



Facultad de Ciencias Económicas y Empresariales
ICADE

Análisis de la eficiencia del mercado de energía limpia

Autor: Laura Abarca Carralero

Director: Karin Alejandra Irene Martín Bujack

MADRID | Marzo 2026

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos

Fin de Grado

ADVERTENCIA: Desde la Universidad consideramos que ChatGPT u otras herramientas similares son herramientas muy útiles en la vida académica, aunque su uso queda siempre bajo la responsabilidad del alumno, puesto que las respuestas que proporciona pueden no ser veraces. En este sentido, NO está permitido su uso en la elaboración del Trabajo fin de Grado para generar código porque estas herramientas no son fiables en esa tarea. Aunque el código funcione, no hay garantías de que metodológicamente sea correcto, y es altamente probable que no lo sea.

Por la presente, yo, Laura Abarca Carralero, estudiante de ADE de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Análisis de la eficiencia del mercado de energía limpia", 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. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación.
4. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
5. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
6. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
7. **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: 12/03/2026

Firma:

A handwritten signature in black ink, consisting of several loops and a long horizontal stroke at the end, positioned over a horizontal line.

ABSTRACT

This paper analyses the efficiency of the clean energy market by applying the Asymmetric Multifractal Detrended Fluctuation Analysis (A-MFDFA) methodology to the iShares Global Clean Energy ETF (ICLN). This exchange-traded fund is particularly relevant within the sector due to its established track record, high liquidity, and broad representation of companies associated with clean energy.

Clean energy has become a fundamental pillar of the ecological transition and the decarbonization policies being implemented worldwide. As a result, the presence of financial assets linked to clean energy has increased significantly. In this context, analysing market efficiency is especially relevant, since it constitutes a necessary condition for the efficient allocation of resources, enabling productive investment and supporting technological progress.

The time series of the ETF's daily returns exhibits extreme values and heavy tails, which justifies the application of the A-MFDFA methodology. This approach allows for the detection of long-term dependencies, multifractal structure, and potential asymmetries between bullish and bearish market conditions.

The analysis shows that the series displays inefficient market behaviour, characterized by persistence in response to small fluctuations and antipersistence in response to larger fluctuation. Furthermore, the series exhibits multifractal behaviour, indicating that its dynamics vary across different time scales. These results suggest the presence of temporal dependence and nonlinear scaling properties. This allows investors to obtain extraordinary returns by analysing historical data.

Finally, the analysis of periods associated with high economic uncertainty, such as the COVID-19 pandemic and the Russia-Ukraine war, does not reveal significantly different behaviour in the series.

Key words: clean energy, ETF, market efficiency, multifractality, asymmetry.

RESUMEN EJECUTIVO

El presente trabajo analiza la eficiencia del mercado de energías limpias aplicando la metodología multifractal asimétrica de fluctuación con eliminación de tendencias (A-MFDFA) al ETF iShares Global Clean Energy (ICLN). Este fondo cotizado es relevante en el sector debido a su consolidada trayectoria, su elevada liquidez y la amplia representación de empresas vinculadas a las energías limpias.

Las energías limpias son un pilar fundamental para la transición ecológica y las políticas de descarbonización que se están llevando a cabo a nivel internacional. Esto ha aumentado la presencia de activos financieros vinculados a energías limpias. En este contexto, resulta de interés analizar la eficiencia del mercado, ya que es condición necesaria para una asignación eficiente de los recursos que permita una inversión productiva y favorezca los avances tecnológicos.

La serie temporal de los retornos diarios del ETF analizado presenta valores extremos y colas pesadas, que justifican emplear la metodología A-MFDFA. Esta permite detectar dependencias de largo plazo, estructura multifractal y posibles asimetrías entre mercados alcistas y bajistas.

El análisis realizado evidencia que la serie presenta un comportamiento ineficiente de mercado, presentando persistencia frente a pequeñas fluctuaciones y antipersistencia frente a mayores fluctuaciones. Asimismo, la serie presenta un comportamiento multifractal, que indica que la dinámica varía en función de las escalas temporales. Los resultados obtenidos sugieren la existencia de propiedades de dependencia temporal y escalamiento no lineal. Esto permite a los inversores obtener rendimientos extraordinarios analizando los datos históricos.

Finalmente, el análisis de periodos asociados a elevada incertidumbre económica como la pandemia por el COVID-19 y la guerra entre Rusia y Ucrania no evidencia un comportamiento significativamente diferente.

Palabras clave: energía limpia, ETF, eficiencia de mercado, multifractalidad, asimetría.

ÍNDICE

1. Introducción.....	1
1.1. Objetivos.....	3
1.2. Justificación e interés del tema.....	3
1.3. Estructura.....	4
2. Marco teórico y revisión de la literatura.....	4
2.1. Análisis de la relación del precio de las acciones de energía limpia con otros activos	5
2.2. Análisis de la eficiencia del mercado de energías limpias mediante diferentes metodologías.....	6
3. Metodología.....	7
3.1. Origen de la multifractalidad.....	13
3.2. Origen de la asimetría.....	14
4. Descripción de los datos.....	14
5. Resultados.....	18
5.1. Análisis de la multifractalidad.....	19
5.2. Análisis de la asimetría.....	21
5.3. Análisis de periodos característicos.....	21
5.3.1. Periodo de la pandemia del COVID-19.....	22
5.3.2. Periodo del comienzo de la guerra entre Rusia y Ucrania.....	24
6. Conclusiones.....	25
7. Bibliografía.....	27

1. Introducción

En los últimos años la transición hacia un modelo energético más sostenible se ha convertido en uno de los principales retos económicos y políticos a nivel global (Convención Marco de las Naciones Unidas sobre el Cambio Climático [CMNUCC], 2015). El cambio climático ha impulsado la promoción de sistemas de producción de energía más limpios y sostenibles. El desarrollo de energías limpias se ha convertido en pilar de las estrategias de descarbonización, impulsadas por organismos internacionales como la Unión Europea (Unión Europea, s. f.), la International Energy Agency (IEA, 2025) o la Agencia Internacional de Energías Renovables y Gobiernos.

La IEA (2025) define energía limpia como un término que agrupa las fuentes de energía que son compatibles con un sistema energético con emisiones netas cero. Estas incluyen las fuentes renovables, energía nuclear y combustibles fósiles con captura, utilización y almacenamiento de carbono.

La IEA establece la inversión en tecnologías de energía limpia como una prioridad, al indicar que son una solución a largo plazo no solo para reducir las emisiones sino también la dependencia económica de combustibles fósiles (IEA,2025). Estos están sujetos a volatilidad e interrupciones de suministro ya que están expuestos a factores geopolíticos que pueden afectar al precio e incluso impedir el suministro de los mismos. Díaz-Pinzón (2023) evidencia que los precios del petróleo en el mercado Brent se vieron afectados por el conflicto entre Rusia y Ucrania. Esta volatilidad genera vulnerabilidad en los países que dependen de estas fuentes para el suministro eléctrico.

Según BloombergNEF (2026) la inversión en energías renovables ha aumentado un 19% en 2025, alcanzando el valor récord de 2,3 trillones de dólares a nivel mundial. En cuanto a la inversión en energías limpias en Europa, el informe European Renewable Energy Market Overview Report 2026 (Aurora Energy, 2026) indica que se realizará una inversión de 1,5 trillones de euros hasta 2050. Más concretamente, en España, el Plan Nacional Integrado de Energía y Clima prevé unas inversiones de 114.000 millones ligados a generación renovable entre 2021 y 2030 (Ministerio para la Transición Ecológica y el Reto Demográfico, 2020).

El aumento de la inversión en energías limpias, junto con una mayor preocupación por la sostenibilidad, han incrementado la presencia de activos financieros vinculados a criterios

ESG (ambientales, sociales y de gobierno, por sus siglas en inglés, *Environmental, Social y Governance*) y, concretamente, de activos vinculados a las energías limpias, como índices bursátiles centrados en estas tecnologías (Özduvak, 2021).

Para favorecer el desarrollo de esta tecnología, es importante que los recursos financieros se dirijan hacia los proyectos y empresas con mayor capacidad para generar valor económico, ambiental y social. Una asignación eficiente del capital no solo contribuye al crecimiento y consolidación del sector, sino que también favorece la innovación tecnológica, la reducción de costes y el avance hacia sistemas energéticos más sostenibles (Wurgler, 2000).

En este contexto, resulta especialmente relevante analizar la eficiencia de los mercados de acciones de energías limpias. Según la Hipótesis de Eficiencia del Mercado (HEM), formulada por Eugene Fama (1970), un mercado es eficiente cuando los precios de los activos reflejan de forma rápida y completa toda la información disponible sobre los mismos. Si el mercado es eficiente, los precios reflejan correctamente la información disponible, lo cual es condición necesaria para una asignación eficiente del capital (Wurgler, 2000). Por el contrario, en un mercado ineficiente, los inversores pueden obtener rendimientos anormales, los precios pueden reflejar burbujas o sobrevaloración y además, la asignación del capital podría ser ineficiente.

Este trabajo se centra en el análisis del ETF iShares Global Clean Energy, ya que se trata de un ETF relevante y representativo del sector. Fue creado en julio de 2007 para proporcionar acceso a los inversores a empresas productoras de energía solar, eólica y otras fuentes renovables. Los fondos cotizados en bolsa (Exchange Traded Funds, ETFs) permiten a los inversores acceder de forma diversificada y eficiente a sectores relacionados con energías renovables como la solar o eólica, contribuyendo así a la transición hacia un modelo energético más sostenible. Se analizará la HEM en su forma débil, la cual establece que los precios incorporan toda la información contenida en las series históricas de precios.

Para este análisis se empleará la metodología multifractal asimétrica de fluctuación con eliminación de tendencias (A-MFDFA). Esta permite evaluar el comportamiento de series temporales distinguiendo en función de si las fluctuaciones son al alza o a la baja y, fue descrita por primera vez por Cao et al. (2013).

