

Eficiencia adaptativa y volatilidad asimétrica en mercados globales de *commodities*

Agustín Burgos-Baena ¹   - Universidad de Sevilla: Sevilla, Andalusia, España

Ana Isabel Irimia-Dieguez  - Universidad de Sevilla: Sevilla, Andalusia, España

Félix Jiménez-Naharro  - Universidad de Sevilla: Sevilla, Andalusia, España

Resumen

Este estudio evalúa la eficiencia en forma débil y la dinámica de la volatilidad en 14 materias primas durante el periodo de estrés inflacionario 2022–2024. Su metodología aplica un enfoque de dos etapas: el periodo 1999 a 2022 se emplea para el entrenamiento del modelo y el periodo 2022–2024 como análisis fuera de muestra, basado en modelos ARIMA-EGARCH con distribución *t* de Student sesgada y validación por backtesting de VaR. Los resultados confirman que la eficiencia varía según la liquidez del activo y revelan una volatilidad persistente y asimétrica con efecto apalancamiento. Como recomendación, se sugiere adoptar modelos asimétricos para lograr una gestión de riesgos más precisa en contextos de alta incertidumbre. Las limitaciones de la investigación se acotan al uso univariante de precios de cierre diarios omitiendo variables exógenas, lo que impacta la parametrización de carteras extremas. Su originalidad radica en utilizar el periodo 2022–2024 como un experimento natural de estrés sistémico global. Finalmente, se concluye que el modelo EGARCH es superior para preservar la estabilidad financiera al demostrar la coexistencia de precios impredecibles y riesgos predecibles.

Clasificación JEL: G14, Q02, C22

Palabras clave: Materias primas; commodities; hipótesis de los mercados eficientes; hipótesis de los mercados adaptativos; Estrés inflacionario.

Adaptive Efficiency and Asymmetric Volatility in Global Commodity Markets

Abstract

This study evaluates weak-form efficiency and volatility dynamics across 14 commodities during the 2022–2024 inflationary stress period. The methodology employs a two-stage approach: the 1999–2022 period is used for model training, and the 2022–2024 period for out-of-sample analysis, based on ARIMA-EGARCH models with a skewed Student's *t*-distribution and validated through VaR backtesting. The results confirm that efficiency varies according to asset liquidity and reveal persistent, asymmetric volatility with a leverage effect. Consequently, adopting asymmetric models is recommended to achieve more precise risk management in contexts of high uncertainty. The limitations of the study are restricted to the univariate use of daily closing prices, omitting exogenous variables, which impacts the parameterization of extreme portfolios. Its originality lies in utilizing the 2022–2024 period as a natural experiment of global systemic stress. Finally, the study concludes that the EGARCH model is superior for preserving financial stability by demonstrating the coexistence of unpredictable prices and predictable risks.

JEL Classification: G14, Q02, C22

Keywords: Commodities, Efficient Market Hypothesis, Adaptive Market Hypothesis, Inflationary Stress.

¹ Corresponding Author. Email: aburgos@us.es



1. Introducción

Desde su formulación por Fama (1970), la Hipótesis de los Mercados Eficientes (HME) se ha mantenido en el centro del análisis financiero contemporáneo debido a los intensos debates teóricos y empíricos que ha generado. La literatura financiera continúa discutiendo la validez de la eficiencia sin alcanzar consenso (Kumar & Bandi, 2015; Kristoufek & Vosvrda, 2014; Lim et al., 2013a), encontrando evidencia de que la eficiencia varía según el contexto económico y el régimen de mercado (Cajueiro & Tabak, 2005a; Rönkkö et al., 2024). Este fenómeno ocurre tanto en el mercado de renta variable como en el de materias primas; en este último, la dinámica se intensifica debido a características propias tales como la estacionalidad, los costes de almacenamiento, el rendimiento de conveniencia, las tensiones geopolíticas y los choques de oferta.

Los mercados de materias primas reflejan las expectativas financieras de los inversores, el impacto de restricciones de oferta y demanda, conflictos geopolíticos y factores macroeconómicos globales (Adhikari & Putnam, 2025). De acuerdo con la propuesta de la Hipótesis de los Mercados Adaptativos (Lo, 2004), la eficiencia del mercado se adapta en función del entorno competitivo y las condiciones estructurales del mercado que se esté analizando, por lo tanto, la eficiencia no es estática como sugiere Fama (1970). Bajo este enfoque, el comportamiento del mercado estaría influenciado por las asimetrías de información y dinámicas no lineales (Grossman & Stiglitz, 1980; Lo & MacKinlay, 1988; Peters, 1994). Este tipo de comportamiento es relevante en las materias primas por su relación con los ciclos de inventarios y su sensibilidad frente a crisis económicas globales.

Este estudio se distingue de la literatura previa especialmente por la escala del análisis, ya que en trabajos de referencia previos como puede ser el de Batten et al. (2019) examinan la integración y transmisión de volatilidad en metales preciosos bajo condiciones regulares de mercado. Sin embargo, en esta investigación se introduce un marco comparativo unificado que abarca 14 materias primas representativas de metales preciosos e industriales, agrícolas y energéticos. Además, esta investigación se distancia de las propuestas metodológicas como la de Rezitis (2023), la cual prioriza a los canales de transmisión del sector agrícola ante shocks de precios, entre otros estudios. En contraste, esta investigación propone el uso de modelos EGARCH combinados con una distribución *t* de Student sesgada el cual permite modelar simultáneamente la asimetría y las colas pesadas en un periodo de estrés severo con alta volatilidad. Su principal aportación se basa en utilizar la crisis inflacionaria de 2022–2024 como un escenario de tensión estructural a escala global el cual permite evaluar no solo la persistencia del riesgo, sino la validez empírica de la Hipótesis de los Mercados Adaptativos (HMA) en tiempo real, ofreciendo una métrica predictiva de backtesting (VaR) que sirve de insumo directo para el diseño de estrategias de cobertura en escenarios de quiebra geopolítico.

Evaluar la eficiencia en el mercado de materias primas es fundamental, ya que impacta en la estabilidad macroeconómica, la optimización de portafolios y la cobertura frente a la inflación (Batten et al., 2019). Además, estos mercados desempeñan un papel estratégico para el desarrollo económico, la asignación de recursos en las diversas economías y la seguridad energética (Ma & Zhang, 2025). Al mismo tiempo, el mercado de materias primas condiciona las presiones inflacionarias y la política monetaria de los bancos centrales (Abbas & Lan, 2021; Castaño et al., 2024). Si bien existe abundante evidencia empírica en índices bursátiles y divisas (Bekiros et al., 2016; Wang et al., 2019), la

investigación en materias primas bajo episodios prolongados de estrés sistémico sigue siendo relativamente limitada. Los resultados obtenidos en este estudio son relevantes para inversores, gestores de fondos de materias primas e intermediarios financieros enfocados en la diversificación de portafolios y la cobertura inflacionaria, ya que requieren de modelos precisos para estimar la evolución de los activos para maximizar el rendimiento. Asimismo, el estudio es de interés para autoridades monetarias, dado que la eficiencia y la volatilidad en los mercados de materias primas tienen un impacto directo en la formación de precios minoristas, la seguridad energética y la estabilidad macroeconómica global.

A diferencia de los índices bursátiles, los precios de las materias primas incorporan restricciones reales de producción, logística y almacenamiento. Por ello, la naturaleza de las materias primas afectase a su comportamiento de forma que el mercado de commodities energéticos, como el petróleo y el gas natural, reaccionan intensamente ante tensiones geopolíticas y disrupciones en la oferta (Chi, et al., 2025; Almeida, et al. 2025); otros como los metales industriales muestran un comportamiento relacionado con el ciclo económico global (Ginn, 2023; Labys et al, 1999). Por su parte, los metales preciosos, como el oro, suelen actuar como activos refugio (Feder-Sempach, et al. 2025; Faraj, et al. 2025).

Desde el punto de vista metodológico, los modelos ARIMA desarrollados por Box y Jenkins (1970) han mostrado capacidad predictiva en series financieras; no obstante, los mercados de commodities presentan frecuentemente volatilidad asimétrica y cambios estructurales que requieren especificaciones más complejas (Chen & Mu, 2021; Espinoza y Meza, 2026)

El período 2022–2024 constituye un cambio estructural de régimen caracterizado por inflación persistente (Dao, et al, 2024), endurecimiento monetario sincronizado (Caldara, et al. 2024), disrupciones en cadenas de suministro (Ascari, et al, 2024) y el conflicto entre Rusia y Ucrania (Li, et al. 2024) y la creciente tensión geopolítica en Medio Oriente, destacando el papel de Irán en la inestabilidad regional (Nasri, et al. 2026). Este entorno generó presiones sostenidas sobre los precios energéticos, agrícolas y metálicos, así como episodios prolongados de volatilidad asimétrica (Rezitis, et al. 2023). En consecuencia, este período ofrece un experimento natural para evaluar la validez de la HME en su forma débil bajo condiciones de estrés prolongado. Utilizando datos comprendidos entre el 25 de junio de 1999 y el 25 de junio de 2024, este estudio analiza un conjunto representativo de materias primas como la Plata, Café, Cacao, Soja, Maíz, Trigo, Cebada, Aluminio, Oro, Cobre, Paladio, Platino, Algodón y Petróleo; con el objetivo de examinar si la previsibilidad de los rendimientos y la dinámica de la volatilidad permanecen estables bajo un contexto de tensión macrofinanciera global sincronizada. La contribución de este trabajo es triple:

1. Evaluar la eficiencia del mercado de materias primas como fenómeno dependiente del régimen temporal
2. Distinguir entre previsibilidad en rendimientos y previsibilidad en volatilidad
3. Comparar el desempeño de modelos simétricos y asimétricos de volatilidad en contextos de estrés prolongado

En consecuencia, la investigación aborda tres preguntas centrales:

1. ¿Se erosiona la eficiencia en forma débil durante períodos prolongados de turbulencia global?
2. ¿Cómo responde la dinámica de la volatilidad y su persistencia ante el régimen de estrés macrofinanciero e inflacionario del periodo fuera de muestra 2022–2024?

