



Facultad de Ciencias Económicas y Empresariales (ICADE)

# **ANÁLISIS DE LA EFICIENCIA DE MERCADO DEL ÍNDICE STOXX GLOBAL AI ANTES Y DESPUÉS DE CHATGPT MEDIANTE MF-DFA, CON ENFOQUE EN SEMICONDUCTORES**

Autor: Alejandro Portellano Rodríguez  
Director: Alejandro Rodríguez Gallego

## RESUMEN

Este Trabajo de Fin de Grado analiza el impacto del lanzamiento de ChatGPT sobre la eficiencia del mercado en el índice STOXX Global AI, con un enfoque particular en las empresas del sector de semiconductores. El objetivo es evaluar si este evento disruptivo ha alterado la estructura estadística de los precios financieros, utilizando el Análisis de Fluctuaciones Detrendadas Multifractales (MF-DFA) como herramienta principal. Esta metodología permite detectar multifractalidad, memoria de largo plazo y comportamientos no aleatorios en series temporales financieras.

La muestra abarca datos diarios entre 2018 y 2024. Se analizan tanto el índice agregado como las trayectorias individuales de sus componentes. Se aplican transformaciones logarítmicas, ventanas móviles y contrastes estadísticos mediante bootstrap. Además, se utiliza el exponente de Hurst en su versión rolling para detectar cambios dinámicos en la eficiencia temporal antes y después del evento ChatGPT.

Los resultados muestran una clara presencia de multifractalidad y un aumento sostenido del exponente de Hurst tras la aparición de ChatGPT, lo que indica una mayor eficiencia de mercado y una alineación más fuerte en las expectativas de los inversores. Las empresas líderes como NVIDIA e Intel exhiben patrones de persistencia más estables, mientras que otras muestran comportamientos más erráticos o especulativos.

Desde una perspectiva económica, los hallazgos sugieren que la eficiencia en los mercados tecnológicos es dinámica y sensible a disrupciones informativas. La inteligencia artificial actúa como una narrativa colectiva capaz de modificar el comportamiento de precios y generar nuevas fases de eficiencia temporal.

Este trabajo contribuye al debate sobre la validez de la Hipótesis de Mercado Eficiente en contextos altamente tecnológicos, proponiendo el MF-DFA como una herramienta robusta para capturar la complejidad real del comportamiento financiero.

Palabras clave: inteligencia artificial, multifractalidad, eficiencia de mercado, ChatGPT, exponente de Hurst, MF-DFA, semiconductores, rolling hurst, STOXX Global AI

## ***ABSTRACT***

*This thesis analyzes the impact of ChatGPT's launch on market efficiency within the STOXX Global AI index, with a specific focus on semiconductor firms. The objective is to determine whether this disruptive event altered the statistical structure of financial prices by applying the Multifractal Detrended Fluctuation Analysis (MF-DFA) methodology. This technique identifies multifractality, long-term memory, and non-random behaviors in financial time series.*

*The dataset includes daily observations from 2018 to 2024, covering both the aggregate index and the individual performance of its components. Logarithmic returns are computed, and rolling windows and bootstrap tests are used to assess structural changes. Additionally, the rolling Hurst exponent is employed to compare dynamic patterns in efficiency before and after ChatGPT's emergence.*

*The results reveal clear evidence of multifractality, as well as a sustained increase in the Hurst exponent following the introduction of ChatGPT. This suggests a shift toward greater market efficiency and stronger alignment in investor expectations. Leading firms such as NVIDIA and Intel display more stable persistence, while others exhibit erratic or speculative behavior.*

*From an economic perspective, the findings indicate that efficiency in technology markets is not static but evolves in response to informational shocks. Artificial intelligence has emerged as a collective narrative that influences pricing behavior and generates new cycles of temporal efficiency.*

*This research contributes to the debate on the validity of the Efficient Market Hypothesis (EMH) in highly technological environments. It positions MF-DFA as a robust tool for capturing the real complexity of financial market behavior in the face of accelerating innovation and automation.*

*Keywords: artificial intelligence, multifractality, market efficiency, ChatGPT, Hurst exponent, MF-DFA, semiconductors, rolling Hurst, STOXX Global AI*

## ÍNDICE DE CONTENIDOS

|  |           |
|--|-----------|
| RESUMEN.....   | 1         |
| <i>ABSTRACT</i> .....  | 2         |
| ÍNDICE DE CONTENIDOS .....   | 3         |
| 1. INTRODUCCIÓN .....  | 5         |
| <b>1.1. Descripción general e importancia de la IA</b> .....                           | <b>5</b>  |
| <b>1.2. Objetivos del trabajo</b> .....  | <b>6</b>  |
| <b>1.3. Datos y metodología utilizada</b> .....  | <b>7</b>  |
| 2. MARCO TEÓRICO.....  | 9         |
| <b>2.1. Inteligencia Artificial</b> .....  | <b>9</b>  |
| 2.1.1. Semiconductores e IA .....  | 9         |
| 2.1.2. Aplicaciones actuales y futuras .....   | 10        |
| 2.1.3. Índice STOXX Global AI.....   | 12        |
| 2.1.4. ¿Existen cambios en las empresas de IA después del lanzamiento de ChatGPT?..... | 13        |
| <b>2.2. Hipótesis de mercado eficiente (Efficient Market Hypothesis (EMH))</b> .....   | <b>14</b> |
| 2.2.1. Introducción .....  | 14        |
| 2.2.2. Las tres formas de EMH .....  | 15        |
| 2.2.3. EMH y MF-DFA .....  | 17        |
| <b>2.3. Antecedentes teóricos del MF-DFA</b> .....                                     | <b>18</b> |
| 2.3.1. Introducción .....  | 18        |
| 2.3.2. Python Notebook.....  | 21        |
| 3. OBJETIVOS .....   | 23        |
| <b>3.1. Generales</b> .....  | <b>23</b> |
| <b>3.2. Específicos</b> .....  | <b>23</b> |
| 4. METODOLOGÍA .....   | 25        |
| <b>4.1. Datos</b> .....  | <b>25</b> |
| <b>4.2. Empleo de MF-DFA</b> .....   | <b>26</b> |
| 4.2.1. Construcción de la serie acumulada.....   | 26        |
| 4.2.2. Segmentación de la serie.....   | 27        |
| 4.2.3. Detrending en cada segmento .....   | 27        |

|  |           |
|--|-----------|
| 4.2.4. Fluctuaciones generalizadas.....  | 27        |
| 4.2.5. Relación de escala para estimar el exponente $h(q)$ .....   | 27        |
| 4.2.6. Interpretación del exponente $h(2)$ :.....  | 27        |
| 4.2.6. Contraste estadístico mediante bootstrap:.....  | 28        |
| 5. RESULTADOS .....  | 30        |
| <b>5.1. Presentación de resultados del Índice STOXX Global AI .....</b>  | <b>30</b> |
| <b>5.2. Empresas semiconductoras del STOXX Global AI.....</b>  | <b>40</b> |
| 5.2.1. Posición en la industria .....  | 40        |
| 5.2.2. Análisis de eficiencia individual: Rolling Hurst por empresa.....   | 44        |
| 6. CONCLUSIONES .....  | 47        |
| 7. DECLARACIÓN DE USO DE HERRAMIENTAS DE INTELIGENCIA .....  | 49        |
| ARTIFICIAL GENERATIVA EN TRABAJOS FIN DE GRADO.....  | 49        |
| 8. BIBLIOGRAFÍA .....  | 51        |
| 9. ANEXO I: Composición del índice STOXX Global AI: empresas constituyentes, país, sector y peso relativo (2024) ..... | 54        |
| 10. ANEXO II: Métricas MF-DFA año por año.....   | 55        |
| 11. ANEXO III: Código Python MF-DFA STOXX Global AI .....  | 58        |
| 12. ANEXO III: Código Python Rolling Hurst 46 componentes.....   | 68        |

# 1. INTRODUCCIÓN

## 1.1. Descripción general e importancia de la IA

En las últimas décadas, hemos sido testigos de un rápido y significativo avance en el campo de la inteligencia artificial (IA) y la industria de semiconductores, impulsados por eventos disruptivos como el lanzamiento de ChatGPT en 2022. Este hito marcó un punto de inflexión al popularizar el uso de modelos de lenguaje avanzados (Large Language Models, LLMs<sup>1</sup>) y acelerar la adopción de tecnologías basadas en IA. El impacto ha sido notable tanto en la dinámica de mercado como en el comportamiento de las empresas tecnológicas, con implicaciones económicas y sociales relevantes.

La aceleración en la adopción de herramientas de IA generativa ha amplificado el alcance de esta tecnología, integrándola en procesos industriales, administrativos y financieros. En particular, la demanda de semiconductores <sup>2</sup> especializados se incrementó significativamente, sobre todo en sectores como los centros de datos y la computación de alto rendimiento, esenciales para soportar la infraestructura de los modelos de IA.

Este progreso ha llevado a un aumento sustancial en la inversión en I+D por parte de empresas líderes como NVIDIA y AMD, que han experimentado notables incrementos en su capitalización de mercado. Paralelamente, gobiernos como los de Estados Unidos y China han reforzado su apoyo mediante subsidios y políticas<sup>3</sup> orientadas a la autosuficiencia tecnológica.

La IA ha emergido como una de las tecnologías más disruptivas del siglo XXI, con el potencial de transformar la estructura de los mercados financieros. Desde sus orígenes en los años 50 hasta los actuales sistemas de Deep Learning<sup>4</sup>, la convergencia entre capacidad computacional, datos masivos y avances algorítmicos ha sido constante. Esta convergencia ha posibilitado el desarrollo de modelos cada vez más precisos y autónomos. Este cambio de paradigma plantea interrogantes sobre la validez de principios tradicionales, como la hipótesis de eficiencia de mercado, en un entorno cada vez más automatizado.

En este contexto, el presente estudio analiza el impacto del lanzamiento de ChatGPT sobre las dinámicas de mercado de las empresas de IA representadas en el índice STOXX Global

---

<sup>1</sup> Modelos de IA entrenados con grandes volúmenes de texto para generar y comprender lenguaje humano.

<sup>2</sup> Componentes electrónicos fundamentales que controlan el flujo de corriente en dispositivos como chips y procesadores.

<sup>3</sup> Iniciativas como el CHIPS Act en EE. UU. y la European Chips Act en Europa buscan impulsar la producción local de semiconductores y reducir la dependencia externa.

<sup>4</sup> Técnica de aprendizaje automático basada en redes neuronales profundas que permite a los sistemas aprender patrones complejos a partir de grandes volúmenes de datos.

AI. El objetivo es evaluar si dicho evento ha alterado significativamente la eficiencia del mercado, identificando patrones en los retornos y comportamientos dinámicos de los activos. Este índice, que agrupa compañías líderes tanto en el desarrollo de soluciones de IA como en infraestructura (semiconductores, servicios cloud), constituye un laboratorio empírico idóneo. Permite examinar cómo un avance tecnológico puede influir en las propiedades estadísticas del mercado.

Los resultados preliminares sugieren que el mercado presenta características multifractales, con señales de una mayor eficiencia tras el lanzamiento de ChatGPT, lo que indicaría una evolución significativa en la dinámica del sector.

## **1.2. Objetivos del trabajo**

Este Trabajo de Fin de Grado tiene como propósito analizar si el lanzamiento de ChatGPT ha generado un cambio estructural en la eficiencia de mercado. El análisis se centra en las empresas tecnológicas incluidas en el índice STOXX Global AI. Dado el carácter transversal de la inteligencia artificial y su creciente protagonismo en la narrativa tecnológica, se plantea que su impacto podría haberse extendido más allá del ámbito técnico. En particular, podría haber alcanzado también las propiedades estadísticas de los precios financieros.

Desde una perspectiva cuantitativa, se utilizará el método de Análisis de Fluctuaciones Detrendadas Multifractales (MF-DFA) para examinar la evolución de la eficiencia del mercado antes y después del evento. Se prestará especial atención al comportamiento de empresas del sector de semiconductores. El estudio buscará detectar patrones de persistencia, anti-persistencia o eficiencia temporal a través del análisis de retornos, el exponente de Hurst y otras métricas multifractales.

El objetivo general es, por tanto, evaluar si el auge de la IA generativa ha modificado la dinámica interna de los mercados financieros. Para ello, se integrará un enfoque que combina herramientas de econofísica (economía y física) con una interpretación económica centrada en el comportamiento de los inversores ante eventos tecnológicos disruptivos.

Los objetivos específicos de esta investigación se detallan en la sección 3, donde se presentan de forma desglosada y alineada con el análisis desarrollado en las secciones de resultados.

### 1.3. Datos y metodología utilizada

Para evaluar la eficiencia del mercado en el contexto de la IA, este estudio utiliza datos proporcionados por STOXX y FactSet relacionados con el índice STOXX Global AI. La base empírica está compuesta por datos diarios ajustados de precios, volumen y rentabilidad de las principales empresas del índice. Estas han sido seleccionadas por su relevancia en el desarrollo, aplicación o provisión de tecnología basada en IA. El análisis del índice STOXX Global AI cubre el periodo desde 2018 hasta finales de 2024. Este rango amplio permite observar cambios estructurales en la eficiencia del mercado antes y después del lanzamiento de ChatGPT. Por su parte, el análisis individual de los componentes del índice, centrado en empresas del sector de semiconductores, abarca desde 2018 hasta mediados de septiembre de 2024. Esta doble perspectiva permite comparar el comportamiento multifractal a nivel agregado e individual. Se aplica el método MF-DFA con ventanas móviles de un año bursátil para detectar posibles cambios en la eficiencia del mercado.

El conjunto de datos incluye:

- Precios de cierre ajustados por dividendos y splits.
- Volumen diario negociado.
- Datos agregados del índice STOXX Global AI como benchmark.
- Clasificación de las empresas según subsectores (semiconductores, software, servicios en la nube, etc.).

La metodología se basa en el uso del MF-DFA, una técnica estadística avanzada desarrollada inicialmente en campos como la física y la biomedicina, y recientemente aplicada al análisis de series temporales financieras. Esta herramienta permite identificar autosimilitud y estructuras multifractales en distintas escalas temporales, proporcionando información sobre la presencia de correlaciones, persistencia y complejidad dinámica en los precios<sup>5</sup>.

Para ello, se calculan los rendimientos logarítmicos, que sirven como entrada del algoritmo MF-DFA. El método permite estimar el exponente de Hurst generalizado,  $h(q)$ , que describe la relación entre la escala de análisis y la magnitud de las fluctuaciones para diferentes momentos estadísticos. Valores de  $h(2)$  distintos a 0.5 indican desviaciones respecto a un

---

<sup>5</sup> Indican que los patrones en los precios se repiten a diferentes escalas y reflejan dinámicas complejas con correlaciones y comportamientos no aleatorios.

Random Walk<sup>6</sup>, revelando la existencia de persistencia ( $h(2) > 0.5$ ) o anti-persistencia ( $h(2) < 0.5$ ), y, por tanto, señales de ineficiencia o memoria de largo plazo en los datos.

Además, se incorpora un contraste estadístico mediante técnicas de bootstrap<sup>7</sup> para evaluar la significancia de las diferencias entre periodos. Esto refuerza la validez empírica de los resultados, evitando que las conclusiones estén sesgadas por fluctuaciones aleatorias del mercado.

Aunque existe una creciente literatura sobre la aplicación del MF-DFA a series financieras (como la de Aslam, Ferreira y Mohti sobre mercados bursátiles durante el COVID-19) hay una notable ausencia de investigaciones centradas en mercados financieros relacionados con IA. Esta falta de estudios es particularmente evidente en activos vinculados al sector de semiconductores. Este trabajo busca contribuir a llenar ese vacío, integrando un enfoque cuantitativo riguroso con una interpretación económica relevante sobre el impacto de la IA en la dinámica de los mercados financieros.

---

<sup>6</sup> Modelo en el que los precios se mueven de forma aleatoria e impredecible, sin depender de valores pasados.

<sup>7</sup> Método que consiste en repetir muestras aleatorias para comprobar si un resultado es estadísticamente sólido.

## 2. MARCO TEÓRICO

### 2.1. Inteligencia Artificial

#### 2.1.1. Semiconductores e IA

La relación entre la IA y la industria de los semiconductores es uno de los vínculos tecnológicos más importantes del siglo XXI. No se trata de una coincidencia, sino de una necesidad estructural: los modelos de IA requieren una enorme capacidad de procesamiento, que solo pueden ofrecer chips cada vez más avanzados. Al mismo tiempo, el auge de la IA está cambiando las reglas del juego para los fabricantes de semiconductores, convirtiéndolos en piezas clave del ecosistema digital actual.

El desarrollo y entrenamiento de modelos avanzados de IA, como los grandes modelos de lenguaje (LLMs), exigen arquitecturas computacionales con un rendimiento excepcional. Las unidades de procesamiento gráfico (GPU)<sup>8</sup>, las unidades tensoriales (TPU)<sup>9</sup> y otras soluciones especializadas se han convertido en la infraestructura base sobre la que se ejecutan estos modelos. Según Reiter y Kim (2025), este fenómeno ha otorgado una ventaja competitiva determinante a compañías como Nvidia. Estas han experimentado revalorizaciones bursátiles extraordinarias no solo por su producto actual, sino por su posición como habilitadores tecnológicos clave en la revolución de la IA. El llamado "*halo de la IA*" ha contaminado positivamente a toda la industria, generando expectativas de crecimiento también en empresas auxiliares del sector.

Este efecto de arrastre se refleja incluso en métricas como el ratio precio-beneficio (P/E) del S&P 500, que ha mantenido niveles elevados excluyendo a las conocidas "Magnificent 7"<sup>10</sup>. Esto sugiere que la narrativa de transformación tecnológica asociada a la IA ha permeado más allá del núcleo de grandes tecnológicas (Reiter & Kim, 2025). En otras palabras, la valorización de los fabricantes de chips no responde únicamente a resultados financieros inmediatos, sino a su papel anticipado en un ciclo expansivo de productividad inducido por IA.

Desde una perspectiva más académica, Kotecha (2025) profundiza en la idea de que la IA no puede implementarse sin una base sólida de infraestructura tecnológica, en la cual los semiconductores desempeñan un rol central. Los algoritmos de Deep Learning, los sistemas de

---

<sup>8</sup> Chips diseñados para realizar cálculos en paralelo, ideales para entrenar modelos de inteligencia artificial.

<sup>9</sup> Procesadores creados por Google, optimizados para acelerar el entrenamiento de modelos de inteligencia artificial.

<sup>10</sup> Conjunto de siete grandes empresas tecnológicas estadounidenses: Apple, Microsoft, Alphabet, Amazon, Meta, Nvidia y Tesla.

predicción en tiempo real y los modelos de análisis de sentimientos son cruciales para la toma de decisiones en mercados financieros. Todos ellos requieren una capacidad de cómputo intensiva y en expansión constante. Este requerimiento ha consolidado la importancia estratégica de los semiconductores en sectores como la gestión de inversiones, la banca algorítmica y la supervisión financiera automatizada.