1.1. Objetivos

En este apartado se presentan los objetivos que se persiguen en este trabajo.

- Determinar si el ETF iGlobal Shares Clean Energy cumple la hipótesis de mercados eficientes de Fama (1970) en su forma débil
- Identificar la posible presencia de estructuras multifractales en la serie temporal de precios mediante la metodología A-MFDFA.
- Analizar el comportamiento del ETF durante el periodo asociado a la pandemia de COVID-19, con el fin de evaluar si la elevada incertidumbre afectó a la eficiencia del activo.
- Examinar la eficiencia del ETF durante el periodo posterior al inicio de la guerra en Ucrania, para determinar si la crisis energética y el periodo de incertidumbre que desencadenó generaron desviaciones respecto al comportamiento habitual del ETF.

1.2. Justificación e interés del tema

Como ya se ha comentado, la presencia de instrumentos financieros relacionados con las energías limpias en los mercados ha aumentado. Esto está relacionado con el proceso de transición hacia modelos más sostenibles y acciones hacia la descarbonización. En este contexto, las energías limpias son un pilar principal para la reducción de emisiones y lucha contra el cambio climático. Como consecuencia, la inversión en activos relacionados con el sector de las energías limpias ha aumentado considerablemente.

Se trata de un mercado relativamente joven y en rápida expansión. Además, depende en gran medida de políticas regulatorias y avances tecnológicos. Estas características pueden generar mayor volatilidad e incertidumbre en los precios de los activos. Por esto, resulta relevante analizar la eficiencia de este mercado para poder determinar si está teniendo lugar una adecuada asignación de capital y analizar el grado de madurez del mercado.

Este trabajo aporta evidencia empírica sobre el grado de eficiencia de este sector, contribuyendo a una mejor comprensión del funcionamiento de los mercados financieros vinculados a la transición hacia un sistema energético más sostenible. Además, se podrá extraer información relevante para inversores y responsables de políticas públicas.

1.3. Estructura

Este trabajo se estructura en siete capítulos, estando organizado de la siguiente manera. En primer lugar, el Capítulo 2 desarrolla el marco teórico y la revisión de la literatura sobre este tema objeto de estudio. A continuación, el Capítulo 3 expone de forma detallada la metodología empleada para llevar a cabo el análisis. En el Capítulo 4 se describen los datos, mientras que el Capítulo 5 recoge los resultados obtenidos. Por último, el Capítulo 6 presenta las conclusiones derivadas del análisis.

2. Marco teórico y revisión de la literatura

En primer lugar, es necesario introducir la Hipótesis de Mercado Eficiente (HME) presentada por Fama (1970). Esta define un mercado eficiente como aquel en el que los precios de los activos financieros reflejan completamente toda la información disponible y reflejan de forma rápida nueva información. Esto implica que no es posible obtener rendimientos superiores al mercado utilizando la información disponible.

Fama (1970) distingue tres formas de eficiencia del mercado. En primer lugar, la forma débil, establece que los precios actuales de los activos reflejan la información contenida en precios y rendimientos pasados. Bajo esta forma el estudio de los precios históricos no permitiría obtener beneficios extraordinarios ya que seguirían un comportamiento similar al paseo aleatorio. La segunda es la forma semifuerte, según la cual, además de la información histórica, los precios reflejan la información pública. Por último, en la forma fuerte los precios incorporan toda la información del mercado, tanto pública como privada.

En cuanto al análisis financiero de las energías limpias, en la literatura se encuentran dos corrientes principales. En primer lugar, artículos que se centran en la relación de los precios de energías limpias con otros activos financieros, como el precio del petróleo (Kumar et al., 2012; Pham, 2019 y Yahya et al., 2021), acciones de empresas tecnológicas (Dutta et al. 2023 y Ferrer et al. 2018) o el precio del dióxido de carbono (Kumar et al., 2012 y Dutta et al., 2018). En segundo lugar, literatura que analiza la eficiencia del mercado de energías limpias mediante diferentes metodologías.

2.1. Análisis de la relación del precio de las acciones de energía limpia con otros activos

En cuanto al análisis de la relación del precio de las acciones de energías limpias con el precio del petróleo, Kumar et al. (2012) indica que existe una relación positiva y significativa, ya que, a medida que sube el precio del petróleo, las inversiones en energía alternativa se vuelven más atractivas. Pham (2019) analiza si todas las acciones de energía limpia responden de la misma manera al precio del petróleo y concluye que la relación es heterogénea y depende del subsector.

Yahya et al. (2021) analiza la relación entre el índice de energía limpia WilderHill Clean Energy Index y el precio del mercado Brent, mercado de petróleo referente en Europa, en el periodo entre abril de 2004 y julio de 2020. A diferencia de los estudios comentados anteriormente, realiza una separación entre los periodos anterior y posterior a la crisis financiera de 2008, así como un análisis específico para periodos extremos. Antes de 2008, el petróleo ejercía influencia sobre las acciones de energía limpia. Sin embargo, tras la crisis de 2008 las evidencias sugieren que las acciones de energía limpia no se ven significativamente influenciadas por el precio del petróleo. Los autores también analizan el comportamiento de esta relación en contextos de elevada inestabilidad financiera, mostrando que, en regímenes extremos, la dinámica entre ambos mercados puede modificarse, asumiendo el petróleo un papel más relevante. No obstante, cuando se examina específicamente el período asociado a la pandemia de COVID-19, la evidencia apunta a un debilitamiento del vínculo de largo plazo entre ambos mercados. Esto pudo deberse a perturbaciones intensas y asimétricas en ambos mercados. El mercado del petróleo se vio afectado por una bajada drástica de la demanda mientras que el mercado de las energías limpias mostró mayor sensibilidad a factores financieros, junto con expectativas de transición energética y el respaldo de políticas públicas.

También se ha analizado la relación de las acciones de energía limpia con el precio del carbono. Kumar et al. (2012) y Dutta et al. (2018) concluyen que el precio del carbono no es un factor relevante sobre las acciones de energía limpia. Por otro lado, la literatura consultada indica que existe una fuerte relación entre los precios de las acciones de energía limpia y las acciones de empresas tecnológicas (Pham, 2019, Kumar et al., 2012,

Dutta et al. 2023 y Ferrer et al. 2018). Esto sugiere que la energía limpia se percibe como un sector de alta tecnología.

2.2. Análisis de la eficiencia del mercado de energías limpias mediante diferentes metodologías

Otra parte de la literatura estudia la posibilidad de predecir el precio de las energías limpias. Sadorsky (2022) aborda la predicción de los precios de las acciones de energía limpia mediante diferentes métodos de aprendizaje automático. Concluye que algunas de esas técnicas son efectivas para predecir la dirección de los precios de las acciones de energía limpia. Esto podría indicar ineficiencia del mercado ya que se pueden predecir los precios y, por tanto, no son aleatorios.

Sadorsky (2021) busca también predecir el precio de las acciones de energía limpia, en este caso, con el método de aprendizaje automático de máquinas de bosque aleatorio. La precisión de estos fue superior al 85% en un horizonte de 20 días. Los indicadores más importantes fueron el volumen de balance y la media móvil de 200 días.

La posibilidad de predecir el precio de las acciones de energía limpia con técnicas de aprendizaje automático cuestiona la eficiencia del mercado. En relación con esto, existe literatura que ha analizado la eficiencia de los mercados de energía limpia. Narayan (2024) busca analizar el comportamiento de precios y el fenómeno de asignación de precios incorrecta en acciones de energías limpias. Para ello, analiza 11 índices de acciones de energía limpia del NASDAQ empleando la metodología de modelo de descubrimiento de precios basado en un factor común de Westerlund et al. (2017). Concluye que los mercados de energía limpia no son completamente eficientes y, por tanto, se pueden llevar a cabo estrategias de trading basadas en ello. Para medir el error de valoración en las acciones de energía limpia emplea el modelo de cinco factores de Fama-French.

Dias (2023) también analiza la eficiencia del índice de energías limpias con datos de 2018 a 2023. Analiza dos cosas distintas: (i) la dependencia SERIAL por la metodología Brock y De Lima; (ii) si los retornos están autocorrelacionados a lo largo del tiempo por la metodología Lo y Mackinlay. Concluye que el Global Clean Energy Index tiene reversión a la media, es decir, tendencia a volver a su valor medio. Se trata de un mercado no eficiente. Por la naturaleza del periodo que analiza, incluye también un estudio concreto

de los periodos de crisis, como 2020 (COVID-19) y 2022 (guerra Rusia y Ucrania) durante estos periodos aumenta la predictibilidad de las acciones.

Por último, Shahzad (2020) analiza la eficiencia de los mercados de empresas de energía limpia en su forma débil. Este análisis lo realiza sobre tres índices representativos del sector: ECO, ERIX y S&P Global Clean Energy con datos desde enero de 2004 a febrero de 2019. Emplea la metodología A-MFDFA, que mide el exponente de Hurst, espectro de singularidad y asimetrías entre los movimientos alcistas y bajistas. Los resultados indican que los mercados de energía limpia no son completamente eficientes, ya que presentan memoria a largo plazo. La asimetría es más fuerte en Estados Unidos, pero también está presente en Europa y el mercado global. En Estados Unidos predomina la persistencia, es decir, si los precios suben tienen tendencia a seguir subiendo y hay una mayor ineficiencia en tendencias alcistas. Mientras que en Europa y Global hay mayor reversión, es decir, los precios tienden a recuperar su valor medio. El artículo sugiere que los activos muestran, en los últimos años analizados, tendencia hacia una mayor eficiencia.