3. ¿Superan los modelos asimétricos a las especificaciones simétricas en capacidad predictiva fuera de muestra bajo estrés?

Estas preguntas conducen a las siguientes hipótesis: la previsibilidad de los rendimientos permanece económicamente insignificante (H1); la persistencia y asimetría de la volatilidad se intensifican significativamente al evaluar el desempeño del modelo bajo el régimen de estrés macrofinanciero de 2022–2024 (H2); y los modelos asimétricos superan a los simétricos en términos de precisión predictiva fuera de muestra (H3).

El artículo se divide en seis partes. Después de la introducción, se presenta la revisión de la literatura. El tercero detalla la metodología. El cuarto presenta los resultados obtenidos. El quinto apartado muestra la discusión de resultados. El sexto apartado se dedica a las conclusiones, futuras recomendaciones y los límites del estudio.

2. Revisión de literatura

2.1. Hipótesis de mercado eficiente y eficiencia variable en el tiempo

La Hipótesis de los Mercados Eficientes (HME) postula que los precios reflejan inmediatamente toda la información disponible, imposibilitando el arbitraje sistemático. Sin embargo, en el mercado de materias primas, las restricciones físicas de almacenamiento, la estacionalidad y los shocks de oferta cuestionan los supuestos de eficiencia estática. En su lugar, la Hipótesis de los Mercados Adaptativos (HMA) propone un marco dinámico en el que la eficiencia evoluciona según el entorno competitivo, la liquidez y las condiciones macroestructurales. Bajo la HMA, la presencia de pequeñas dependencias temporales o fricciones no implica una ineficiencia explotable, sino la adaptación gradual de los agentes ante distorsiones informativas y cambios de régimen.

2.2. Heterocedasticidad Condicional y Volatilidad Asimétrica

A diferencia de los rendimientos, que presentan baja autocorrelación lineal en la media, la varianza condicional de las materias primas muestra una marcada persistencia y agrupación de volatilidad (*volatility clustering*). Aunque los modelos simétricos ARCH/GARCH capturan esta heterocedasticidad, resultan insuficientes ante el comportamiento asimétrico característico de los activos energéticos, metálicos y agrícolas. Especificaciones asimétricas como el modelo EGARCH permiten incorporar el efecto apalancamiento y la mayor sensibilidad del riesgo ante choques negativos. La predictibilidad de la varianza no contradice la eficiencia en forma débil, ya que la impredecibilidad de los precios puede coexistir con una estructura de riesgo predecible.

2.3. El periodo de estrés inflacionario 2022–2024 como experimento natural

El periodo fuera de muestra 2022–2024, marcado por tensiones geopolíticas, interrupciones logísticas y un endurecimiento monetario global, constituye un experimento natural para evaluar la validez empírica de la HMA. En entornos de alta incertidumbre, el grado de eficiencia adaptativa difiere según la microestructura y profundidad de cada mercado: materias primas altamente líquidas (como

el oro o el petróleo) absorben la información casi instantáneamente, mientras que activos menos líquidos o fragmentados (como la cebada) exhiben estructuras de rezago más prolongadas y reacciones discontinuas. Evaluar la capacidad predictiva de modelos asimétricos bajo estos episodios de tensión resulta clave para la gestión de riesgos y la cobertura de carteras.

3. Metodología

3.1. Muestra y periodo de estudio

El estudio analiza los precios de cierre diarios de 14 materias primas a lo largo de 25 años (1999–2024), clasificadas en metales preciosos como activos refugio, metales industriales ligados al ciclo económico, energía de alto impacto inflacionario y productos agrícolas vulnerables a shocks climáticos o geopolíticos. Para evaluar la capacidad predictiva de los modelos ARIMA-EGARCH mediante un diseño fuera de muestra con ventana fija, se emplean 5727 observaciones diarias de entrenamiento (1999–2021) para formular pronósticos secuenciales a un paso hacia adelante ($t+1$) sobre una ventana de evaluación de 795 observaciones durante el periodo de estrés inflacionario 2022–2024. Esta amplia perspectiva temporal y estructuración sectorial otorgan firmeza estadística al análisis, permitiendo verificar si la eficiencia adaptativa y la estimación de la volatilidad funcionan de manera homogénea o si existen asimetrías y comportamientos de riesgo heterogéneos entre las distintas categorías de activos.

3.2. Preprocesamiento de datos

La fuente principal de información de este estudio proviene de Reuters Datastream Workspace. Desde esta base de datos financieras se obtuvieron las series temporales de precios de cierres diarios de las materias primas analizadas en esta investigación. Los rendimientos logarítmicos se calcularon a partir de la serie de precios originales de Reuters mediante la especificación de la ecuación 01:

$$r_t = \ln(P_t) - \ln(P_{t-1}) \quad (1)$$

donde r_t denota el rendimiento en el tiempo t (Cont, 2001). Los rendimientos logarítmicos facilitan la comparabilidad intertemporal y contribuyen a una estabilización preliminar de la varianza de la serie. La muestra se dividió en dos periodos, uno de entrenamiento que abarca el periodo 2000–2022 la cual recoge multitud de ciclos y eventos económicos para llevar a cabo el modelizado para llevar a cabo el análisis fuera de muestra para analizar el periodo de inflación persistente que abarca el periodo 2022–2024 marcada por shocks de oferta post-COVID-19, conflictos geopolíticos y restricciones monetarias globales.

3.3. Propiedades estadísticas y pruebas iniciales

Para realizar el análisis de las propiedades univariadas y la distribución de los retornos de la serie de datos se empleó la evaluación mediante estadística descriptiva y el test de Jarque-Bera (Jarque & Bera, 1980). Por su parte, la evaluación de la estacionariedad se verificó con el test de Dickey-Fuller Aumentado (Dickey & Fuller, 1979) optimizado por AIC, contrastado con el test KPSS (Kwiatkowski et al., 1992) y la prueba de Zivot-Andrews (1992) para identificar quiebres estructurales endógenos.

3.4. Estimación econométrica

La primera etapa empleada en la estimación econométrica es la modelización univariante en el que se emplea ARIMA y EGARCH. La media condicional se estimó a través de modelos ARIMA para evaluar la predictibilidad lineal (Box & Jenkins, 1970).

$$s_t = c + \sum_{i=1}^p \phi_i s_{t-i} + \epsilon_t + \sum_{j=1}^q \theta_j \epsilon_{t-j} \quad (2)$$

Donde L es el operador de rezago, $\phi(L) = 1 - \sum_{i=1}^p \phi_i L^i$ y $\theta(L) = 1 + \sum_{j=1}^q \theta_j L^j$. El orden óptimo (p, q) se determinó dinámicamente minimizando los criterios de información (AIC/BIC) e inspeccionando las funciones ACF y PACF.

Para capturar la varianza condicional el agrupamiento de volatilidad y la asimetría ante choques de mercado, se especificó un modelo EGARCH(1,1) (Nelson, 1991):

$$\ln(h_t) = \omega + \beta \ln(h_{t-1}) + \alpha \left| \frac{\epsilon_{t-1}}{\sqrt{h_{t-1}}} \right| + \gamma \frac{\epsilon_{t-1}}{\sqrt{h_{t-1}}} \quad (3)$$

Donde ω es el intercepto, β la persistencia de la volatilidad, α la magnitud del shock y γ el parámetro de asimetría o efecto apalancamiento. Para gestionar las colas pesadas y el sesgo de las series financieras, los errores estandarizados $z_t = \epsilon_t / \sqrt{h_t}$ se ajustaron bajo una distribución t de Student sesgada (Fernández & Steel, 1998; Hansen, 1994) con parámetros de grados de libertad (ν) y asimetría (λ).

3.5. Diagnósticos de especificación y robustez

La validez del modelo sobre los residuos estandarizados se evaluó mediante la verificación de la autocorrelación y heterocedasticidad a través del contraste de Ljung-Box (1978) y ARCH-LM (Engle, 1982), junto con la prueba BDS (Brock, et al. 1996). Además de que al modelado del comportamiento asimétrico se validó con el test de sesgo de signo de Engle y Ng (1993), concluyendo la fase diagnóstica con la estadística de L de Nybloe (1989) para descartar quiebres no estacionarios en la constancia de los parámetros.

3.6. Predicción Fuera de Muestra y Evaluación de Riesgo (VaR)

Para contrastar y evaluar la hipótesis de los mercados adaptativos se emplean pronósticos fuera de muestra con ventana móvil empleando la volatilidad absoluta como proxy de la volatilidad observada. (Cont, 2001) Por un lado, la precisión de los pronósticos se examinó a través de indicadores RMSE, MAE y MASE contrastando las divergencias predictivas con el test de DIEBOLD-MARIANO, 1995 y calibrando la densidad con el logarithmic predictive score (Geweke & Amisano, 2010) Asimismo, la fiabilidad del valor en riesgo al 1% se estudia con pruebas de cobertura incondicional de Kupiec y condicional de Christoffersen 1998, consiguiendo integrar la teoría de valores extremos bajo una especificación de distribución de Pareto generalizada (Embrechts, et al, 1997)

4. Modelos Validados y Errores de Estimación de los Modelos

Con el propósito de ofrecer una aproximación inicial a las propiedades estadísticas de las series analizadas, la Tabla 1 expone los estadísticos descriptivos correspondientes. Estos indicadores permiten verificar, de manera preliminar, la presencia de los denominados hechos estilizados en el comportamiento financiero de los activos.