Asimismo, la interdependencia entre IA y semiconductores está provocando un rediseño en las cadenas globales de valor. Las inversiones en nuevas fábricas de chips (fabs), la relocalización de procesos productivos críticos y la presión geopolítica por asegurar el suministro de componentes tecnológicos clave son indicadores de cómo la IA está modificando no solo los modelos de negocio, sino también las estrategias industriales de largo plazo. En este sentido, los semiconductores no son simplemente una "commodity"<sup>11</sup> tecnológica, sino un recurso estructural cuya importancia se amplifica en la medida en que la IA se convierte en una General Purpose Technology (GPT)<sup>12</sup> (Kotecha, 2025).

En conclusión, la industria de los semiconductores no solo suministra el hardware que hace posible la IA, sino que evoluciona junto a ella. A medida que la IA impulsa la productividad, la eficiencia y la automatización, los fabricantes de chips ganan protagonismo en la economía global. Esta relación mutua está redefiniendo el valor estratégico del sector y exige una atención especial por parte de analistas, reguladores e inversores.

### **2.1.2. Aplicaciones actuales y futuras**

Las aplicaciones de la IA en el ámbito financiero están creciendo a un ritmo exponencial, tanto en sofisticación técnica como en alcance funcional. En la actualidad, la IA ya está transformando la forma en que las empresas analizan información, automatizan decisiones y gestionan riesgos. Sin embargo, su impacto no se limita a optimizar lo existente, sino que apunta a redefinir completamente los procesos de negocio. Esta sección explora las aplicaciones prácticas más destacadas, los desafíos organizativos para su adopción y las proyecciones a futuro en el uso de estas tecnologías.

Uno de los usos más extendidos de la IA en los mercados es el trading algorítmico, que representa aproximadamente el 70 % del volumen de operaciones bursátiles en EE. UU. (Wu,

---

<sup>11</sup> Bien genérico e intercambiable cuyo valor depende más del mercado que de sus características individuales.

<sup>12</sup> Tecnología con múltiples usos que transforma sectores enteros y genera amplios impactos económicos, como ocurrió con la electricidad o internet.

2024). A través de algoritmos que analizan millones de datos en tiempo real, las instituciones financieras pueden ejecutar operaciones con una velocidad, precisión y eficiencia imposibles de replicar por operadores humanos. Entre las técnicas más utilizadas se encuentran las redes neuronales para identificar patrones de precios y las herramientas de procesamiento de lenguaje natural (NLP) para interpretar noticias y redes sociales. Esto permite anticipar el sentimiento del mercado y ajustar estrategias en consecuencia.

Más allá del ámbito puramente técnico, la IA también está teniendo un impacto directo en la experiencia laboral y en la cultura organizativa. Según Conboye (2025), aunque muchas empresas ya han incorporado herramientas de IA generativa como ChatGPT para aumentar la productividad, los empleados no siempre perciben claramente sus beneficios. En parte, esto se debe a una falta de formación y comunicación efectiva por parte de las organizaciones. De hecho, estudios recientes muestran que, aunque el 48 % de los trabajadores utilizan IA a diario, solo una cuarta parte ha recibido formación específica para hacerlo. Este desajuste reduce el potencial transformador de la IA en los entornos laborales.

Sin embargo, cuando se implementa correctamente, la IA puede liberar tiempo para tareas de mayor valor añadido, como el análisis estratégico, la creatividad o la interacción humana. También puede mejorar la precisión en la toma de decisiones y reducir la exposición al riesgo mediante sistemas predictivos robustos. Plataformas como Kensho o AlphaSense, ya utilizadas por fondos de inversión y agencias gubernamentales, integran modelos de análisis en tiempo real y análisis de sentimientos para detectar eventos relevantes de forma automática. Esto genera una ventaja competitiva clara para quienes las adoptan de forma temprana.

En este contexto, Wu (2024) destaca que las limitaciones actuales de la IA no están tanto en la capacidad tecnológica como en los aspectos organizativos, regulatorios y éticos. Persisten desafíos como el sesgo algorítmico, la opacidad de ciertos modelos y la incapacidad para prever eventos inesperados. No obstante, su potencial para mejorar la eficiencia operativa, democratizar el acceso a la información y transformar la función analítica dentro de las organizaciones es incuestionable.

En resumen, la IA no solo está redefiniendo cómo se trabaja en el sector financiero, sino también quién puede participar en él y bajo qué condiciones. Las aplicaciones actuales ya mejoran la velocidad, la precisión y la profundidad del análisis financiero, mientras que las futuras podrían dar lugar a modelos de gestión del conocimiento completamente nuevos. Su correcta integración será clave para que su impacto sea verdaderamente transformador.

### 2.1.3. Índice STOXX Global AI

El índice STOXX Global Artificial Intelligence se ha consolidado como una herramienta de referencia para capturar el desempeño de un universo empresarial fuertemente expuesto al desarrollo y aplicación de IA. A diferencia de los índices tradicionales que agrupan empresas por sector o región, este índice lo hace por su nivel de implicación en tecnologías de IA. Incluye desde desarrolladores de algoritmos hasta fabricantes de semiconductores y empresas que integran soluciones de IA en sus procesos operativos. Su construcción refleja la naturaleza transversal de la IA como tecnología de propósito general (GPT), capaz de impactar múltiples industrias de forma simultánea.

El auge de la IA generativa a partir del lanzamiento de ChatGPT en noviembre de 2022 ha amplificado significativamente el interés inversor en este tipo de índices temáticos. Como destaca Dodd (2023), la rápida valorización de acciones vinculadas a IA en China y Estados Unidos generó incluso alertas de sobrevaloración por parte de medios oficiales. Esto ocurrió en un contexto donde empresas como Microsoft realizaron inversiones multimillonarias en OpenAI<sup>13</sup>. El STOXX Global AI se benefició directamente de esta euforia, actuando como vehículo de exposición rápida y diversificada a este nuevo paradigma tecnológico.

No obstante, el creciente atractivo de estos índices no está exento de desafíos. Uno de ellos es la heterogeneidad de sus componentes, lo que genera una dispersión significativa en la forma en que las distintas empresas capitalizan el impulso de la IA. Algunas compañías generan ingresos directamente del desarrollo de modelos de lenguaje o herramientas analíticas, mientras que otras solo las utilizan como soporte para sus operaciones internas. Esta diversidad, aunque atractiva desde un enfoque de diversificación, complica la interpretación económica de los rendimientos agregados.

Desde el ámbito académico, Al-Harbi (2025) señala que este tipo de índices permiten analizar cómo interactúan las nuevas tecnologías con el funcionamiento de los mercados. Su estudio muestra que el uso creciente de algoritmos en las decisiones financieras puede hacer que la información se refleje más rápido en los precios. Sin embargo, también puede generar riesgos importantes, sobre todo cuando muchas estrategias se comportan de forma similar. En este contexto, índices como el STOXX Global AI sirven como escenarios reales para observar cómo cambian las expectativas y los precios frente a avances tecnológicos.

---

<sup>13</sup> Empresa líder en investigación y desarrollo de inteligencia artificial, creadora de modelos como ChatGPT.

#### **2.1.4. ¿Existen cambios en las empresas de IA después del lanzamiento de ChatGPT?**

La aparición pública de ChatGPT en noviembre de 2022 no solo marcó un punto de inflexión en el desarrollo de la IA, sino que alteró profundamente la percepción social, política y financiera sobre esta tecnología. Desde su lanzamiento, múltiples indicadores financieros y académicos han evidenciado cambios sustanciales en los patrones de inversión, productividad y comportamiento laboral vinculados a la adopción de IA generativa. Esta sección examina las transformaciones observadas tras el surgimiento de ChatGPT, poniendo especial énfasis en los efectos económicos, bursátiles y organizativos.

Según Strauss (2023), la IA generativa podría automatizar hasta una cuarta parte de todas las tareas laborales en economías avanzadas como Estados Unidos y Europa. Este cambio afectaría potencialmente a más de 300 millones de empleos a tiempo completo. Esta estimación, derivada de un análisis de Goldman Sachs, destaca el impacto sistémico que herramientas como ChatGPT pueden tener en sectores de alto contenido cognitivo, como el jurídico, el administrativo o el financiero. Además del riesgo de sustitución de ciertas tareas, esta disrupción tecnológica podría también desencadenar un nuevo ciclo de crecimiento de la productividad. Las estimaciones proyectan un aumento del 7 % en el PIB global durante la próxima década si se materializa todo el potencial de la IA generativa.

En el ámbito financiero, el lanzamiento de ChatGPT ha actuado como un catalizador de inversión y revalorización bursátil. Como señala Kotecha (2025), el creciente uso de modelos de lenguaje como base para análisis de sentimiento, algoritmos de predicción y plataformas de asesoramiento automático ha intensificado la adopción de herramientas de IA. Este fenómeno se ha visto especialmente reflejado en el sector financiero. Estas tecnologías, al ofrecer ventajas competitivas basadas en la velocidad, profundidad y adaptabilidad del análisis, están modificando la estructura del mercado y el perfil de los actores dominantes. A raíz de esto, se han documentado cambios tanto en la volatilidad como en los patrones de correlación entre activos, lo cual sugiere una transición hacia mercados más sensibles a señales algorítmicas y eventos tecnológicos.

Un segundo impacto relevante se manifiesta en la accesibilidad a herramientas financieras avanzadas. Plataformas como ChatGPT, por su facilidad de uso e integración en servicios digitales, han democratizado el acceso a funciones analíticas que anteriormente requerían experiencia técnica o asesoramiento profesional. Esto plantea oportunidades de inclusión financiera, pero también riesgos relacionados con el uso irresponsable de modelos de

IA. Como advierte Kotecha (2025), la interpretación errónea de predicciones generadas por IA o la sobreconfianza en modelos opacos pueden comprometer la calidad de las decisiones de inversión.

## 2.2. Hipótesis de mercado eficiente (Efficient Market Hypothesis (EMH))

### 2.2.1. Introducción

El esfuerzo por cuantificar el impacto de eventos disruptivos ha sido una constante en disciplinas como la economía, las finanzas, la tecnología y las ciencias sociales. En el ámbito financiero y tecnológico, este interés se ha concentrado recientemente en analizar cómo eventos como el lanzamiento de ChatGPT afectan a sectores clave como la IA y los semiconductores.

Una de las metodologías más utilizadas para este fin es el estudio de eventos, basado en la EMH. Esta sostiene que los precios de los activos reflejan toda la información disponible en cada momento (Fama, 1970), lo que implica que cualquier cambio en los precios debe corresponder a la incorporación de nueva información relevante. En un mercado eficiente, dicha incorporación ocurre de manera casi inmediata (Fama, 1965; Grossman & Stiglitz, 1976).

Esta visión ha sido respaldada por estudios como el de Jensen (1968), que demuestran que, incluso ajustando por riesgo, los fondos activos no logran superar sistemáticamente a los índices de referencia. Así, el análisis del impacto de ChatGPT permite poner a prueba la EMH en un contexto donde las tecnologías emergentes podrían alterar las dinámicas tradicionales del mercado.

Según Investopedia (2024), la EMH se clasifica en tres formas:

- **Débil:** toda la información histórica de precios está reflejada en los precios actuales, invalidando el análisis técnico.
- **Semi-fuerte:** toda la información pública está incorporada, por lo que el análisis fundamental tampoco generaría ventajas.
- **Fuerte:** incluso la información privada estaría ya descontada, eliminando cualquier fuente de ventaja sostenida.

No obstante, la EMH ha sido objeto de críticas. Como señaló Fama en una entrevista reciente con el Financial Times, “la eficiencia del mercado es una hipótesis, no una realidad” (Wigglesworth, 2024). Esta afirmación pone de relieve la distancia entre el ideal teórico de los mercados eficientes y los comportamientos observados: burbujas, anomalías y reacciones

irracionalidad de los inversores. Aun así, Fama defiende su utilidad como marco práctico, destacando que para la mayoría de los participantes del mercado, asumir precios justos es más sensato que tratar de superarlos.

La influencia de la EMH ha sido profunda. Ha respaldado la proliferación de la inversión pasiva, el desarrollo del CAPM y la Teoría de Carteras Moderna. Sin embargo, la economía del comportamiento ha puesto en entredicho su vigencia al cuestionar la racionalidad de los agentes y la eficiencia informativa.

En este nuevo escenario, dominado por la proliferación de algoritmos y tecnologías como la IA, se vuelve crucial reevaluar el papel explicativo y normativo de la EMH. Estas herramientas, capaces de procesar grandes volúmenes de datos y detectar patrones invisibles para el ser humano, podrían estar redefiniendo el equilibrio entre eficiencia e ineficiencia. Esto plantea nuevos retos teóricos y empíricos para las finanzas modernas.

### 2.2.2. Las tres formas de EMH

La Hipótesis de Mercado Eficiente (EMH), propuesta formalmente por Eugene Fama (1970), sostiene que los precios de los activos financieros reflejan en todo momento la información disponible. Para hacer operativa esta teoría, Fama definió tres niveles de eficiencia informacional: débil, semi-fuerte y fuerte, cada uno representando un grado creciente de incorporación de información en los precios.

#### Formas de la Hipótesis de Mercado Eficiente

- **Eficiencia débil (weak form efficiency):** Establece que toda la información contenida en los precios históricos está ya incorporada en los precios actuales. Por tanto, el uso de análisis técnico no permite generar retornos anormales ajustados por riesgo. Fama (1970) incluía originalmente precios pasados, pero más adelante amplió esta categoría a variables como el volumen negociado, bid-ask spreads, dividendos o tasas de interés. También incorporó anomalías conocidas como el efecto enero o el efecto tamaño (Fama, 1991)<sup>14</sup>. Según Investopedia (2024), esta forma implica que los precios siguen un Random Walk,

---

<sup>14</sup> Comportamientos de mercado repetitivos, como el aumento de precios en enero (efecto enero) o mayores rendimientos en empresas pequeñas frente a grandes (efecto tamaño), que contradicen la eficiencia total del mercado.

donde cualquier patrón aparente carece de valor predictivo estadísticamente significativo.

- **Eficiencia semifuerte (semi-strong form efficiency):** Sostiene que los precios reflejan toda la información pública disponible, incluyendo estados financieros, anuncios macroeconómicos y noticias corporativas. Bajo esta forma, el análisis fundamental no permite obtener beneficios extraordinarios, dado que el mercado reacciona rápida y racionalmente a cualquier nueva información.
- **Eficiencia fuerte (strong form efficiency):** Propone que los precios de los activos incorporan toda la información disponible, tanto pública como privada. En este escenario, ni siquiera los insiders<sup>15</sup> podrían obtener retornos ajustados por riesgo superiores al del mercado. Aunque Fama (1970) reconoció que esta forma extrema no es realista en contextos reales, sí puede servir como referencia teórica para evaluar el grado máximo de eficiencia.

Estas tres formas siguen un orden y se acumulan entre sí: si un mercado es eficiente en su forma fuerte, también lo será en las formas semifuerte y débil. Sin embargo, los estudios empíricos ponen en duda que esto se cumpla siempre en la práctica.

El gestor de fondos Cliff Asness (2024), exalumno de Fama, reconoce la solidez conceptual de estas categorías, pero advierte que los mercados rara vez operan bajo eficiencia plena. Según él, "el mercado ha llegado a ser algo menos eficiente durante mi carrera", en referencia a anomalías persistentes como la dispersión en múltiplos de valoración entre acciones baratas y caras. Estas distorsiones deberían desaparecer en mercados totalmente eficientes, lo que sugiere que la EMH requiere matices en su aplicación práctica.

Además, estudios recientes como el de Ali et al. (2023) han utilizado MF-DFA para evaluar la eficiencia de los mercados europeos. Lo han hecho comparando períodos anteriores y posteriores a eventos disruptivos como la crisis financiera de 2008 o la pandemia de COVID-19. Sus resultados muestran que la eficiencia varía según el país, la magnitud de las fluctuaciones y el horizonte temporal analizado. Esto sugiere que la EMH es más una hipótesis contextual que una verdad universal.

En el contexto del índice STOXX Global AI, los niveles de eficiencia de Fama ofrecen un marco teórico útil para evaluar cómo reaccionan los precios de las empresas tecnológicas.

---

<sup>15</sup> Personas con acceso privilegiado a información confidencial de una empresa, como directivos, empleados o grandes accionistas.

En especial, resulta relevante analizar la respuesta de aquellas vinculadas a la IA y los semiconductores ante eventos como el lanzamiento de ChatGPT.

- Si el mercado es eficiente en su forma débil, la información histórica (precios, volúmenes) no debe ofrecer ventajas predictivas.
- Si lo es en su forma semifuerte, la información pública (noticias, reportes financieros) ya estará reflejada en los precios.
- Si fuera fuertemente eficiente, ni siquiera el acceso a información privilegiada tecnológica permitiría obtener retornos anormales.

Desde esta perspectiva, evaluar el comportamiento multifractal de las series del índice permite comprobar si existe evidencia empírica que respalde o contradiga estas formas de eficiencia.

### **2.2.3. EMH y MF-DFA**

El MF-DFA proporciona una herramienta cuantitativa para evaluar hasta qué punto los mercados responden de manera eficiente a eventos disruptivos. Esta técnica analiza las fluctuaciones de retornos a través de distintas escalas temporales, permitiendo detectar persistencia, correlaciones de largo plazo y multifractalidad. Si un evento como el lanzamiento de ChatGPT provoca efectos prolongados en los precios, esto sugeriría un fallo del mercado para incorporar eficientemente dicha información, en contraposición a los postulados de la EMH (Ball, 2015; Kothari & Warner, 2007). En cambio, si el impacto es breve y se disipa rápidamente, se observaría un comportamiento más cercano al ideal de eficiencia.

En este estudio se emplea el MF-DFA para analizar las series temporales del índice STOXX Global AI, evaluando cómo reaccionan los precios de empresas del sector tecnológico ante un evento disruptivo. Una disminución en las correlaciones de largo plazo tras el evento podría indicar un movimiento hacia mercados más eficientes.

El enfoque se centra especialmente en la forma semifuerte de la EMH, que postula que toda la información pública está ya reflejada en los precios, impidiendo ventajas mediante análisis fundamental o técnico. El MF-DFA resulta especialmente útil para contrastar esta versión, al permitir detectar patrones de dependencia temporal que contradicen la hipótesis del Random Walk (Samuelson, 1965).

Más allá de su vínculo con la EMH, el MF-DFA ha emergido como una de las metodologías más robustas para analizar series financieras complejas. Kantelhardt et al. (2001)

introdujeron esta técnica para detectar correlaciones de largo alcance en datos no estacionarios<sup>16</sup>, extendiendo el DFA clásico hacia un enfoque multifractal<sup>17</sup>. Esta técnica consiste en descomponer la serie temporal en distintas escalas y calcular el exponente de Hurst generalizado,  $h(q)$ , que permite cuantificar persistencia ( $h(q)>0.5$ ) o antipersistencia ( $h(q)<0.5$ )<sup>18</sup>.

Frente a métodos como el análisis espectral o las wavelets<sup>19</sup>, el MF-DFA presenta ventajas metodológicas clave: es menos sensible al ruido y más adecuado para tratar con series reales no estacionarias. Estas características lo convierten en una herramienta idónea para evaluar la estructura dinámica de precios en mercados financieros contemporáneos.

Estudios recientes han demostrado que los precios de los activos, especialmente en contextos de alta especulación o shocks exógenos, presentan dependencias temporales que cuestionan la validez de la EMH. El trabajo de Aslam, Ferreira y Mohti ha sido clave en este ámbito, aplicando MF-DFA para evaluar la eficiencia de los mercados durante situaciones de alta incertidumbre, como la pandemia de COVID-19.