Sobre esta línea de investigación, el presente trabajo aporta una ampliación temporal, al incorporar el análisis de los precios desde 2008 hasta 2026, incluyendo por tanto, la crisis del COVID-19 así como la guerra entre Rusia y Ucrania. La metodología A-MFDFA permite un análisis en mayor profundidad frente al análisis que realiza Dias (2023), al analizar la multifractalidad y asimetría. Además, a diferencia de los estudios previamente mencionados que se centran en índices agregados, este trabajo analiza un ETF específico, lo que permite evaluar la eficiencia desde una perspectiva vinculada con oportunidades de inversión real.

3. Metodología

El análisis multifractal asimétrico de fluctuación con eliminación de tendencias (A-MFDFA) permite evaluar el comportamiento de series temporales en función de si las fluctuaciones son al alza o a la baja (Cao et al., 2013). Fue introducido por primera vez por Cao et al. (2013), como una extensión del método de análisis multifractal de fluctuación con eliminación de tendencias (MF-DFA) (Kantelhardt et al., 2002). Posteriormente, ha sido empleado para realizar análisis de la eficiencia de las acciones de energía limpia (Shahzad et al., 2020), la dinámica de los mercados de Finanzas Descentralizadas (Benbachir et al., 2025), análisis multifractal de los índices bursátiles

de Estados Unidos (Lee et al., 2018) y para realizar una comparativa de la eficiencia de los precios de energías renovables a nivel global (Khurshid et al., 2024) entre otros.

Ang y Chen (2002) demuestran la presencia de correlaciones asimétricas en el mercado financiero estadounidense. Además, Li et al. (2016) establecen que las correlaciones en los mercados financieros analizados son asimétricas, por lo que la metodología A-MFDFA es adecuada para el análisis del ETF iShares Global Clean Energy.

Algunos conceptos clave del método A-MFDFA son los siguientes:

- Multifractalidad: los datos muestran patrones complejos que cambian según la escala con la que se analizan.
- Asimetría: las tendencias crecientes y decrecientes no se comportan de la misma manera. Por ejemplo, los precios pueden subir lentamente, pero caer de forma abrupta.
- Eliminación de tendencias: elimina tendencias en los datos (como crecimiento a largo plazo) para poder extraer patrones y fluctuaciones que se mantienen.

El A-MFDFA calcula el exponente de Hurst H que permite determinar el comportamiento antipersistente ($H < 0,5$), aleatorio ($H = 0,5$) o persistente ($H > 0,5$) de la serie temporal. A continuación, se explican los pasos presentados por Cao et al. (2013) a realizar sobre una serie temporal para aplicar esta metodología y calcular el exponente de Hurst.

Sea $X = \{x(t), t = 1, 2, \dots, N\}$ una serie temporal donde N es la longitud de la serie.

Paso 1:

En primer lugar, se calcula el perfil $Y = \{y(t), t = 1, 2, \dots, N\}$ de la serie temporal mediante integración de la serie:

$$y(t) = \sum_{j=1}^t [x(j) - \bar{x}] \quad t = 1, \dots, N \quad (1)$$

donde \bar{x} es la media de la serie.

Paso 2:

La serie temporal y su perfil se dividen en subseries, todas de la misma longitud s , que no se solapan. El número de ventanas vendrá determinado por: $N_s = \text{int}\left(\frac{N}{s}\right)$. Se toma solo la parte entera, ya que el número de datos no será necesariamente divisible entre la longitud de las ventanas. Por ello, habría algunos datos que se descartarían. Para evitar esto, el proceso de división en ventanas de misma longitud no solapadas se realiza dos veces, en primer lugar, empezando desde el principio y descartando datos del final y, a continuación, empezando desde el final, descartando los valores del principio. Por tanto, el número de ventanas final será $2 \cdot N_s$.

Sea $V_{j,s} = \{v_{j,s}(k), k = 1, 2, \dots, s\}$ cada una de las ventanas y $Y_{j,s}(k) = \{y_{j,s}(k), k = 1, 2, \dots, s\}$ la serie integrada (perfil) de cada ventana $j \forall j = 1, 2, \dots, 2N_s$ de longitud s .

$$v_{j,s}(k) = x((j-1) \cdot s + k) \quad 1 \leq k \leq s \quad \text{si } j \leq N_s \quad (2)$$

$$v_{j,s}(k) = x(N - (j - N_s) \cdot s + k) \quad 1 \leq k \leq s \quad \text{si } j > N_s \quad (3)$$

Este paso se realizará para diferentes valores de s , que, según Peng et al. (1994), deberán estar comprendidos entre 5 y $N/4$, ya que, para valores de s pequeños, la eliminación de tendencias introduciría desviaciones que desvirtuarían este análisis. Peng et al. (1994) indica que estudios numéricos de varios tipos de secuencias de control muestran que esta desviación es despreciable si evaluamos el exponente de Hurst para valores de s mayores que cuatro.

Paso 3:

Para cada subserie y su perfil se realiza la regresión de mínimos cuadrados. En el caso de la subserie se realiza una regresión lineal:

$$L_{V_{j,s}}(k) = a_{j,s} + b_{j,s} \cdot k \quad (4)$$

donde k representa la coordenada horizontal dentro de la ventana j de longitud s . La recta de regresión lineal $L_{V_{j,s}}$ representa la tendencia lineal de la subserie $V_{j,s}$. La regresión

lineal de la ventana se emplea únicamente para determinar si la tendencia de esa ventana es ascendente o descendente. Para ello, se analizará el signo de la pendiente de $L_{Y_{j,s}}$.

Por otro lado, la regresión de mínimos cuadrados del perfil busca ajustarse al mismo. Por tanto, podrá ser de diferente orden según las características del perfil. Como se observa en la Figura 1, que representa la ventana $Y_{1,849}$, el perfil no sigue una tendencia lineal, por lo que es más adecuado el método cuadrático (Benbachir et al., 2025).




Figura 1. Perfil de la ventana 1 de longitud 849.

$$L_{Y_{j,s}}(k) = c_{j,s} + d_{j,s} \cdot k + e_{j,s} \cdot k^2 \quad (5)$$

Donde k representa la coordenada horizontal dentro de la ventana j de longitud s . La recta de regresión $L_{Y_{j,s}}$ representa la tendencia de la subserie $Y_{j,s}$. A partir de la regresión lineal del perfil se calcula la función de fluctuaciones.

$$F_s(j) = \frac{1}{s} \sum_{k=1}^s \left(y_{j,k} - L_{Y_j}(k) \right)^2 \quad j = 1, 2, \dots, 2N_s \quad \forall s = 5, \dots, \frac{N}{4} \quad (6)$$

Paso 4:

Para analizar el comportamiento de la serie, se considera la media de la función de fluctuaciones diferenciando entre los casos en los que la serie tiene tendencia positiva y

negativa. Para discriminar la tendencia de las series, se emplea la pendiente de la regresión lineal de la ventana: $b_{j,s} > 0$ ($b_{j,s} < 0$) indica que la serie tiene tendencia positiva (negativa) en la ventana j , de longitud s . Esto permite calcular la media de la función de fluctuaciones como se muestra a continuación:

$$F_q^+(s) = \left(\frac{1}{M^+} \sum_{j=1}^{2N_s} \frac{\text{sign}(b_j)+1}{2} [F_s(j)]^2 \right)^{\frac{1}{q}} \quad s = 5, 6, \dots, \frac{N}{4} \quad (7)$$

$$F_q^-(s) = \left(\frac{1}{M^-} \sum_{j=1}^{2N_s} \frac{-(\text{sign}(b_j)-1)}{2} [F_s(j)]^2 \right)^{\frac{1}{q}} \quad s = 5, 6, \dots, \frac{N}{4} \quad (8)$$

donde M^+ y M^- son el número de subseries con tendencia positiva y negativa respectivamente y se calculan de la siguiente manera:

$$M^+ = \sum_{j=1}^{2N_s} \frac{\text{sign}(b_j)+1}{2} \quad (9)$$

$$M^- = \sum_{j=1}^{2N_s} \frac{-(\text{sign}(b_j)-1)}{2} \quad (10)$$

Se debe realizar el cálculo para diferentes valores de q , excluyendo el cero. Los valores de H cuando $q > 0$ hacen referencia al comportamiento de la serie frente a grandes fluctuaciones, mientras que valores de H cuando $q < 0$ describen el comportamiento de escalamiento de pequeñas fluctuaciones.

El comportamiento de la serie temporal se determina a través del exponente de Hurst, $H(q)$. Si existen correlaciones cruzadas de tipo ley de potencia, entonces la media de la función de fluctuaciones satisface:

$$F_q(s) \sim s^{H(q)}; F_q^+(s) \sim s^{H^+(q)}; F_q^-(s) \sim s^{H^-(q)} \quad (11)$$

siendo $H(q), H^+(q), H^-(q)$ el exponente de Hurst global, ascendente y descendente respectivamente. Estos se determinan observando la pendiente de la expresión logarítmica de la función de fluctuaciones frente a s , por lo que la Ecuación (11) se puede expresar de la siguiente forma:

$$\log(F_q(s)) = H(q) \log(s) + \log(A1) \quad (12)$$

Si $H(q)$ es menor de 0,5 la serie presenta antipersistencia. Esto indica que, tras una fluctuación, la serie tiende, con mayor probabilidad, a ser seguida por una fluctuación de signo opuesto, favoreciendo el retorno a su valor medio.

Por otro lado, valores de $H(q)$ mayores de 0,5 caracterizan una serie persistente, es decir, incrementos (decrementos) pasados tienden a ser seguidos por incrementos (decrementos) futuros.

Por último, $H(q) = 0,5$ sugiere que la serie temporal es compatible con un proceso no correlacionado. Esto se asocia con un mercado eficiente.

