Facultad de Ciencias Económicas y Empresariales

ICADE

Estructura temporal y eficiencia del mercado europeo de derechos de emisión (EU ETS): un análisis de la curva de futuros y del convenience yield

Autor: Mario Laureano Simón Alonso

Director: Isabel Catalina Figuerola Ferreti

MADRID | junio 2026

Indice

I. Introducción 5

II. Revisión de la Literatura 8

III. El Mercado de EU ETS (EUAs) 11

IV. Datos 13

V. Metodología 14

a. Modelo Nelson Siegel (NS) 14

b. Dinámica de factores (OLS /ARX) 15

c. Cointegración spot – futuro y convenience yield 17

d. Eficiencia spot – futuro (VECM) 19

VI. Resultados 20

VII. Conclusiones 38

VIII. Bibliografía 41

IX. Anexo 48

I. Tablas y gráficos 48

II. Código Python 51

X. Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado 85

Resumen

Este trabajo analiza el comportamiento financiero del mercado europeo de derechos de emisión (EU ETS) durante sus Fases III (2013-2020) y IV (2021-2026), con el objetivo de evaluar la eficiencia del mercado y la relación de equilibrio de largo plazo entre los precios spot y futuros de los EUA. La metodología combina el modelado de la estructura temporal de la curva de futuros mediante el modelo de Nelson-Siegel con un análisis de cointegración de Johansen y un modelo de corrección de error vectorial (VECM) trivariante (precio spot (s), precio del futuro (f) y el tipo de interés (r)). Los resultados evidencian una transformación estructural del mercado entre ambos regímenes regulatorios. El poder explicativo de los drivers energéticos sobre los factores de la curva se reduce drásticamente en la Fase IV, lo que indica que el precio del carbono se desacopla de sus fundamentos físicos. Paralelamente, mientras en la Fase III la relación de cointegración se aleja del modelo de cost-of-carry, en la Fase IV los coeficientes convergen hacia los valores teóricos de no arbitraje, resultado no documentado previamente en la literatura sobre el EU ETS. La descomposición de Gonzalo-Granger muestra que el mercado de futuros lidera el proceso de price discovery en la Fase IV, patrón propio de los mercados de commodities maduros que contrasta con el descubrimiento compartido hallado para las fases iniciales del sistema (fases I y II). En conjunto, la evidencia sugiere que el EU ETS ha madurado hacia un mercado financiero estándar, en el que la formación del precio se ancla en su estructura financiera interna, expectativas regulatorias incorporadas en la curva de futuros y equilibrio de cost-of-carry, más que en los fundamentos energéticos exógenos.

Palabras clave: EU ETS, derechos de emisión (EUAs), estructura temporal, modelo de Nelson-Siegel, cointegración, VECM, price discovery, cost-of-carry, convenience yield, commodities, descubrimiento de precios.

Abstract

This paper analyses the financial behavior of the European Union Emissions Trading System (EU ETS) during its Phases III (2013-2020) and IV (2021-2026), to assess market efficiency and the long-run equilibrium relationship between EUA spot and futures prices. The methodology combines the modelling of the futures term structure through the Nelson-Siegel model with a Johansen cointegration analysis and a trivariate Vector Error Correction Model (VECM) (spot price (s), the futures price (f), and the interest rate (r)). The results reveal a structural transformation of the market across the two regulatory regimes. The explanatory power of energy drivers over the curve factors falls sharply in Phase IV, indicating that the carbon price decouples from its physical fundamentals. In parallel, whereas in Phase III the cointegration relationship departs from the cost-of-carry model, in Phase IV the coefficients converge towards the theoretical no-arbitrage values, a result not previously documented in the EU ETS literature. The Gonzalo-Granger decomposition shows that the futures market leads the price discovery process in Phase IV, a pattern typical of mature commodity markets that contrasts with the shared price discovery found in the early phases of the system (phase I and II). Overall, the evidence suggests that the EU ETS has matured into a standard financial market, in which price formation is anchored in its internal financial structure, regulatory expectations embedded in the futures curve and the cost-of-carry equilibrium, rather than in exogenous energy drivers.