En conjunto, la incorporación del MF-DFA en investigaciones académicas representa una evolución en el análisis de la eficiencia de los mercados. Su enfoque fractal y dinámico permite captar mejor la complejidad de los sistemas financieros, proporcionando una visión más realista y matizada del comportamiento de los precios.

## **2.3. Antecedentes teóricos del MF-DFA**

### **2.3.1. Introducción**

El MF-DFA fue desarrollado por Kantelhardt et al. (2002) como una mejora del método DFA clásico. Su objetivo es analizar al mismo tiempo las correlaciones a largo plazo y las distribuciones con extremos muy marcados, dos rasgos comunes en los mercados financieros. Su utilidad ha sido comprobada en estudios sobre bolsas de valores, materias primas y energía

---

<sup>16</sup> Series temporales cuyos patrones estadísticos, como la media o la varianza, cambian a lo largo del tiempo.

<sup>17</sup> Técnica que permite analizar comportamientos complejos y variables en diferentes escalas dentro de una misma serie temporal.

<sup>18</sup> La persistencia indica que las tendencias tienden a continuar; la antipersistencia, que cambian de dirección con frecuencia.

<sup>19</sup> Técnicas matemáticas usadas para descomponer series temporales en sus componentes de frecuencia y analizar patrones cíclicos o locales.

(Memon, Yao, & Naveed, 2022; Stosic, Nejad, & Stosic, 2020; Di Matteo, 2007; Zunino et al., 2008; Aslam, Ferreira, & Mohti, 2023).

En mercados que tradicionalmente se interpretan mediante la Hipótesis de la Random Walk (Bachelier, 1900), el MF-DFA permite evidenciar patrones de persistencia, anti-persistencia y heterogeneidad temporal. Esto desafía la idea de que los precios se comportan de forma puramente estocástica<sup>20</sup> (Wang, Liu, & Qin, 2014).

En el caso del índice STOXX Global AI, el MF-DFA resulta especialmente adecuado para evaluar si eventos disruptivos como el lanzamiento de ChatGPT han producido cambios estructurales en las series de precios de empresas tecnológicas. A través del análisis de sus dinámicas multifractales, es posible determinar si los retornos muestran comportamientos aleatorios, dependientes o reversibles, proporcionando así una lectura más precisa sobre la eficiencia del mercado.

Una de las principales ventajas del MF-DFA es su robustez frente a la no estacionariedad y al ruido estadístico<sup>21</sup>, condiciones típicas de los mercados reales. A diferencia de métodos como el análisis espectral o las transformadas wavelet, el MF-DFA combina profundidad analítica con relativa simplicidad computacional. Además, ha sido validado en ámbitos tan diversos como la climatología, la cardiología o la geofísica.

Desde un punto de vista teórico, el MF-DFA representa una alternativa empírica a la EMH. Mientras la EMH presupone precios racionales y aleatorios, el MF-DFA ha demostrado que los mercados presentan estructuras dependientes del tiempo, cuyas propiedades cambian según el contexto informativo o el ciclo del mercado (Gorjão et al., 2024).

Este enfoque refleja también la evolución del pensamiento financiero. Uno de los grandes promotores de la EMH, Dan Wheeler, la popularizó a través de su trabajo en Dimensional Fund Advisors. Sin embargo, autores como Wigglesworth (2023) han señalado cómo la creciente complejidad de los mercados, con la irrupción de algoritmos, alta volatilidad y shocks exógenos, ha puesto en entredicho la aplicabilidad estricta de dicha hipótesis.

---

<sup>20</sup> Se refiere a procesos aleatorios, donde los resultados dependen del azar y no siguen un patrón determinista.

<sup>21</sup> Variaciones aleatorias sin un patrón claro que pueden dificultar la detección de señales reales en los datos.

El procedimiento del MF-DFA consta de seis etapas fundamentales, que permiten descomponer la serie temporal y evaluar su grado de multifractalidad (Kantelhardt et al., 2002; Miloš et al., 2020):

1. **Perfil acumulado:** Se transforma la serie de rendimientos en una trayectoria acumulativa, eliminando tendencias lineales y facilitando el análisis de fluctuaciones.
2. **División en segmentos:** La serie acumulada se divide en múltiples segmentos de igual longitud desde ambos extremos de la serie, garantizando la cobertura completa de los datos.
3. **Eliminación de tendencia local:** En cada segmento se ajusta un polinomio que representa la tendencia local, y se calcula la desviación respecto a esta tendencia para medir la fluctuación interna.
4. **Cálculo de la fluctuación media generalizada:** Se calcula la magnitud promedio de las fluctuaciones en todos los segmentos, variando la sensibilidad del análisis a través de diferentes órdenes estadísticos.
5. **Relación de escalado:** Se analiza cómo se comportan las fluctuaciones a medida que cambia la escala temporal. Si estas siguen una ley de potencias, se extrae el exponente de Hurst generalizado, que indica el tipo de dependencia temporal.
6. **Espectro multifractal:** Finalmente, se calcula el espectro que representa la diversidad de comportamientos presentes en la serie. El ancho del espectro indica el grado de multifractalidad, es decir, cuán compleja y variable es la estructura del mercado a lo largo del tiempo.

El trabajo de Miloš et al. (2020) aplicó esta metodología a siete índices bursátiles de Europa Central y del Este, encontrando niveles significativos de multifractalidad que variaban según el país y el periodo. Estos hallazgos refuerzan el valor del MF-DFA como herramienta analítica en contextos donde la eficiencia del mercado puede ser dinámica, parcial o incluso deteriorarse temporalmente tras eventos disruptivos.

En resumen, el MF-DFA proporciona un marco metodológico riguroso y flexible para analizar la eficiencia del mercado en entornos complejos. Su aplicación al índice STOXX Global AI permite evaluar hasta qué punto eventos como el lanzamiento de ChatGPT han modificado la estructura estadística de los precios financieros.

### 2.3.2. Python Notebook

La implementación práctica del MF-DFA en este estudio se llevó a cabo mediante un notebook en Python, siguiendo la metodología descrita por Kantelhardt et al. (2002) y aplicada recientemente por Datta (2024). El objetivo fue aplicar esta técnica a las series temporales de precios de las empresas que componen el índice STOXX Global AI, para evaluar su eficiencia multifractal a lo largo del tiempo.

El notebook está estructurado en seis bloques principales, alineados con las fases teóricas del MF-DFA:

1. Carga y preprocesamiento de datos, garantizando calidad y coherencia de las series temporales.
2. Construcción del perfil acumulado de los rendimientos logarítmicos.
3. Detrending local mediante ajuste polinómico.
4. Cálculo de la función de fluctuación para distintos valores de  $q$ .
5. Estimación del exponente generalizado de Hurst,  $h(q)$ , según la ley de potencias.
6. Obtención del espectro multifractal mediante la transformación de Legendre.

Para ello, se utilizó un enfoque reproducible basado en librerías como NumPy y pandas para el manejo de datos, y SciPy para los ajustes polinómicos. Además, se emplearon Matplotlib y Seaborn para la visualización de resultados en formato SVG<sup>22</sup>, buscando máxima calidad gráfica. El rango de  $q$  utilizado fue simétrico (por ejemplo, de  $-5$  a  $5^{23}$ ) y los tamaños de ventana oscilaron entre 16 y 1024. Esto sigue las recomendaciones metodológicas de Ihlen (2012) y Datta (2024) para captar tanto fluctuaciones pequeñas como grandes.

Un aspecto importante del análisis fue la incorporación de pruebas para asegurar la solidez de los resultados. Se usaron técnicas como el barajado aleatorio y la aleatorización de fase para comprobar si la multifractalidad observada se debía a patrones de largo plazo o simplemente a valores extremos en la distribución, como sugiere Datta (2024). Gracias a estas pruebas, fue posible entender mejor de dónde vienen y qué tan fuertes son las propiedades multifractales en cada serie analizada.

El análisis se realizó inicialmente sobre la serie completa, y posteriormente año por año, aplicando la función definida *get\_mfdfa*, que ajusta automáticamente los parámetros (como el

---

<sup>22</sup> Formato de imagen vectorial que permite gráficos con alta calidad y sin pérdida de resolución al escalar.

<sup>23</sup> Rango típico en el análisis multifractal que permite estudiar tanto las pequeñas como las grandes fluctuaciones de la serie.

lag y  $q^{24}$ ) para calcular las métricas multifractales. Entre ellas se incluyen el exponente de Hurst, el espectro multifractal, y sus correspondientes visualizaciones dinámicas.

Para evaluar la eficiencia del mercado, se realizó un bootstrapping de los rendimientos del índice y se establecieron umbrales de eficiencia estadística. Con un nivel de significancia del 5%, se definieron como límites los valores de  $h(2) < 0.392$  y  $h(2) > 0.603$ , indicando ineficiencia en ambos extremos. Este criterio empírico permite clasificar las observaciones según su cercanía al comportamiento eficiente.

En conjunto, este enfoque computacional facilita la replicabilidad del estudio y convierte al MF-DFA en una herramienta accesible para investigadores, estudiantes y profesionales financieros. Siguiendo la lógica de Datta (2024), esta aplicación no sustituye el marco teórico, sino que lo complementa, al permitir contrastar sus predicciones con datos reales y condiciones de mercado dinámicas.

---

<sup>24</sup> Lag indica la distancia entre puntos en la serie;  $q$  es un parámetro que ajusta la sensibilidad del análisis a diferentes tipos de fluctuaciones.

### 3. OBJETIVOS

#### 3.1. Generales

Evaluar si el grado de eficiencia del mercado de las empresas que integran el índice STOXX Global AI ha cambiado tras el lanzamiento de ChatGPT. Para ello, se utiliza el método de Análisis de Fluctuaciones Detrendadas Multifractales (MF-DFA). El objetivo es determinar si dicho evento ha provocado alteraciones en la estructura dinámica de los retornos financieros, especialmente en términos de persistencia, multifractalidad y comportamiento adaptativo del mercado.

#### 3.2. Específicos

**1. Analizar la evolución temporal del exponente de Hurst generalizado antes y después del evento ChatGPT, tanto a nivel agregado como individual.**

Este análisis permite identificar cambios en la eficiencia del mercado y detectar posibles patrones de persistencia o anti-persistencia como reflejo de transformaciones estructurales en el comportamiento financiero.

**2. Comparar el grado de multifractalidad del índice y sus componentes entre los periodos pre y post ChatGPT, evaluando su evolución anual mediante indicadores como  $\Delta h(q)$  y  $\Delta \alpha$ .**

Este objetivo busca determinar si la complejidad interna de las series temporales ha variado con el tiempo, lo cual puede evidenciar una homogeneización o fragmentación de las expectativas del mercado.

**3. Estimar el grado de eficiencia de mercado a través del Rolling Hurst aplicado individualmente a las empresas del sector semiconductores, identificando patrones estables o rupturas estructurales.**

Esta técnica permite observar con mayor granularidad cómo ha reaccionado cada empresa al evento, y si sus trayectorias siguen una lógica común o presentan dinámicas particulares.

**4. Detectar heterogeneidad entre empresas según su tamaño, exposición a IA y comportamiento estadístico, diferenciando entre firmas líderes como NVIDIA e Intel, y compañías con dinámicas más especulativas.**

Esta diferenciación es clave para comprender si los efectos del evento disruptivo se distribuyen de forma homogénea o si están condicionados por factores estructurales propios de cada compañía.

**5. Interpretar los resultados desde una perspectiva económica, analizando el papel de la IA como generador de narrativa colectiva y su impacto en la formación de precios, la eficiencia temporal y la estructura informacional del mercado.**

Esta reflexión final busca conectar los hallazgos cuantitativos con implicaciones estratégicas y financieras más amplias.

## 4. METODOLOGÍA

### 4.1. Datos

Este estudio analiza la eficiencia de mercado del índice STOXX Global Artificial Intelligence, con especial atención al subconjunto de empresas del sector de semiconductores. Se utiliza una muestra compuesta por precios diarios de cierre ajustados. Para el índice STOXX Global AI, el periodo de estudio va de 2018 a 2024, lo que permite identificar patrones de largo plazo. En el caso de sus componentes, especialmente las empresas de semiconductores, el análisis se extiende desde 2018 hasta mediados de septiembre de 2024. Esta diferencia en la cobertura temporal permite analizar la eficiencia tanto a nivel agregado como individual. Se aplican el MF-DFA y el Rolling Hurst para evaluar los efectos de la adopción masiva de herramientas de IA.

Las series temporales de precios fueron transformadas en rendimientos logarítmicos, definidos como:

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

donde  $P_t$  representa el precio de cierre del día  $t$ . Esta transformación es fundamental para aplicar correctamente el método MF-DFA, que requiere series no estacionarias y sin tendencias deterministas (Shrestha et al., 2023). Posteriormente, se construyeron ventanas móviles de 252 días (un año bursátil) para observar la evolución dinámica de los coeficientes de eficiencia multifractal en el tiempo.

Para cada empresa, se recopilaron las siguientes variables:

- Precio de cierre ajustado por dividendos y splits
- Volumen negociado diario
- Capitalización de mercado
- Ratio de Sharpe
- Volatilidad anualizada

Los datos fueron obtenidos y contrastados a través de plataformas como Bloomberg, FactSet y Yahoo Finance, y posteriormente depurados para asegurar consistencia temporal

Desde un enfoque metodológico, el uso de MF-DFA permite detectar comportamientos monofractales, asociados a eficiencia de mercado, y multifractales, indicativos de estructuras complejas o ineficiencias. Esto resulta especialmente relevante en entornos con alta disrupción

tecnológica (Shrestha et al., 2023). Esto resulta especialmente relevante en un contexto donde la IA ha comenzado a transformar profundamente los mercados.

En este sentido, el trabajo de Rock et al. (2024) ofrece una perspectiva adicional. Muestra que más del 18 % de los trabajadores en economías avanzadas tienen al menos la mitad de sus tareas expuestas a automatización mediante modelos de IA como GPT-4. Este impacto presenta un sesgo significativo hacia ocupaciones altamente remuneradas. Este panorama contextualiza el impacto de la IA no solo a nivel macroeconómico y laboral, sino también en los mercados financieros, reforzando el papel del índice STOXX Global AI como termómetro de dicha transformación.

## 4.2. Empleo de MF-DFA

Esta sección describe la metodología empleada para aplicar el Análisis de Fluctuaciones Detrendadas Multifractales (MF-DFA), utilizando la librería en Python desarrollada por Gorjão et al. (2022). Se detallan los procedimientos computacionales, las formulaciones matemáticas aplicadas y la base teórica que sustenta su implementación, siguiendo las guías metodológicas establecidas por Gorjão et al. (2022), Thompson & Wilson (2016), Ihlen (2012) y Kantelhardt et al. (2002), entre otros. Python fue elegido por su elevada capacidad de procesamiento y por sus potentes librerías integradas, lo que lo convierte en una herramienta especialmente adecuada para el tratamiento de datos complejos y los cálculos estadísticos requeridos por el MF-DFA.

El MF-DFA se emplea para estimar el exponente generalizado de Hurst  $h(q)$ , que describe cómo evolucionan las fluctuaciones en distintas escalas y órdenes estadísticos. Su variación con respecto al parámetro  $q$  revela la presencia de multifractalidad, y por ende, estructuras complejas que se alejan del comportamiento aleatorio de un mercado eficiente.

### 4.2.1. Construcción de la serie acumulada

A partir de la serie de rendimientos logarítmicos  $r_t$ , se construye el perfil integrado:

$$Y(i) = \sum_{t=1}^i (r_t - \langle r \rangle)$$

donde  $\langle r \rangle$  es el promedio de los rendimientos. Esta transformación convierte la serie en una Random Walk, base para el análisis posterior.

#### 4.2.2. Segmentación de la serie

El perfil  $Y(i)$  se divide en  $N_s = \text{int}(N/s)$  segmentos no superpuestos de longitud  $s$ . Para no perder información, se repite el proceso desde el extremo final, generando un total de  $2N_s$  segmentos.

#### 4.2.3. Detrending en cada segmento

En cada segmento  $v$ , se ajusta un polinomio  $P_v(i)$  (de orden 1 o 2) y se calcula la varianza respecto a dicha tendencia:

$$F^2(s, v) = \frac{1}{s} \sum_{i=1}^s [Y((v-1)s + i) - P_v(i)]^2$$

Este paso elimina las tendencias polinómicas locales, permitiendo analizar solo las fluctuaciones.

#### 4.2.4. Fluctuaciones generalizadas

Se define la función de fluctuación para un orden  $q$  dado como:

$$F_q(s) = \left\{ \frac{1}{2N_s} \sum_{v=1}^{2N_s} [F^2(s, v)]^{q/2} \right\}^{1/q}$$

Para  $q=0$ , se utiliza una media logarítmica. Esta función permite analizar tanto fluctuaciones pequeñas (para  $q < 0$ ) como grandes (para  $q > 0$ ).

#### 4.2.5. Relación de escala para estimar el exponente $h(q)$

La dependencia de  $F_q(s)$  con la escala  $s$  se representa en doble escala logarítmica:

$$F_q(s) \sim s^{h(q)}$$

El exponente  $h(q)$  describe la relación entre la magnitud de las fluctuaciones y su escala temporal. Si  $h(q)$  es constante, la serie es monofractal (asociada a eficiencia). Si varía con  $q$ , la serie es multifractal, lo cual indica ineficiencia estructural.

#### 4.2.6. Interpretación del exponente $h(2)$ :

- a. Si  $h(2) \approx 0.5$ : mercado eficiente
- b. Si  $h(2) > 0.5$ : comportamiento persistente
- c. Si  $h(2) < 0.5$ : comportamiento anti-persistente

Este conjunto de pasos permite extraer información detallada sobre la estructura interna de las series financieras, identificando patrones de complejidad, memoria y eficiencia. Como señalan Shrestha et al. (2023), aplicar MF-DFA a series bursátiles permite distinguir entre comportamientos compatibles con la EMH y aquellos que reflejan estructuras multifractales. Estas últimas son más típicas en entornos expuestos a innovaciones tecnológicas disruptivas.

#### **4.2.6. Contraste estadístico mediante bootstrap:**

Una vez estimado el exponente generalizado de Hurst mediante el método MF-DFA, resulta necesario evaluar la significancia estadística de los resultados obtenidos. Para ello, se implementa un procedimiento de contraste basado en remuestreo bootstrap, que permite determinar si la multifractalidad observada en las series originales es genuina o producto de artefactos estadísticos.

##### **a) Simulación y bandas de confianza**

Se simulan 100.000 series aleatorias con  $h=0.5$  (asociado a un comportamiento puramente aleatorio), cada una con una longitud de 252 observaciones (equivalente a un año bursátil). Estas simulaciones se utilizan para construir bandas de confianza al 95 % y evaluar el grado de desviación de la serie real respecto al supuesto de eficiencia de mercado.

##### **b) Transformaciones y contrastes**

El procedimiento se basa en la generación de dos versiones aleatorias de cada serie temporal original:

1. **Serie barajada (shuffled):** los elementos se reordenan aleatoriamente, eliminando las correlaciones temporales, pero manteniendo la distribución de los valores. Este enfoque permite detectar si la multifractalidad proviene de correlaciones de largo plazo.
2. **Serie aleatorizada por fase (phase-randomized):** se aplica una transformación de Fourier que modifica las fases, lo que mantiene las correlaciones lineales pero elimina las relaciones no lineales. Esto permite comprobar si la multifractalidad se debe principalmente a la presencia de valores extremos en la distribución.