Además, se puede analizar la dependencia del exponente de Hurst respecto del orden q . Si $H(q)$ depende de q , la serie presenta un comportamiento multifractal. Por el contrario, si $H(q)$ es independiente de q , se trata de una serie monofractal (Benbachir et al., 2025). En el caso de multifractalidad, los valores de $q > 0$ hacen referencia al comportamiento de la serie frente a grandes fluctuaciones, mientras que valores de $q < 0$ describen el comportamiento de escalamiento de pequeñas fluctuaciones (Cao et al., 2013).

Para completar el análisis, se puede evaluar la simetría de las correlaciones. Si $H^+ = H^-$ indica que las correlaciones son simétricas, ya que se comportan de la misma manera las fluctuaciones positivas que las negativas. Mientras que si H^+ es distinto de H^- indica que las correlaciones son asimétricas, comportándose de manera diferente según el signo de la fluctuación. Para este análisis se calcula $\Delta H^\pm(q)$.

$$\Delta H^\pm(q) = H^+(q) - H^-(q) \quad (13)$$

El exponente de Hurst, $H(q)$, está relacionado con el exponente de multifractalidad, conocido como exponente de Renyi, $\tau(q)$, de la siguiente manera:

$$\tau(q) = q \cdot H(q) - 1 \quad (14)$$

Si $\tau(q)$ aumenta de forma no lineal con q , la serie es multifractal, pero si es una función lineal de q la serie es monofractal. A través de la transformada de Legendre se calcula la fuerza de singularidad (α), también conocido como exponente de Hölder (Benbachir et al., 2025).

$$\alpha(q) = \tau'(q) \quad (15)$$

donde $\tau'(q)$ representa la derivada de la función del exponente de Renyi. Al disponer de datos discretos, se calcula la derivada mediante la derivada numérica central.

$$\alpha(q_i) = \frac{\tau(q_{i+1}) - \tau(q_{i-1}))}{q_{i+1} - q_{i-1}} \quad (16)$$

A partir del exponente de Hölder se calcula su espectro, $f(\alpha)$.

$$f(\alpha) = q (\alpha - H(q)) + 1 \quad (17)$$

El espectro permite analizar la multifractalidad; si presenta forma convexa indica multifractalidad en la serie analizada.

3.1. Origen de la multifractalidad

Kantelhard et al. (2002) identifica dos tipos de multifractalidad, por un lado, la debida a correlaciones a largo plazo o temporales y, por otro lado, multifractalidad debida a una distribución de probabilidad caracterizada por colas anchas. Conocer el origen de la multifractalidad permite realizar un análisis completo de la eficiencia del mercado. Si se identifican correlaciones temporales, el mercado presenta memoria estadística, estructuras temporales persistentes y, por tanto, contradice la forma débil de la HME. Por otro lado, si la distribución presenta colas anchas, indica probabilidad de eventos extremos, lo cual no implica necesariamente ineficiencia explotable, pero sí complejidad estructural.

Para llevar a cabo este análisis de origen de la multifractalidad, es necesario aplicar la metodología previamente explicada a dos transformaciones de la serie original.

En primer lugar, la serie barajada permite eliminar las correlaciones temporales, pero mantiene la distribución de valores. Para obtener la serie barajada se varían las posiciones de los valores de forma aleatoria. Si la multifractalidad desaparece al analizar esta serie, indica que esta provenía de correlaciones temporales.

En segundo lugar, la serie sustituta modifica la distribución, que pasa a ser una distribución gaussiana, pero se mantienen las correlaciones temporales. Esta permite medir el efecto de las colas pesadas sobre la multifractalidad. Para calcular esta serie se ha empleado la metodología descrita por Zhou (2009), explicada a continuación.

En primer lugar, se genera una serie gaussiana con media y desviación típica iguales a la serie original.

$$X' = \{x'(t), t = 1, 2, \dots, N\} \sim N(\mu, \sigma) \quad (18)$$

A continuación, se reordena esta serie siguiendo los mismos rangos de la serie original, es decir, que el valor más alto esté en la misma posición que el valor más alto de la serie original y así con todos los valores. De esta forma se mantienen las correlaciones temporales en la serie sustituta con distribución gaussiana respecto de la original.

3.2. Origen de la asimetría

Álvarez-Ramírez et al. (2009) determina que la asimetría también puede verse inducida por correlaciones intrínsecas o por distribuciones con colas anchas. Por tanto, sobre las mismas alteraciones de la serie original (barajada y sustituta) se calculará la medida de asimetría. De esta forma se podrá determinar el origen de la asimetría.

4. Descripción de los datos

Este estudio analiza el ETF iShares Global Clean Energy (ICLN), un fondo cotizado que busca replicar el rendimiento del S&P Global Clean Energy Transition Index, un índice global compuesto por acciones de empresas en el sector de la energía limpia. El fondo

fue creado en 2008, por lo que cuenta con suficiente trayectoria para analizar la eficiencia de este. En enero de 2026, el ETF cuenta con acciones de 101 empresas y aproximadamente 113,7 millones de acciones en circulación (BlackRock, s.f.).

Con el objetivo de contextualizar la relevancia del ETF analizado, se realiza una comparación con otros ETF relevantes del sector. La selección se ha realizado a partir de los ETF presentados en plataformas de información financiera como relevantes en el sector de energías limpias (Degiro, s.f.; IG, s.f.). La información sobre estos ETF comparados se resume en la Tabla 2.

La elección de este ETF como objeto de estudio se justifica por varias razones. En primer lugar, es uno de los fondos cotizados con más antigüedad del sector. Esto es relevante, ya que permite disponer de una serie temporal amplia, necesario para la aplicación de la metodología mencionada y la obtención de resultados robustos.

En segundo lugar, el ETF presenta un volumen significativo de activos bajo gestión. Esto está asociado a mayores niveles de liquidez, lo que contribuye a una rápida incorporación de nueva información del mercado en el precio del ETF. Además, reduce posibles distorsiones derivadas de problemas de liquidez o baja profundidad del mercado.

En tercer lugar, el índice subyacente es un índice global, es decir, incluye a empresas de diferentes regiones y mercados. Esto da lugar a un ETF expuesto a diferentes marcos regulatorios, políticas energéticas y condiciones macroeconómicas, lo que permite obtener una visión global del mercado de energías limpias.

Adicionalmente, a diferencia de otros ETF del sector que están compuestos únicamente por una tecnología el ICLN presenta una exposición más amplia. Esta diversificación permite obtener un análisis más representativo del sector.

En conjunto, estas características convierten al ETF iShares Global Clean Energy en un instrumento adecuado y representativo para el análisis de la eficiencia de mercado de energías limpias.

Se van a analizar los datos desde el 24 de junio de 2008 hasta el 7 de enero de 2026. Se dispone de los precios diarios de cierre de mercado. A partir de los precios diarios se

calculan los retornos logarítmicos (r_i) ya que son aditivos en el tiempo y permiten una interpretación de los resultados más limpia (Benbachir et al., 2025)

$$r_i = \ln(P_{i+1}) - \ln(P_i) \quad (19)$$

donde P_i es el precio diario y $\ln(\cdot)$ el logaritmo natural.

La Tabla 1 muestra los principales estadísticos descriptivos de los retornos diarios. Se observa una elevada simetría en la serie, que podría asemejarse a una distribución normal. Sin embargo, el elevado valor de Curtosis indica una distribución muy apuntada, con gran concentración de datos cerca de la media. Esto puede indicar presencia de valores extremos y colas pesadas. Resulta apropiado emplear la metodología A-MFDFA, que permite detectar dependencias de largo plazo, estructura multifractal y posibles asimetrías entre mercados alcistas y bajistas, ya que no se cumplen los supuestos de linealidad y normalidad.

Media	Mediana	Rango	Desviación típica	Varianza	Sesgo	Curtosis
0,000253	0	0,330	0,0188	0,000355	0,04	11,69

Tabla 1. Estadísticos descriptivos de los retornos diarios del ETF iShares Global Clean Energy

ETF	Ticker	Índice subyacente	Fecha de constitución	Objetivo de inversión	Activos netos (M \$)	Fuente
iShares Global Clean Energy	ICLN	S&P Global Clean Energy Index	24/06/2008	Busca replicar los resultados de inversión de un índice compuesto por valores de renta variable global del sector de energías renovables.	2.111,18	(BlackRock, s.f.)
Invesco solar Energy	ISUN	MAC Global Solar Energy Index	2/08/2021	Replicar la rentabilidad de empresas de todo el mundo del sector de la energía solar, con una exposición diversificada a todas las tecnologías solares, al conjunto de la cadena de valor y a los equipos solares relacionados.	157,53	(Invesco, s.f.-b)
Invesco Global Clean Energy	GCLE	WilderHill New Energy Global Innovation Index	1/03/2021	Ofrece exposición a empresas globales que cuentan con tecnologías innovadoras orientadas a la generación y el uso de energías limpias, conservación de la energía, eficiencia energética y promoción de energías renovables.	99,76	(Invesco, s.f.-a)
Amundi Global Bioenergy	CWE	Bloomberg BioEnergy Screened Index	30/01/2018	Tiene como objetivo replicar lo más exacto posible, tanto si la tendencia es alcista como bajista, la evolución del índice de referencia.	40,52	(Amundi, s.f.)
Global Clean Water X	AQWA	Solactive Global Clean Water Industry v2 Index	07/12/2021	Tiene como objetivo proporcionar resultados de inversión que se correspondan, en términos generales, con el rendimiento del precio y la rentabilidad, antes de comisiones y gastos, del índice Solactive Global Clean Water Industry v2.	25,74	(Global X ETF, s.f.)
SPDR S&P Kensho Clean Power ETF	CNRG	S&P Kensho Clean Power Index	22/10/2018	Busca medir el desempeño de empresas dedicadas a los avances en tecnología limpia y energía no contaminante.	197,66	(S&P Dow Jones, s.f.)
First trust global wind energy	FAN	ISE Clean Edge Global Wind Energy Index™.	6/06/2008	Busca resultados de inversión que se correspondan en general con el precio y el rendimiento (antes de las comisiones y gastos del fondo) del índice bursátil de referencia	225,7	(First Trust Advisors, s.f.)

