustado'].diff()
df_emerging_nan['delta GPR Threat diario'] = df_emerging_nan['GPR diario Threat ajustado'].diff()
df_emerging_nan['delta GPR diario'] = df_emerging_nan['GPR diario ajustado'].diff()

df_emerging_nan['log GPR diario Act'] = np.log(df_emerging_nan['GPR diario Act ajustado'])
df_emerging_nan['log GPR diario Threat'] = np.log(df_emerging_nan['GPR diario Threat ajustado'])
df_emerging_nan['log GPR diario'] = np.log(df_emerging_nan['GPR diario ajustado'])

df_emerging_nan['delta log GPR diario Act'] = df_emerging_nan['log GPR diario Act'].diff()
df_emerging_nan['delta log GPR diario Threat'] = df_emerging_nan['log GPR diario Threat'].diff()
df_emerging_nan['delta log GPR diario'] = df_emerging_nan['log GPR diario'].diff()

df_emerging_nan = df_emerging_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajusta

df_emerging_nan

```

✓ **4. ETF Bonos del Tesoro de EEUU a 10 años**

```

df_tesoro_nan = df_tesoro.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GF

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_tesoro_nan = df_tesoro_nan.join(df[cols_to_add])

df_tesoro_nan = df_tesoro_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

df_tesoro_nan['Rt USGG10YR Index_x'] = 100 * np.log(df_tesoro_nan['USGG10YR Index_x'] / df_tesoro_nan['USGG10YR Index_x'].st

#Calcular la primera diferencia de los índices GPR
df_tesoro_nan['delta GPR Act diario'] = df_tesoro_nan['GPR diario Act ajustado'].diff()
df_tesoro_nan['delta GPR Threat diario'] = df_tesoro_nan['GPR diario Threat ajustado'].diff()
df_tesoro_nan['delta GPR diario'] = df_tesoro_nan['GPR diario ajustado'].diff()

df_tesoro_nan['log GPR diario Act'] = np.log(df_tesoro_nan['GPR diario Act ajustado'])
df_tesoro_nan['log GPR diario Threat'] = np.log(df_tesoro_nan['GPR diario Threat ajustado'])
df_tesoro_nan['log GPR diario'] = np.log(df_tesoro_nan['GPR diario ajustado'])

df_tesoro_nan['delta log GPR diario Act'] = df_tesoro_nan['log GPR diario Act'].diff()
df_tesoro_nan['delta log GPR diario Threat'] = df_tesoro_nan['log GPR diario Threat'].diff()
df_tesoro_nan['delta log GPR diario'] = df_tesoro_nan['log GPR diario'].diff()

df_tesoro_nan = df_tesoro_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

df_tesoro_nan

```

✓ **5. ETF Bonos corporativos de alta calificación**

```

df_corporativos_nan = df_corporativos.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat aj

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_corporativos_nan = df_corporativos_nan.join(df[cols_to_add])

```

```

df_corporativos_nan = df_corporativos_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Three
df_corporativos_nan['Rt BGCi Index'] = 100 * np.log(df_corporativos_nan['BGCi Index'] / df_corporativos_nan['BGCi Index'].st

#Calcular la primera diferencia de los índices GPR
df_corporativos_nan['delta GPR Act diario'] = df_corporativos_nan['GPR diario Act ajustado'].diff()
df_corporativos_nan['delta GPR Threat diario'] = df_corporativos_nan['GPR diario Threat ajustado'].diff()
df_corporativos_nan['delta GPR diario'] = df_corporativos_nan['GPR diario ajustado'].diff()

df_corporativos_nan['log GPR diario Act'] = np.log(df_corporativos_nan['GPR diario Act ajustado'])
df_corporativos_nan['log GPR diario Threat'] = np.log(df_corporativos_nan['GPR diario Threat ajustado'])
df_corporativos_nan['log GPR diario'] = np.log(df_corporativos_nan['GPR diario ajustado'])

df_corporativos_nan['delta log GPR diario Act'] = df_corporativos_nan['log GPR diario Act'].diff()
df_corporativos_nan['delta log GPR diario Threat'] = df_corporativos_nan['log GPR diario Threat'].diff()
df_corporativos_nan['delta log GPR diario'] = df_corporativos_nan['log GPR diario'].diff()

df_corporativos_nan = df_corporativos_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Three
df_corporativos_nan

```

✓ 6. ETF Bonos de mercados emergentes