Para cada tipo de transformación, se repite el análisis MF-DFA 1.000 veces, obteniendo distribuciones empíricas del ancho del espectro multifractal  $\Delta\alpha$ . Se calculan los percentiles 2.5 y 97.5 de cada distribución, generando intervalos de confianza bootstrap al 95 %.

### **c) Criterio de significancia**

Se compara el valor observado de  $\Delta\alpha$  en la serie original con los rangos de confianza obtenidos. Si este valor queda fuera de ambos intervalos (barajado y con fase aleatorizada), se descarta la idea de que la multifractalidad detectada sea un simple artefacto o producto del azar, con un nivel de confianza del 95 %.

Este contraste estadístico ha sido aplicado en estudios recientes como el de Shrestha et al. (2023), donde se utilizó para validar la autenticidad del comportamiento multifractal en índices fintech. En el presente trabajo, este enfoque permite evaluar si las diferencias detectadas antes y después del evento ChatGPT son estadísticamente robustas, o si pueden explicarse por artefactos derivados de la correlación o la distribución.

### **d) Valor añadido del contraste bootstrap**

La incorporación del método bootstrap proporciona validez empírica adicional a los resultados del MF-DFA, fortaleciendo la solidez metodológica del estudio. Esto permite interpretar los hallazgos con mayor confianza estadística, especialmente en contextos donde la presencia de interrupciones tecnológicas puede inducir estructuras multifractales difíciles de identificar con técnicas tradicionales.

## 5. RESULTADOS

Esta sección se estructura en dos bloques principales. En primer lugar, la sección 5.1 presenta una serie de visualizaciones y métricas multifractales que ilustran la evolución del índice STOXX Global AI desde una perspectiva técnica.

A continuación, la sección 5.2 se centra en las empresas semiconductoras incluidas en el índice, analizando tanto su posición en la industria como su eficiencia individual mediante el Rolling Hurst.

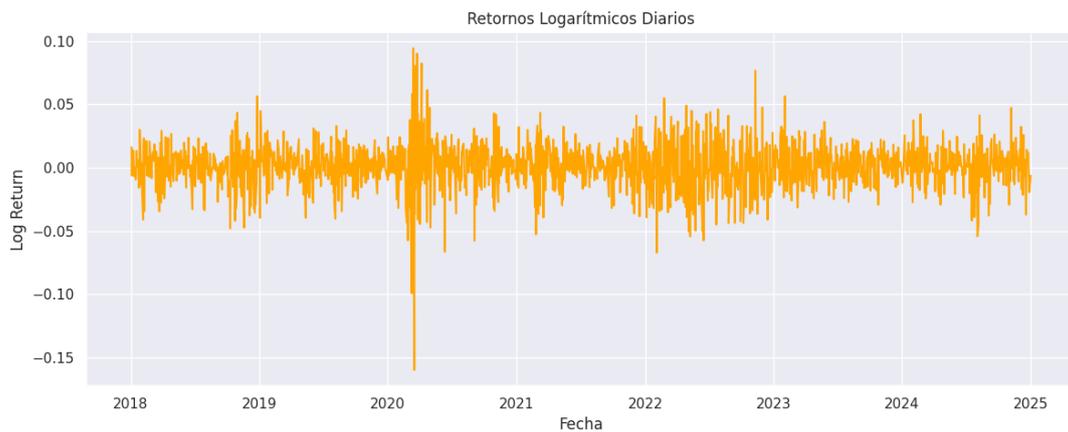
A partir de estos resultados, se plantea una evaluación crítica sobre las diferencias entre compañías, el impacto del lanzamiento de ChatGPT y la evolución observada en la eficiencia de mercado.

### 5.1. Presentación de resultados del Índice STOXX Global AI



**Figura 1:** Evolución del Índice STOXX Global AI

La **Figura 1** presenta la evolución temporal del índice STOXX Global AI desde el año 2018 hasta principios de 2025. En el eje horizontal se representan las fechas, mientras que el eje vertical muestra el nivel de precios del índice. La línea azul refleja la evolución diaria de los precios, permitiendo visualizar las principales tendencias, periodos de volatilidad y puntos de inflexión. Se identifican varias etapas claramente diferenciadas: un crecimiento moderado hasta 2020, una caída abrupta a principios de ese año coincidiendo con el inicio de la pandemia, seguida de una recuperación sostenida hasta finales de 2021. A partir de 2022, el índice muestra una mayor volatilidad, con repuntes interrumpidos por correcciones. Destaca especialmente la aceleración del crecimiento a partir de finales de 2023, que culmina en un máximo histórico en los primeros meses de 2025.



**Figura 2: Evolución de los retornos diarios logarítmicos**

La **Figura 2** muestra cómo han evolucionado los retornos logarítmicos diarios del índice STOXX Global AI entre 2018 y 2025. A lo largo del periodo se observa una alta volatilidad, con cambios diarios marcados en ciertos momentos. Destaca el fuerte desplome de marzo de 2020, coincidiendo con el inicio de la pandemia, y varios episodios de gran inestabilidad en los años siguientes. A partir de finales de 2022, con la expansión de herramientas como ChatGPT, se registran varios episodios con subidas inusualmente altas.

Desde una perspectiva económica, la presencia de picos extremos tanto positivos como negativos refleja la sensibilidad del mercado a eventos disruptivos y a cambios en las expectativas tecnológicas. La intensificación de movimientos positivos tras la irrupción de la IA generativa sugiere un reposicionamiento estructural de los inversores. Esto refuerza la hipótesis de que la IA ha alterado la dinámica tradicional de los precios del índice. Este patrón de comportamiento será clave para interpretar los resultados multifractales presentados en las siguientes Figuras.

**Tabla 1: Principales métricas de los retornos diarios logarítmicos**

|   | Año  | Rentabilidad anual (%) | Volatilidad anual (%) | Sharpe ratio | Skewness | Kurtosis | JB stat | JB p-value |
|---|------|------------------------|-----------------------|--------------|----------|----------|---------|------------|
| 0 | 2018 | -9.998                 | 24.671                | -0.426       | -0.229   | 1.084    | 14.769  | 0.001      |
| 1 | 2019 | 50.969                 | 20.904                | 2.414        | -0.275   | 0.889    | 11.571  | 0.003      |
| 2 | 2020 | 33.580                 | 40.307                | 0.821        | -0.964   | 8.246    | 773.960 | 0.000      |
| 3 | 2021 | 40.140                 | 23.320                | 1.700        | -0.321   | 0.912    | 13.364  | 0.001      |
| 4 | 2022 | -36.576                | 36.557                | -1.014       | 0.126    | 0.071    | 0.737   | 0.692      |
| 5 | 2023 | 64.339                 | 21.514                | 2.967        | 0.251    | 0.461    | 4.928   | 0.085      |
| 6 | 2024 | 40.042                 | 23.382                | 1.691        | -0.367   | 1.370    | 25.859  | 0.000      |

La tabla recoge una serie de métricas estadísticas clave que permiten caracterizar el comportamiento anual del índice STOXX Global AI entre 2018 y 2024. Se incluyen la rentabilidad y volatilidad anual, el ratio de Sharpe, asimetría (skewness), curtosis, y los resultados del test de normalidad de Jarque-Bera (JB stat y p-value)<sup>25</sup>. Esta información permite observar no solo el rendimiento del índice, sino también la distribución y estabilidad de sus retornos a lo largo del tiempo.

Destacan varios elementos: la elevada rentabilidad obtenida en 2019, 2021, 2023 y 2024, en contraste con las caídas de 2018 y, especialmente, de 2022, año en el que el índice experimentó una corrección significativa. El ratio de Sharpe, que mide la rentabilidad ajustada al riesgo, muestra valores notablemente positivos en 2019 y 2023, coincidiendo con los periodos de mayor impulso en torno al desarrollo de IA. En cuanto a la asimetría y curtosis, se aprecia una distribución de retornos moderadamente no normal en la mayoría de los años. Esto se confirma con los p-values del test de Jarque-Bera, que indican una significativa desviación de la normalidad salvo en 2022 y 2023.

Desde el punto de vista económico, esta tabla confirma que el impacto del lanzamiento de ChatGPT no solo se refleja en la revalorización del índice. También muestra una mejora sustancial de su rendimiento ajustado al riesgo. El año 2023 registra el mayor Sharpe ratio del periodo analizado, acompañado de una volatilidad relativamente baja, lo cual sugiere una percepción favorable y estable del mercado respecto al potencial de la IA. Estos resultados respaldan la hipótesis del trabajo, al evidenciar un cambio estructural en los patrones de comportamiento del índice tras la difusión masiva de herramientas de IA.

---

<sup>25</sup> La asimetría mide la inclinación de la distribución; el test de Jarque-Bera evalúa si los datos siguen una distribución normal, usando la asimetría y la curtosis.

**Tabla 2: Métricas MF-DFA (general)**

|   | q    | slope    | h(q)     | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|----------|----------|-----------|----------|---------------|
| 0 | -5.0 | 2.353612 | 1.353612 | -7.768060 | 1.629185 | -0.377867     |
| 1 | -4.0 | 2.284719 | 1.284719 | -6.138875 | 1.618062 | -0.333375     |
| 2 | -3.0 | 2.177312 | 1.177312 | -4.531935 | 1.568031 | -0.172158     |
| 3 | -2.0 | 2.001406 | 1.001406 | -3.002813 | 1.401978 | 0.198856      |
| 4 | -1.0 | 1.727979 | 0.727979 | -1.727979 | 0.836742 | 0.891236      |
| 5 | 1.0  | 1.507414 | 0.507414 | -0.492586 | 0.563699 | 1.056285      |
| 6 | 2.0  | 1.481560 | 0.481560 | -0.036881 | 0.442623 | 0.922127      |
| 7 | 3.0  | 1.464220 | 0.464220 | 0.392660  | 0.412935 | 0.846145      |
| 8 | 4.0  | 1.447247 | 0.447247 | 0.788989  | 0.379444 | 0.728788      |
| 9 | 5.0  | 1.430310 | 0.430310 | 1.151549  | 0.362560 | 0.661249      |

La tabla presenta los principales resultados derivados del MF-DFA aplicado a los retornos logarítmicos del índice STOXX Global AI para distintos valores del parámetro  $q$ . Se muestran las pendientes estimadas, el exponente de Hurst generalizado  $h(q)$ , la función de escala multifractal  $\tau(q)$ <sup>26</sup>, el exponente de Hölder  $\alpha$ <sup>27</sup>, y la dimensión espectral  $D(\alpha)$ <sup>28</sup>. Estos indicadores permiten evaluar la presencia y naturaleza de la multifractalidad en la serie temporal analizada.

Se observa que  $h(q)$  decrece conforme aumenta el valor de  $q$ , lo cual es un claro indicio de comportamiento multifractal. Este patrón implica que las fluctuaciones pequeñas y grandes del índice tienen dinámicas distintas, lo que revela una estructura compleja en los retornos. El valor de  $h(q)$  varía desde 1.35 para  $q=-5$ , hasta 0.43 para  $q=5$ , mostrando una amplitud significativa. Por otro lado, la dimensión espectral  $D(\alpha)$  alcanza un máximo cercano a 1.06, lo que indica una distribución rica en singularidades y, por tanto, una fuerte heterogeneidad temporal.

Desde una perspectiva económica, la amplitud del rango de  $h(q)$  y la forma del espectro de singularidad respaldan la hipótesis de que el comportamiento del índice no puede explicarse por modelos lineales simples. Tampoco puede entenderse dentro del marco de mercados plenamente eficientes. La presencia de multifractalidad sugiere que factores como la

---

<sup>26</sup> Mide cómo cambian las fluctuaciones a distintas escalas según el valor de  $q$ ; su forma indica la presencia y grado de multifractalidad en la serie.

<sup>27</sup> Indica la intensidad o regularidad de las fluctuaciones locales en una serie temporal; valores variados reflejan comportamientos complejos y multifractales.

<sup>28</sup> Mide cuántos puntos de la serie comparten el mismo nivel de irregularidad  $\alpha$ ; su forma revela la diversidad y complejidad del comportamiento multifractal.

concentración informativa, la especulación y la asimetría en la respuesta de los inversores ante eventos como el lanzamiento de ChatGPT han influido en el comportamiento del mercado. Estos factores pueden haber acentuado la complejidad dinámica del índice. Estos resultados aportan evidencia empírica sólida sobre los cambios estructurales en la formación de precios en el contexto del auge de la IA.

**Tabla 3: Métricas MF-DFA por año (2018-2024)**

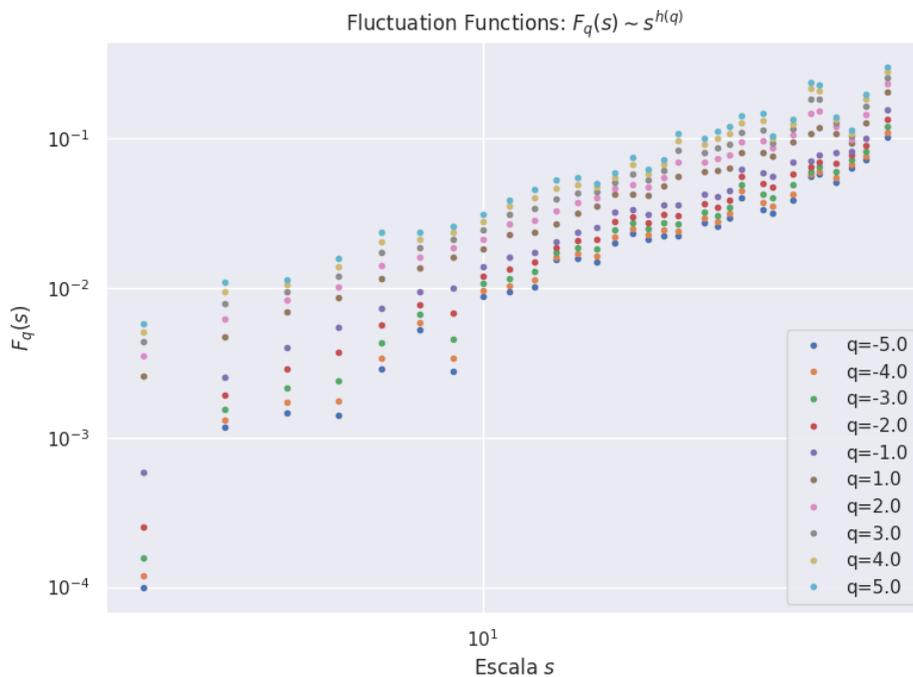
|   | Año  | max $h(q)$ | min $h(q)$ | $\Delta h(q)$ | max $\alpha$ | min $\alpha$ | $\Delta\alpha$ |
|---|------|------------|------------|---------------|--------------|--------------|----------------|
| 0 | 2018 | 2.0473     | 0.3236     | 1.7237        | 2.3770       | 0.2076       | 2.1694         |
| 1 | 2019 | 1.7905     | 0.4298     | 1.3607        | 2.0703       | 0.3305       | 1.7399         |
| 2 | 2020 | 1.3744     | 0.3800     | 0.9944        | 1.6151       | 0.2887       | 1.3264         |
| 3 | 2021 | 1.6943     | 0.3843     | 1.3100        | 2.0067       | 0.3263       | 1.6804         |
| 4 | 2022 | 1.5444     | 0.2633     | 1.2811        | 1.8377       | 0.1927       | 1.6450         |
| 5 | 2023 | 0.9535     | 0.3386     | 0.6150        | 1.1217       | 0.1660       | 0.9557         |
| 6 | 2024 | 1.5051     | 0.3811     | 1.1240        | 1.7546       | 0.2910       | 1.4636         |

La tabla presenta un resumen de las métricas multifractales clave calculadas anualmente a partir del análisis MF-DFA aplicado al índice STOXX Global AI. Se incluyen el valor máximo y mínimo del exponente generalizado de Hurst  $h(q)$ , así como su rango  $\Delta h(q)$ , junto con los valores extremos del exponente de Hölder  $\alpha$  y su rango  $\Delta\alpha$ . Estas métricas permiten evaluar la evolución temporal de la complejidad estructural del índice en términos de multifractalidad.

Se observa que el año 2018 registra los valores más altos de  $\Delta h(q)$  y  $\Delta\alpha$ , lo que indica una fuerte heterogeneidad en las fluctuaciones del índice en ese periodo. En cambio, 2023 muestra una reducción significativa en ambos rangos, especialmente en  $\Delta h(q)$  que desciende hasta 0.6150, sugiriendo una menor complejidad multifractal. No obstante, en 2024 se aprecia un repunte en ambas métricas, aunque sin alcanzar los niveles de los primeros años del periodo.

Desde una perspectiva económica, esta evolución indica que la estructura multifractal del índice ha experimentado cambios relevantes a lo largo del tiempo, reflejando posibles transformaciones en el comportamiento del mercado. En particular, la caída de la multifractalidad en 2023 puede interpretarse como un periodo de mayor consenso inversor y menor diversidad de respuestas ante la irrupción de la IA. Esta tendencia coincide con la consolidación de ChatGPT como fenómeno tecnológico. El repunte de la complejidad en 2024

podría estar asociado al ajuste posterior del mercado ante nuevas dinámicas competitivas dentro del ecosistema de IA. Estos resultados ofrecen evidencia empírica de que el auge de la IA ha influido en la naturaleza del proceso de formación de precios dentro del índice.



**Figura 3: Funciones de fluctuación entre  $q=-5$  y  $q=5$**

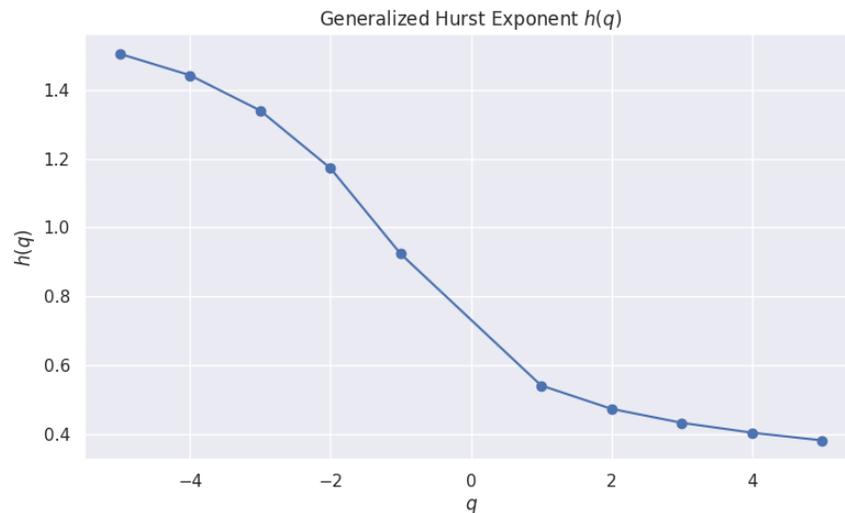
La **Figura 3** representa las funciones de fluctuación  $F_q(s)$  obtenidas mediante el análisis MF-DFA aplicado al índice STOXX Global AI. Se muestran los resultados para diferentes valores del parámetro  $q$ , tanto positivos como negativos, lo que permite analizar la sensibilidad del índice a pequeñas y grandes fluctuaciones. Cada curva sigue una relación de tipo potencia con la escala  $s$ , evidenciada por el comportamiento lineal en escala  $\log\text{-}\log$ <sup>29</sup>.