Tabla 2. Comparativa ETF de energías limpias

5. Resultados

La Figura 2 muestra en la parte superior la representación de $\log(F_3)$ frente a $\log(s)$, mientras que la parte inferior muestra F_3 frente a s para las series ascendente, descendente y global. Se observa la asimetría entre las ventanas con tendencia ascendente y descendente, ya que presentan desviaciones marcadas, especialmente en mayores escalas.

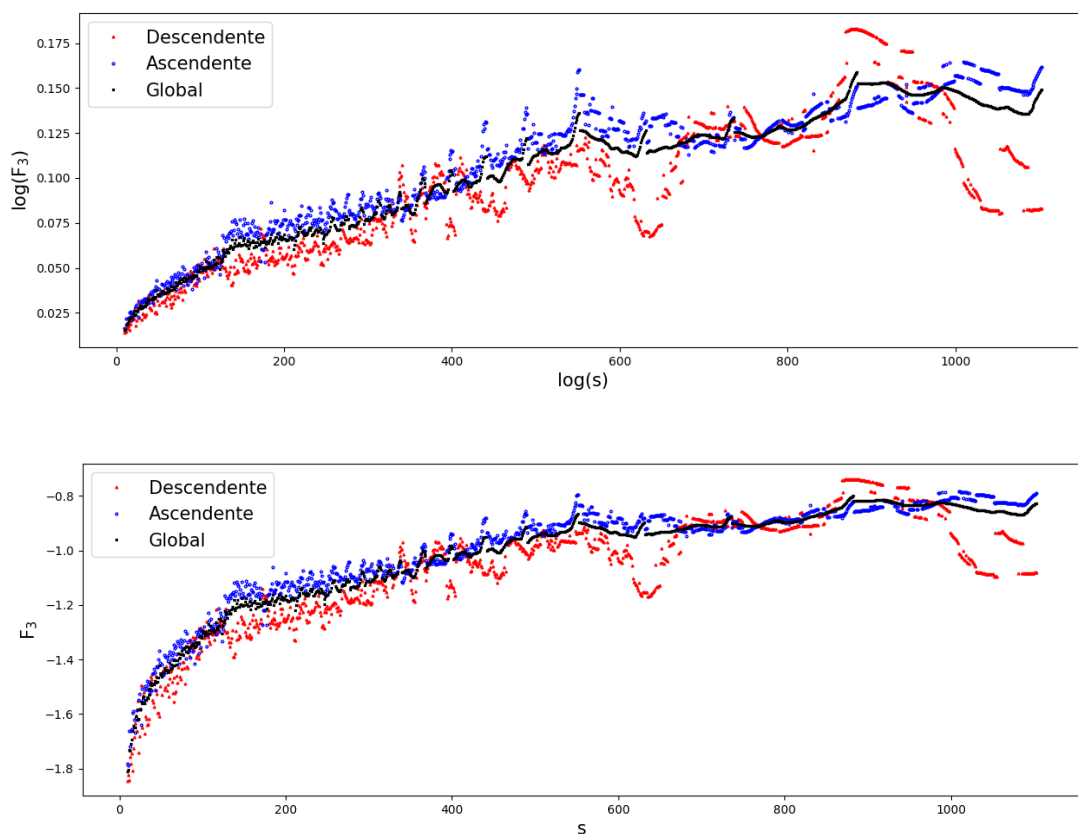


Figura 2. (a) $\log(F_3)$ frente a $\log(s)$. (b) F_3 frente a s . $\log(\cdot)$ denota logaritmo en base 10.

La Figura 3 muestra el exponente de Hurst generalizado $H(q)$ en función de q , distinguiendo entre las tendencias bajistas y alcistas para realizar el análisis de la asimetría. El gráfico muestra que el coeficiente de Hurst no es constante, es decir, depende del valor de q , lo cual indica un comportamiento multifractal. Concretamente, para ambas tendencias, muestra pendiente negativa respecto a q . Cuando $q > 0$ dominan las fluctuaciones grandes, se observa en ese caso un valor de H por debajo de 0,5 lo cual indica antipersistencia. Mientras que para $q < 0$, cuando dominan las pequeñas fluctuaciones el valor de H es mayor que 0,5, y, por tanto, el comportamiento de la serie es persistente.

Se observa que, para todo valor de q , se cumple que $H^- > H^+$, lo cual implica asimetría, la brecha es mayor para $q < 0$, por tanto, la asimetría es mayor cuando se producen pequeñas fluctuaciones, mientras que para mayores fluctuaciones el comportamiento de la serie se asemeja más entre tendencias alcistas y bajistas.




Figura 3. $H^+(q)$, $H^-(q)$ y $H(q)$

5.1. Análisis de la multifractalidad

Como se ha comentado en el apartado anterior, en la Figura 3 se observa multifractalidad, al depender el valor del coeficiente de Hurst de q . Además, se muestra en la Figura 4 el espectro del exponente de Hölder ($f(\alpha)$), cuya forma convexa confirma la multifractalidad de la serie.

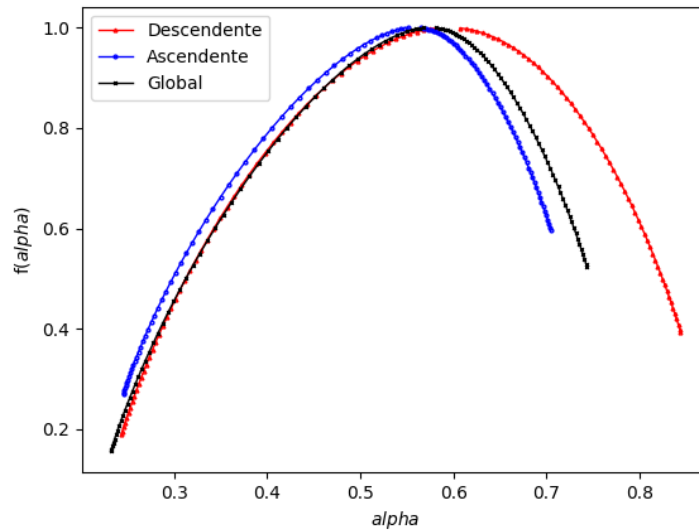


Figura 4. Espectro del exponente de Hölder

Es relevante analizar el origen de la multifractalidad. Para ello, se calculan la serie barajada y la serie sustituta. El parámetro que se emplea para comparar la multifractalidad es ΔH .

$$\Delta H = \max(H(q)) - \min(H(q)) \quad (20)$$

La Tabla 3 presenta los valores de ΔH para las series original, barajada y sustituta.

ΔH	Original	Barajada	Sustituta
Alcista	0,268	0,128	0,148
Bajista	0,362	0,131	0,170

Tabla 3. ΔH para la serie original, barajada y sustituta.

Los valores de ΔH se reducen para la serie barajada, lo cual indica que una parte significativa de la multifractalidad proviene de correlaciones de largo plazo. Por otro lado, la serie sustituta presenta también un valor menor de ΔH por lo que la no linealidad (colas pesadas) es también una fuente importante de la multifractalidad.

5.2. Análisis de la asimetría

Para analizar la asimetría se calcula $\Delta H^\pm(q)$, que se muestra en la Figura 5. En la serie original la asimetría es más intensa en escalas dominadas por pequeñas fluctuaciones. Para grandes fluctuaciones la serie original presenta muy poca asimetría; sin embargo, al analizar la serie barajada y sustituta se observa que la serie presenta asimetría debida a la distribución y a las correlaciones lineales, pero de signo contrario.




Figura 5. $\Delta H^\pm(q)$

5.3. Análisis de periodos característicos

Los datos empleados en el análisis abarcan desde el 24 de junio de 2008 al 7 de enero de 2026. Esto incluye dos periodos relevantes en el ámbito económico y financiero. En primer lugar, la crisis de la pandemia del COVID-19, que se caracteriza por una contracción de la actividad económica a nivel mundial (Richards et al., 2022). En segundo lugar, el periodo de asociado al comienzo de la guerra en Ucrania. Durante este último tuvo lugar un significativo aumento del precio del petróleo y otras materias primas (Zaid, 2022).

En la Figura 6 se muestra la evolución del precio diario del ETF desde marzo de 2018 a enero de 2026. Se observa que, durante la pandemia de COVID-19 el precio experimentó un incremento muy significativo. Tras alcanzar el máximo, el precio se redujo de forma progresiva pero no alcanzó los valores previos a la pandemia. Por otro lado, en torno al

comienzo de la guerra en Ucrania se observa un aumento en el precio, aunque este es menos pronunciado en comparación al observado durante la pandemia.




Figura 6. Evolución del precio del ETF ICLN

Este incremento del precio del ETF durante el COVID-19 se debió a varios factores, principalmente, los tipos de interés alcanzaron valores muy bajos, lo que revaloriza activos como las energías limpias que requieren de gran inversión. Además, mejoraron las expectativas de inversión pública en la transición energética dentro de los programas de recuperación económica posteriores a la pandemia (Richards et al., 2022).

En cuanto a la guerra entre Rusia y Ucrania, el conflicto generó un incremento significativo del precio del petróleo entre otros productos (Zaid, 2022). El encarecimiento de combustibles fósiles fomentó el interés por fuentes alternativas de energía como las energías limpias.

5.3.1. Periodo de la pandemia del COVID-19

Para el análisis de este periodo, se han considerado los datos comprendidos entre febrero 2020 a agosto 2021. Este periodo coincide con la fase de mayor impacto de la pandemia del COVID-19 en los mercados financieros (Shanmuga, 2021).