```

df_emergentes_nan = df_emergentes.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajusta

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_emergentes_nan = df_emergentes_nan.join(df[cols_to_add])

df_emergentes_nan = df_emergentes_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat aj

df_emergentes_nan['Rt JPEIGLBL Index'] = 100 * np.log(df_emergentes_nan['JPEIGLBL Index'] / df_emergentes_nan['JPEIGLBL Inde

#Calcular la primera diferencia de los índices GPR
df_emergentes_nan['delta GPR Act diario'] = df_emergentes_nan['GPR diario Act ajustado'].diff()
df_emergentes_nan['delta GPR Threat diario'] = df_emergentes_nan['GPR diario Threat ajustado'].diff()
df_emergentes_nan['delta GPR diario'] = df_emergentes_nan['GPR diario ajustado'].diff()

df_emergentes_nan['log GPR diario Act'] = np.log(df_emergentes_nan['GPR diario Act ajustado'])
df_emergentes_nan['log GPR diario Threat'] = np.log(df_emergentes_nan['GPR diario Threat ajustado'])
df_emergentes_nan['log GPR diario'] = np.log(df_emergentes_nan['GPR diario ajustado'])

df_emergentes_nan['delta log GPR diario Act'] = df_emergentes_nan['log GPR diario Act'].diff()
df_emergentes_nan['delta log GPR diario Threat'] = df_emergentes_nan['log GPR diario Threat'].diff()
df_emergentes_nan['delta log GPR diario'] = df_emergentes_nan['log GPR diario'].diff()

df_emergentes_nan = df_emergentes_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat aj

df_corporativos_nan

```

✓ 7. Oro

```

df_oro_nan = df_oro.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR deci

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_oro_nan = df_oro_nan.join(df[cols_to_add])

df_oro_nan = df_oro_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'XAU

df_oro_nan['Rt XAU Curncy'] = 100 * np.log(df_oro_nan['XAU Curncy'] / df_oro_nan['XAU Curncy'].shift(1))

```

```
df_oro_nan.to_excel('df_oro_nan.xlsx', index=True)

#Calcular la primera diferencia de los índices GPR
df_oro_nan['delta GPR Act diario'] = df_oro_nan['GPR diario Act ajustado'].diff()
df_oro_nan['delta GPR Threat diario'] = df_oro_nan['GPR diario Threat ajustado'].diff()
df_oro_nan['delta GPR diario'] = df_oro_nan['GPR diario ajustado'].diff()

df_oro_nan['log GPR diario Act'] = np.log(df_oro_nan['GPR diario Act ajustado'])
df_oro_nan['log GPR diario Threat'] = np.log(df_oro_nan['GPR diario Threat ajustado'])
df_oro_nan['log GPR diario'] = np.log(df_oro_nan['GPR diario ajustado'])

df_oro_nan['delta log GPR diario Act'] = df_oro_nan['log GPR diario Act'].diff()
df_oro_nan['delta log GPR diario Threat'] = df_oro_nan['log GPR diario Threat'].diff()
df_oro_nan['delta log GPR diario'] = df_oro_nan['log GPR diario'].diff()

df_oro_nan = df_oro_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'delt

df_oro_nan
```

✓ 8. *Petróleo (WTI)*

```
df_petroleo_nan = df_petroleo.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_petroleo_nan = df_petroleo_nan.join(df[cols_to_add])

df_petroleo_nan = df_petroleo_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajusta

df_petroleo_nan['Rt CL1 Comdty'] = 100 * np.log(df_petroleo_nan['CL1 Comdty'] / df_petroleo_nan['CL1 Comdty'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_petroleo_nan['delta GPR Act diario'] = df_petroleo_nan['GPR diario Act ajustado'].diff()
df_petroleo_nan['delta GPR Threat diario'] = df_petroleo_nan['GPR diario Threat ajustado'].diff()
df_petroleo_nan['delta GPR diario'] = df_petroleo_nan['GPR diario ajustado'].diff()