La dispersión creciente entre las curvas conforme aumenta el valor absoluto de  $q$  indica que el exponente  $h(q)$  varía con  $q$ , lo cual confirma la presencia de multifractalidad en la serie de retornos. Las curvas asociadas a valores negativos de  $q$ , sensibles a pequeñas fluctuaciones, tienden a situarse por debajo de las correspondientes a valores positivos. Esto refleja diferencias estructurales en la dinámica del índice según la magnitud de las variaciones analizadas.

Desde una perspectiva económica, la existencia de multifractalidad sugiere que el comportamiento del índice no responde únicamente a un proceso lineal o eficiente. Está influido

<sup>29</sup> Gráfico donde ambos ejes están en escala logarítmica; permite identificar relaciones de tipo potencia como líneas rectas.

por factores de distinta escala, como reacciones heterogéneas de los inversores, especulación tecnológica y picos informativos. La clara separación entre las curvas refuerza la hipótesis del trabajo sobre el impacto de la IA. En particular, destaca el lanzamiento de ChatGPT como elemento generador de mayor complejidad en los precios de los activos que componen el índice.



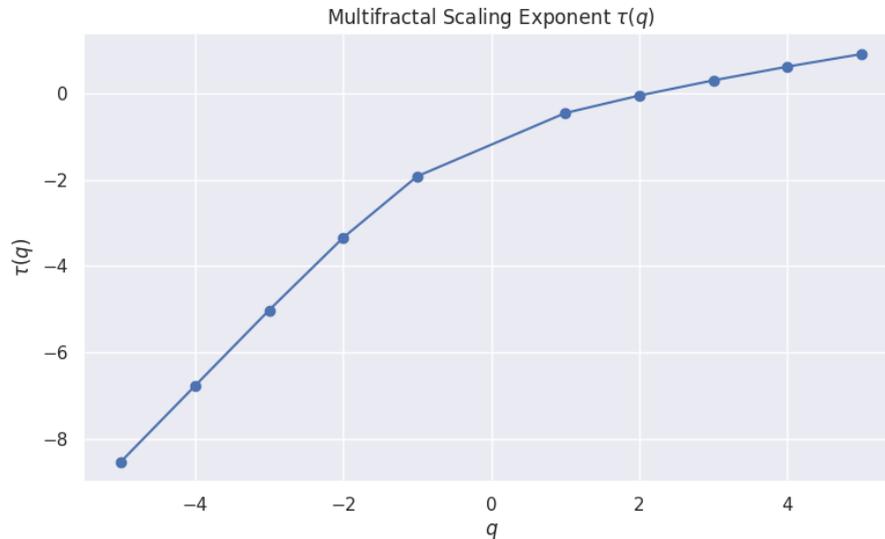
**Figura 4:** *Función del exponente Hurst en términos de q*

La **Figura 4** muestra la evolución del exponente de Hurst generalizado  $h(q)$  para distintos valores del parámetro  $q$ , lo que permite analizar la dependencia de escala en los retornos logarítmicos del índice STOXX Global AI. Se observa una clara pendiente descendente, lo que indica que  $h(q)$  disminuye a medida que aumenta  $q$ , confirmando la existencia de multifractalidad.

Este comportamiento implica que las pequeñas fluctuaciones del índice (valores negativos de  $q$ ) presentan una persistencia mayor, mientras que las grandes fluctuaciones (valores positivos de  $q$ ) tienden a ser más erráticas o anti-persistentes. La diferencia significativa entre los extremos del rango de  $h(q)$  refuerza la presencia de estructuras de dependencia no lineales y dinámicas heterogéneas en la serie de precios.

Desde el punto de vista económico, esta variabilidad del exponente de Hurst en función de  $q$  indica que el comportamiento del índice no puede explicarse mediante un proceso monofractal ni plenamente eficiente. La mayor persistencia en movimientos pequeños y la dispersión en escalas mayores sugieren que factores como el acceso asimétrico a la información o la especulación asociada al desarrollo de la IA, particularmente tras la aparición de ChatGPT, han contribuido a generar una estructura multifractal compleja en la dinámica del índice. Estos

resultados fortalecen la hipótesis del trabajo sobre el impacto estructural de la IA en los mercados.

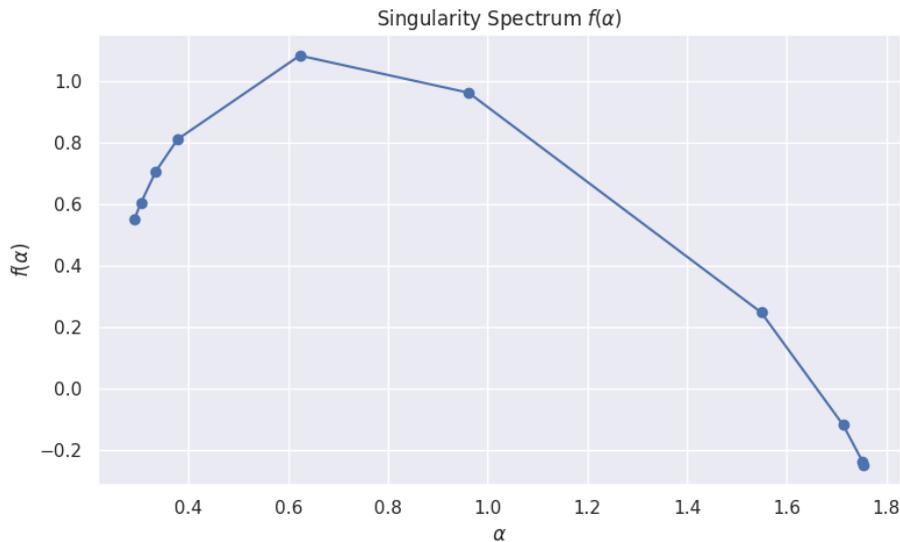


**Figura 5: Multifractal Scaling Exponent (Exponente Renyi)**

La **Figura 5** muestra la evolución del exponente de escalado multifractal  $\tau(q)$  en función del parámetro  $q$ , derivado del análisis MF-DFA aplicado al índice STOXX Global AI. La curva es claramente no lineal, lo que confirma la presencia de multifractalidad en la serie temporal de retornos. En ausencia de multifractalidad, la relación entre  $\tau(q)$  y  $q$  sería lineal; sin embargo, la curvatura observada indica la existencia de múltiples escalas de comportamiento.

El crecimiento progresivo de  $\tau(q)$  desde valores negativos hasta positivos sugiere que tanto las pequeñas como las grandes fluctuaciones contribuyen de manera distinta a la dinámica del índice. Este patrón refleja una estructura interna rica y heterogénea, en la que coexisten distintos niveles de persistencia y volatilidad en función del tamaño de los movimientos de mercado.

Desde un punto de vista económico, esta no linealidad de  $\tau(q)$  proporciona evidencia adicional sobre la complejidad estructural del índice. El hecho de que no se comporte como una serie monofractal sugiere que su dinámica no puede explicarse únicamente mediante modelos de eficiencia clásica. Este hallazgo se alinea con la hipótesis del trabajo, que plantea que la irrupción de herramientas de IA, como ChatGPT, ha alterado de forma significativa los patrones de comportamiento del mercado. Ha introducido nuevas fuentes de heterogeneidad y complejidad en la evolución de los precios.



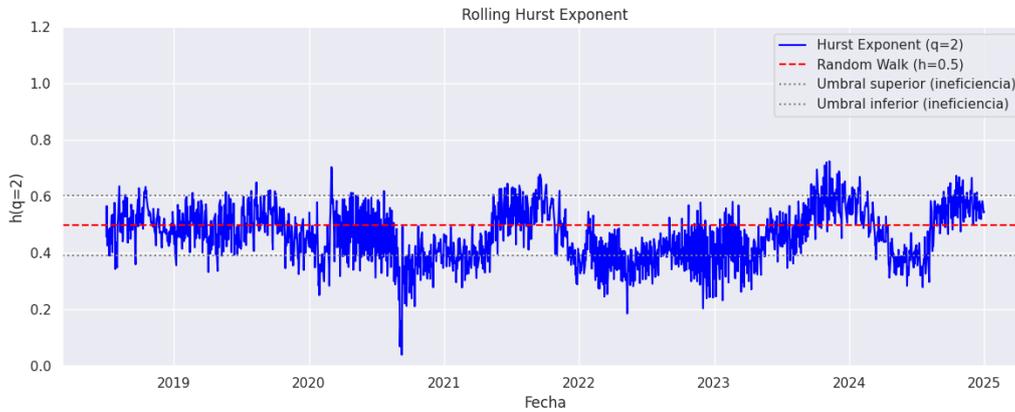
**Figura 6: Espectro de singularidad**

La **Figura 6** representa el espectro de singularidad  $f(\alpha)$ , que permite caracterizar la distribución de los exponentes de Hölder  $\alpha$ . Estos exponentes están asociados a las distintas estructuras locales de la serie de retornos del índice STOXX Global AI. La forma cóncava de la curva, con un máximo claro y una caída simétrica hacia ambos lados, es indicativa de un comportamiento multifractal. En este tipo de comportamiento coexisten diferentes grados de regularidad y complejidad en la dinámica del precio.

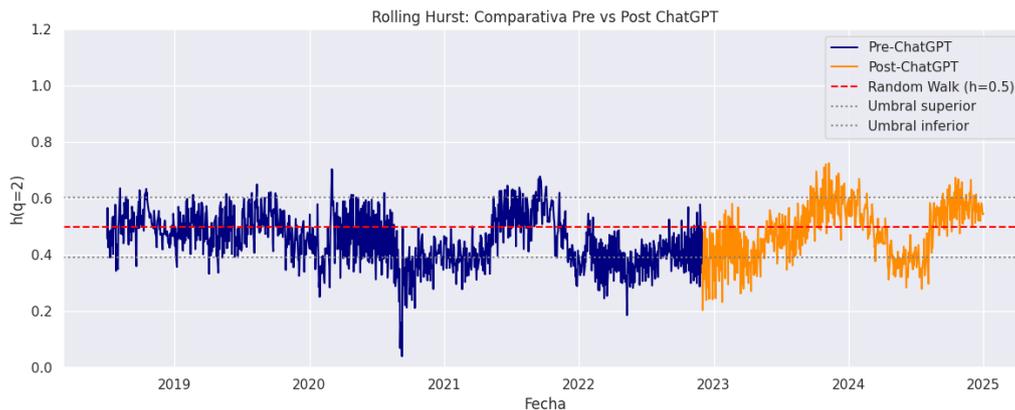
El espectro alcanza su valor máximo alrededor de  $\alpha \approx 0.6$ , lo que sugiere que esa es la regularidad dominante en la serie temporal. La anchura del espectro, medida como la diferencia entre los valores máximos y mínimos de  $\alpha$ , proporciona información sobre la amplitud de las singularidades presentes. En este caso, la amplitud relativamente alta indica una heterogeneidad estructural significativa en los retornos del índice.

Desde una perspectiva económica, esta distribución amplia de regularidades implica que el índice no está regido por una dinámica única o homogénea. Más bien, responde a una superposición de comportamientos locales con distintos niveles de persistencia y volatilidad. Este resultado apoya la hipótesis de que la irrupción de herramientas como ChatGPT ha intensificado la complejidad informacional del mercado, dando lugar a una estructura de precios

más fragmentada y multifacética<sup>30</sup>. El espectro de singularidad actúa así como un reflejo cuantitativo de esta complejidad creciente en la era de la IA.



**Figura 7: Rolling Hurst**



**Figura 8: Rolling Hurst: Pre/Post ChatGPT**

Las Figuras 7 y 8 muestran la evolución del exponente de Hurst de segundo orden  $h(q=2)$  a lo largo del tiempo mediante una ventana móvil. Esto permite comparar los periodos previos y posteriores al lanzamiento de ChatGPT. La serie en azul corresponde al periodo anterior a diciembre de 2022, mientras que la serie en naranja representa el periodo posterior. La línea discontinua roja indica el valor de referencia de un Random Walk ( $h=0.5$ ), mientras

<sup>30</sup> Que presenta muchas caras o aspectos distintos; en este contexto, indica una estructura de precios compleja y diversa.

que las líneas punteadas grises representan un umbral superior e inferior para identificar persistencia o anti-persistencia significativa.

Durante el periodo pre-ChatGPT, los valores de  $h(q=2)$  fluctúan mayoritariamente en torno al valor teórico del Random Walk, con episodios puntuales de comportamiento más persistente o anti-persistente. Sin embargo, a partir del lanzamiento de ChatGPT, se observa un cambio estructural: el exponente se mantiene sistemáticamente por encima de 0.5, con una tendencia creciente y valores más estables. Esto indica un comportamiento persistentemente autocorrelacionado<sup>31</sup> en los retornos del índice.

Desde una perspectiva económica, este cambio sugiere que la irrupción de la IA generativa ha inducido una alteración significativa en la estructura dinámica del mercado. La persistencia observada post-ChatGPT puede interpretarse como una señal de mayor coordinación en las expectativas de los inversores y una narrativa común en torno al potencial transformador de la IA. Este comportamiento refuerza de forma clara la hipótesis del trabajo: el impacto de la IA en el mercado no ha sido meramente coyuntural, sino estructural, afectando directamente a la eficiencia temporal de los precios.

## **5.2. Empresas semiconductoras del STOXX Global AI**

### **5.2.1. Posición en la industria**

Para complementar el análisis multifractal y dar mayor profundidad a la interpretación económica de los resultados, esta sección presenta una caracterización visual de las empresas semiconductoras incluidas en el índice STOXX Global AI. El objetivo es mostrar gráficamente cómo varía su grado de exposición a la IA, su evolución temporal y su relevancia estructural en el ecosistema del índice.

---

<sup>31</sup> Significa que los valores pasados influyen en los futuros; en este caso, los retornos del índice muestran dependencia temporal sostenida.

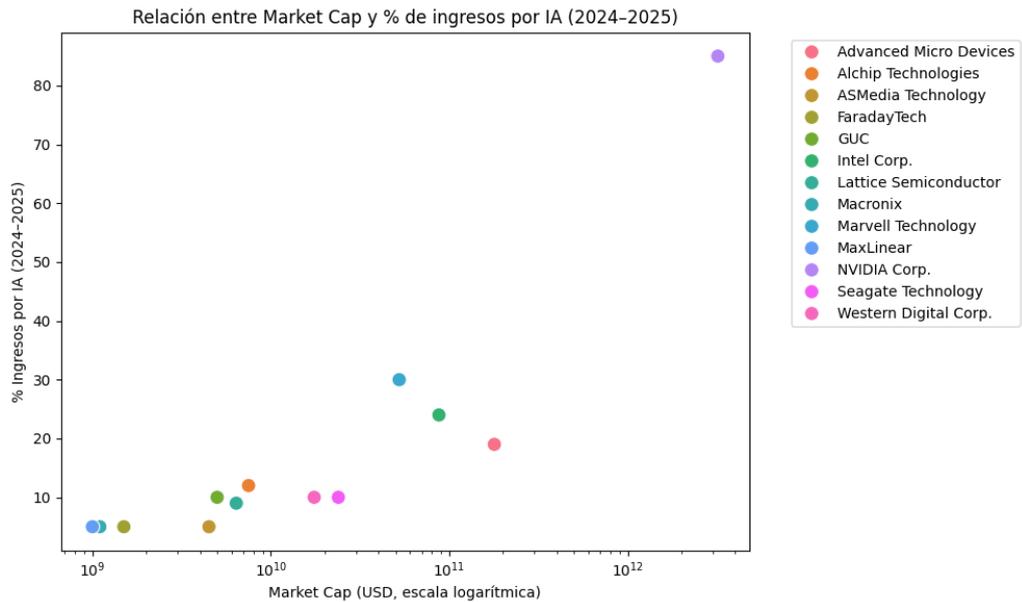
**Tabla 4: Empresas de la industria de los semiconductores pertenecientes al STOXX Global AI**

| Company                     | Supersector | Country | Weight (%) | Semiconductor | Ticker  |
|-----------------------------|-------------|---------|------------|---------------|---------|
| ADVANCED MICRO DEVICES      | Technology  | USA     | 3.45748    | YES           | AMD     |
| ALCHIP TECHNOLOGIES         | Technology  | Taiwan  | 0.9614     | YES           | 3661.TW |
| ASMEDIA TECHNOLOGY          | Technology  | Taiwan  | 0.24374    | YES           | 5269.TW |
| Faraday Tech                | Technology  | Taiwan  | 0.31166    | YES           | 3035.TW |
| GUC                         | Technology  | Taiwan  | 0.49291    | YES           | GENI    |
| Intel Corp.                 | Technology  | USA     | 3.0537     | YES           | INTC    |
| LATTICE SEMICONDUCTOR       | Technology  | USA     | 1.19706    | YES           | LSCC    |
| Macronix                    | Technology  | Taiwan  | 0.21825    | YES           | 2337.TW |
| MARVELL TECHNOLOGY          | Technology  | USA     | 3.82973    | YES           | MRVL    |
| MAXLINEAR                   | Technology  | USA     | 0.13304    | YES           | MXL     |
| NVIDIA Corp.                | Technology  | USA     | 11.00656   | YES           | NVDA    |
| SEAGATE TECHNOLOGY HOLDINGS | Technology  | USA     | 3.28358    | YES           | STX     |
| Western Digital Corp.       | Technology  | USA     | 3.73538    | YES           | WDC     |