Tabla 1: Datos descriptivos, prueba de normalidad y test de raíz unitaria ADF

Commodities	Media	Desviación Típica	Asimetría	Curtosis	JB p-valor	Estadístico ADF
Plata	0.000266	0.018162	-0.5153	88.657	< 0.001	-188.692***
Café	0.000159	0.015699	0.2097	112.142	< 0.001	-195.129***
Cacao	0.000277	0.018263	-0.6461	198.978	< 0.001	-195.679***
Soja	0.000148	0.028344	-0.4310	8.445.707	< 0.001	-188.634***
Maíz	0.000111	0.018713	-0.2214	118.439	< 0.001	-172.711***
Trigo	0.000135	0.024168	-0.0435	115.924	< 0.001	-196.614***
Cebada	0.000135	0.013107	-14.268	1.808.771	< 0.001	-165.707***
Aluminio	0.000092	0.013569	-0.1395	54.959	< 0.001	-185.016***
Oro	0.000336	0.010476	-0.3029	92.050	< 0.001	-192.648***
Cobre	0.000284	0.015750	-0.1279	75.227	< 0.001	-192.648***
Paladio	0.000163	0.022000	-0.3583	95.114	< 0.001	-170.102***
Platino	0.000160	0.015066	-0.6301	110.309	< 0.001	-187.200***
Algodón	0.000033	0.019597	-0.0003	46.759	< 0.001	-183.982***
Petróleo	0.000252	0.022790	-11.396	305.697	< 0.001	-184.345***

Fuente: Elaboración propia.

La Tabla 1 expone los estadísticos descriptivos de los retornos logarítmicos, reflejando la presencia de los hechos estilizados característicos de los mercados financieros. Los retornos medios son positivos pero muy cercanos a cero, liderados por el oro (0.000335), el cobre (0.000284) y el cacao (0.000277), frente al menor valor observado en el algodón (0.00003253213). La volatilidad es mayor en la soja (0.0283), el trigo (0.0242), el petróleo (0.0228) y el paladio (0.0220), y menor en el oro (0.0105), la cebada (0.0131) y el aluminio (0.0136). Destacan la asimetría negativa —especialmente en la cebada (-1.43) y el petróleo (-1.14)— y la elevada curtosis en la soja (844.57), la cebada (180.88) y el petróleo (30.57), evidenciando distribuciones de colas pesadas.

En consecuencia, la prueba de Jarque-Bera ($p < 0.001$) rechaza contundentemente la hipótesis de normalidad en todas las series. Por su parte, la Tabla 1 presenta los resultados del test de Dickey-Fuller Aumentado (ADF), confirmando la estacionariedad en niveles de todas las series. Con estadísticos que oscilan entre -19.66 (trigo) y hasta -76.67 (soja, obtenido mediante especificaciones alternativas de robustez) frente al valor crítico de -2.86 al 5% ($p < 0.01$), se descarta la presencia de raíz unitaria, proporcionando una base sólida para la posterior estimación de los modelos ARIMA-EGARCH.


La Tabla A1 (Anexo 1) presenta los modelos ARIMA para los commodities, seleccionados mediante AIC, BIC y la significancia de los parámetros para estimar la media condicional. Las estructuras resultantes son heterogéneas: el maíz, el oro y el platino equivalen a ruido blanco con especificaciones ARIMA(0,0,0); la plata y el cacao siguen modelos ARIMA(1,0,0) con persistencia

autorregresiva; el café y la soja responden a estructuras ARIMA(0,0,1) asociadas a efectos de medias móviles; y el trigo, la cebada y el paladio requieren modelos ARMA complejos con múltiples términos AR y MA. El adecuado ajuste de estas especificaciones, alcanzando la cebada y el café los criterios AIC y BIC más bajos (Tabla A4, Anexo 4) fundamenta el posterior modelado de la volatilidad.

Por su parte, la selección de los modelos de volatilidad (Tabla A2, Anexo 2) basada en LogLik, AIC, BIC y el error cuadrático medio confirma que el modelo EGARCH ofrece el mejor ajuste para la mayoría de los activos, superando a las especificaciones SGARCH y GJR-GARCH al registrar un mayor LogLik, menores AIC/BIC y un menor error cuadrático medio.

La estructura EGARCH captura eficazmente la asimetría y el efecto apalancamiento en la plata, el café, la soja, el oro y el platino. El modelo GJR-GARCH resulta ligeramente inferior, mientras que el SGARCH presenta el menor desempeño al no capturar la heterocedasticidad condicional, evidenciando la importancia de incorporar la volatilidad asimétrica para obtener pronósticos representativos del mercado.

Figura 1: Comparativa de errores de pronóstico.



Fuente: Elaboración propia.

Se utilizó el test de Diebold–Mariano para comparar la precisión predictiva de los modelos EGARCH y GJR-GARCH frente a SGARCH para los commodities (Tabla A2 en el anexo 2). Los resultados muestran que, para varios commodities como Plata, Soja, Oro y Cebada, EGARCH y GJR-GARCH superan significativamente a SGARCH, evidenciado por estadísticas DM negativas o positivas extremas y p-valores < 0.05 , obteniendo en la mayoría de los casos valores inferiores al 0.001, lo que confirma la ventaja de los modelos que capturan la volatilidad asimétrica y los efectos de apalancamiento. En otros commodities, como Café, Maíz, Trigo, Cobre, Paladio, Platino y Petróleo, las mejoras de EGARCH y GJR-GARCH frente a SGARCH son débiles o no significativas ($p > 0.05$), indicando volatilidad relativamente simétrica o efectos asimétricos menos pronunciados. Los resultados respaldan la superioridad de EGARCH y GJR-GARCH para modelar la heterocedasticidad condicional asimétrica y la persistencia de shocks en los retornos de la mayoría de los commodities, mientras que SGARCH se muestra menos eficaz para capturar estos efectos.


La Tabla A3 en el anexo 3 presenta los parámetros estimados para los modelos de volatilidad condicional de las catorce commodities utilizando una distribución t de Student sesgada. La tabla muestra como la media condicional para la mayor parte de los commodities es positiva y significativa,


esto refleja que los retornos diarios promedio son ligeramente positivos. La constante del modelo de volatilidad es negativo y muy significativo para casi todos los commodities, lo que indica que las cotizaciones de las materias primas presentan un componente de varianza constante pequeño. Mientras que el coeficiente α_1 , es generalmente cercano a cero o con valores negativos, confirmando que la volatilidad presenta efectos asimétricos en varias materias primas. Mientras que el coeficiente β_1 , está cercano a 1, reflejando una alta persistencia de la volatilidad. El parámetro γ es positivo y significativo, lo que evidencia una mayor respuesta de la volatilidad ante choques negativos, mientras que el parámetro de forma v indica colas pesadas, variando entre aproximadamente 2 y 7.6, según el commodity, mostrando leptocurtosis significativa en los retornos.


Con los resultados que se han obtenido se demuestra la idoneidad del modelo EGARCH para modelar la volatilidad de las materias primas, proporcionando un marco robusto para pronósticos y análisis del riesgo en este tipo de mercado. La Tabla A1 (ver anexo 1) presenta los resultados de las pruebas de estabilidad para los modelos ARIMA ajustados a las catorce commodities. Todos los modelos cumplen con el criterio global de estabilidad, sin que ninguna raíz comprometa la validez del modelo. Algunos commodities, como Plata, Cacao, Trigo, Cebada, Aluminio, Cobre y Petróleo, muestran raíces AR mayores a 1, indicando cierta persistencia autorregresiva en sus retornos. Otros, como Café, Soja, Paladio, Algodón y algunos más, presentan raíces MA mayores a 1, reflejando efectos de choque acumulados. Maíz, Oro y Platino no muestran raíces significativas en ninguno de los componentes, mostrando dinámicas más cercanas a ruido blanco.

La Figura 2 ilustra la evolución temporal de la volatilidad condicional para el subconjunto seleccionado de materias primas. Con el objetivo de contrastar el comportamiento del mercado bajo diferentes entornos macroeconómicos, se han delimitado mediante áreas sombreadas los regímenes clave ocurridos durante el periodo de estudio. En primer lugar, el periodo previo a la pandemia (2020) se incluye la crisis de las empresas punto com (2000–2002) y la crisis financiera global (2009–2010), estableciendo así una sólida línea de base comparativa. En segundo lugar, se identifica el régimen del choque global por COVID-19 (2020–2021), caracterizado por una alta incertidumbre de mercado. Finalmente, se delimita el periodo reciente de estrés inflacionario prolongado y endurecimiento monetario (2022–2024).

Figura 2. Evolución de la volatilidad condicional mediante el modelo EGARCH (1,1). Las franjas sombreadas delimitan los tres regímenes macroeconómicos bajo análisis: (i) Crisis de las punto com. (2000 – 2002), (ii) Crisis financiera de 2009 (2009-2010), (iii) Choque global por COVID-19 (2020-2021) y (iv) Periodo de estrés inflacionario prolongado y endurecimiento monetario (2022-2024).







Fuente: Elaboración propia.

Para evaluar la consistencia de la descomposición propuesta y la precisión de los pronósticos fuera de muestra (2022-2024), se consolidan las métricas de error y las pruebas de diagnóstico en la siguiente tabla. Siguiendo los criterios de Nyblom para estabilidad paramétrica y ARCH-LM para heterocedasticidad remanente, se valida la robustez de la especificación ARIMA-EGARCH frente al régimen de estrés inflacionario.