df_petroleo_nan['log GPR diario Act'] = np.log(df_petroleo_nan['GPR diario Act ajustado'])
df_petroleo_nan['log GPR diario Threat'] = np.log(df_petroleo_nan['GPR diario Threat ajustado'])
df_petroleo_nan['log GPR diario'] = np.log(df_petroleo_nan['GPR diario ajustado'])

df_petroleo_nan['delta log GPR diario Act'] = df_petroleo_nan['log GPR diario Act'].diff()
df_petroleo_nan['delta log GPR diario Threat'] = df_petroleo_nan['log GPR diario Threat'].diff()
df_petroleo_nan['delta log GPR diario'] = df_petroleo_nan['log GPR diario'].diff()

df_petroleo_nan = df_petroleo_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajusta

df_petroleo_nan
```

✓ 9. *Gas Natural*

```
df_gas_nan = df_gas.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GPR deci

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_gas_nan = df_gas_nan.join(df[cols_to_add])

df_gas_nan = df_gas_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'NG1

df_gas_nan['Rt NG1 Comdty'] = 100 * np.log(df_gas_nan['NG1 Comdty'] / df_gas_nan['NG1 Comdty'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_gas_nan['delta GPR Act diario'] = df_gas_nan['GPR diario Act ajustado'].diff()
df_gas_nan['delta GPR Threat diario'] = df_gas_nan['GPR diario Threat ajustado'].diff()
df_gas_nan['delta GPR diario'] = df_gas_nan['GPR diario ajustado'].diff()
```

```

df_gas_nan['log GPR diario Act'] = np.log(df_gas_nan['GPR diario Act ajustado'])
df_gas_nan['log GPR diario Threat'] = np.log(df_gas_nan['GPR diario Threat ajustado'])
df_gas_nan['log GPR diario'] = np.log(df_gas_nan['GPR diario ajustado'])

df_gas_nan['delta log GPR diario Act'] = df_gas_nan['log GPR diario Act'].diff()
df_gas_nan['delta log GPR diario Threat'] = df_gas_nan['log GPR diario Threat'].diff()
df_gas_nan['delta log GPR diario'] = df_gas_nan['log GPR diario'].diff()

df_gas_nan = df_gas_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'delt

df_gas_nan

```

✓ 10. EUR/USD (Euro-Dólar)

```

df_eurusd_nan = df_eurusd.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GF

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_eurusd_nan = df_eurusd_nan.join(df[cols_to_add])

df_eurusd_nan = df_eurusd_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

df_eurusd_nan['Rt EURUSD Curncy'] = 100 * np.log(df_eurusd_nan['EURUSD Curncy'] / df_eurusd_nan['EURUSD Curncy'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_eurusd_nan['delta GPR Act diario'] = df_eurusd_nan['GPR diario Act ajustado'].diff()
df_eurusd_nan['delta GPR Threat diario'] = df_eurusd_nan['GPR diario Threat ajustado'].diff()
df_eurusd_nan['delta GPR diario'] = df_eurusd_nan['GPR diario ajustado'].diff()

df_eurusd_nan['log GPR diario Act'] = np.log(df_eurusd_nan['GPR diario Act ajustado'])
df_eurusd_nan['log GPR diario Threat'] = np.log(df_eurusd_nan['GPR diario Threat ajustado'])
df_eurusd_nan['log GPR diario'] = np.log(df_eurusd_nan['GPR diario ajustado'])

df_eurusd_nan['delta log GPR diario Act'] = df_eurusd_nan['log GPR diario Act'].diff()
df_eurusd_nan['delta log GPR diario Threat'] = df_eurusd_nan['log GPR diario Threat'].diff()
df_eurusd_nan['delta log GPR diario'] = df_eurusd_nan['log GPR diario'].diff()

df_eurusd_nan = df_eurusd_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

df_eurusd_nan

```

✓ 11. USD/JPY (Dólar-Yen)

```

df_usdjpy_nan = df_usdjpy.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', 'GF

# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_usdjpy_nan = df_usdjpy_nan.join(df[cols_to_add])

df_usdjpy_nan = df_usdjpy_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado',

df_usdjpy_nan['Rt USDJPY Curncy'] = 100 * np.log(df_usdjpy_nan['USDJPY Curncy'] / df_usdjpy_nan['USDJPY Curncy'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_usdjpy_nan['delta GPR Act diario'] = df_usdjpy_nan['GPR diario Act ajustado'].diff()
df_usdjpy_nan['delta GPR Threat diario'] = df_usdjpy_nan['GPR diario Threat ajustado'].diff()
df_usdjpy_nan['delta GPR diario'] = df_usdjpy_nan['GPR diario ajustado'].diff()

df_usdjpy_nan['log GPR diario Act'] = np.log(df_usdjpy_nan['GPR diario Act ajustado'])
df_usdjpy_nan['log GPR diario Threat'] = np.log(df_usdjpy_nan['GPR diario Threat ajustado'])
df_usdjpy_nan['log GPR diario'] = np.log(df_usdjpy_nan['GPR diario ajustado'])

df_usdjpy_nan['delta log GPR diario Act'] = df_usdjpy_nan['log GPR diario Act'].diff()

```

```
df_usdjpy_nan['delta log GPR diario Threat'] = df_usdjpy_nan['log GPR diario Threat'].diff()
df_usdjpy_nan['delta log GPR diario'] = df_usdjpy_nan['log GPR diario'].diff()

df_usdjpy_nan = df_usdjpy_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '
df_usdjpy_nan
```

✓ 12. Bitcoin (BTC/USD)

```
df_bitcoin_nan = df_bitcoin.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '
# Lista de columnas que deseas añadir
cols_to_add = ['VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prima por término']

# Realiza el join basado en el índice
df_bitcoin_nan = df_bitcoin_nan.join(df[cols_to_add])

df_bitcoin_nan = df_bitcoin_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '
df_bitcoin_nan['Rt XBTUSD Curncy'] = 100 * np.log(df_bitcoin_nan['XBTUSD Curncy'] / df_bitcoin_nan['XBTUSD Curncy'].shift(1))

#Calcular la primera diferencia de los índices GPR
df_bitcoin_nan['delta GPR Act diario'] = df_bitcoin_nan['GPR diario Act ajustado'].diff()
df_bitcoin_nan['delta GPR Threat diario'] = df_bitcoin_nan['GPR diario Threat ajustado'].diff()
df_bitcoin_nan['delta GPR diario'] = df_bitcoin_nan['GPR diario ajustado'].diff()

df_bitcoin_nan['log GPR diario Act'] = np.log(df_bitcoin_nan['GPR diario Act ajustado'])
df_bitcoin_nan['log GPR diario Threat'] = np.log(df_bitcoin_nan['GPR diario Threat ajustado'])
df_bitcoin_nan['log GPR diario'] = np.log(df_bitcoin_nan['GPR diario ajustado'])

df_bitcoin_nan['delta log GPR diario Act'] = df_bitcoin_nan['log GPR diario Act'].diff()
df_bitcoin_nan['delta log GPR diario Threat'] = df_bitcoin_nan['log GPR diario Threat'].diff()
df_bitcoin_nan['delta log GPR diario'] = df_bitcoin_nan['log GPR diario'].diff()

df_bitcoin_nan = df_bitcoin_nan.dropna(subset=['GPR diario ajustado', 'GPR diario Act ajustado', 'GPR diario Threat ajustado', '
df_bitcoin_nan
```

MODELO 2

✓ 1. S&P500

```
# Variables independientes
X = df_sp500_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Pr
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_sp500_nan['Rt SPX Index']
modelo_sp500 = sm.OLS(y, X).fit()
print("Modelo para Rt SPX Index:")
print(modelo_sp500.summary())
```

✓ 2. EURO STOXX 50

```
# Variables independientes
X = df_eurostoxx50_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_eurostoxx50_nan['Rt SX5E Index']
modelo_eurostoxx50 = sm.OLS(y, X).fit()
print("Modelo para Rt SX5E Index:")
print(modelo_eurostoxx50.summary())
```

✓ 3. MSCI Emerging Markets