**Tabla 5: Datos clave sobre la exposición a la IA en empresas semiconductoras dentro del índice STOXX Global AI**

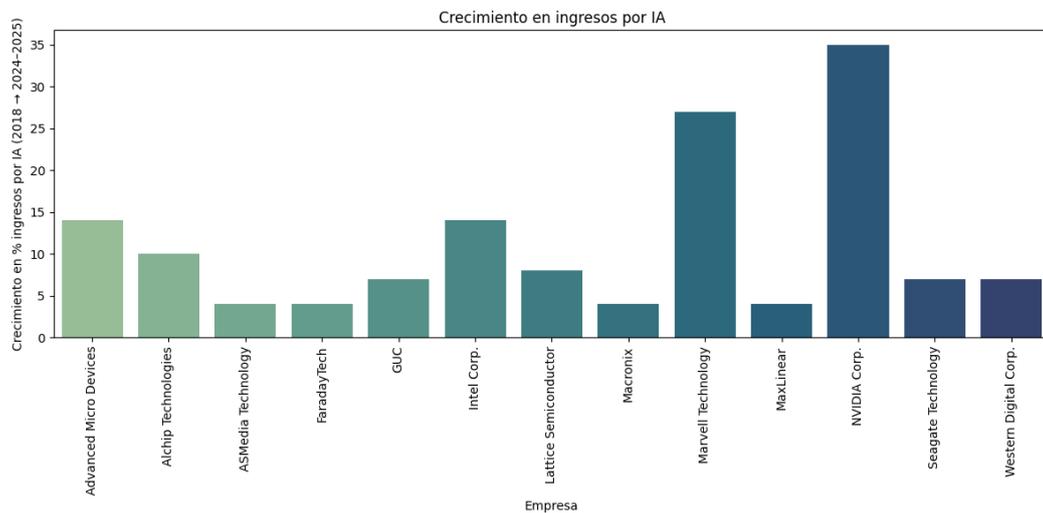
| Empresa                | País   | Market Cap (USD) | Parte de la Supply Chain                   | Exposición a IA (2018) | Exposición a IA (2024–2025) | % IA 2018 | % IA 2024–2025 |
|------------------------|--------|------------------|--|------------------------|-----------------------------|-----------|----------------|
| Advanced Micro Devices | USA    | \$178.9 B        | Diseño de chips (fabless)                  | Moderada               | Alta                        | 5         | 19             |
| Alchip Technologies    | Taiwán | \$7.5 B          | Diseño ASIC / Backend services             | Baja                   | Alta                        | 2         | 12             |
| ASMedia Technology     | Taiwán | \$4.5 B          | Diseño de chips (fabless)                  | Baja                   | Moderada                    | 1         | 5              |
| FaradayTech            | Taiwán | \$1.5 B          | Diseño IP y SoC (fabless)                  | Baja                   | Moderada                    | 1         | 5              |
| GUC                    | Taiwán | \$5 B            | Backend IC design / ASIC services          | Baja                   | Alta                        | 3         | 10             |
| Intel Corp.            | USA    | \$87.5 B         | IDM (Diseño + Fabricación + Ensamblaje)    | Moderada               | Alta                        | 10        | 24             |
| Lattice Semiconductor  | USA    | \$6.4 B          | Diseño de chips FPGA (fabless)             | Baja                   | Alta                        | 1         | 9              |
| Macronix               | Taiwán | \$1.1 B          | IDM (memorias NOR/NAND flash)              | Baja                   | Moderada                    | 1         | 5              |
| Marvell Technology     | USA    | \$52.4 B         | Diseño de chips (fabless)                  | Moderada               | Alta                        | 3         | 30             |
| MaxLinear              | USA    | \$1.0 B          | Diseño de chips (fabless)                  | Baja                   | Moderada                    | 1         | 5              |
| NVIDIA Corp.           | USA    | \$3.20 T         | Diseño de chips (fabless)                  | Alta                   | Muy alta                    | 50        | 85             |
| Seagate Technology     | USA    | \$23.9 B         | Ensamblaje de almacenamiento (HDD)         | Baja                   | Moderada                    | 3         | 10             |
| Western Digital Corp.  | USA    | \$17.5 B         | Ensamblaje y fabricación (memorias y HDDs) | Baja                   | Moderada                    | 3         | 10             |

La **Figura 9** muestra la relación entre la capitalización bursátil (en escala logarítmica) y el porcentaje de ingresos provenientes de actividades relacionadas con IA en el periodo 2024–2025. Se observa una correlación positiva entre ambos ejes, destacando el liderazgo de NVIDIA Corp., que combina un tamaño de mercado excepcional con una altísima concentración de ingresos por IA (85 %). Empresas como Intel Corp. y Marvell Technology también presentan posiciones intermedias con perfiles estratégicos relevantes.



**Figura 9: Relación entre capitalización bursátil e ingresos por IA (2024–2025)**

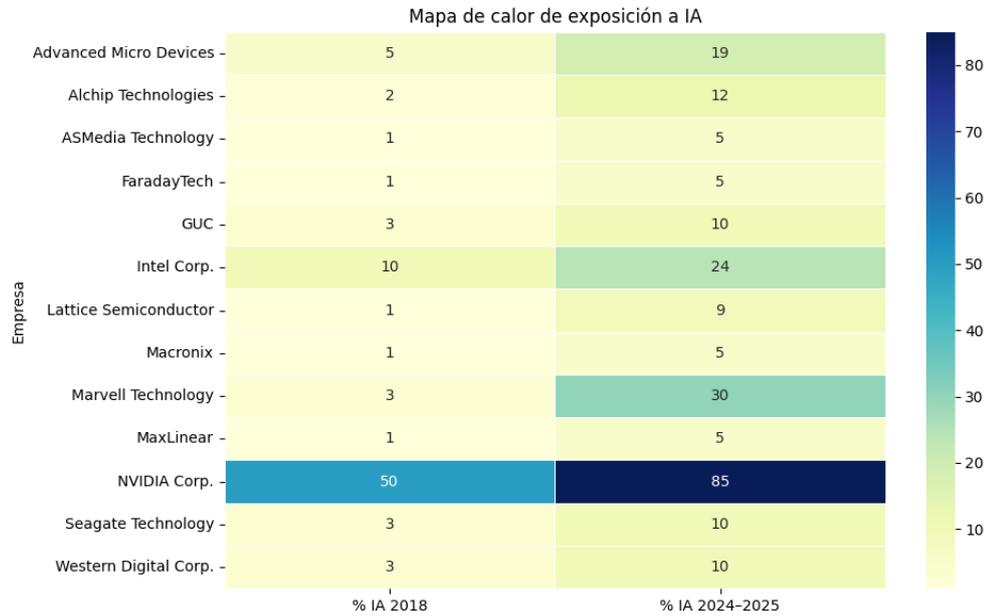
La **Figura 10** muestra el crecimiento porcentual de los ingresos relacionados con IA entre 2018 y 2025. Este dato permite identificar qué empresas han cambiado su enfoque hacia productos y soluciones basados en IA. Una vez más, NVIDIA y Marvell lideran con los mayores aumentos, seguidas por Intel y AMD, lo que confirma su papel como motores del avance tecnológico en el sector.



**Figura 10: Crecimiento en ingresos IA entre 2018 y 2025**

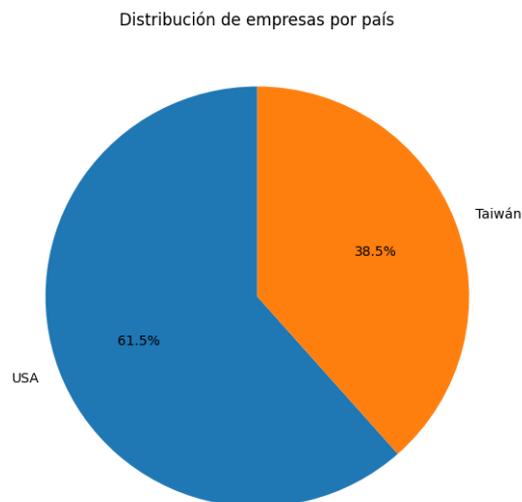
La **Figura 11** sintetiza la exposición a IA mediante un mapa de calor que compara los porcentajes de ingresos por IA en 2018 y 2025 para cada empresa. Este formato permite visualizar tanto el punto de partida como el nivel alcanzado tras el auge de la IA generativa. La heterogeneidad es notable: mientras compañías como ASMedia, Macronix o MaxLinear

muestran crecimientos limitados, otras como NVIDIA, Marvell o Intel han triplicado o cuadruplicado su nivel de exposición.



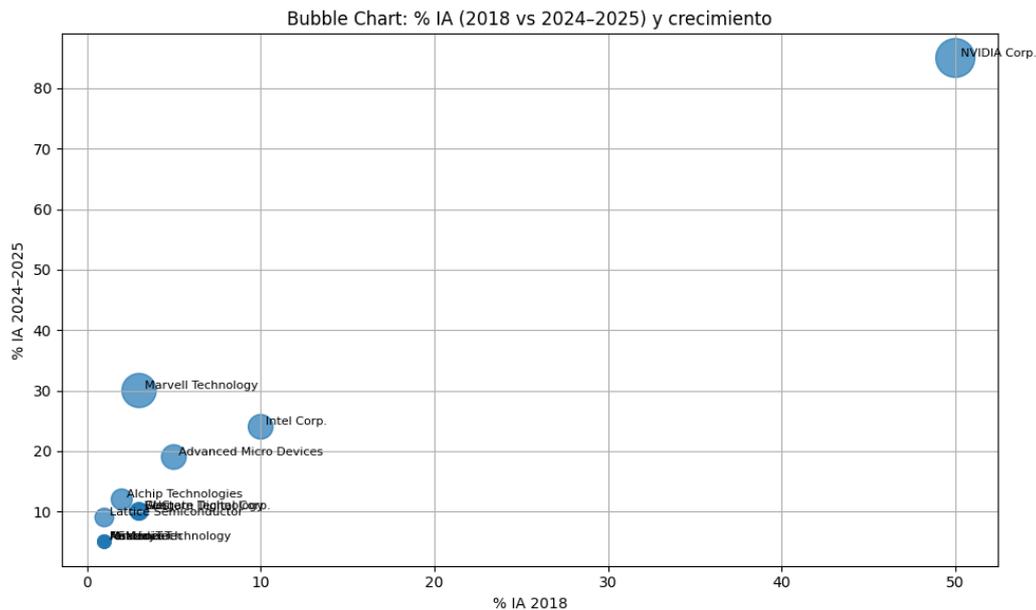
**Figura 11: Evolución de la exposición a ingresos por IA (2018 vs. 2024–2025)**

Desde una perspectiva geoestratégica, la **Figura 12** muestra la distribución geográfica de las empresas semiconductoras analizadas. El 61,5 % de ellas tienen sede en Estados Unidos, mientras que el 38,5 % se ubican en Taiwán. Esto subraya la concentración industrial en dos polos clave y refuerza el vínculo entre esta dinámica y las tensiones en torno a la soberanía tecnológica global.



**Figura 12: Distribución geográfica de las empresas semiconductoras**

Por último, la **Figura 13** presenta un gráfico de burbujas que combina el porcentaje de ingresos por IA en 2018 (eje X), en 2025 (eje Y) y el tamaño del círculo como medida del crecimiento acumulado. Esta visualización permite identificar rápidamente qué empresas han tenido una transformación más significativa, ilustrando con claridad la trayectoria ascendente de empresas como NVIDIA y Marvell, frente a otras con evolución más modesta.



**Figura 13: Comparativa de exposición a IA en 2018 vs. 2024–2025 y ritmo de crecimiento**

En conjunto, estas representaciones gráficas aportan contexto estructural y dinámico al análisis multifractal desarrollado en este trabajo. Ayudan a interpretar las diferencias en los patrones de eficiencia observados, vinculando la complejidad estadística de los retornos con las realidades económicas y estratégicas de cada empresa. Además, permiten reforzar una de las conclusiones clave: que el impacto de la IA en los mercados financieros no ha sido uniforme. Ha estado profundamente condicionado por el perfil y evolución de cada actor dentro del ecosistema tecnológico.

### 5.2.2. Análisis de eficiencia individual: Rolling Hurst por empresa

Tras el análisis agregado del índice STOXX Global AI, se realiza en esta sección un desglose detallado del comportamiento del Rolling Hurst. Este se ha aplicado de forma individual a las 13 empresas semiconductoras que lo componen. El objetivo es identificar qué empresas siguen un patrón de eficiencia similar al índice y cuáles presentan desviaciones

notables. Estas diferencias pueden indicar estructuras multifractales más marcadas o procesos de reversión distintos al conjunto del mercado.

La **Figura 14** muestra el Rolling Hurst para cada una de estas empresas, diferenciando el periodo pre-ChatGPT (en azul) y post-ChatGPT (en naranja). Las líneas horizontales marcan las bandas teóricas de eficiencia (0.392 – 0.603) definidas en el análisis del índice completo.

Algunas empresas presentan una trayectoria del exponente de Hurst que oscila en torno a las bandas de eficiencia, sin rupturas estructurales bruscas. Este comportamiento sugiere que estas compañías replican en gran medida la dinámica del índice, lo que podría deberse a su tamaño relativo, su liquidez o una exposición más estable a la IA. En este grupo se incluyen:

- **Advanced Micro Devices (AMD)**
- **Lattice Semiconductor**
- **Marvell Technology**
- **Western Digital Corp.**

En estos casos, el Rolling Hurst se mantiene contenido y muestra una transición progresiva entre ambos periodos temporales, sin fuertes picos de persistencia o antipersistencia.

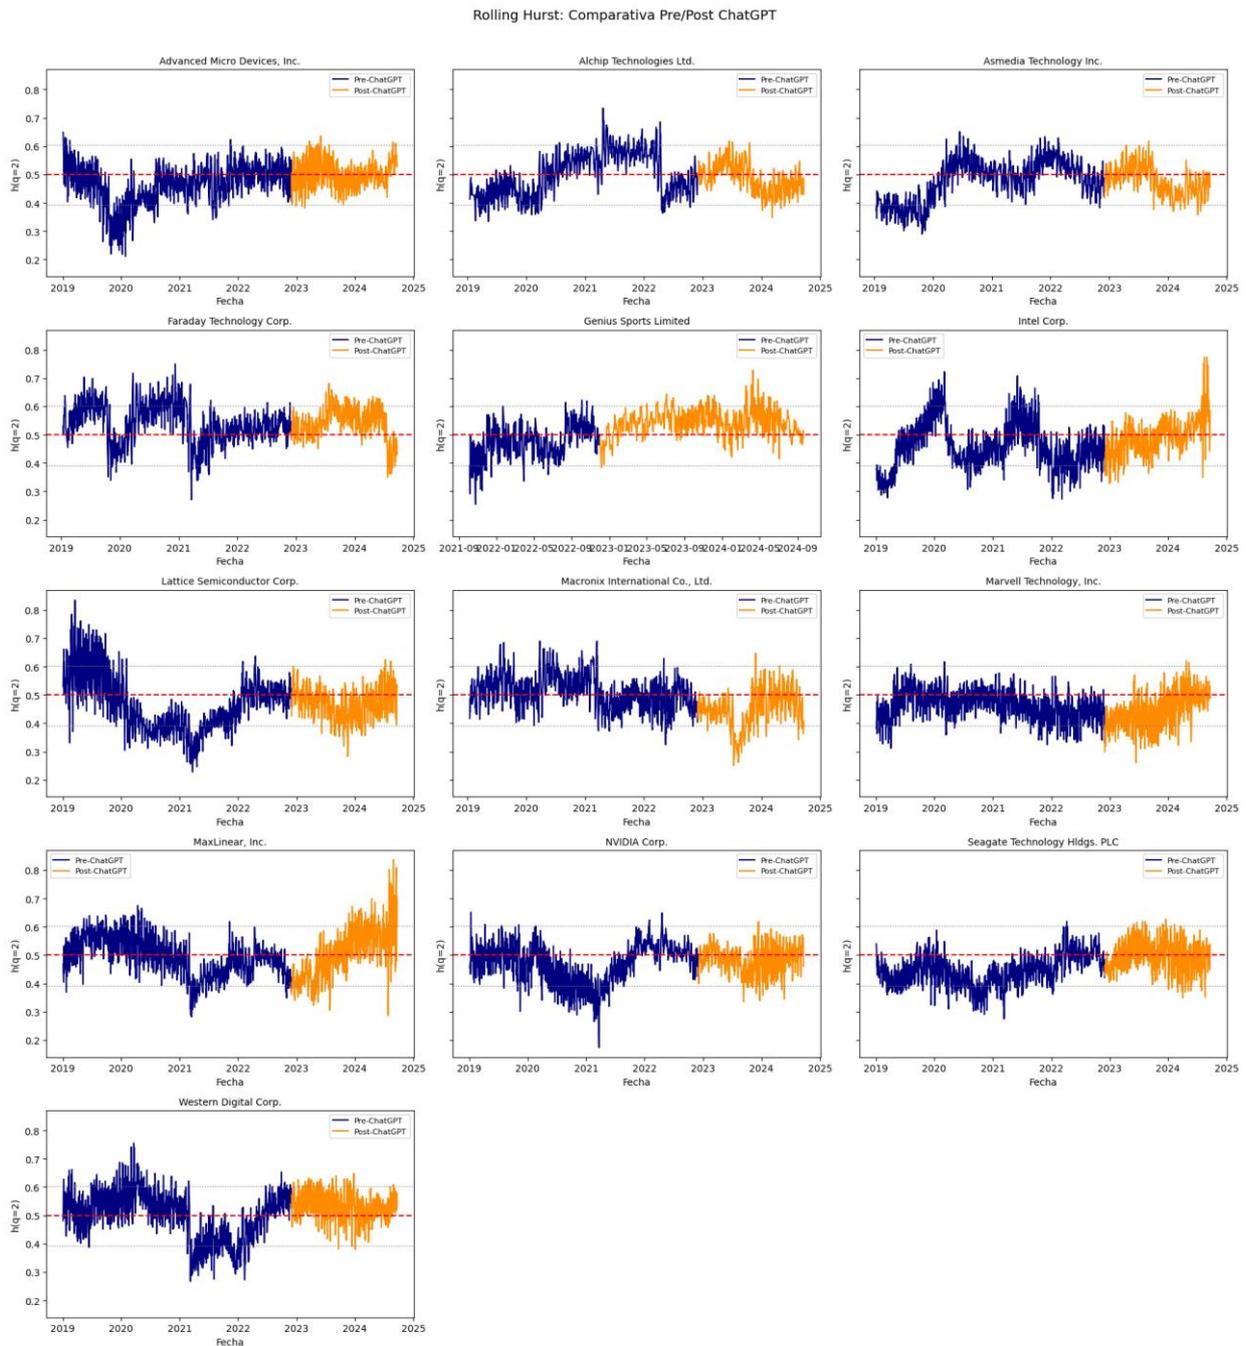
Por otro lado, algunas compañías presentan patrones más extremos, con valores del exponente de Hurst que se sitúan de forma consistente por fuera de las bandas de eficiencia, especialmente tras el evento ChatGPT. Este comportamiento puede reflejar cambios estructurales abruptos en los retornos, posibles efectos especulativos o una mayor sensibilidad a shocks de demanda tecnológica. Destacan en este grupo:

- **ASMedia**
- **FaradayTech**
- **Genius Sports**
- **Intel**
- **Macronix**
- **MaxLinear**
- **NVIDIA Corp.**
- **Seagate Technology**

La divergencia observada entre estas empresas sugiere que la eficiencia del mercado no se distribuye de forma homogénea entre los componentes del índice. Las empresas líderes con alta exposición a IA y gran capitalización tienden a mostrar un comportamiento más estable.

En cambio, las firmas de menor tamaño o con perfiles más especulativos presentan patrones multifractales más extremos.

Este resultado refuerza la idea de que los efectos del evento ChatGPT no solo afectan a nivel índice. También producen asimetrías estructurales en el comportamiento individual de los activos, las cuales pueden ser captadas eficientemente por herramientas como el Rolling Hurst y el MF-DFA.



**Figura 14: Rolling Hurst por empresa semiconductor: antes y después de ChatGPT**

## 6. CONCLUSIONES

Este trabajo ha analizado la eficiencia de mercado del índice STOXX Global AI antes y después del lanzamiento de ChatGPT, aplicando el método MF-DFA para captar dinámicas complejas en los retornos financieros. El estudio se enmarca en un contexto de aceleración tecnológica, creciente protagonismo de la IA y transformación estructural de los mercados bursátiles. A partir de una aproximación empírica y cuantitativa, se identifican tres ideas clave sobre eficiencia y tres implicaciones relevantes para el sector de los semiconductores.