Tabla 3. Diagnóstico Global, Precisión y Densidad Predictiva del Modelo EGARCH(1,1)

Commodity	RMSE (Volatilidad)	MAE (Volatilidad)	MASE (Retornos)	ARCH-LM (p-valor)	Nyblom (Estabilidad)	Engle & Ng (p-valor)
Plata	0.000588	0.000371	0.6810	0.4048	0.808	0.00318
Café	0.000712	0.000307	0.7502	0.0233	97.062	0.00064
Cacao	0.002538	0.000587	0.7112	0.0160	131.105	< 0.0001
Soja	0.000535	0.000273	0.7653	0.9547	6.437	0.54242
Maíz	0.002210	0.000469	0.6910	0.5037	2.395	0.00046
Trigo	0.001740	0.000666	0.7360	0.1221	2.620	< 0.0001
Cebada	0.000683	0.000116	0.3506	0.9458	269.820	0.49964
Aluminio	0.000506	0.000251	0.7945	0.0887	17.514	0.03344
Oro	0.000156	0.000106	0.6629	0.5165	25.198	0.00335
Cobre	0.000422	0.000227	0.7480	0.5311	23.474	0.11227
Paladio	0.001799	0.000751	0.7601	0.5794	48.506	0.00956
Platino	0.000399	0.000241	0.6680	0.3455	4.657	0.00005
Algodón	0.000617	0.000488	0.7015	0.1468	30.356	0.00013
Petróleo	0.001231	0.000505	0.6318	0.9154	51.543	< 0.0001


Fuente: Elaboración propia.


La Tabla 3 presenta los resultados de validación del modelo EGARCH(1,1) mediante los tests de Engle y Ng, BDS y el Log Predictive Score (LPS). El test de Engle y Ng indica asimetrías residuales significativas en Plata, Café, Cacao, Maíz, Trigo, Aluminio, Oro, Paladio, Platino, Algodón y Petróleo, mientras que Soja, Cebada y Cobre no muestran evidencia estadísticamente significativa de sesgos remanentes. En cuanto al test BDS, la mayoría de los activos presentan dependencia no lineal residual, destacando Plata, Café, Cacao, Trigo, Cebada, Aluminio, Oro, Paladio y Algodón, cuyos p-valoros son inferiores al 1%. Por el contrario, no se detecta dependencia no lineal tanto en el Platino ($p = 0.0668$) como en el Petróleo ($p = 0.5072$). Mientras que en el caso de la Soja ($p = 0.03$), Maíz ($p = 0.0356$) y Cobre ($p = 0.0383$) muestran una significación marginal. Respecto a la capacidad predictiva fuera de muestra, medida mediante el LPS, los mayores valores se obtienen para Oro (2622.567), Soja (2200.605), Cobre (2198.804) y Aluminio (2112.264), mientras que los menores corresponden a Plata (431.31), Paladio (1523.479), Cebada (1557.302) y Petróleo (1659.307).


Los resultados obtenidos confirman que el modelo EGARCH (1,1) posee una buena capacidad predictiva generalmente, no consigue capturar por completo la asimetría y las dinámicas no lineales de las materias primas. Complementando el análisis estadístico, la Figura 3 ilustra la comparativa entre los rendimientos reales y los pronosticados por el modelo ARIMA-EGARCH durante el periodo de estrés 2022-2024. Visualmente, se aprecia que los modelos logran capturar la trayectoria y el signo de los rendimientos en la mayoría de las materias primas, lo cual es consistente con los resultados de la Tabla 3.

La validez del modelo se muestra a través del Error absoluto medio escalado, con valores inferiores a uno, especialmente en el oro (0.6629) y la cebada (0.3506), constatando de esta forma que los modelos propuestos superan sistemáticamente el pronóstico ingenuo fuera de muestra. No obstante, la dispersión observada en activos como el petróleo o el paladio en la Figura 3 refleja su mayor sensibilidad a los choques macroeconómicos y geopolíticos del periodo, lo que se traduce en errores cuadráticos medios ligeramente superiores en comparación con los productos agrícolas.

Figura 3. Rendimientos reales frente a rendimientos pronosticados.








Fuente: Elaboración propia.


Para validar la metodología de forma empírica y analizar la evolución temporal de los mercados la figura 4 muestra la descomposición estructural de las materias primas. Cada gráfico consiste en la integración vertical de la evolución de los precios históricos junto con los rendimientos logarítmicos y la varianza condicional. Con esta visualización se persigue identificar los cambios de régimen y patrones de agrupación de la varianza a lo largo de toda la muestra. La inspección visual de las descomposiciones temporales revela dinámicas estructurales robustas en las materias primas analizadas. En todos los casos, las series de precios presentan tendencias de largo plazo interrumpidas por episodios de corrección y cambios en la dinámica del mercado.

Los rendimientos logarítmicos oscilan alrededor de una media cercana a cero, mostrando períodos alternados de alta y baja volatilidad, fenómeno conocido como *volatility clustering*. Asimismo, las varianzas condicionales estimadas mediante el modelo EGARCH(1,1)-Student-t evidencian picos pronunciados asociados a eventos de tensión financiera y choques de mercado, seguidos de procesos graduales de reversión hacia niveles normales. Este patrón confirma la presencia de heterocedasticidad condicional y persistencia de la volatilidad. Este fenómeno de agrupamiento de volatilidad, marcadamente visible valida la pertinencia de abandonar los supuestos tradicionales de varianza constante y justifica metodológicamente la adopción de la familia de modelos GARCH asimétricos.


Figura 4. Análisis Visual de las Series y Descomposición de la Volatilidad.




Cebada




Aluminio




Oro




Cobre




Paladio



Platino





Fuente: Elaboración propia.

Los modelos ARIMA-EGARCH fueron seleccionados considerando estructuras de rezagos óptimas y criterios de ajuste como AIC, verosimilitud y pruebas de diagnóstico, tal como se presenta en la Tabla A3 (ver anexo 3). El desempeño predictivo fuera de muestra, medido por Error Cuadrático Medio, Error Absoluto Medio y Error Absoluto Medio Escalado, se detalla en la Tabla A6 (ver anexo 6), y muestra que los modelos capturan adecuadamente tanto la media condicional como la dinámica de volatilidad de los precios. Los parámetros estimados de los modelos EGARCH (Tabla A3, ver anexo 3) evidencian efectos significativos de los retornos y la volatilidad pasados sobre los precios futuros. Los coeficientes de α y β son significativos a un nivel de 0,001, mientras que los coeficientes γ muestran la presencia de efectos de apalancamiento, particularmente en metales preciosos y materias primas energéticas. Esto indica respuestas asimétricas de la volatilidad ante shocks positivos y negativos, coherente con la agrupación de volatilidad. Los test de Diebold-Mariano los cuales se muestran en la Tabla A6 (ver anexo 6) muestran una capacidad predictiva uniforme entre los modelos competidores en la mayoría de los casos. No obstante, commodities como el petróleo o el cobre presentan un Error Cuadrático Medio ligeramente mayor que los agrícolas, lo que evidencia su mayor sensibilidad a shocks macroeconómicos y estructurales.

Asimismo, los resultados del backtesting de VaR (Tabla A5, ver anexo 5) muestran que los modelos proporcionan predicciones de riesgo precisas, especialmente para oro y plata ya que el número de excedencias es prácticamente igual al esperado, y las pruebas de Kupiec y Christoffersen confirman la validez de los modelos bajo niveles de confianza del 95%. Sin embargo, cabe destacar que se registran desviaciones menores en commodities con alta volatilidad como es el caso del petróleo. ARIMA-EGARCH proporciona pronósticos confiables para retornos y volatilidad de commodities, con bajos niveles de error y medidas de riesgo robustas. La Tabla A4 (ver anexo 4) presenta los parámetros estimados de los modelos ARIMA combinados con EGARCH(1,1). Las estimaciones muestran la idoneidad del enfoque ARIMA-EGARCH(1,1) para el modelado de las commodities. Los resultados sugieren rendimientos diarios promedio generalmente positivos, aunque con dependencias temporales heterogéneas (efectos de corto plazo en Plata y Café, y de orden superior en Trigo y Cebada). Además de destacar la elevada persistencia de la volatilidad (beta cercano a 1) y un marcado efecto asimétrico (α_1 y γ significativos). Por último, el parámetro Shape varía entre 2 y 7 indicando colas pesadas, justificando el empleo de distribuciones t de student para capturar los extremos en los retornos.

La Tabla A3 (ver anexo 3) presenta los resultados del ajuste de los modelos EGARCH para las catorce *commodities*, considerando LogLik, AIC y BIC. Los modelos EGARCH desarrollados reflejan eficazmente tanto la heterodasticidad condicional como la asimetría en las materias primas seleccionadas. Siendo la cebada, el oro y la soja las que muestran un ajuste más eficiente y el Petróleo y Paladio un desempeño menor pero adecuado. Estos modelos validan el empleo de EGARCH para realizar el pronóstico de la volatilidad. La Tabla A9 (ver anexo 9) presenta los resultados de los tests de diagnóstico para los modelos GARCH ajustados a catorce *commodities*, considerando LB(res), LB(res²), ARCH LM y la estadística de Nyblom, así como un criterio general de adecuación del modelo.

Es necesario advertir que, en el caso específico del café, el cacao y el algodón, las pruebas de diagnóstico de residuos (Tabla A9) revelan la persistencia de heterocedasticidad condicional remanente (valores *p* significativos en LB(res²) y ARCH LM), así como un estadístico Nyblom elevado. Para mantener la coherencia en todo el estudio, se decidió conservar el modelo EGARCH en el backtesting del VaR, a pesar de ciertas limitaciones encontradas en los residuos de algunos activos. Se tomó esta decisión tras compararlo con modelos más tradicionales, como el sGARCH y el GJR-GARCH. En esas pruebas, el EGARCH demostró un rendimiento superior ya que obtuvo los valores más bajos en los criterios AIC y BIC, además de un menor Error Cuadrático Medio al estimar la varianza. Al final, se asumió este compromiso metodológico. Aunque el EGARCH no captura a la perfección las anomalías extremas de esas tres materias primas en particular, nos asegura un marco de análisis uniforme y robusto para toda la cartera, superando a las otras alternativas en ajuste y predicción. Los modelos muestran un ajuste sólido y estable para la mayoría de los activos como Plata, Soja, Maíz, Trigo, Aluminio, Oro, Cobre, Paladio, Platino y Petróleo. Estas materias primas cumplen con los criterios adecuados sin presentar problemas de autocorrelación de los errores o heterocedasticidad residual. Sin embargo, el Café, Cacao, Cebada y Algodón no superan las pruebas ya que presentan valores de *p* significativos, indicando problemas de ajuste y presencia de heterocedasticidad no capturada, lo que sugiere que un GARCH convencional podría no ser suficiente para modelar completamente la dinámica de volatilidad en estos casos.