```
# Variables independientes
X = df_emerging_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index',
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_emerging_nan['Rt MXEF Index']
modelo_emerging = sm.OLS(y, X).fit()
print("Modelo para Rt MXEF Index:")
print(modelo_emerging.summary())
```

✓ 4. Bonos del Tesoro de EEUU a 10 años

```
# Variables independientes
X = df_tesoro_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'F
X = sm.add_constant(X) # Añadir constante (término independiente)
0
y = df_tesoro_nan['Rt USGG10YR Index_x']
modelo_tesoro = sm.OLS(y, X).fit()
print("Modelo para Rt USGG10YR Index:")
print(modelo_tesoro.summary())
```

✓ 5. ETF Bonos corporativos de alta calificación

```
# Variables independientes
X = df_corporativos_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Inde
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_corporativos_nan['Rt BGC Index']
modelo_corporativos = sm.OLS(y, X).fit()
print("Modelo para Rt BGC Index:")
print(modelo_corporativos.summary())
```

✓ 6. ETF Bonos de mercados emergentes

```
# Variables independientes
X = df_emergentes_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index'
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_emergentes_nan['Rt JPEIGLBL Index']
modelo_emergentes = sm.OLS(y, X).fit()
print("Modelo para Rt JPEIGLBL Index:")
print(modelo_emergentes.summary())
```

✓ 7. Oro

```
# Variables independientes
X = df_oro_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prin
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_oro_nan['Rt XAU Curncy']
modelo_oro = sm.OLS(y, X).fit()
print("Modelo para Rt XAU Curncy:")
print(modelo_oro.summary())
```

✓ 8. Petróleo (WTI)

```
# Variables independientes
X = df_petroleo_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index',
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_petroleo_nan['Rt CL1 Comdty']
modelo_petroleo = sm.OLS(y, X).fit()
print("Modelo para Rt CL1 Comdty:")
print(modelo_petroleo.summary())
```

✓ 9. Gas Natural

```

# Variables independientes
X = df_gas_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'Prin
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_gas_nan['Rt NG1 Comdty']
modelo_gas = sm.OLS(y, X).fit()
print("Modelo para Rt NG1 Comdty:")
print(modelo_gas.summary())

```

✓ 10. EUR/USD (Euro-Dólar)

```

# Variables independientes
X = df_eurusd_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'F
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_eurusd_nan['Rt EURUSD Curncy']
modelo_eurusd = sm.OLS(y, X).fit()
print("Modelo para Rt EURUSD Curncy:")
print(modelo_eurusd.summary())

```

✓ 11. USD/JPY (Dólar-Yen)

```

# Variables independientes
X = df_usdjpy_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', 'F
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_usdjpy_nan['Rt USDJPY Curncy']
modelo_usdjpy = sm.OLS(y, X).fit()
print("Modelo para Rt USDJPY Curncy:")
print(modelo_usdjpy.summary())

```

✓ 12. Bitcoin (BTC/USD)

```

# Variables independientes
X = df_bitcoin_nan[['delta log GPR diario', 'VIX Index', 'MOVE Index', 'USGG2YR Index', 'USGGBE10 Index', 'LF980AS Index', '
X = sm.add_constant(X) # Añadir constante (término independiente)

y = df_bitcoin_nan['Rt XBTUSD Curncy']
modelo_bitcoin = sm.OLS(y, X).fit()
print("Modelo para Rt XBTUSD Curncy:")
print(modelo_bitcoin.summary())

```

✓ Código en Python para la prueba de estacionariedad de Dickey-Fuller y el análisis de causalidad de Granger

```
import pandas as pd
import numpy as np
import statsmodels.api as sm
from statsmodels.tsa.stattools import adfuller
from statsmodels.tsa.stattools import grangercausalitytests
from statsmodels.tsa.vector_ar.var_model import VAR
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns
import statsmodels.formula.api as smf
import sklearn as sk
import plotly.express as px
import statsmodels.api as sm
from sklearn.preprocessing import MinMaxScaler

df = pd.read_excel('df2.xlsx')

df.head()

# Desplazar las columnas 'GPR diario' una fila hacia arriba
df['GPR diario ajustado'] = df['GPR diario'].shift(-1)

df['delta GPR diario'] = df['GPR diario ajustado'].diff()