### 1. Tres ideas clave sobre eficiencia de mercado

#### **(1) La eficiencia del índice no es absoluta, sino relativa y evolutiva.**

El análisis multifractal revela que el comportamiento del índice STOXX Global AI se aleja de la eficiencia fuerte postulada por la EMH. La persistencia de correlaciones de largo plazo, la presencia de multifractalidad y la variabilidad temporal del exponente de Hurst indican una eficiencia parcial, sujeta a las condiciones informativas y estructurales del mercado.

#### **(2) El lanzamiento de ChatGPT marca un punto de inflexión estadístico y estructural.**

Los resultados muestran un aumento sostenido del exponente  $h(q=2)$  posterior al evento, acompañado de una reducción transitoria de la multifractalidad en 2023. Esta dinámica refleja un periodo de alineación de expectativas, narrativa compartida y mayor previsibilidad en los retornos, que altera temporalmente la estructura informacional del mercado.

#### **(3) La eficiencia en mercados tecnológicos es sensible a ciclos de innovación y percepción colectiva.**

El comportamiento del índice responde a una lógica adaptativa, en la que la difusión de tecnologías disruptivas genera fases de mayor o menor complejidad. Esta eficiencia dinámica depende del grado de madurez del ecosistema tecnológico, la heterogeneidad de los actores y el contexto narrativo que rodea a la innovación.

## 2. Tres implicaciones futuras para el sector

### **(1) Los semiconductores como núcleo del nuevo régimen informacional.**

Las empresas del sector se consolidan como infraestructuras críticas para el desarrollo de la IA. Su peso creciente en la narrativa tecnológica las convierte en activos estratégicos, altamente sensibles a disrupciones informativas y especulativas.

### **(2) Necesidad de adaptación a métricas dinámicas de riesgo y eficiencia.**

Los fabricantes de semiconductores deberán complementar los análisis fundamentales con herramientas que capten la evolución multifractal de los precios. En un entorno donde la eficiencia no es constante, entender la persistencia y la complejidad de los retornos será clave para anticipar movimientos de mercado.

### **(3) Exposición creciente a ciclos de euforia tecnológica y sobrevaloración.**

El alineamiento de expectativas en torno a la IA puede generar burbujas narrativas en torno a determinados actores del sector. Esto obliga a vigilar los ciclos de exceso de confianza, la concentración informativa y los riesgos asociados a valoraciones disociadas de los fundamentales.

En conclusión, los resultados de este estudio evidencian que la IA no solo transforma sectores productivos, sino que también modifica las reglas de funcionamiento del mercado financiero. En este nuevo entorno, la eficiencia deja de ser un supuesto estático para convertirse en un proceso dinámico, moldeado por la tecnología, la información y el comportamiento colectivo de los agentes económicos.

## 7. 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, Alejandro Portellano Rodríguez, estudiante de [nombre del título] de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "ANÁLISIS DE LA EFICIENCIA DE MERCADO DEL ÍNDICE STOXX GLOBAL AI ANTES Y DESPUÉS DE CHATGPT MEDIANTE MF-DFA, CON ENFOQUE EN SEMICONDUCTORES ", 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 [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir "no he usado ninguna"]:

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

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Fecha: 18 de Junio de 2025

Firma: Alejandro Portellano Rodríguez

## 8. BIBLIOGRAFÍA

- Al-Harbi, A. T. (2025). *Impact of AI on market efficiency and stability*. International Journal of Science and Research Archive, 14(1), 552–560. <https://doi.org/10.30574/ijrsra.2025.14.1.0128>
- Ali, S., Raza, S. A., & Khan, K. A. (2023). *Asymmetric market efficiency of the Eurozone using the MF-DFA: a comparison between global financial crisis and COVID-19 era*. European Journal of Management and Business Economics, 32(2), 145–172. <https://doi.org/10.1108/EJMBE-04-2021-0116>
- Asness, C. (2024, March 8). *AI is still just statistics*. Financial Times. Recuperado de <https://www.ft.com/content/86eb1c4f-ef5f-4bf9-93b1-74a484dd4a20>
- Chen, Y., & Yu, J. (2011). *Efficient market hypothesis in the international oil price fluctuation: Based on the MF-DFA model*. International Journal of Global Energy Issues, 35(2/3/4), 275–286. <https://doi.org/10.1504/IJGEI.2011.045023>
- Conboye, J. (2025, March 6). Companies are failing to convince staff of AI benefits. Financial Times. Recuperado de <https://www.ft.com/janina-conboye>
- Datta, R. P. (2024). *Analysis of Indian Foreign Exchange Markets: A Multifractal Detrended Fluctuation Analysis (MFDFA) Approach*. International Journal of Empirical Economics, 3(3), 2450006. <https://doi.org/10.1142/S2810943024500069>
- Dodd, D. (2023, February 20). *ChatGPT hype sparks hopes and fears around AI*. Financial Times. Recuperado de <https://www.ft.com/content/5067361c-9dcc-43dd-8a0a-aed959cfb943>
- Farmer, J. D., Patelli, P., & Zovko, I. I. (2005). *The predictive power of zero intelligence in financial markets*. Proceedings of the National Academy of Sciences, 102(6), 2254–2259. <https://doi.org/10.1073/pnas.0409157102>
- Gorjão, D., Ferreira, C., Pinto, C. M., & Pereira, M. J. (2024). *Decoding Market Efficiency: A Multifractal Approach to Financial Market Dynamics*. Physica A: Statistical Mechanics and its Applications, 629, 129421. <https://doi.org/10.1016/j.physa.2023.129421>
- Ihlen, E. A. F. (2012). *Introduction to multifractal detrended fluctuation analysis in MATLAB*. Frontiers in Physiology, 3, 141. <https://doi.org/10.3389/fphys.2012.00141>

- Investopedia. (2024). *The Weak, Strong, and Semi-Strong Efficient Market Hypotheses*.  
<https://www.investopedia.com>
- Kantelhardt, J. W., Koscielny-Bunde, E., Rego, H. H. A., Havlin, S., & Bunde, A. (2001). *Detecting long-range correlations with detrended fluctuation analysis*. *Physica A: Statistical Mechanics and its Applications*, 295(3–4), 441–454.  
[https://doi.org/10.1016/S0378-4371\(01\)00144-3](https://doi.org/10.1016/S0378-4371(01)00144-3)
- 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)
- Kotecha, N. (2025). *Artificial Intelligence in the Stock Market: The Trends and Challenges Regarding AI-Driven Investments*. *Open Journal of Business and Management*, 13(2), 709–734. <https://doi.org/10.4236/ojbm.2025.132037>
- Miloş, L. R., Haşegan, C., Miloş, M. C., Barna, F. M., & Boţoc, C. (2020). *Multifractal Detrended Fluctuation Analysis (MF-DFA) of Stock Market Indexes: Empirical Evidence from Seven Central and Eastern European Markets*. *Sustainability*, 12(2), 535.  
<https://doi.org/10.3390/su12020535>
- Parikh, T. (2024, July 18). *The bear case for AI*. *Financial Times*. Recuperado de <https://www.ft.com/content/99d36d90-5d08-49e1-84f5-6981f44dd6ee>
- Peel, M. (2024, June 20). *Higher earners face greater AI exposure, study finds*. *Financial Times*.  
<https://www.ft.com/content/2b0cf734-1f20-44e5-8eea-0aeba650e416>
- Reiter, A., & Kim, H. (2025, May 21). *What to buy if AI is transformative*. *Financial Times*.  
Recuperado de <https://www.ft.com/content/b1dfa77b-cbc6-4274-9362-cffc21025d5c>
- Shrestha, K., Naysary, B., & Philip, S. S. S. (2023). *Fintech market efficiency: A multifractal detrended fluctuation analysis*. *Finance Research Letters*, 54, 103775.  
<https://doi.org/10.1016/j.frl.2023.103775>
- Strauss, D. (2023, March 27). *Generative AI set to affect 300mn jobs across major economies*. *Financial Times*. Recuperado de <https://www.ft.com/content/16342e5a-550e-46ae-a3d6-5244c140cb9b>

- Wigglesworth, R. (2023, February 22). *Wheeler of fortune: Remembering an EMH missionary*. Financial Times. Recuperado de <https://www.ft.com/content/3db33572-f644-11e9-9ef3-eca8fc8f2d65>
- Wigglesworth, R. (2024, August 30). *Economist Eugene Fama: 'Efficient markets is a hypothesis. It's not reality'*. Financial Times. <https://www.ft.com/content/94ef34a8-a3b7-4dc7-ba82-2abcb127d62e>
- Wu, D. (2024). The Use of AI and AI Algorithms in Financial Markets. Michigan Journal of Economics. <https://sites.lsa.umich.edu/mje/>

## 9. ANEXO I: Composición del índice STOXX Global AI: empresas constituyentes, país, sector y peso relativo (2024)

| Company                        | Supersector                   | Country     | Weight (%) | Semiconductor | Ticker             |
|--------------------------------|-------------------------------|-------------|------------|---------------|--------------------|
| ADVANCED MICRO DEVICES         | Technology                    | USA         | 3.45748    | YES           | AMD                |
| ALCHIP TECHNOLOGIES            | Technology                    | Taiwan      | 0.9614     | YES           | 3661.TW            |
| ALPHABET INC. CL A             | Technology                    | USA         | 10.77209   | NO            | GOOGL              |
| AMBARELLA                      | Technology                    | USA         | 0.33859    | NO            | AMBA               |
| ASMEDIA TECHNOLOGY             | Technology                    | Taiwan      | 0.24374    | YES           | 5269.TW            |
| Baidu Inc                      | Technology                    | China       | 2.14405    | NO            | BIDU               |
| BOX CL.A                       | Technology                    | USA         | 0.56592    | NO            | BOX                |
| CLARIVATE ANALYTICS            | Technology                    | USA         | 0.22164    | NO            | CLVT               |
| COGENT COMMS.HOLDINGS          | Telecommunications            | USA         | 0.34509    | NO            | CCOI               |
| COGNEX                         | Industrial Goods and Services | USA         | 1.25395    | NO            | CGNX               |
| Digital Realty Trust Inc.      | Real Estate                   | USA         | 4.43838    | NO            | DLR                |
| ELASTIC                        | Technology                    | USA         | 1.21539    | NO            | EQIX               |
| Equinix Inc.                   | Real Estate                   | USA         | 3.82721    | NO            | ESTC               |
| ESMT                           | Technology                    | Taiwan      | 0.1391     | NO            | ESMT               |
| Faraday Tech                   | Technology                    | Taiwan      | 0.31166    | YES           | 3035.TW            |
| GDS Holdings Ltd               | Technology                    | China       | 0.09809    | NO            | GDS                |
| GENIUS SPORTS                  | Travel and Leisure            | USA         | 0.09671    | NO            | 3443.TW            |
| GUC                            | Technology                    | Taiwan      | 0.49291    | YES           | GENI               |
| Intel Corp.                    | Technology                    | USA         | 3.0537     | YES           | INTC               |
| KINGDEE INT L SOFTWARE GP -100 | Technology                    | China       | 0.32527    | NO            | 0268.HK /<br>KGDEY |
| LATTICE SEMICONDUCTOR          | Technology                    | USA         | 1.19706    | YES           | LSCC               |
| Macronix                       | Technology                    | Taiwan      | 0.21825    | YES           | 2337.TW            |
| MARVELL TECHNOLOGY             | Technology                    | USA         | 3.82973    | YES           | MRVL               |
| MAXLINEAR                      | Technology                    | USA         | 0.13304    | YES           | MXL                |
| META PLATFORMS CLASS A         | Technology                    | USA         | 7.78461    | NO            | META               |
| Microsoft Corp.                | Technology                    | USA         | 8.85898    | NO            | MSFT               |
| MICROSTRATEGY                  | Technology                    | USA         | 3.38486    | NO            | MSTR               |
| MICROVISION                    | Technology                    | USA         | 0.02802    | NO            | MVIS               |
| NANO X IMAGING                 | Health Care                   | USA         | 0.05882    | NO            | NNOX               |
| NetApp Inc.                    | Technology                    | USA         | 2.77951    | NO            | NTAP               |
| NEXTDC                         | Technology                    | Australia   | 0.92973    | NO            | NXT.AX             |
| NVIDIA Corp.                   | Technology                    | USA         | 11.00656   | YES           | NVDA               |
| Oracle Corp.                   | Technology                    | USA         | 5.59986    | NO            | ORCL               |
| Oracle Corp. Japan             | Technology                    | Japan       | 0.30933    | NO            | ORCL               |
| PINTEREST A                    | Technology                    | USA         | 3.94752    | NO            | PINS               |
| PURE STORAGE CL.A              | Technology                    | USA         | 1.87712    | NO            | PSTG               |
| RADNET                         | Health Care                   | USA         | 0.50271    | NO            | RDNT               |
| RAKUS                          | Technology                    | Japan       | 0.12256    | NO            | 3923.T             |
| SEAGATE TECHNOLOGY HOLDINGS    | Technology                    | USA         | 3.28358    | YES           | STX                |
| SNOWFLAKE A                    | Technology                    | USA         | 3.43925    | NO            | SNOW               |
| SOFTWAREONE HOLDING            | Technology                    | Switzerland | 0.17523    | NO            | SWON               |
| Teradata Corp.                 | Technology                    | USA         | 0.51108    | NO            | TDC                |
| Western Digital Corp.          | Technology                    | USA         | 3.73538    | YES           | WDC                |
| XERO                           | Technology                    | Australia   | 1.89706    | NO            | XRO                |
| YEXT                           | Technology                    | USA         | 0.08778    | NO            | YEXT               |

## 10. ANEXO II: Métricas MF-DFA año por año

### Métricas MF-DFA 2018

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 3.0473 | 2.0473 | -11.2363  | 2.3152   | -0.3394       |
| 1 | -4.0 | 2.9803 | 1.9803 | -8.9212   | 2.3354   | -0.4203       |
| 2 | -3.0 | 2.8552 | 1.8552 | -6.5656   | 2.3770   | -0.5655       |
| 3 | -2.0 | 2.5836 | 1.5836 | -4.1671   | 2.2403   | -0.3134       |
| 4 | -1.0 | 2.0851 | 1.0851 | -2.0851   | 1.2402   | 0.8448        |
| 5 | 1.0  | 1.5536 | 0.5536 | -0.4464   | 0.6679   | 1.1143        |
| 6 | 2.0  | 1.4593 | 0.4593 | -0.0814   | 0.3165   | 0.7144        |
| 7 | 3.0  | 1.3956 | 0.3956 | 0.1867    | 0.2459   | 0.5510        |
| 8 | 4.0  | 1.3526 | 0.3526 | 0.4104    | 0.2157   | 0.4522        |
| 9 | 5.0  | 1.3236 | 0.3236 | 0.6180    | 0.2076   | 0.4201        |

### Métricas MF-DFA 2020

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 2.3744 | 1.3744 | -7.8719   | 1.6151   | -0.2038       |
| 1 | -4.0 | 2.3142 | 1.3142 | -6.2567   | 1.6129   | -0.1948       |
| 2 | -3.0 | 2.2154 | 1.2154 | -4.6461   | 1.5852   | -0.1096       |
| 3 | -2.0 | 2.0431 | 1.0431 | -3.0863   | 1.4386   | 0.2090        |
| 4 | -1.0 | 1.7689 | 0.7689 | -1.7689   | 0.8535   | 0.9154        |
| 5 | 1.0  | 1.4742 | 0.4742 | -0.5258   | 0.5542   | 1.0800        |
| 6 | 2.0  | 1.4469 | 0.4469 | -0.1063   | 0.4021   | 0.9104        |
| 7 | 3.0  | 1.4261 | 0.4261 | 0.2784    | 0.3588   | 0.7980        |
| 8 | 4.0  | 1.4028 | 0.4028 | 0.6113    | 0.3108   | 0.6320        |
| 9 | 5.0  | 1.3800 | 0.3800 | 0.9000    | 0.2887   | 0.5434        |

### Métricas MF-DFA 2019

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 2.7905 | 1.7905 | -9.9527   | 2.0677   | -0.3856       |
| 1 | -4.0 | 2.7213 | 1.7213 | -7.8850   | 2.0703   | -0.3963       |
| 2 | -3.0 | 2.6040 | 1.6040 | -5.8120   | 2.0554   | -0.3542       |
| 3 | -2.0 | 2.3871 | 1.3871 | -3.7742   | 1.9154   | -0.0566       |
| 4 | -1.0 | 1.9813 | 0.9813 | -1.9813   | 1.1065   | 0.8747        |
| 5 | 1.0  | 1.5454 | 0.5454 | -0.4546   | 0.6656   | 1.1202        |
| 6 | 2.0  | 1.5078 | 0.5078 | 0.0156    | 0.4480   | 0.8803        |
| 7 | 3.0  | 1.4804 | 0.4804 | 0.4413    | 0.4014   | 0.7630        |
| 8 | 4.0  | 1.4546 | 0.4546 | 0.8185    | 0.3538   | 0.5967        |
| 9 | 5.0  | 1.4298 | 0.4298 | 1.1489    | 0.3305   | 0.5034        |

### Métricas MF-DFA 2021

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 2.6943 | 1.6943 | -9.4714   | 1.9998   | -0.5277       |
| 1 | -4.0 | 2.6179 | 1.6179 | -7.4716   | 2.0067   | -0.5551       |
| 2 | -3.0 | 2.4860 | 1.4860 | -5.4581   | 1.9867   | -0.5021       |
| 3 | -2.0 | 2.2491 | 1.2491 | -3.4981   | 1.7806   | -0.0631       |
| 4 | -1.0 | 1.8969 | 0.8969 | -1.8969   | 1.0062   | 0.8907        |
| 5 | 1.0  | 1.5205 | 0.5205 | -0.4795   | 0.6041   | 1.0836        |
| 6 | 2.0  | 1.4577 | 0.4577 | -0.0845   | 0.3712   | 0.8270        |
| 7 | 3.0  | 1.4210 | 0.4210 | 0.2630    | 0.3399   | 0.7567        |
| 8 | 4.0  | 1.3988 | 0.3988 | 0.5953    | 0.3293   | 0.7218        |
| 9 | 5.0  | 1.3843 | 0.3843 | 0.9215    | 0.3263   | 0.7099        |

### Métricas MF-DFA 2022

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 2.5444 | 1.5444 | -8.7220   | 1.8377   | -0.4664       |
| 1 | -4.0 | 2.4711 | 1.4711 | -6.8843   | 1.8361   | -0.4600       |
| 2 | -3.0 | 2.3500 | 1.3500 | -5.0499   | 1.8062   | -0.3688       |
| 3 | -2.0 | 2.1359 | 1.1359 | -3.2719   | 1.6328   | 0.0062        |
| 4 | -1.0 | 1.7842 | 0.7842 | -1.7842   | 0.8810   | 0.9032        |
| 5 | 1.0  | 1.3711 | 0.3711 | -0.6289   | 0.4801   | 1.1091        |
| 6 | 2.0  | 1.3281 | 0.3281 | -0.3438   | 0.2671   | 0.8780        |
| 7 | 3.0  | 1.3018 | 0.3018 | -0.0947   | 0.2339   | 0.7964        |
| 8 | 4.0  | 1.2810 | 0.2810 | 0.1239    | 0.2057   | 0.6988        |
| 9 | 5.0  | 1.2633 | 0.2633 | 0.3166    | 0.1927   | 0.6468        |