Keywords: EU ETS, emission allowances (EUA), term structure, Nelson-Siegel model, cointegration, VECM, price discovery, cost-of-carry, convenience yield, commodities.

I. Introducción

En el contexto de la creciente urgencia climática y los compromisos internacionales de descarbonización, la Unión Europea ha desarrollado uno de los instrumentos más ambiciosos y sofisticados para reducir las emisiones de gases de efecto invernadero: el Régimen de Comercio de Derechos de Emisión (European Union Emissions Trading System o EU ETS por sus siglas en inglés). Este sistema, implementado en 2005, fue el primero en su tipo y hoy constituye el mayor mercado de carbono del mundo. Cubre aproximadamente el 45% de las emisiones totales de gases de efecto invernadero de la UE (Ji et al., 2018) y abarca sectores intensivos a nivel energético, como lo son la generación eléctrica, la siderurgia, los materiales de construcción o la aviación dentro del espacio europeo.

El EU ETS opera bajo un esquema de cap-and-trade, que combina la fijación de un límite máximo (cap) a las emisiones permitidas con la posibilidad de comerciar derechos de emisión (trade) entre las empresas participantes. Cada uno de estos derechos, conocidos como European Union Allowance (EUA), autoriza a las empresas, la emisión de una tonelada de CO_2 equivalente. El total de permisos se reduce de manera progresiva cada año, en consonancia con los objetivos climáticos de la UE, generando así un incentivo económico para disminuir las emisiones allí donde sea más rentable hacerlo (Carbon Market Watch, 2024).

Desde su puesta en marcha, el EU ETS ha atravesado cuatro fases de desarrollo institucional y sobre todo, regulatorio. La Fase I (2005–2007) funcionó como programa piloto, con una asignación principalmente gratuita de permisos dando lugar a ciertos problemas de sobreasignación y volatilidad de precios (Balietti, 2016). La Fase II (2008–2012), coincidió con el primer periodo de cumplimiento del Protocolo de Kioto La Fase III (2013–2020) supuso un cambio estructural hacia un sistema más centralizado, con un tope único a nivel

europeo y la generalización de las subastas como principal mecanismo de asignación, lo que redujo notablemente las concesiones gratuitas (Hobbie et al., 2019). La Fase IV (2021–2030), actualmente en vigor, busca alinear el sistema con el objetivo de reducir un 55% las emisiones para 2030, conforme al paquete Fit for 55, e introduce mecanismos de estabilidad como la Market Stability Reserve (MSR) para corregir excesos de oferta y mantener una señal de precio coherente con los objetivos de descarbonización (BOE, 2023).

El EU ETS desempeña un papel clave en la transición energética europea, ya que no solo proporciona el precio del carbono que orienta decisiones de inversión y consumo, sino que también ha impulsado la creación de un mercado de derivados en torno a los derechos de emisión. El desarrollo de mercados de futuros y opciones sobre EUAs (European Allowances), ha contribuido a aumentar la liquidez, mejorar la cobertura de riesgos y medir las expectativas del mercado sobre la evolución de los precios del carbono además de otorgar oportunidades de arbitraje (Liu et al., 2021). En este contexto, el comportamiento del precio de los derechos de emisión ha mostrado una marcada sensibilidad a los cambios regulatorios, a las condiciones macroeconómicas y al equilibrio entre oferta y demanda de permisos. En sus primeras fases, el mercado se caracterizó por una elevada volatilidad y episodios de desplome de precios, especialmente tras la sobreasignación de permisos observada al final de la Fase I y el cambio estructural en la relación entre precios spot y futuros a partir de 2008 (Bredin and Parsons, 2014). Durante las fases II y principios de la fase III, el mercado experimentó una tendencia prolongada a la baja en el precio de EUAs debido al exceso de oferta generado tras la crisis de 2008. Sin embargo, las reformas aprobadas al inicio de la Fase IV (2021–2030) contribuyeron a restaurar el equilibrio del mercado, provocando un notable repunte de los precios a partir de 2018 (Aspinall et al., 2021). En los últimos años, factores como el aumento de los precios energéticos y las tensiones geopolíticas derivadas de la guerra en Ucrania han intensificado nuevamente la volatilidad, reforzando el papel del EU ETS tanto como instrumento de política climática como activo financiero. En este sentido, los derivados sobre EUAs se han consolidado como un componente esencial del EU ETS, al desempeñar una función de price discovery, y reflejar las expectativas del mercado

sobre la evolución futura del precio del carbono. Asimismo, su comportamiento se ve influido por factores macroeconómicos, energéticos y de riesgo geopolítico (Lu et al., 2024).