# Lista de activos (sus precios diarios)
activos = [
    'SPX Index', 'SX5E Index', 'MXEF Index',
    'XAU Curncy', 'CL1 Comdty', 'NG1 Comdty', 'XBTUSD Curncy',
    'EURUSD Curncy', 'USDJPY Curncy', 'USGG10YR Index_x', 'BGCI Index', 'JPEIGLBL Index'
]

# Lista de resultados
resultados = []

# ADF para "delta GPR diario" (ya calculado en el df)
serie_gpr = df["delta GPR diario"].dropna()
resultado = adfuller(serie_gpr)
resultados.append({
    'Variable': 'delta GPR diario',
    'ADF Statistic': resultado[0],
    'p-value': resultado[1],
    'Stationary (p < 0.05)': resultado[1] < 0.05
})

# Calcular retornos simples (%) y aplicar ADF
for var in activos:
    precios = df[var]
    retornos = 100 * (precios - precios.shift(1)) / precios.shift(1)
    retornos = retornos.dropna()
    resultado = adfuller(retornos)
    resultados.append({
        'Variable': f'Retorno {var} (%)',
        'ADF Statistic': resultado[0],
        'p-value': resultado[1],
        'Stationary (p < 0.05)': resultado[1] < 0.05
    })

# Mostrar resultados
resultados_df = pd.DataFrame(resultados)
print(resultados_df)
```

Empieza a programar o a [crear código](#) con IA.

Empieza a programar o a [crear código](#) con IA.

```
df_sp500 = df[['GPR diario ajustado', 'SPX Index']]
df_eurostoxx50 = df[['GPR diario ajustado', 'SX5E Index']]
df_emerging = df[['GPR diario ajustado', 'MXEF Index']]
```

```

df_tesoro = df[['GPR diario ajustado', 'USGG10YR Index_x']]
df_corporativos = df[['GPR diario ajustado', 'BHCI Index']]
df_emergentes = df[['GPR diario ajustado', 'JPEIGLBL Index']]
df_oro = df[['GPR diario ajustado', 'XAU Curncy']]
df_petroleo = df[['GPR diario ajustado', 'CL1 Comdty']]
df_gas = df[['GPR diario ajustado', 'NG1 Comdty']]
df_eurusd = df[['GPR diario ajustado', 'EURUSD Curncy']]
df_usdjpy = df[['GPR diario ajustado', 'USDJPY Curncy']]
df_bitcoin = df[['GPR diario ajustado', 'XBTUSD Curncy']]

```

✓ 1. S&P500

```

df_sp500 = df_sp500.dropna(subset=['GPR diario ajustado', 'SPX Index'])

df_sp500['delta GPR diario'] = df_sp500['GPR diario ajustado'].diff()

df_sp500['Rt SPX Index'] = 100 * np.log(df_sp500['SPX Index'] / df_sp500['SPX Index'].shift(1))

df_sp500 = df_sp500.dropna(subset=['GPR diario ajustado', 'SPX Index', 'delta GPR diario', 'Rt SPX Index'])

# Seleccionar las variables relevantes
variables1 = df_sp500[['delta GPR diario', 'Rt SPX Index']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables1)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag1 = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag1.summary())

resultado1 = grangercausalitytests(variables1, maxlag=50, verbose=True)

```

✓ 2. EUROSTOXX50

```

df_eurostoxx50 = df_eurostoxx50.dropna(subset=['GPR diario ajustado', 'SX5E Index'])

df_eurostoxx50['delta GPR diario'] = df_eurostoxx50['GPR diario ajustado'].diff()

df_eurostoxx50['Rt SX5E Index'] = 100 * np.log(df_eurostoxx50['SX5E Index'] / df_eurostoxx50['SX5E Index'].shift(1))

df_eurostoxx50 = df_eurostoxx50.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'SX5E Index', 'Rt SX5E Index'])

# Seleccionar las variables relevantes
variables2 = df_eurostoxx50[['delta GPR diario', 'Rt SX5E Index']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables2)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado2 = grangercausalitytests(variables2, maxlag=50, verbose=True)

```

✓ 3. MSCI Emerging Markets