En la Figura 7 se puede observar que existe ineficiencia de mercado durante este periodo, muy similar a la que presentaba la serie completa. Para fluctuaciones pequeñas el

coeficiente de Hurst es mayor de 0,5 lo que indica persistencia, mientras que para fluctuaciones grandes en la serie de fluctuaciones ascendentes y global alcanza valores inferiores a 0,5 por lo que presenta antipersistencia.




Figura 7. $H^+(q)$, $H(q)$ y $H(q)$ durante el COVID-19

Además, en la Figura 7 se observa que la serie presenta asimetría, ya que las tendencias alcistas y bajistas se comportan de forma diferente. Se observa una asimetría mayor que la que presentaba la serie completa.

Se trata de una serie multifractal ya que se observa en la Figura 7 que el valor del coeficiente de Hurst varía en función de la q . Además, la Figura 8 muestra el exponente de Hölder ($f(\alpha)$), que, al ser convexo, demuestra también multifractalidad.

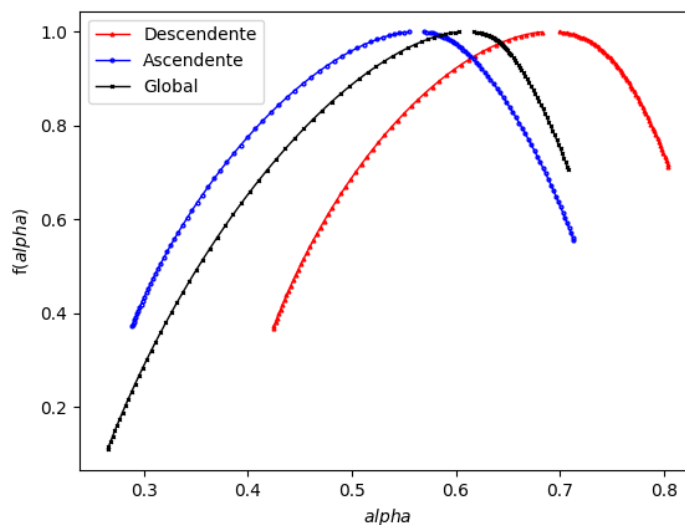


Figura 8. Espectro del exponente de Hölder del periodo COVID-19

5.3.2. Periodo del comienzo de la guerra entre Rusia y Ucrania

Para analizar el impacto de la guerra entre Rusia y Ucrania en el comportamiento del ETF de energías limpias se han considerado los datos comprendidos entre febrero de 2022 y marzo 2023. Este periodo corresponde con las primeras fases del conflicto, cuando los mercados se vieron más afectados por la incertidumbre. Aunque el conflicto no ha finalizado, a partir de marzo de 2023 se observa una progresiva estabilidad en los mercados (Club Español de la Energía, 2024).

En la Figura 9 se muestra el valor del coeficiente de Hurst para las fluctuaciones alcistas y bajistas. Se observa que el mercado no es eficiente al diferir su valor de 0,5. Se observan valores de $H(q)$ superiores a 0,5 por lo que el mercado presenta persistencia. También se observa asimetría, ya que la serie se comporta de forma diferente en función de si las fluctuaciones son al alza o a la baja. Además, se observa multifractalidad, ya que el coeficiente de Hurst varía en función de q ; esto se confirma con la forma convexa del espectro de Hölder, representado en la Figura 10.




Figura 9. $H^+(q)$, $H^-(q)$ y $H(q)$ durante el comienzo de la guerra de Ucrania




Figura 10. Espectro del exponente de Hölder durante el comienzo de la guerra de Ucrania

6. Conclusiones

Este estudio emplea la metodología multifractal asimétrica de fluctuación con eliminación de tendencias en el ETF de energía limpias iShares Global Clean Energy ICLN para determinar la eficiencia en su forma débil. En este apartado se expresan las conclusiones extraídas del análisis.

En primer lugar, existe evidencia significativa de que se trata de un mercado ineficiente en su forma débil. El coeficiente de Hurst muestra persistencia para pequeñas fluctuaciones y antipersistencia para grandes fluctuaciones, lo cual sugiere que la dinámica de precios del ETF no es un proceso aleatorio.

Como consecuencia de la ineficiencia del ETF, se podrían predecir los precios a partir de la información histórica, lo cual permite a los inversores realizar estrategias de trading a corto plazo. En particular, el comportamiento persistente en fluctuaciones pequeñas implica que los movimientos moderados tienden a continuar en la misma dirección, mientras que ante variaciones de mayor magnitud se puede esperar una reversión a la media.

Además, se observa que la asimetría es significativa para pequeñas fluctuaciones, donde tendencias bajistas presentan un coeficiente de Hurst mayor y, por tanto, mayor persistencia, frente a tendencias alcistas.

En segundo lugar, se ha demostrado que la serie analizada presenta un comportamiento multifractal. Esto implica que el comportamiento del ETF varía en función de las escalas temporales. Esto es incompatible con un proceso aleatorio, es decir, eficiente. Además, la multifractalidad proviene principalmente de correlaciones temporales, lo cual indica memoria temporal explotable. Por tanto, los analistas e inversores podrían beneficiarse de emplear modelos capaces de capturar estas propiedades de dependencia temporal y escalamiento no lineal.

Por último, desde una perspectiva regulatoria, la presencia de dependencia temporal e ineficiencia de mercado indica que la información no se refleja de manera inmediata en los precios del ETF de energía limpia analizado. Sería necesario aplicar medidas para ampliar la transparencia informativa, mejora de los mecanismos de difusión de información y fortalecimiento de la infraestructura de negociación. Estas medidas podrían contribuir a un proceso de formación de precios más eficiente y a un desarrollo más estable de los mercados financieros asociados a la energía limpia.

En cuanto a periodos de estrés económicos, como la pandemia del COVID-19 y la guerra entre Rusia y Ucrania se ha observado que no varía considerablemente el comportamiento del mercado. Se observó un comportamiento persistente, especialmente en las fluctuaciones con tendencias bajistas. Pero el comportamiento durante estos periodos fue, al igual que en la serie completa, asimétrico y multifractal.

Este estudio presenta algunas limitaciones que deben ser consideradas. En primer lugar, se centra exclusivamente en un ETF, lo que limita la generalización de los resultados a otros instrumentos del sector. Además, la metodología empleada captura dependencia temporal y propiedades de escalamiento no lineal, pero no incorpora factores macroeconómicos que pueden influir en los precios. De esta forma, futuras investigaciones podrían ampliar el análisis a otros ETFs o acciones del sector de la energía limpia. Además, se pueden desarrollar modelos de predicción de precios que permitan estudiar la efectividad de estrategias de trading basadas en estas propiedades bajo distintas condiciones de volatilidad. Asimismo, sería relevante examinar el impacto de políticas regulatorias y mejoras en la transparencia informativa sobre la eficiencia de los precios en los mercados.

7. Bibliografía

- Álvarez-Ramírez, J., Rodríguez, E., Echeverría, J.C. (2009) A DFA approach for assessing asymmetric correlations. *Physica A* 2009 388 2263–2270. DOI: 10.1016/j.physa.2009.03.007
- Amundi. (s.f.) Amundi Global Bioenergy UCITS ETF EUR Acc. <https://www.amundi-etf.es/es/individual/products/equity/amundi-global-bioenergy-ucits-etf-eur-acc/lu1681046006>
- Ang, A. & Chen, J. (2002) Asymmetric correlations of equity portfolios. [https://doi.org/10.1016/S0304-405X\(02\)00068-5](https://doi.org/10.1016/S0304-405X(02)00068-5)
- Aurora Energy. (2026) European renewables market overview report. <https://auroraer.com/resources/aurora-insights/market-reports/2nd-edition-resmor>
- Benbachir, S., Amzile, K. & Beraich M. (2025). Exploring the Asymmetric Multifractal Dynamics of DeFi Markets. *J. Risk Financial Manag.* 2025, 18(3), 122. <https://doi.org/10.3390/jrfm18030122>
- BlackRock (s.f.) iShares Global Clean Energy ETF. Recuperado el 15 de febrero de 2026 de: <https://www.blackrock.com/cl/productos/239738/ishares-global-clean-energy-etf>.
- BloombergNEF. (2026). Energy Transition Investment Trends BloombergNEF. <https://about.bnef.com/insights/finance/energy-transition-investment-trends/>
- Cao, G., Cao, J., & Xu, L. (2013) Asymmetric multifractal scaling behavior in the Chinese stock market: Based on asymmetric MF-DFA. *Physica A: Statistical Mechanics and its Applications*, 392 (4), 797-807. <https://doi.org/10.1016/j.physa.2012.10.042>
- Club Español de la Energía. (2024). Balance energético de 2023 y perspectivas para 2024. <https://www.enerclub.es/wp-content/uploads/2024/06/Balance-Energetico-de-2023-y-Perspectivas-para-2024.pdf>