La relación entre los precios spot y futuros es un elemento clave para evaluar el grado de eficiencia del mercado del carbono y la posible existencia de convenience yield, es decir, el beneficio implícito asociado a la tenencia del activo físico frente a los contratos a futuro (Gibson, R., Schwartz, 1990). Comprender la relación de equilibrio spot-futuro de los EUAs es fundamental dado que, una relación estable de cointegración entre ambos mercados es necesaria para que los contratos de futuros funcionen como instrumentos eficaces de cobertura del riesgo de precios (Milunovich y Joyeux, 2007). En segundo lugar, como subrayan Bredin y Parsons (2014), los EUAs carecen de costes físicos de almacenamiento y, dado que el banking[1] entre años está permitido dentro de cada fase, su convenience yield debería aproximarse a cero, por lo que la estructura temporal debería replicar la estructura temporal de los tipos de interés en condiciones normales (se exige una mayor compensación por tener el dinero inmovilizado durante más tiempo). La tercera razón, es que el EU ETS ha experimentado transformaciones regulatorias profundas a lo largo de sus distintas fases, que han alterado las reglas fundamentales sobre las que se construye la relación spot-futuro. La transición de Fase II a Fase III supuso la introducción del cap único europeo y la generalización de las subastas como mecanismo principal de asignación de allowances; la activación de la Market Stability Reserve a partir de 2019 introdujo un mecanismo de ajuste de la oferta; y el paso a Fase IV trajo consigo la aceleración del LRF al 4,3% anual y el endurecimiento progresivo del cap bajo el paquete Fit for 55. Cada uno de estos cambios afecta directamente a la dinámica de la oferta de permisos, a las expectativas de los participantes sobre la escasez futura y, por tanto, a los mecanismos que sustentan la relación de equilibrio entre el spot y el futuro.

[1] *Banking: permite a las empresas conservar los EUAs no utilizados de un año para emplearlos en años posteriores, lo que implica que el coste de mantener un EUA se reduce al coste de oportunidad del capital, sin coste físico de almacenamiento. El banking constituye la base teórica de la predicción del cost-of-carry para el mercado del carbono (Bredin y Parsons, 2014).*

Aunque en los mercados de materias primas tradicionales se ha estudiado ampliamente la cointegración entre los precios spot y futuros, así como la presencia de contango o backwardation en el marco de la teoría del almacenamiento, la naturaleza del EU ETS plantea cuestiones adicionales sobre la aplicabilidad de estos conceptos al mercado del carbono (Feng, L., Wang, J. 2023). A pesar del creciente interés académico por la dinámica de precios de los EUA, las pruebas empíricas sobre la existencia y el papel del convenience yield en este mercado siguen siendo limitadas y no concluyentes, especialmente en las últimas fases.

El objetivo principal de este trabajo es analizar la relación entre el precio spot y el precio de los futuros de los derechos de emisión del EU ETS, con el fin de evaluar la eficiencia de mercado y la existencia de una relación de equilibrio. Para ello, se emplea un enfoque econométrico basado en el análisis de cointegración y modelos de corrección de errores vectoriales (VECM), complementado con un análisis descriptivo de la estructura temporal de la curva de futuros de los EUA mediante el modelo de Nelson-Siegel. El estudio se centra en las fases III (2013-2020) y IV (2021-actualidad), siguiendo con línea de estudio de Dittmann et al. (2024), además de ser periodos en los que el EU ETS ha alcanzado un mayor grado de madurez institucional, liquidez y relevancia financiera, y en los que los cambios regulatorios permiten analizar con mayor rigor la dinámica spot-futuro del mercado del carbono.