```

df_emerging.head()

df_emerging = df_emerging.dropna(subset=['GPR diario ajustado', 'MXEF Index'])

df_emerging['delta GPR diario'] = df_emerging['GPR diario ajustado'].diff()

df_emerging['Rt MXEF Index'] = 100 * np.log(df_emerging['MXEF Index'] / df_emerging['MXEF Index'].shift(1))

```

```
df_emerging = df_emerging.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'MXEF Index', 'Rt MXEF Index'])

# Seleccionar las variables relevantes
variables3 = df_emerging[['delta GPR diario', 'Rt MXEF Index']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables3)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado3 = grangercausalitytests(variables3, maxlag=10, verbose=True)
```

✓ 4. ETF Bonos del Tesoro de EEUU a 10 años

```
df_tesoro = df_tesoro.dropna(subset=['GPR diario ajustado', 'USGG10YR Index_x'])

df_tesoro['delta GPR diario'] = df_tesoro['GPR diario ajustado'].diff()

df_tesoro['Rt USGG10YR Index_x'] = 100 * np.log(df_tesoro['USGG10YR Index_x'] / df_tesoro['USGG10YR Index_x'].shift(1))

df_tesoro = df_tesoro.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'USGG10YR Index_x', 'Rt USGG10YR Index_x'])

# Seleccionar las variables relevantes
variables4 = df_tesoro[['delta GPR diario', 'Rt USGG10YR Index_x']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables4)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado4 = grangercausalitytests(variables4, maxlag=50, verbose=True)
```

✓ 5. ETF Bonos corporativos de alta calificación

```
df_corporativos = df_corporativos.dropna(subset=['GPR diario ajustado', 'BGCI Index'])

df_corporativos['delta GPR diario'] = df_corporativos['GPR diario ajustado'].diff()

df_corporativos['Rt BGCI Index'] = 100 * np.log(df_corporativos['BGCI Index'] / df_corporativos['BGCI Index'].shift(1))

df_corporativos = df_corporativos.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'BGCI Index', 'Rt BGCI Index'])

# Seleccionar las variables relevantes
variables5 = df_corporativos[['delta GPR diario', 'Rt BGCI Index']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables5)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado5 = grangercausalitytests(variables5, maxlag=50, verbose=True)
```

✓ 6. ETF Bonos de mercados emergentes

```
df_emergentes = df_emergentes.dropna(subset=['GPR diario ajustado', 'JPEIGLBL Index'])

df_emergentes['delta GPR diario'] = df_emergentes['GPR diario ajustado'].diff()

df_emergentes['Rt JPEIGLBL Index'] = 100 * np.log(df_emergentes['JPEIGLBL Index'] / df_emergentes['JPEIGLBL Index'].shift(1))
```

```

df_emergentes = df_emergentes.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'JPEIGLBL Index', 'Rt JPEIGLBL Index'])

# Seleccionar las variables relevantes
variables6 = df_emergentes[['delta GPR diario', 'Rt JPEIGLBL Index']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables6)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado6 = grangercausalitytests(variables6, maxlag=10, verbose=True)

```

✓ 7. Oro

```

df_oro = df_oro.dropna(subset=['GPR diario ajustado', 'XAU Curncy'])

df_oro['delta GPR diario'] = df_oro['GPR diario ajustado'].diff()

df_oro['Rt XAU Curncy'] = 100 * np.log(df_oro['XAU Curncy'] / df_oro['XAU Curncy'].shift(1))

df_oro = df_oro.dropna(subset=['GPR diario ajustado', 'XAU Curncy', 'delta GPR diario', 'Rt XAU Curncy'])

# Seleccionar las variables relevantes
variables7 = df_oro[['delta GPR diario', 'Rt XAU Curncy']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables7)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado7 = grangercausalitytests(variables7, maxlag=10, verbose=True)

```

✓ 8. Petróleo (WTI - West Texas Intermediate)