La Tabla A6 (ver anexo 6) expone los resultados de predicción de los modelos ARIMA-EGARCH de las *commodities*. El análisis consideró el Error Cuadrático Medio, Error Absoluto Medio, Error Absoluto Medio Escalado para retornos y Error Cuadrático Medio y Error Absoluto Medio para volatilidad. Los errores en la predicción de retornos son moderados, con Error Cuadrático Medio que varía entre 0.00899 (Cebada) y 0.02804 (Paladio), y Error Absoluto Medio más bajo para Cebada (0.00353) y Oro (0.00624), reflejando un buen desempeño relativo en activos de menor volatilidad histórica. Los valores de Error Absoluto Medio Escalado < 1 indican que los modelos superan consistentemente un pronóstico ingenuo, destacando especialmente Cebada y Oro en precisión relativa. En cuanto a la volatilidad, las predicciones son altamente precisas, con Error Cuadrático Medio entre 0.000156 (Oro) y 0.002538 (Cacao) y Error Absoluto Medio mínimo para Cebada (0.000116) y Oro (0.000106), confirmando que los modelos capturan adecuadamente la dinámica condicional de heterocedasticidad y los efectos asimétricos de los shocks.

Para evaluar formalmente la consistencia de la modelización en dos etapas y garantizar que la descomposición entre la media condicional (ARIMA) y la varianza condicional (EGARCH) no introduzca sesgos de especificación, se analizaron las métricas de error predictivo fuera de muestra expuestas en la Tabla A6. Los bajos niveles de Error Cuadrático Medio (RMSE) y Error Absoluto

Medio (MAE) registrados en la predicción de la volatilidad —con valores mínimos destacados en el Oro y la Cebada— confirman la alta estabilidad del modelo. Asimismo, dado que el Error Absoluto Medio Escalado (MASE) se sitúa consistentemente por debajo de la unidad para todas las materias primas analizadas, se demuestra que el enfoque propuesto supera significativamente a un modelo de pronóstico ingenuo, validando estadísticamente la robustez del ajuste en el periodo de estrés inflacionario. La Tabla A6 (ver anexo 6) presenta los resultados del test Diebold–Mariano para comparar los pronósticos de los modelos ARIMA–EGARCH frente a un pronóstico ingenuo. Los modelos ARIMA–EGARCH capturan de forma más eficiente la dinámica de los retornos y la volatilidad. De hecho, los resultados del test Diebold–Mariano muestran que los modelos ARIMA–EGARCH demostraron una precisión predictiva superior a la del pronóstico ingenuo en la totalidad de las series, con valores de p altamente significativos. De hecho, el rendimiento que presentan los modelos superan ampliamente los pronósticos ingenuos, especialmente en el Algodón y el Café.

La Tabla A5 (ver anexo 5) muestra los resultados del backtesting de VaR para distintos commodities utilizando los tests de Kupiec y Christoffersen. La columna “excedido” indica el número de pérdidas que superaron el VaR, mientras que esperado corresponde al número esperado. Para la mayoría de los activos, como Plata, Cacao, Soja, Maíz, Aluminio, Oro, Cobre, Paladio y Algodón, los valores p de Kupiec y Christoffersen son altos, lo que indica que el modelo captura de manera adecuada tanto la frecuencia como la independencia de los excesos de pérdidas, confirmando la validez del VaR. Sin embargo, algunos activos presentan resultados preocupantes como el Café, Trigo, Cebada, Platino y Petróleo muestran valores de p bajos, lo que indica que el modelo subestima o no captura correctamente el riesgo extremo, fallando en cumplir los criterios de backtesting. El modelo de VaR es adecuado para la mayoría de los commodities, pero ciertos activos con alta volatilidad o eventos extremos requieren ajustes adicionales para una estimación de riesgo más robusta.

5. Discusión de resultados

Los resultados del periodo 2022–2024 confirman la coexistencia entre la eficiencia en forma débil en los rendimientos y la predictibilidad en la volatilidad condicional de los commodities. En respuesta a la primera hipótesis (H1), las series de retornos muestran un comportamiento cercano al paseo aleatorio con medias próximas a cero, lo que impide obtener beneficios sistemáticos mediante la predicción de precios. No obstante, la estructura de retardos varía según la liquidez del activo: mientras materias primas altamente líquidas (oro, plata, petróleo) requieren solo 1–2 lags, activos menos líquidos (cebada) demandan hasta 5 lags. Esta heterogeneidad respalda la Hipótesis de los Mercados Adaptativos (HMA), evidenciando que la eficiencia es un fenómeno dinámico condicionado por la microestructura y la profundidad del mercado.

En cuanto a la segunda hipótesis (H2), se valida la alta persistencia ($\beta \approx 1$) y asimetría de la volatilidad, donde los shocks negativos incrementan el riesgo en mayor medida que las variaciones positivas de igual magnitud (efecto apalancamiento), especialmente en energéticos y metales. Respecto a la tercera hipótesis (H3), los tests de Diebold–Mariano confirman la superioridad fuera de muestra de las especificaciones asimétricas ARIMA–EGARCH frente al pronóstico ingenuo. Sin embargo, surge una excepción notable: el modelo simétrico SGARCH resulta estadísticamente superior en el aluminio y el algodón ($p=1.000$), lo cual es coherente con la dinámica de ciertos

mercados agrícolas e industriales donde los choques positivos y negativos generan incrementos simétricos de volatilidad.

Por último, el backtesting del Valor en Riesgo (VaR) valida la capacidad de los modelos ARIMA-EGARCH para gestionar el riesgo mediante las pruebas de Kupiec y Christoffersen en la mayoría de los activos. Sin embargo, en escenarios de estrés extremo se observan subestimaciones puntuales en el petróleo y el platino, y una falla sistemática en la cebada (35 excedencias frente a las 8 esperadas). Este desacierto en la cebada se atribuye a su leptocurtosis extrema (curtosis de 180.88), iliquidez y cambios de régimen durante el periodo analizado, factores que rebasan la capacidad de respuesta de la distribución *t* de Student sesgada en modelos univariantes. Aunque los diagnósticos de residuos confirman la idoneidad general de las estimaciones, la presencia de efectos residuales no capturados en el café, cacao, cebada y algodón sugiere la conveniencia de explorar enfoques no lineales o modelos con cambios de régimen (Markov-switching).

6. Conclusiones

De los resultados obtenidos en la investigación se puede inferir que los precios incorporan la información histórica disponible con rapidez lo que hace que tengan un comportamiento cercano al paseo aleatorio, confirmando que los mercados de materias primas son eficientes en su forma débil, lo que hace que la previsión de los rendimientos sea económicamente insignificante. Este hallazgo responde a la primera pregunta de investigación y valida la hipótesis H1. Sin embargo, esto no ocurre con la volatilidad condicional, la cual presenta una elevada persistencia y asimetría, especialmente en las materias primas energéticas y metales preciosos. Los modelos desarrollados capturan eficazmente el fenómeno de agrupamiento de volatilidad proporcionando pronósticos fuera de muestra robustos. De esta forma, se valida la hipótesis H2, ya que la volatilidad experimenta cambios estructurales persistentes durante el periodo 2022–2024.

En este contexto, el estudio distingue de manera explícita entre la previsibilidad de los rendimientos y la previsibilidad de la volatilidad. Mientras que los primeros mantienen un comportamiento consistente con la eficiencia en forma débil, la segunda exhibe una estructura altamente predecible y asimétrica. Esta coexistencia de imprevisibilidad en los precios y predictibilidad en el riesgo constituye un rasgo característico de los mercados en entornos de incertidumbre elevada. Esto refuerza la idea de que estos modelos tienen como principal ámbito de aplicación la gestión del riesgo y no la predicción de rendimiento.

Asimismo, los resultados evidencian que la eficiencia del mercado no presenta un carácter estático, por el contrario, presentan un proceso evolutivo que depende de la liquidez, la microestructura del mercado y el contexto económico. Esta evidencia se encuentra respaldada por la Hipótesis de los Mercados Adaptativos (Lo, 2004). Particularmente esto ocurre en *commodities* con elevada liquidez como son el oro y el petróleo, ya que estos asimilan la información inmediatamente. Esta situación produce que requieran estructuras de rezago breves (1 - 2 lags). Al contrario, materias primas menos líquidas, como la Cebada, presentan comportamientos más persistentes con rezagos más largos los cuales pueden alcanzar hasta 5 lags. Además, bajo condiciones de estrés inflacionario prolongado y tensiones geopolíticas, la eficiencia puede ajustarse temporalmente, reflejando su carácter dependiente del régimen.