- Convención Marco de las Naciones Unidas sobre el Cambio Climático (CMNUCC), (2015) El Acuerdo de París. <https://unfccc.int/es/acerca-de-las-ndc/el-acuerdo-de-paris>
- Degiro. (s.f.) ETF de energía limpia. Recuperado el 03 de marzo de 2026 de: <https://www.degiro.es/invertir/comprar-un-etf/energia-limpia>
- Dias, R., Horta, N., & Chambino, M. (2023). Clean Energy Action Index Efficiency: An Analysis in Global Uncertainty Contexts. *Energies*, 16 (9), 3937. <https://doi.org/10.3390/en16093937>
- Díaz-Pinzón, J. E. (2023) Fluctuación del precio del petróleo Brent debido a la guerra entre Rusia y Ucrania <https://doi.org/10.25097/rep.n37.2023.06>
- Dutta, A., Bouri, E., & Noor, M. H. (2018). Return and volatility linkages between CO₂ emission and clean energy stock prices. *Energy*, 164, 803-810. <https://doi.org/10.1016/j.energy.2018.09.055>
- Dutta, A., Bouri, E., Rothovius, T., & Uddin, G. S. (2023). Climate risk and green investments: New evidence. *Energy*, 265, 126376. <https://doi.org/10.1016/j.energy.2022.126376>
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- Ferrer, R., Shahzad, S. J. H., López, R., & Jareño, F. (2018). Time and frequency dynamics of connectedness between renewable energy stocks and crude oil prices. *Energy Economics*, 76, 1-20. <https://doi.org/10.1016/j.eneco.2018.09.022>
- First Trust Advisors L.P. (s.f.) First Trust Global Wind Energy ETF (FAN). Recuperado el 26 de febrero de 2026 de: <https://www.ftportfolios.com/retail/etf/etfsummary.aspx?Ticker=FAN>
- Global X ETF. (s.f.) Global X Clean Water UCITS ETF (AQWA). Recuperado el 25 de febrero de 2026 de: <https://globalxetfs.eu/funds/aqwa/>

- IG. (s.f.) ¿Cuáles son los 6 mejores ETFs del sector de las energías renovables para invertir este mes? Recuperado el 3 de marzo de 2026 de: <https://www.ig.com/es/estrategias-de-trading/-cuales-son-los-6-mejores-etfs-del-sector-de-las-energias-renova-221206#Seis>
- International Energy Agency. (2025). World Energy Outlook 2025. IEA. <https://www.iea.org/reports/world-energy-outlook-2025>
- Invesco. (s.f.-a) Invesco Global Clean Energy UCITS ETF Acc. Recuperado el 25 de febrero de 2026 de: <https://www.invesco.com/es/es/financial-products/etfs/invesco-global-clean-energy-ucits-etf-acc.html>
- Invesco. (s.f.-b) Invesco Solar Energy UCITS ETF Acc. Recuperado el 25 de febrero de 2026 de: <https://www.invesco.com/es/es/financial-products/etfs/invesco-solar-energy-ucits-etf-acc.html>
- Kantelhardt, J. W., Zschiegner, S.A., Koscielny-Bunde, E., Havlin, S., Bunde, A., & Stanley, H. E. (2002). Multifractal detrended fluctuation analysis of nonstationary time series. *Physica A: Statistical Mechanics and its Applications*, 316 (1-4), 87-114. [https://doi.org/10.1016/S0378-4371\(02\)01383-3](https://doi.org/10.1016/S0378-4371(02)01383-3)
- Khurshid, A., Khan, K., Cifuentes-Faura, J. & Chen, Y. (2024) Asymmetric multifractality: Comparative efficiency analysis of global technological and renewable energy prices using MF DFA and A-MF DFA approaches. <https://doi.org/10.1016/j.energy.2023.130106>
- Kumar, S., Managi, S., & Matsuda, A. (2012). Stock prices of clean energy firms, oil and carbon markets: A vector autoregressive analysis. *Energy Economics*, 34(1), 215-226. <https://doi.org/10.1016/j.eneco.2011.03.002>
- Lee, M., Song, J.W., Kim, S. & Chang, W. (2018). Asymmetric market efficiency using the index-based asymmetric-MF DFA. <https://doi.org/10.1016/j.physa.2018.08.030>
- Li, X., Shen, X. & Huang, J. (2016) Asymmetric and symmetric meta-correlations in financial markets. 10.1088/1674-1056/25/10/108903

- Ministerio para la Transición Ecológica y el Reto Demográfico (2020). Plan Nacional de Adaptación al Cambio Climático 2021-2030. https://www.miteco.gob.es/content/dam/miteco/es/cambio-climatico/temas/impactos-vulnerabilidad-y-adaptacion/pnacc-2021-2030_tcm30-512163.pdf
- Narayan, P. K. (2024). Pricing behaviour of clean energy stocks? Some trading implications. *Energy Economics*, 134, Article 107590. <https://doi.org/10.1016/j.eneco.2024.107590>
- Özdemir, C. (2021) Will clean energy investments provide a more sustainable financial ecosystem? Less carbon and more democracy. <https://doi.org/10.1016/j.rser.2021.111556>
- Peng, C.-K., Buldyrev, S. V., Havlin, S., Simons, M., Stanley, H. E., & Goldberger, A. L. (1994). Mosaic organization of DNA nucleotides. *Physical Review E*, 49(2), 1685–1689. <https://doi.org/10.1103/PhysRevE.49.1685>
- Pham, L. (2019). Do all clean energy stocks respond homogeneously to oil price? *Energy Economics*, 81, 355-379. <https://doi.org/10.1016/j.eneco.2019.04.010>
- Richards, F., Kodjamanova, P., Chen, X., Li, N., Atanasov, P., Bennetts, L., Patterson, B. J., Yektashenas, B., Mesa-Frias, M., Tronczynski, K., Buyukkaramikli, N., & El Khoury, A. C. (2022). Economic burden of COVID-19: A systematic review. *ClinicoEconomics and Outcomes Research*, 14, 293–307. <https://doi.org/10.2147/CEOR.S338225>
- Sadorsky, P. (2021). A Random Forests Approach to Predicting Clean Energy Stock Prices. *Journal of Risk and Financial Management*, 14 (2), 48. <https://doi.org/10.3390/jrfm14020048>
- Sadorsky, P. (2022). Using machine learning to predict clean energy stock prices: How important are market volatility and economic policy uncertainty? *Journal of Climate Finance*. <https://doi.org/10.1016/j.jclimf.2022.100002>
- Shahzad, S. J. H., Bouri, E., Kayani, G. M., Nasir, R. M., & Kristoufek, L. (2020). Are clean energy stocks efficient? Asymmetric multifractal scaling

- behaviour. *Physica A: Statistical Mechanics and Its Applications*, 550, 124519. <https://doi.org/10.1016/j.physa.2020.124519>
- S&P Dow Jones Indices. (s.f.) S&P Kensho Clean Power Index. <https://www.spglobal.com/spdji/es/indices/equity/sp-kensho-clean-power-index/#overview>
- Unión Europea. (s. f.). Actuación de la UE: energía sostenible. Recuperado el 24 de octubre de 2025 de https://european-union.europa.eu/priorities-and-actions/actions-topic/energy_es
- Westerlund, J., Reese, S., Narayan, P., 2017. A factor analytical approach to price discovery. *Oxf. Bull. Econ. Stat.* 79, 366-3. <https://doi.org/10.1111/obes.12167>
- Wurgler, J. (2000). Financial markets and the allocation of capital. *Journal of Financial Economics*, 58(1-2) 187-214. [https://doi.org/10.1016/S0304-405X\(00\)00070-2](https://doi.org/10.1016/S0304-405X(00)00070-2)
- Yahya, M., Kanjilal, K., Dutta, A., Uddin, G.S. & Ghosh, S. (2021) Can clean energy stock price rule oil price? New evidences from a regime-switching model at first and second moments. <https://doi.org/10.1016/j.eneco.2021.105116>
- Zaid, M. (2022) Russian-Ukrainian War and its Economic Implications on the Prices of Strategic Commodities. <https://doi.org/10.48185/sebr.v3i2.738>
- Zhou, W. (2009). The components of empirical multifractality in financial returns. *Europhysics Letters*, Volume 88, Number 2. DOI 10.1209/0295-5075/88/28004

ANEXO. Código desarrollado para el análisis

Returns.py

```
import pandas as pd
import numpy as np

version= input('Qué número de hoja quieres usar? (1-versión corta, 2-
todo) ')

ruta = '../TFG_ADE_Datos_COVID.xlsx'
hoja = 'Hoja' + version

df = pd.read_excel(ruta, hoja)
df_return = pd.DataFrame()
for i in range(1,len(df.iloc[:,0])):
    df_return.loc[i-1,'return'] = np.log(df.iloc[i,0]) -
np.log(df.iloc[i-1,0])

nombre_p = '../TFG_ADE_Return.xlsx'
with pd.ExcelWriter(nombre_p) as writer:
    df_return.to_excel(writer, sheet_name='Hoja'+version, index=False)
```

Ventanas.py

```
import pandas as pd
def ventanas(serie,n):
    #Devuelve las ventanas de la serie
    ven = pd.DataFrame()
    n_s = int(len(serie)/n)
    for j in range(1,n_s+1):
        for k in range(n):
            print(k)
            ven.loc[k,str(j)]=float(serie[(j-1)*n+k])
    num = len(serie)
    for j in range(n_s + 1, 2 * n_s + 1):
        for k in range(n):
            ven.loc[k, str(j)] = float(serie[num-(j-n_s)*n+k])
    return ven

def profile(serie):
    # Devuelve el perfil de la serie que haya recibido
    media = float(sum(serie)/(len(serie)))
    resultado = []
    for i in range(len(serie)):
        suma = 0
        for j in range(i+1):
            suma += float(serie[j])-media
        resultado.append(suma)
    return resultado

version= input('Qué número de hoja quieres usar? (1-versión corta, 2-
todo) ')

ruta = '../TFG_ADE_Return.xlsx'
hoja = 'Hoja' + version
```

```

df = pd.read_excel(ruta, hoja)
N = len(df.iloc[:, 0])
s_js = []
s = []
ys_js = []
s_0 = int(input('Desde qué s quieres empezar? '))
s_f = int(input(f'Hay un total de {N} datos, hasta qué s quieres
hacer? '))
for n in range(s_0, s_f):
    vent = ventanas(df.iloc[:, 0], n)
    s_js.append(vent)
    s.append(n)
    vent_perfil = ventanas(profile(df.iloc[:, 0]), n)
    ys_js.append(vent_perfil)
    print(f'longitud perfil {len(vent_perfil)}')
    print(f'longitud ventana {len(vent)}')

nombre_v = '../TFG_ADE_sj' + version + '.xlsx'

with pd.ExcelWriter(nombre_v) as writer:
    for long in range(len(s)):
        s_js[long].to_excel(writer, sheet_name=str(s[long]),
index=False)

nombre_p = '../TFG_ADE_ysj' + version + '.xlsx'
with pd.ExcelWriter(nombre_p) as writer:
    for long in range(len(s)):
        ys_js[long].to_excel(writer, sheet_name=str(s[long]),
index=False)