```

df_petroleo = df_petroleo.dropna(subset=['GPR diario ajustado', 'CL1 Comdty'])

df_petroleo['delta GPR diario'] = df_petroleo['GPR diario ajustado'].diff()

df_petroleo['Rt CL1 Comdty'] = 100 * np.log(df_petroleo['CL1 Comdty'] / df_petroleo['CL1 Comdty'].shift(1))

df_petroleo = df_petroleo.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'CL1 Comdty', 'Rt CL1 Comdty'])

# Seleccionar las variables relevantes
variables8 = df_petroleo[['delta GPR diario', 'Rt CL1 Comdty']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables8)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado8 = grangercausalitytests(variables8, maxlag=10, verbose=True)

```

✓ 9. Gas Natural

```

df_gas = df_gas.dropna(subset=['GPR diario ajustado', 'NG1 Comdty'])

df_gas['delta GPR diario'] = df_gas['GPR diario ajustado'].diff()

```

```

df_gas['Rt NG1 Comdty'] = 100 * np.log(df_gas['NG1 Comdty'] / df_gas['NG1 Comdty'].shift(1))

df_gas = df_gas.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'NG1 Comdty', 'Rt NG1 Comdty'])

# Seleccionar las variables relevantes
variables9 = df_gas[['delta GPR diario', 'Rt NG1 Comdty']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables9)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado9 = grangercausalitytests(variables9, maxlag=10, verbose=True)

```

✓ 10. EUR/USD (Euro-Dólar)

```

df_eurusd = df_eurusd.dropna(subset=['GPR diario ajustado', 'EURUSD Curncy'])

df_eurusd['delta GPR diario'] = df_eurusd['GPR diario ajustado'].diff()

df_eurusd['Rt EURUSD Curncy'] = 100 * np.log(df_eurusd['EURUSD Curncy'] / df_eurusd['EURUSD Curncy'].shift(1))

df_eurusd = df_eurusd.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'EURUSD Curncy', 'Rt EURUSD Curncy'])

# Seleccionar las variables relevantes
variables10 = df_eurusd[['delta GPR diario', 'Rt EURUSD Curncy']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables10)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado10 = grangercausalitytests(variables10, maxlag=10, verbose=True)

```

✓ 11. USD/JPY (Dólar-Yen)

```

df_usdjpy = df_usdjpy.dropna(subset=['GPR diario ajustado', 'USDJPY Curncy'])

df_usdjpy['delta GPR diario'] = df_usdjpy['GPR diario ajustado'].diff()

df_usdjpy['Rt USDJPY Curncy'] = 100 * np.log(df_usdjpy['USDJPY Curncy'] / df_usdjpy['USDJPY Curncy'].shift(1))

df_usdjpy = df_usdjpy.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'USDJPY Curncy', 'Rt USDJPY Curncy'])

# Seleccionar las variables relevantes
variables11 = df_usdjpy[['delta GPR diario', 'Rt USDJPY Curncy']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables11)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado11 = grangercausalitytests(variables11, maxlag=10, verbose=True)

```

✓ 12. Bitcoin (BTC/USD)

```

df_bitcoin = df_bitcoin.dropna(subset=['GPR diario ajustado', 'XBTUSD Curncy'])

df_bitcoin['delta GPR diario'] = df_bitcoin['GPR diario ajustado'].diff()

```

```
df_bitcoin['Rt XBTUSD Curncy'] = 100 * np.log(df_bitcoin['XBTUSD Curncy'] / df_bitcoin['XBTUSD Curncy'].shift(1))

df_bitcoin = df_bitcoin.dropna(subset=['GPR diario ajustado', 'delta GPR diario', 'XBTUSD Curncy', 'Rt XBTUSD Curncy'])

# Seleccionar las variables relevantes
variables12 = df_bitcoin[['delta GPR diario', 'Rt XBTUSD Curncy']].dropna()

# Determinar el número óptimo de rezagos usando un modelo VAR
model = VAR(variables12)

# Seleccionar el rezago óptimo basado en AIC, BIC y HQIC
selected_lag = model.select_order(maxlags=50) # Puedes ajustar el número máximo de rezagos
print(selected_lag.summary())

resultado12 = grangercausalitytests(variables12, maxlag=10, verbose=True)
```