Si bien este estudio no operacionaliza formalmente la Hipótesis de los Mercados Adaptativos de Lo (2004) mediante métricas dinámicas continuas, los hallazgos empíricos sobre la alternancia de periodos de previsibilidad bajo condiciones de estrés sistémico resultan cualitativamente consistentes con este enfoque teórico. La HMA sirve aquí como un marco conceptual interpretativo que permite entender por qué la eficiencia en forma débil no es un estado estático, sino un proceso evolutivo condicionado por el entorno macroeconómico. Por otro lado, la comparación entre modelos de volatilidad demuestra que las especificaciones asimétricas superan sistemáticamente a las simétricas en capacidad predictiva fuera de muestra, especialmente en contextos de alta volatilidad. Los modelos EGARCH y GJR-GARCH capturan con mayor precisión los efectos de apalancamiento y las respuestas diferenciadas ante choques negativos, mientras que los modelos simétricos tienden a deteriorar su desempeño en escenarios de estrés. Este resultado responde a la tercera pregunta de investigación y valida la hipótesis H3. Asimismo, el backtesting de VaR confirma la fiabilidad de estas especificaciones para la estimación del riesgo, aunque se observan ligeras desviaciones en activos con volatilidad extrema, como el petróleo, atribuibles a la sensibilidad ante shocks severos.

7. Líneas futuras de investigación

Como futuras líneas de investigación se plantean las siguientes. En primer lugar, trabajos posteriores podrían profundizar en estos hallazgos incorporando pruebas formales de eficiencia variable en el tiempo, tales como el test de cociente de varianza múltiple con ventana deslizante. Ello permitiría mapear con precisión matemática exacta el tránsito y la velocidad de adaptación de los agentes económicos ante shocks inflacionarios como el analizado, convirtiéndose en una prometedora línea de investigación futura, la necesidad de operacionalizar de forma cuantitativa y dinámica la Hipótesis de los Mercados Adaptativos en este sector durante los periodos de estrés sistémico. Segundo, implementar un enfoque multivariante que integre factores macroeconómicos y geopolíticos para estudiar la eficiencia del mercado entre las materias primas. Tercero, emplear datos intradías para analizar la volatilidad latente y la microestructura del mercado. Cuarto, implementar los modelos GARCH con cambios de régimen para capturar cisnes negros en activos de baja liquidez y alta leptocurtosis.

Entre las limitaciones de la presente investigación se encuentra el empleo de precios de cierre diarios y retornos absolutos. Esta situación simplifica la volatilidad latente de los commodities e ignora los movimientos intradías. También se prescindió del empleo de variables macroeconómicas. Todo ello con la finalidad de aislar el comportamiento intrínseco del mercado. Por último, si bien el convulso periodo 2022–2024 pudo introducir sobreajuste, este se mitigó con la validación fuera de muestra; asimismo, la heterocedasticidad residual detectada en algunos activos no responde a un fallo en la especificación del modelo, sino a la naturaleza compleja e interconectada del propio sistema.

Referencias

- [1] Abbas, S. K., & Lan, H. (2020). Commodity price pass through and inflation regimes. *Energy Economics*, 92, 104977. <https://doi.org/10.1016/j.eneco.2020.104977>
- [2] Adhikari, R., & Putnam, K. J. (2025). Macroeconomic Conditions, Speculation, and Commodity Futures Returns. *International Journal of Financial Studies*, 13(1), 5. <https://doi.org/10.3390/ijfs13010005>
- [3] Almeida, D.; Ferreira, P.; Dionísio, A. & Aslam, F. (2025). Exploring the connection between geopolitical risks and energy markets, *Energy Economics*, Volume 141, 108113, <https://doi.org/10.1016/j.eneco.2024.108113>.
- [4] Ascari, G., Bonam, D., & Smadu, A. (2024). Global supply chain pressures, inflation, and implications for monetary policy. *Journal of International Money and Finance*, 142, Article 103029. <https://doi.org/10.1016/j.jimonfin.2024.103029>
- [5] Batten, J. A., Kinatader, H., Szilagyi, P. G., & Wagner, N. F. (2019). Time varying energy and stock market integration in Asia. *Energy Economics*, 80, 777–792. <https://doi.org/10.1016/j.eneco.2019.01.008>
- [6] Bekiros, S., Gupta, R., & Majumdar, A. (2016). Incorporating economic policy uncertainty in US equity premium models: A nonlinear predictability analysis. *Finance Research Letters*, 18, 291–296. <https://doi.org/10.1016/j.frl.2016.01.012>
- [7] Box, G. and Jenkins, G. (1970) *Time series analysis: forecasting and control*. holden-day, San Francisco.
- [8] Brock, W. A., Dechert, W. D., Scheinkman, J. A., & LeBaron, B. (1996). A test for independence based on the correlation dimension. *Econometric Reviews*, 15(3), 197–235. <https://doi.org/10.1080/07474939608800353>
- [9] Cajueiro, D. O., & Tabak, B. M. (2005). Ranking efficiency for emerging equity markets II. *Chaos, Solitons & Fractals*, 23(2), 671–675. <https://doi.org/10.1016/j.chaos.2004.05.009>
- [10] Caldara, D., Ferrante, F., Iacoviello, M., Prestipino, A., & Queralto, A. (2024). The international spillovers of synchronous monetary tightening. *Journal of Monetary Economics*, 141, 127–152. <https://doi.org/10.1016/j.jmoneco.2023.10.017>
- [11] Castaño, L., Farinós, J. E., & Ibáñez, A. M. (2024). The stock market reaction to political and economic changes: the Spanish case. *Review of Economic Design*, 28, 593–630. <https://doi.org/10.1007/s10058-024-00353-1>
- [12] Chen, Y. F., & Mu, X. (2021). Asymmetric volatility in commodity markets. *Journal of Commodity Markets*, 22, 100139. <https://doi.org/10.1016/j.jcomm.2020.100139>
- [13] Chi X, Zheng R, Chen Y and Xiao G (2025) Research on the volatility spillover effects of geopolitical conflict risks on international shipping and crude oil markets. *Front. Mar. Sci.* 12:1647599. <https://doi.org/10.3389/fmars.2025.1647599>
- [14] Christoffersen, P. F. (1998). Evaluating interval forecasts. *International Economic Review*, 39(4), 841–862. <https://doi.org/10.2307/2527341>
- [15] Cont, R. (2001). Empirical properties of asset returns: stylized facts and statistical issues. *Quantitative Finance*, 1(2), 223–236. <https://doi.org/10.1080/713665670>
- [16] Dao, M. C., Gourinchas, P. O., Leigh, D., & Mishra, P. (2024). Understanding the international rise and fall of inflation since 2020. *Journal of Monetary Economics*, 148, 103658. <https://doi.org/10.1016/j.jmoneco.2024.103658>

- [17] Dickey, D. A., & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366a), 427–431. <https://doi.org/10.1080/01621459.1979.10482531>
- [18] Diebold, F. X., & Mariano, R. S. (1995). Comparing predictive accuracy. *Journal of Business & Economic Statistics*, 13(3), 253–263. <https://doi.org/10.1080/07350015.1995.10524599>
- [19] Embrechts, P., Klüppelberg, C., & Mikosch, T. (1997). *Modelling extremal events for insurance and finance*. Springer-Verlag. <https://doi.org/10.1007/978-3-642-33483-2>
- [20] Engle, R. F. (1982). Autoregressive conditional heteroskedasticity with estimates of the variance of UK inflation. *Econometrica*, 50(4), 987–1008. <https://doi.org/10.2307/1912773>
- [21] Engle, R. F., & Ng, V. K. (1993). Measuring and testing the impact of news on volatility. *The Journal of Finance*, 48(5), 1749–1778. <https://doi.org/10.1111/j.1540-6261.1993.tb05127.x>
- [22] Espinoza Ipanaque, P. C., & Meza Pérez, H. (2026). External shocks in the world economy: a SVAR approach. *Revista Mexicana de Economía y Finanzas Nueva Época REMEF*, 21(1), e1129. <https://doi.org/10.21919/remef.v21i1.1129>
- [23] Fama, E. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal Of Financial*. 25, 383–417. <https://doi.org/10.2307/2325486>
- [24] Faraj, H., McMillan, D., & Al Sabah, M. (2025). The diminishing lustre: Gold’s market volatility and the fading safe haven effect. *Global Finance Journal*, 67, 101145. <https://doi.org/10.1016/j.gfj.2025.101145>
- [25] Feder-Sempach, E., Szczepocki, P., & Bogołębska, J. (2025). Can Precious Metals Act as Safe-Haven or Hedge Assets in Capital Markets of China? *The Chinese Economy*, 59(2), 141–159. <https://doi.org/10.1080/10971475.2025.2529647>
- [26] Geweke, J., & Amisano, G. (2010). Comparing and evaluating densities and density forecasting models. *Journal of Econometrics*, 154(2), 247–258. <https://doi.org/10.1016/j.ijforecast.2009.10.007>
- [27] Ginn, W. (2023). World Output and Commodity Price Cycles*. *International Economic Journal*, 37(4), 530–554. <https://doi.org/10.1080/10168737.2023.2263844>
- [28] Grossman, S. J., & Stiglitz, J. E. (1980). On the Impossibility of Informationally Efficient Markets. *The American Economic Review*, 70(3), 393–408. <http://www.jstor.org/stable/1805228>
- [29] Hansen, B. E. (1994). Autoregressive conditional density estimation. *International Economic Review*, 35(3), 705–730. <https://doi.org/10.2307/2527081>
- [30] Jarque, C. M., & Bera, A. K. (1980). Efficient tests for normality, homoscedasticity and serial independence of regression residuals. *Economics Letters*, 6(3), 255–259. [https://doi.org/10.1016/0165-1765\(80\)90024-5](https://doi.org/10.1016/0165-1765(80)90024-5)
- [31] Kristoufek, L. and Vosvrda, M. (2014). Measuring capital market efficiency: long-term memory, fractal dimension and approximate entropy. *The European Physical Journal B*. Vol. 87, 162. <https://doi.org/10.1140/epjb/e2014-50113-6>
- [32] Kumar, A. and Bandi, K. (2015). Explaining nancial crisis by fractal market hypothesis: Evidences from Indian Equity Markets. *Hyperion International Journal of Econophysics*. New Economy 8, 2015.
- [33] Labys, W. C., Achouch, A., & Terraza, M. (1999). Metal prices and the business cycle. *Resources Policy*, 25(4), 229–238. [https://doi.org/10.1016/S0301-4207\(99\)00030-6](https://doi.org/10.1016/S0301-4207(99)00030-6)
- [34] Li, P., Zhang, P., Guo, Y. et al. How has the relationship between major financial markets changed during the Russia–Ukraine conflict?. *Humanit Soc Sci Commun* 11, 1731 (2024). <https://doi.org/10.1057/s41599-024-04231-7>