```

Calculos.py

```

import pandas as pd
import numpy as np
import statsmodels.api as sm

def mincua(x, y):
    X = sm.add_constant(x)
    model = sm.OLS(y, X).fit()
    v=model.params
    return v

def fluctuaciones(perfil, m, n):
    fluc=[]
    for col in range(len(perfil)):
        aux=[]
        for j in range(len(perfil[col].columns)):
            sum = 0
            for k in range(len(perfil[col].iloc[:, j])):
                sum += (perfil[col].iloc[k, j]-m.iloc[j, col]*(k+1)-
n.iloc[j, col])**2
            sum=sum/len(perfil[col].iloc[:, j])
            aux.append(sum)
        fluc.append(aux)
    return fluc

def fluctuaciones_dos(perfil, m, mdos, n):
    fluc=[]
    for col in range(len(perfil)):
        aux=[]

```

```

        for j in range(len(perfil[col].columns)):
            sum = 0
            for k in range(len(perfil[col].iloc[:,j])):
                sum += (perfil[col].iloc[k,j]-m.iloc[j,col]*(k+1)-
mdos.iloc[j,col]*(k+1)**2-n.iloc[j,col])**2
            sum=sum/len(perfil[col].iloc[:,j])
            aux.append(sum)
        fluc.append(aux)
    return fluc

def fluctuaciones_tres(perfil,m, mdos, mtres, n):
    fluc=[]
    for col in range(len(perfil)):
        aux=[]
        for j in range(len(perfil[col].columns)):
            sum = 0
            for k in range(len(perfil[col].iloc[:,j])):
                sum += (perfil[col].iloc[k,j]-m.iloc[j,col]*(k+1)-
mdos.iloc[j,col]*(k+1)**2-mtres.iloc[j,col]*(k+1)**3-n.iloc[j,col])**2
            sum=sum/len(perfil[col].iloc[:,j])
            aux.append(sum)
        fluc.append(aux)
    return fluc

def eme(b, signo):
    #signo 0 es negativo y 1 positivo
    m=0
    for i in range(len(b)):
        if signo == 0:
            if b[i]<0:
                m+=1
        elif b[i]>0:
            m += 1
    return m

def media_fluct(ffluc, b, signo, q_in, q_fin, q_int):
    resultado = pd.DataFrame()
    q_set = []

    for q in np.arange(int(q_in),int(q_fin),float(q_int)):
        q_set.append(q)
        res=[]
        for i in range(len(b.columns)):
            sum=0
            num = eme(list(b.iloc[:,i]), signo)
            for j in range(len(b.iloc[:,i])):
                if signo == 0:
                    if b.iloc[j,i]<0:
                        aux = pow(ffluc[i][j],q)
                        aux= np.sqrt(aux)
                        sum += aux
                    elif b.iloc[j,i] > 0:
                        aux = pow(ffluc[i][j], q)
                        aux = np.sqrt(aux)
                        sum += aux
            if q > -0.08 and q < 0.08:
                media = np.nan
            else:
                media = (sum / num) ** (1 / q)
            resultado.loc[i,str(q)]=media
    return resultado, q_set

```

```
version= input('Qué número de hoja quieres usar? (1-versión corta, 2-  
todo) ')
```

```
s_0 = int(input('Desde qué s quieres empezar? '))  
s_f = int(input(f'Hasta qué s quieres hacer? '))
```

```
ruta2 = '../TFG_ADE_sj' + version + '.xlsx'  
ruta3 = '../TFG_ADE_ysj' + version + '.xlsx'  
s_js=[]  
ys_js = []  
s = []  
for i in range(s_0, s_f):  
    aux = pd.read_excel(ruta2, sheet_name=str(i))  
    s_js.append(aux)  
    ys_js.append(pd.read_excel(ruta3, sheet_name=str(i)))  
    s.append(i)
```

```
a_sj=pd.DataFrame()  
b_sj=pd.DataFrame()  
for col in range(len(s)):  
    for fil in range(len(s_js[col].columns)):  
        y=list(s_js[col].iloc[:,fil])  
        x=[w for w in range(1,1+len(y))]  
        (a,b)=mincua(x,y)  
        a_sj.loc[fil,col]=a  
        b_sj.loc[fil,col]=b
```

```
si = 1  
while(si):
```

```
    c_sj=pd.DataFrame()  
    d_sj=pd.DataFrame()  
    e_sj=pd.DataFrame()  
    f_sj = pd.DataFrame()
```

```
    regr = input('Tipo de regresión (1/2/3): ')
```

```
    if regr == 0:  
        si = 0
```

```
    else:
```

```
        for col in range(len(s)):  
            for fil in range(len(ys_js[col].columns)):  
                y=list(ys_js[col].iloc[:,fil])  
                if regr=='1':  
                    x_aux = {  
                        'x' : [w for w in range(1,1+len(y))],  
                    }  
                    x = pd.DataFrame(x_aux)  
                    (c,d) = mincua(x,y)  
                    c_sj.loc[fil,col] = c  
                    d_sj.loc[fil,col] = d  
                if regr == '2':  
                    x_aux = {  
                        'x' : [w for w in range(1,1+len(y))],  
                        'x2': [w**2 for w in range(1,1+len(y))]  
                    }  
                    x = pd.DataFrame(x_aux)  
                    (c, d, e) = mincua(x, y)  
                    c_sj.loc[fil, col] = c  
                    d_sj.loc[fil, col] = d  
                    e_sj.loc[fil, col] = e
```

```

        if regr == '3':
            x_aux = {
                'x': [w for w in range(1,1+len(y))],
                'x2': [w**2 for w in range(1,1+len(y))],
                'x3': [w**3 for w in range(1,1+len(y))]
            }
            x = pd.DataFrame(x_aux)
            (c, d, e, f) = mincua(x, y)
            c_sj.loc[fil, col] = c
            d_sj.loc[fil, col] = d
            e_sj.loc[fil, col] = e
            f_sj.loc[fil, col] = f

    if regr == '1':
        fluct = fluctuaciones(ys_js, d_sj, c_sj)
    if regr == '2':
        fluct = fluctuaciones_dos(ys_js, d_sj, e_sj, c_sj)
    if regr == '3':
        fluct = fluctuaciones_tres(ys_js, d_sj, e_sj, f_sj, c_sj)

    q_inicial = input('Desdse qué q? ')
    q_final = input('Hasta qué q? ')
    q_intervalo = input('Intervalos de cuánto? ')

    m_fluct = []
    q_fin = []
    for i in range(2):
        mf_aux, q_aux = media_fluct(fluct, b_sj, i, q_inicial,
q_final, q_intervalo)
        m_fluct.append(mf_aux)
        q_fin.append(q_aux)
    print(f'q fin es {q_fin}')
    s_df = pd.DataFrame(s)

    log_s = np.log10(s_df)

    log_mfluct=[]
    for i in range(len(m_fluct)):
        log_mfluct.append(np.log10(m_fluct[i]))

    nombre_p = '../TFG_ADE_Calculos_' + version + '_r' + regr +
'.xlsx'
    with pd.ExcelWriter(nombre_p) as writer:
        for signo in range(2):
            m_fluct[signo].to_excel(writer, sheet_name=str(signo),
index=False)
            log_mfluct[signo].to_excel(writer, sheet_name='log' +
str(signo), index=False)

    nombre_s = '../TFG_ADE_Calculos_' + version + '_s' + '.xlsx'
    print(s_df)
    with pd.ExcelWriter(nombre_s) as writer:
        s_df.to_excel(writer, sheet_name = 's', index=False)
        log_s.to_excel(writer, sheet_name = 'log_s', index=False)

    cu = pd.DataFrame(q_fin[0])
    coef_h = []
    for i in range(len(log_mfluct)):
        aux_h = pd.DataFrame()
        for j in range(len(log_mfluct[i].columns)):
            (n,h) = mincua(log_s, log_mfluct[i].iloc[:,j])

```

```

        aux_h.loc[j, 'h'] = h
        aux_h.loc[j, 'q'] = q_fin[i][j]
    coef_h.append(aux_h)

    nombre_h = '../TFG_ADE_Calculos_H_' + version + '_r' + regr
+'.xlsx'
    with pd.ExcelWriter(nombre_h) as writer:
        for i in range(len(coef_h)):
            coef_h[i].to_excel(writer, sheet_name = str(i),
index=False)

```

Alpha.py

```

import pandas as pd
import numpy as np

version= input('Qué número de hoja quieres usar? (1-versión corta, 2-
todo) ')
regr = input('Qué regresión quieres?')

ruta = '../TFG_ADE_Calculos_H_' + version + '_r' + regr + '.xlsx'

h=[]

for i in range(2):
    aux = pd.read_excel(ruta, sheet_name=str(i))
    h.append(aux)

for i in range(2):
    h[i]['renyi']=h[i]['q']*h[i]['h']-1
    h[i] = h[i].sort_values('q')
    cu = h[i]['q'].values
    tau = h[i]['renyi'].values
    alfa = np.gradient(tau, cu)
    h[i]['alfa'] = alfa
    h[i]['espectro'] = h[i]['q']*h[i]['alfa']-h[i]['renyi']

ruta2 = '../TFG_ADE_Calculos_Hdef_' + version + '_r' + regr + '.xlsx'

with pd.ExcelWriter(ruta2) as writer:
    for i in range(2):
        h[i].to_excel(writer, sheet_name=str(i), index=False)

```