### Métricas MF-DFA 2024

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 2.5051 | 1.5051 | -8.5256   | 1.7546   | -0.2476       |
| 1 | -4.0 | 2.4427 | 1.4427 | -6.7709   | 1.7525   | -0.2389       |
| 2 | -3.0 | 2.3402 | 1.3402 | -5.0206   | 1.7131   | -0.1186       |
| 3 | -2.0 | 2.1724 | 1.1724 | -3.3448   | 1.5486   | 0.2475        |
| 4 | -1.0 | 1.9234 | 0.9234 | -1.9234   | 0.9619   | 0.9615        |
| 5 | 1.0  | 1.5409 | 0.5409 | -0.4591   | 0.6231   | 1.0822        |
| 6 | 2.0  | 1.4730 | 0.4730 | -0.0541   | 0.3781   | 0.8103        |
| 7 | 3.0  | 1.4323 | 0.4323 | 0.2970    | 0.3343   | 0.7060        |
| 8 | 4.0  | 1.4037 | 0.4037 | 0.6146    | 0.3043   | 0.6026        |
| 9 | 5.0  | 1.3811 | 0.3811 | 0.9056    | 0.2910   | 0.5495        |

### Métricas MF-DFA 2023

|   | q    | slope  | h(q)   | $\tau(q)$ | $\alpha$ | D( $\alpha$ ) |
|---|------|--------|--------|-----------|----------|---------------|
| 0 | -5.0 | 1.9535 | 0.9535 | -5.7677   | 1.1217   | 0.1594        |
| 1 | -4.0 | 1.9115 | 0.9115 | -4.6461   | 1.1077   | 0.2153        |
| 2 | -3.0 | 1.8508 | 0.8508 | -3.5524   | 1.0563   | 0.3833        |
| 3 | -2.0 | 1.7667 | 0.7667 | -2.5334   | 0.9457   | 0.6420        |
| 4 | -1.0 | 1.6610 | 0.6610 | -1.6610   | 0.6853   | 0.9757        |
| 5 | 1.0  | 1.5224 | 0.5224 | -0.4776   | 0.5397   | 1.0173        |
| 6 | 2.0  | 1.4791 | 0.4791 | -0.0419   | 0.3845   | 0.8109        |
| 7 | 3.0  | 1.4305 | 0.4305 | 0.2914    | 0.2844   | 0.5617        |
| 8 | 4.0  | 1.3817 | 0.3817 | 0.5269    | 0.2007   | 0.2761        |
| 9 | 5.0  | 1.3386 | 0.3386 | 0.6929    | 0.1660   | 0.1372        |

*Fuente:* Elaboración propia

## 11. ANEXO III: Código Python MF-DFA STOXX Global AI

### 1. Carga y formateo desde Excel

```
# Paso 1: Subida del archivo CSV
from google.colab import files
import pandas as pd
uploaded = files.upload()

# Paso 2: Leer Excel y preparar columnas
filename = list(uploaded.keys())[0]
df = pd.read_excel(filename)

# Convertimos la columna de fecha al formato datetime
df['Date'] = pd.to_datetime(df['Date'], format='%A, %B %d, %Y')

# Ordenamos por fecha y seleccionamos solo 'Date' y 'Close'
df = df.sort_values('Date').reset_index(drop=True)
df = df[['Date', 'Close']]

# Vista previa
df.head()
```

### 2. Gráficos de precios y log-returns

```
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

sns.set(style="darkgrid")

# Cálculo de retornos logarítmicos
df['Log_Returns'] = np.log(df['Close'] / df['Close'].shift(1))
df = df.dropna().reset_index(drop=True)

# Gráfico 1: Evolución del índice
plt.Figura(figsize=(12, 5))
plt.plot(df['Date'], df['Close'], label='Precio de Cierre')
```

```

plt.title('Evolución del Índice STOXX Global AI')
plt.xlabel('Fecha')
plt.ylabel('Precio')
plt.tight_layout()
plt.show()

# Gráfico 2: Retornos logarítmicos
plt.Figura(figsize=(12, 5))
plt.plot(df['Date'], df['Log_Returns'], label='Log Returns', color='orange')
plt.title('Retornos Logarítmicos Diarios')
plt.xlabel('Fecha')
plt.ylabel('Log Return')
plt.tight_layout()
plt.show()

```

### 3. Tabla con métricas estadísticas de los log-returns

```

from scipy.stats import skew, kurtosis, jarque_bera

# Parámetros
risk_free_rate = 0.005
trading_days = 252

# Lista para guardar resultados
annual_stats = []

for year in sorted(df['Date'].dt.year.unique()):
    yearly_data = df[df['Date'].dt.year == year].copy()

    if len(yearly_data) < 100:
        continue # evitar años con pocos datos

    log_returns = yearly_data['Log_Returns'].dropna()

    ann_return = (np.exp(log_returns.sum()) - 1) * 100
    ann_vol = log_returns.std() * np.sqrt(trading_days) * 100

```

```

sharpe = ((ann_return / 100) - risk_free_rate) / (ann_vol / 100)
skewness = skew(log_returns)
kurt = kurtosis(log_returns)
jb_stat, jb_p = jarque_bera(log_returns)

annual_stats.append({
    'Año': year,
    'Rentabilidad anual (%)': ann_return,
    'Volatilidad anual (%)': ann_vol,
    'Sharpe ratio': sharpe,
    'Skewness': skewness,
    'Kurtosis': kurt,
    'JB stat': jb_stat,
    'JB p-value': jb_p
})

# Convertir a DataFrame
annual_stats_df = pd.DataFrame(annual_stats)

# Mostrar tabla
import IPython.display as display
display.display(annual_stats_df.round(3))

```

#### 4. MF-DFA para todo el periodo completo

```

!pip install MF DFA
from MF DFA import MF DFA
from numpy.polynomial.polynomial import polyfit

def get_mfdfa(data, q=None, order=1, lag_start=3, lag_end=None, lag_steps=50):
    def _integrate(series):
        return (series - np.mean(series)).cumsum()

    if lag_end is None:
        lag_end = len(data) // 6

```

```

# Escalas (segmentos)
lags = np.unique(np.logspace(np.log10(lag_start), np.log10(lag_end),
lag_steps).astype(int))

# Valores de q
if q is None:
    q = np.linspace(-5, 5, 11)
    q = q[q != 0.0] # se excluye q=0

# Integrar serie
y = _integrate(data)

# Ejecutar MFDFA
lag, dfa = MFDFA(y, lag=lags, q=q, order=order)

# Ajuste lineal para estimar pendiente y Hurst
start, end = 0, int(0.6 * len(lag))
slope = polyfit(np.log10(lag[start:end]), np.log10(dfa[start:end]), 1)[1]
hq = slope - 1
tau = q * hq - 1
alpha = np.gradient(tau) / np.gradient(q)
Dalphi = q * alpha - tau

# Resultados en DataFrame
mfdfa_df = pd.DataFrame({
    'q': q,
    'slope': slope,
    'h(q)': hq,
    'τ(q)': tau,
    'α': alpha,
    'D(α)': Dalphi
})

return q, lag, dfa, mfdfa_df

# Aplicar MF-DFA a los log returns completos

```

```

log_returns = df['Log_Returns'].values
q, lag, dfa, mfdfa_df = get_mfdfa(log_returns)

# Mostrar tabla de resultados
import IPython.display as display
display.display(mfdfa_df)

# Diccionario para guardar cada tabla anual por nombre
mfdfa_por_año = {}

for year in sorted(df['Date'].dt.year.unique()):
    year_data = df[df['Date'].dt.year == year]['Log_Returns'].dropna().values

    if len(year_data) < 100:
        continue # Evitar años con pocos datos

    try:
        q, lag, dfa, mfdfa_df_year = get_mfdfa(year_data)

        # Guardar la tabla con nombre personalizado
        mfdfa_por_año[f'mfdfa_{year}'] = mfdfa_df_year.copy()

    except Exception as e:
        print(f'Error en el año {year}: {e}')

for nombre, tabla in mfdfa_por_año.items():
    print(f'\n {nombre}')
    display.display(tabla.round(4))

```

## 5. MF-DFA año por año (tabla comparativa)

```

# Crear lista para almacenar resultados anuales
results_yearly = []

years = df['Date'].dt.year.unique()

```

```

for year in years:
    year_data = df[df['Date'].dt.year == year]['Log_Returns'].dropna().values

    if len(year_data) < 100: # mínimo de datos para estabilidad
        continue

    q, lag, dfa, mfdfa_df = get_mfdfa(year_data)

    delta_hq = mfdfa_df['h(q)'].max() - mfdfa_df['h(q)'].min()
    delta_alpha = mfdfa_df['α'].max() - mfdfa_df['α'].min()

    results_yearly.append({
        'Año': year,
        'max h(q)': round(mfdfa_df['h(q)'].max(), 4),
        'min h(q)': round(mfdfa_df['h(q)'].min(), 4),
        'Δh(q)': round(delta_hq, 4),
        'max α': round(mfdfa_df['α'].max(), 4),
        'min α': round(mfdfa_df['α'].min(), 4),
        'Δα': round(delta_alpha, 4)
    })

# Crear DataFrame y mostrar
results_df = pd.DataFrame(results_yearly)
display.display(results_df)

```

## 6. Visualizaciones finales

### 6.1. Rolling Hurst (q=2)

```

print("Tamaño del rolling_h:", len(rolling_h))
print("Primeros valores no nulos:\n", rolling_h.dropna().head())

# Paso 1: Rolling Hurst robusto
def rolling_hurst_robusto(df, window=126): # usar 126 si no hay 252 datos
    series = df['Log_Returns'].dropna().values
    fechas = df['Date'].values
    hurst_vals = []

```

```

fechas_validas = []

for i in range(window, len(series)):
    ventana = series[i - window:i]
    try:
        q = np.array([-2, 2])
        _, _, _, mfdfa_df = get_mfdfa(ventana, q=q)
        hq_2 = mfdfa_df[mfdfa_df['q'] == 2]['h(q)'].values[0]
        hurst_vals.append(hq_2)
        fechas_validas.append(fechas[i])
    except Exception as e:
        # print(f"Error en ventana {i}: {e}") # para debug
        continue

if not hurst_vals:
    print("No se ha podido calcular ningún valor de Hurst.")
else:
    print(f"Rolling Hurst calculado con {len(hurst_vals)} valores.")

return pd.Series(hurst_vals, index=pd.to_datetime(fechas_validas))

# Aplicar
rolling_h = rolling_hurst_robusto(df)

# Diagnóstico rápido
print("Primeros valores de rolling_h:\n", rolling_h.head())

# Paso 2: Graficar con bandas
plt.Figura(figsize=(12, 5))
plt.plot(rolling_h.index, rolling_h, label='Hurst Exponent (q=2)', color='blue')
plt.axhline(0.5, color='red', linestyle='--', label='Random Walk (h=0.5)')
plt.axhline(0.603, color='gray', linestyle=':', label='Umbral superior (ineficiencia)')
plt.axhline(0.392, color='gray', linestyle=':', label='Umbral inferior (ineficiencia)')
plt.ylim(0, 1.2)
plt.title('Rolling Hurst Exponent')
plt.xlabel('Fecha')

```

```

plt.ylabel('h(q=2)')
plt.legend()
plt.tight_layout()
plt.show()

# Fechas clave
fecha_corte = pd.to_datetime('2022-11-30')

# Separar los valores de Hurst por periodo
rolling_pre = rolling_h[rolling_h.index <= fecha_corte]
rolling_post = rolling_h[rolling_h.index > fecha_corte]

# Gráfico comparativo
plt.Figura(figsize=(12, 5))
plt.plot(rolling_pre.index, rolling_pre, label='Pre-ChatGPT', color='navy')
plt.plot(rolling_post.index, rolling_post, label='Post-ChatGPT', color='darkorange')
plt.axhline(0.5, color='red', linestyle='--', label='Random Walk (h=0.5)')
plt.axhline(0.603, color='gray', linestyle=':', label='Umbral superior')
plt.axhline(0.392, color='gray', linestyle=':', label='Umbral inferior')
plt.ylim(0, 1.2)
plt.title('Rolling Hurst: Comparativa Pre vs Post ChatGPT')
plt.xlabel('Fecha')
plt.ylabel('h(q=2)')
plt.legend()
plt.tight_layout()
plt.show()

# Estadísticas resumen
stats_df = pd.DataFrame({
    'Periodo': ['Pre-ChatGPT', 'Post-ChatGPT'],
    'Media h(q=2)': [rolling_pre.mean(), rolling_post.mean()],
    'Desviación estándar': [rolling_pre.std(), rolling_post.std()],
    'Nº observaciones': [len(rolling_pre), len(rolling_post)]
})

import IPython.display as display

```

```
display.display(stats_df.round(4))
```

## 6.2. Fluctuation analysis $F_q(s)$

```
plt.Figura(figsize=(8, 6))
for i, q_val in enumerate(q):
    plt.loglog(lag, dfa[:, i], '.', label=f'q={q_val:.1f}')
plt.title('Fluctuation Functions:  $F_q(s) \sim s^{h(q)}$ ')
plt.xlabel('Escala  $s$ ')
plt.ylabel(' $F_q(s)$ ')
plt.legend()
plt.tight_layout()
plt.show()
```

## 6.3. Generalized Hurst Exponents $h(q)$

```
plt.Figura(figsize=(8, 5))
plt.plot(mfdfa_df['q'], mfdfa_df['h(q)'], marker='o')
plt.title('Generalized Hurst Exponent  $h(q)$ ')
plt.xlabel('$q$')
plt.ylabel('$h(q)$')
plt.grid(True)
plt.tight_layout()
plt.show()
```

## 6.4. Multifractal Scaling Exponent $\tau(q)$

```
plt.Figura(figsize=(8, 5))
plt.plot(mfdfa_df['q'], mfdfa_df[' $\tau(q)$ '], marker='o')
plt.title('Multifractal Scaling Exponent  $\tau(q)$ ')
plt.xlabel('$q$')
plt.ylabel('$\tau(q)$')
plt.grid(True)
plt.tight_layout()
plt.show()
```

## 6.5. Singularity Spectrum $f(\alpha)$

```
plt.Figure(figsize=(8, 5))
plt.plot(mfdfa_df[' $\alpha$ '], mfdfa_df[' $D(\alpha)$ '], marker='o')
plt.title('Singularity Spectrum  $f(\alpha)$ ')
plt.xlabel(' $\alpha$ ')
plt.ylabel(' $f(\alpha)$ ')
plt.grid(True)
plt.tight_layout()
plt.show()
```

## 12. ANEXO III: Código Python Rolling Hurst 46 componentes

### 1. Instalación de librerías

```
!pip install MF DFA
from google.colab import files
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from MF DFA import MF DFA
from numpy.polynomial.polynomial import polyfit
import io
```

### 2. Definimos función

```
# Definir función get_mfdfa (solo h(q=2))
def get_mfdfa(data, q=np.array([-2, 2]), order=1, lag_start=3, lag_end=None,
lag_steps=40):
    def _integrate(series):
        return (series - np.mean(series)).cumsum()

    if lag_end is None:
        lag_end = len(data) // 6

        lags = np.unique(np.logspace(np.log10(lag_start), np.log10(lag_end),
lag_steps).astype(int))
        y = _integrate(data)
        lag, dfa = MF DFA(y, lag=lags, q=q, order=order)
        start, end = 0, int(0.6 * len(lag))
        slope = polyfit(np.log10(lag[start:end]), np.log10(dfa[start:end]), 1)[1]
        hq = slope - 1

        return hq if isinstance(hq, np.ndarray) else np.array([hq])

# Función para calcular rolling Hurst con q=2
def rolling_hurst_q2(log_returns, dates, window=252):
    hurst_vals = []
    fechas_validas = []
```

```

for i in range(window, len(log_returns)):
    ventana = log_returns[i - window:i]
    try:
        hq = get_mfdfa(ventana)
        hurst_vals.append(hq[1]) # h(q=2)
        fechas_validas.append(dates[i])
    except:
        continue

return pd.Series(hurst_vals, index=pd.to_datetime(fechas_validas))

```

### 3. Importación de archivos

```

# Subir archivos
uploaded = files.upload()

```

### 4. Plotting Rolling Hurst para cada uno de los componentes

```

import math
import pandas as pd
# Parámetros
fecha_inicio = pd.to_datetime("2018-01-01")
fecha_fin = pd.to_datetime("2024-09-20")
fecha_corte = pd.to_datetime("2022-11-30")
window = 252

# Preprocesar cada archivo
resultados = []

for filename in uploaded:
    empresa = filename.replace('.xlsx', '').strip()
    df = pd.read_excel(io.BytesIO(uploaded[filename]), header=2)

    # Validar columnas
    if 'Date' not in df.columns or 'Price' not in df.columns:
        print(f"Saltando {empresa}: columnas no válidas.")

```

continue

# Limpiar y filtrar

```
df = df[['Date', 'Price']].copy()
df['Date'] = pd.to_datetime(df['Date'], errors='coerce')
df = df.dropna()
df = df[(df['Date'] >= fecha_inicio) & (df['Date'] <= fecha_fin)]
df = df.sort_values('Date')
```

# Calcular log-returns

```
df['LogReturn'] = np.log(df['Price'] / df['Price'].shift(1))
df = df.dropna()
```

# Rolling Hurst

```
logret = df['LogReturn'].values
fechas = df['Date'].values
hurst_vals = []
fechas_validas = []
```

```
for i in range(window, len(logret)):
```

```
    ventana = logret[i - window:i]
```

```
    try:
```

```
        hq = get_mfdfa(ventana, q=np.array([-2, 2]))
```

```
        hurst_vals.append(hq[1]) # h(q=2)
```

```
        fechas_validas.append(fechas[i])
```

```
    except:
```

```
        continue
```

```
if not hurst_vals:
```

```
    print(f"Sin resultados válidos para {empresa}")
```

```
    continue
```

```
rolling_h = pd.Series(hurst_vals, index=pd.to_datetime(fechas_validas))
```

```
rolling_pre = rolling_h[rolling_h.index <= fecha_corte]
```

```
rolling_post = rolling_h[rolling_h.index > fecha_corte]
```

```

resultados.append((empresa, rolling_pre, rolling_post))

# Plotear 3 por fila
total = len(resultados)
filas = math.ceil(total / 3)
fig, axs = plt.subplots(filas, 3, figsize=(18, 4 * filas), sharey=True)
axs = axs.flatten()

for idx, (empresa, pre, post) in enumerate(resultados):
    ax = axs[idx]
    ax.plot(pre.index, pre, label='Pre-ChatGPT', color='navy')
    ax.plot(post.index, post, label='Post-ChatGPT', color='darkorange')
    ax.axhline(0.5, color='red', linestyle='--')
    ax.axhline(0.603, color='gray', linestyle=':', linewidth=1)
    ax.axhline(0.392, color='gray', linestyle=':', linewidth=1)
    ax.set_title(f'{empresa}', fontsize=10)
    ax.set_xlabel('Fecha')
    ax.set_ylabel('h(q=2)')
    ax.legend(fontsize=8)

# Si hay subplots vacíos, los escondemos
for j in range(idx + 1, len(axs)):
    fig.delaxes(axs[j])

fig.suptitle('Rolling Hurst: Comparativa Pre/Post ChatGPT', fontsize=14)
plt.tight_layout(rect=[0, 0, 1, 0.97])
plt.show()

```