-
- [35] Lim, K. P., Brooks, R., & Hinich, M. J. (2013). Nonlinear serial dependence and the weak-form efficiency of Asian emerging stock markets. *Journal of International Financial Markets, Institutions and Money*, 23, 209–221. <https://doi.org/10.1016/j.intfin.2007.08.001>
 - [36] Ljung, G. M., & Box, G. E. P. (1978). On a measure of lack of fit in time series models. *Biometrika*, 65(2), 297–303. <https://doi.org/10.1093/biomet/65.2.297>
 - [37] Lo, A.W. (2004) The Adaptive Markets Hypothesis, *Journal of Portfolio Management*, 30, 15–29. DOI: 10.3905/jpm.2004.442611
 - [38] Lo, A. W., & MacKinlay, A. C. (1988). Stock Market Prices do not Follow Random Walks: Evidence from a Simple Specification Test. *The Review of Financial Studies*, 1(1), 41–66. <http://www.jstor.org/stable/2962126>
 - [39] Ma, L., & Zhang, X. (2025). Capital allocation efficiency of SMEs: Global evidence. *International Review of Financial Analysis*, 107, 104596. <https://doi.org/10.1016/j.irfa.2025.104596>
 - [40] Nasri, F., Kchaou, O., & Sassi, S. B. (2026). Did escalating geopolitical risk shake global stock markets? Evidence from the June 2025 Israel–Iran conflict. *Investment Analysts Journal*, 1–21. <https://doi.org/10.1080/10293523.2026.2639822>
 - [41] Nelson, D.B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, 59(2), 347–370. <https://doi.org/10.2307/2938260>
 - [42] Peters, E. (1994). *Fractal market analysis: applying chaos theory to investment and economics*, John Wiley & Sons, Vol. 24. ISBN 978 0 471 58524 4.
 - [43] Rezitis, A. N., Andrikopoulos, P., & Daglis, T. (2023). Assessing the asymmetric volatility linkages of energy and agricultural commodity futures during low and high volatility regimes. *The Journal of Futures Markets*, 44, 451–483. <https://doi.org/10.1002/fut.22477>
 - [44] Rönkkö, M.; Holmi, J.; Niskanen, M. and Mättö, M. (2024). The adaptive markets hypothesis: Insights into small stock market efficiency. *APPLIED ECONOMICS*. 56, 25, 3048–3062. 10.1080/00036846.2024.2326039
 - [45] Wang, N.; Haroon Shah, M.; Ali, K.; Abbas, S. and Ullah, S. (2019) Financial structure, misery index, and economic growth: time series empirics from Pakistan. *J Risk and Financial Manag* 12(2):100. <https://doi.org/10.3390/jrfm12020100>
 - [46] Zivot, E., & Andrews, D. W. K. (2012). Further Evidence on the Great Crash, the Oil-Price Shock, and the Unit-Root Hypothesis. *Journal of Business & Economic Statistics*, 10(3), 251–270. <https://doi.org/10.1080/07350015.1992.10509904>

Anexos

Anexo 1

Tabla A1. Modelo ARIMA para la Media Condicional

Comm.	Modelo ARIMA	Parámetros / Coeficientes	Verosimilitud (LogLik)	AIC	BIC	Raíces AR > 1	Raíces MA > 1	Modelo Adecuado
Plata	ARIMA(1,0,0)	AR(1) = 0.0132	14,791.65	-29,579.31	-29,566.00	Sí	N.A.	Sí
Café	ARIMA(0,0,1)	MA(1) = -0.0428***	15,778.11	-31,552.22	-31,538.91	N.A.	Sí	Sí
Cacao	ARIMA(1,0,0)	AR(1) = -0.0441***	15,009.50	-30,015.00	-30,001.70	Sí	N.A.	Sí
Soja	ARIMA(0,0,1)	MA(1) = -0.4556***	12,488.66	-24,973.33	-24,960.02	N.A.	Sí	Sí
Maíz	ARIMA(0,0,0)	—	14,700.62	-29,399.25	-29,392.59	N.A.	N.A.	Sí
Trigo	ARIMA(3,0,1)	AR(1)=0.6953***, AR(2)=-0.0790***, AR(3)=-0.7823***, MA(1)=-0.0299***	13,235.19	-26,460.39	-26,427.12	Sí	Sí	Sí
Cebada	ARIMA(2,0,1)	AR(1)=0.7154***, AR(2)=0.0433***, MA(1)=-0.6916***	16,520.62	-33,033.24	-33,006.62	Sí	Sí	Sí
Aluminio	ARIMA(1,0,0)	AR(1) = -0.0348***	16,689.13	-33,374.26	-33,360.95	Sí	N.A.	Sí
Oro	ARIMA(0,0,0)	Media = 0.000346***	17,853.72	-35,703.43	-35,690.12	N.A.	N.A.	Sí
Cobre	ARIMA(2,0,3)	AR(1)=0.0334, AR(2)=0.9225***, MA(1)=-0.0977***, MA(2)=-0.9046***, MA(3)=0.0612***	15,592.14	-31,172.28	-31,132.36	Sí	Sí	Sí
Paladio	ARIMA(0,0,5)	MA(1)=0.0480***, MA(2)=-0.0068***, MA(3)=-0.0285***, MA(4)=0.0018***, MA(5)=0.0551***	14,008.01	-28,004.01	-27,964.10	N.A.	Sí	Sí
Platino	ARIMA(0,0,0)	—	15,956.00	-31,910.01	-31,903.35	N.A.	N.A.	Sí
Algodón	ARIMA(0,0,2)	MA(1) = -0.0650, MA(2) = -0.0308	14,412.00	-28,818.00	-28,798.04	N.A.	Sí	Sí
Petróleo	ARIMA(4,0,0)	AR(1)=0.0123, AR(2)=-0.0073, AR(3)=0.0131, AR(4)=0.0342	13,516.15	-27,022.30	-26,989.04	Sí	N.A.	Sí

** p < 0.01. Nota: Todos los modelos incluyen especificación de solo constante. La media condicional estimada es 0 en todos los activos salvo en el Oro (0.000346). Todos los modelos cumplen la condición global de estabilidad ("Modelo Adecuado").

Fuente: Elaboración propia. * p<0.1, ** p<0.05, *** p<0.0

Anexo 2

Tabla A2: Selección de Modelos de Volatilidad y Contraste de Precisión Predictiva (sGARCH vs. EGARCH vs. GJR-GARCH)

Commodity	Modelo	Verosimilitud (LogLik)	AIC	BIC	Error Cuadrático Medio (RMSE)	Test DM vs. sGARCH (p-valor)
Plata	sGARCH	15,858.28	-5.535.981	-5.529.011	0.01633543	—
	EGARCH	15,863.00	-5.537.279	-5.529.147	0.01335430	5.472e-08***
	GJR-GARCH	15,866.96	-5.538.661	-5.530.530	0.01710769	10.000
Café	sGARCH	16,357.81	-5.710.429	-5.703.459	0.01218209	—
	EGARCH	16,384.69	-5.719.465	-5.711.333	0.01203327	0.8461
	GJR-GARCH	16,374.30	-5.715.838	-5.707.706	0.01213179	0.3819
Cacao	sGARCH	15,828.89	-5.505.717	-5.518.747	0.01917750	—
	EGARCH	15,843.22	-5.530.371	-5.522.239	0.01889485	0.9808
	GJR-GARCH	15,828.93	-5.525.381	-5.517.249	0.01916415	0.9817
Soja	sGARCH	16,249.85	-5.672.726	-5.665.756	0.01507432	—
	EGARCH	16,289.48	-5.686.216	-5.678.084	0.01182410	0.002067***
	GJR-GARCH	16,250.52	-5.672.611	-5.664.479	0.01479348	2.139e-12***
Maíz	sGARCH	15,356.18	-5.360.636	-5.353.666	0.01865486	—
	EGARCH	15,370.48	-5.365.280	-5.357.149	0.01665558	0.9017
	GJR-GARCH	15,356.40	-5.360.364	-5.352.232	0.01879961	0.1247
Trigo	sGARCH	14,025.87	-4.896.061	-4.889.091	0.01955926	—
	EGARCH	14,052.71	-4.905.084	-4.896.953	0.01897990	0.8733
	GJR-GARCH	14,026.00	-4.895.756	-4.887.624	0.01957809	0.1299
Cebada	sGARCH	15,858.28	-5.535.981	-5.529.011	0.01633543	—
	EGARCH	15,863.00	-5.537.279	-5.529.147	0.01335430	2.387e-15***
	GJR-GARCH	15,866.96	-5.538.661	-5.530.530	0.01710769	0.08081*
Aluminio	sGARCH	17,158.82	-5.990.158	-5.983.188	0.01096962	—
	EGARCH	17,146.65	-5.985.558	-5.977.427	0.01094055	10.000
	GJR-GARCH	17,160.05	-5.990.241	-5.982.109	0.01097136	0.009659***
Oro	sGARCH	18,739.60	-6.542.202	-6.535.232	0.00947019	—
	EGARCH	18,753.82	-6.546.822	-6.538.690	0.00720524	2.200e-16***
	GJR-GARCH	18,748.81	-6.545.071	-6.536.939	0.01145542	10.000
Cobre	sGARCH	16,452.65	-5.743.549	-5.736.579	0.01095353	—
	EGARCH	16,448.01	-5.741.579	-5.733.447	0.01046163	0.5000
	GJR-GARCH	16,456.19	-5.744.437	-5.736.305	0.01095750	0.05621*
Paladio	sGARCH	14,989.80	-5.232.689	-5.225.719	0.02283548	—
	EGARCH	14,992.86	-5.233.406	-5.225.275	0.01952437	0.9749
	GJR-GARCH	14,990.08	-5.232.437	-5.224.305	0.02304804	0.9755
Platino	sGARCH	16,865.75	-5.887.813	-5.880.843	0.01059468	—
	EGARCH	16,873.26	-5.890.087	-5.881.956	0.01027043	0.9446
	GJR-GARCH	16,868.25	-5.888.337	-5.880.205	0.01072348	0.7650
Algodón	sGARCH	14,816.79	-5.172.270	-5.165.299	0.01542974	—
	EGARCH	14,820.55	-5.173.232	-5.165.101	0.01731046	10.000

	GJR-GARCH	14,817.36	-5.172.117	-5.163.985	0.01544277	0.9999
Petróleo	sGARCH	14,539.56	-5.075.453	-5.068.483	0.01864648	—
	EGARCH	14,572.99	-5.086.777	-5.078.646	0.01617169	0.7410
	GJR-GARCH	14,554.53	-5.080.330	-5.072.199	0.01693650	0.4745

*** p < 0.01, ** p < 0.05, * p < 0.1. Fuentes: Elaboración propia a partir de los datos de estimación y prueba Diebold–Mariano.
Fuente: Elaboración propia.

Anexo 3

Tabla A3. Estimaciones y Criterios de Ajuste del Modelo EGARCH(1,1) (Student-t)

Commodity	μ	ω	α_1	β_1	γ	Shape	LogLik	AIC
Plata	0.000193	-0.035786***	0.025950***	0.995466***	0.095045***	3.763077***	14,791.65	-29,579.31
Café	0.000121	-0.149138***	0.047149***	0.047149***	0.079793***	3.939434***	16,391.57	-57.219
Cacao	0.000391	-0.037595***	-0.002238	0.995191***	0.056860***	3.246192***	15,844.62	-55.309
Soja	0.000225	-0.529093***	0.012904	0.935398***	0.150171***	3.165267***	16,290.51	-56.866
Maíz	0.000363	-0.109810***	0.005921	0.986178***	0.131161***	4.571247***	15,370.12	-53.655
Trigo	0.000189	-0.079481***	-0.003264***	0.989431***	0.108023***	4.642032***	14,060.20	-49.067
Cebada	0.000000	-0.010239***	-0.062016***	0.296904***	0.296904***	2.010000***	21,195.09	-73.987
Aluminio	0.000226	-0.109066***	0.012416**	0.987549***	0.111466***	7.640744***	17,147.63	-59.859
Oro	0.000373***	-0.061367***	0.037685***	0.993233***	0.101337***	4.027442***	18,752.99	-65.469
Cobre	0.000268**	-0.050811***	-0.022060***	0.993964***	0.102537***	6.518043***	16,464.93	-57.461
Paladio	0.000592***	-0.216669***	0.000324	0.972173***	0.217902***	3.761209***	15,002.39	-52.353
Platino	0.000366**	-0.105332***	0.010356	0.987696***	0.136697***	5.273332***	16,872.39	-58.901
Algodón	0.000156	-0.073397***	-0.006473	0.989993***	0.079594***	5.550462***	14,845.66	-51.817
Petróleo	0.000090	-0.057086***	-0.049308***	0.992600***	0.098116***	6.506456***	14,568.10	-50.840

Fuente: Elaboración propia.

*** p < 0.01, ** p < 0.05

Anexo 4

Tabla A4. Estimación Conjunta ARIMA–EGARCH(1,1) con Distribución Student-t

Commodity	Términos ARIMA (Media)	μ (Constante)	Ω (Omega)	α_1 (ARCH)	β_1 (GARCH)	γ (Apalancamiento)
Plata	AR(1) = -0.0319***	0.000491***	-0.038481***	0.028124***	0.995086***	0.096421***
Café	MA(1) = 0.0455***	0.000130	-0.152305***	0.048723***	0.981725***	0.081613***
Cacao	AR(1) = -0.0201*	0.000310*	-0.037702***	-0.002527	0.995173***	0.056316***
Soja	MA(1) = -0.0265**	0.000431***	-0.523101***	0.013634	0.936107***	0.147843***
Maíz	—	0.000363	-0.109810***	0.005921	0.986178***	0.131161***
Trigo	AR(1)=0.695***, AR(2)=-0.079***, AR(3)=-0.782***, MA(1)=-0.030***	0.000189	-0.079481***	-0.003264***	0.989431***	0.108023***
Cebada	AR(1)=0.715***, AR(2)=0.043***, MA(1)=-0.692***	0.000000	-0.010239***	-0.062016***	0.296904***	0.296904***
Aluminio	AR(1) = -0.0348***	0.000226	-0.109066***	0.012416**	0.987549***	0.111466***
Oro	—	0.000373***	-0.061367***	0.037685***	0.993233***	0.101337***
Cobre	AR(1)=0.251***, AR(2)=0.744***, MA(1)=-0.309***, MA(2)=-0.737***, MA(3)=0.059***	0.000161	-0.048492	-0.025542***	0.994244***	0.099173***
Paladio	MA(1)=0.036*, MA(2)=-0.034**, MA(3)=-0.024, MA(4)=-0.006, MA(5)=0.013	0.000619*	-0.218220***	-0.000399	0.971979***	0.217826***
Platino	—	0.000445***	-0.106830***	0.010765	0.987515***	0.138085***

Algodón	MA(1) = -0.0878***, MA(2) = -0.0245	0.000131	-0.071218***	-0.004323	0.990481***	0.080978***
Petróleo	AR(1)=-0.005, AR(2)=0.006, AR(3)=0.015, AR(4)=0.025*	0.000339	-0.060380***	-0.051739***	0.992281***	0.100460**

Fuente: Elaboración propia.

Anexo 5

Tabla A5. Diagnóstico de Residuos EGARCH y Validación de Cobertura de Riesgo (VaR 1%)

Commodity	LB(res) p-valor	ARCH-LM LB(res ²) valor	/ p-	Nyblom (Estabilidad)	Residuos GARCH Adecuados	Pruebas Kupiec Christoffersen (VaR)	/ Cobertura VaR Adecuada
Plata	0.0129	0.4048 / < 0.001		0.8080	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Café	0.6527	0.0233 / < 0.001		97.062	No	p-valores bajos (Subestima riesgo extremo)	No
Cacao	0.8497	0.0160 / < 0.001		131.105	No	p-valores altos (Captura frecuencia e independencia)	Sí
Soja	0.2929	0.9547 / 0.9864		64.370	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Maíz	0.4663	0.5037 / < 0.001		23.950	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Trigo	0.1372	0.1221 / < 0.001		26.200	Sí	p-valores bajos (Subestima riesgo extremo)	No
Cebada	0.9055	0.9458 / 0.9369		2.698.200	No	p-valores bajos (35 excedencias vs. 8 esperadas)	No
Aluminio	0.3086	0.0887 / 0.4675		17.514	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Oro	0.2715	0.5165 / < 0.001		25.198	Sí	p-valores altos (Excedencias iguales a esperadas)	Sí
Cobre	0.0195	0.5311 / 0.0067		23.474	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Paladio	0.0088	0.5794 / 0.1109		48.506	Sí	p-valores altos (Captura frecuencia e independencia)	Sí
Platino	0.0181	0.3455 / 0.0022		46.570	Sí	p-valores bajos (Subestima riesgo extremo)	No
Algodón	0.6065	0.1468 / < 0.001		30.356	No	p-valores altos (Captura frecuencia e independencia)	Sí
Petróleo	0.1328	0.9154 / 0.0127		51.543	Sí	p-valores bajos (Desviaciones por alta volatilidad)	No

Fuente: Elaboración propia.

Anexo 6

Tabla A6. Evaluación del Desempeño Predictivo Fuera de Muestra y Prueba de Diebold–Mariano (2022–2024)

Commodity	MSE (Retornos)	MSE (Volatilidad)	MASE (Retornos)	Estadístico DM	p-valor	Desempeño Predictivo
Plata	0.017235	0.000588	< 1.0	-76.700	0.0000***	Superior a ingenuo
Café	0.017660	0.000712	< 1.0	-97.402	0.0000***	Superior a ingenuo
Cacao	0.022350	0.002538	< 1.0	-91.837	0.0000***	Superior a ingenuo
Soja	0.014850	0.000535	< 1.0	-80.735	0.0000***	Superior a ingenuo
Maíz	0.019670	0.002210	< 1.0	-64.797	0.0000***	Superior a ingenuo
Trigo	0.024640	0.001740	< 1.0	-39.195	0.0001***	Superior a ingenuo
Cebada	0.008989	0.000684	0.3506	-59.044	0.0000***	Superior a ingenuo
Aluminio	0.016350	0.000506	< 1.0	-85.863	0.0000***	Superior a ingenuo
Oro	0.008580	0.000156	0.6629	-84.178	0.0000***	Superior a ingenuo
Cobre	0.014270	0.000422	< 1.0	-81.194	0.0000***	Superior a ingenuo

Paladio	0.028038	0.001799	< 1.0	-55.375	0.0000***	Superior a ingenuo
Platino	0.016087	0.000399	< 1.0	-76.552	0.0000***	Superior a ingenuo
Algodón	0.019652	0.000618	< 1.0	-103.085	0.0000***	Superior a ingenuo
Petróleo	0.022250	0.001231	< 1.0	-37.106	0.0002***	Superior a ingenuo

Fuente: Elaboración propia.