II. Revisión de la Literatura

Desde una perspectiva teórica, la literatura clásica sobre el comportamiento de las materias primas muestra que la existencia de convenience yield puede integrarse en la relación de equilibrio entre precios spot y futuros, lo que permite que el vector de cointegración difiera del caso estándar uno a uno y, por tanto, caracterizar estructuras de contango o backwardation en el largo plazo (Figuerola-Ferretti Gonzalo, 2010).

Este enfoque resulta especialmente relevante para el mercado de EUAs, donde la naturaleza regulatoria del activo y el diseño institucional del mercado introducen fricciones que pueden alterar las condiciones de no arbitraje y la interpretación tradicional del cost-of-carry. En esta línea, Daskalakis et al. (2009) analizan distintos mercados (Powernext, Nord Pool y ECX) y demuestran que restricciones institucionales en particular, la prohibición de banking entre fases en los primeros años del sistema, afectan a la formación de precios de los futuros, limitando la aplicabilidad del cost-of-carry y pudiendo generar ineficiencias en la relación spot–futuro. De forma complementaria, Milunovich y Joyeux (2007), analizan la eficiencia de mercado y el proceso de price discovery en los futuros de carbono, hallando que, aunque spot y futuros están cointegrados y comparten información, los precios no cumplen estrictamente la paridad del cost-of-carry, lo que sugiere la existencia de primas o rendimientos anómalos por riesgo regulatorio. En paralelo, una rama de la literatura se ha centrado en la estructura temporal del precio del carbono y en cómo la regulación y las expectativas del mercado se reflejan en la curva de futuros. En el caso de las primeras fases, Uhrig-Homburg y Wagner (2007) obtienen resultados que respaldan la existencia de un mecanismo de cost-of-carry para futuros que vencen en la primera fase del EU ETS. Trück et al. (2007) muestran que los futuros emitidos en la primera fase, pero con vencimiento en la segunda, incorporan rendimientos de conveniencia significativos. Bredin y Parsons (2014) examinan explícitamente la estructura temporal del precio del carbono (term structure) en el EU ETS (2005-2012). A partir de precios spot y futuros calculan un implied cost of carry y observan que desde 2008 los spots se mantienen persistentemente baratos respecto a los futuros, un fenómeno contrario a la teoría y explicado por expectativas sobre el banking de allowances y la evolución normativa del sistema. El estudio ajusta los datos a un modelo de estructura temporal de tipos de interés, evidenciando que el comportamiento del mercado del carbono difiere sustancialmente del de otros commodities financieros. Siguiendo esa línea, Aspinall et al. (2021) estiman la estructura temporal de precios del EU ETS mediante técnicas de espacio de estados y modelos con componentes de corto y largo plazo, mostrando que la curva de futuros puede descomponerse en factores asociados al horizonte temporal y capturar la evolución de expectativas sobre el precio del carbono; estos resultados son útiles como

soporte descriptivo para interpretar la dinámica de la curva, aunque el foco principal del presente trabajo se sitúa en las relaciones spot–futuro y su equilibrio de largo plazo.

Por otra parte, la literatura sobre determinantes del precio del carbono ha señalado el papel de fundamentos energéticos y macroeconómicos, especialmente en fases tempranas del sistema. Creti et al., (2012), utilizando cointegración con datos de futuros diarios para las Fases I y II, encuentran relaciones de equilibrio entre el precio del carbono y variables energéticas (petróleo, gas, carbón y electricidad), sugiriendo una evolución en la sensibilidad del mercado conforme madura. De forma similar, Fezzi (2006) aplica VAR/VECM para estudiar la interacción entre electricidad, gas y derechos de emisión en los primeros años del EU ETS, identificando vínculos de corto y largo plazo entre mercados energéticos y el precio del CO_2. A nivel estructural, Brink et al. (2016) evalúan mediante un modelo de equilibrio general computable (CGE) diferentes reformas del EU ETS (ajuste del cap, precios-suelo, impuestos paralelos), mostrando que los mecanismos de estabilización de precios y la banca de permisos modifican la trayectoria intertemporal de precios y la distribución de bienestar entre Estados Miembros. Otros estudios relevantes resultados un tanto contradictorios como es el caso de Chung et al. (2018) quienes muestran que es el precio de los EUAs el que afecta al precio de la electricidad y este efecto es unidireccional

Finalmente, trabajos más recientes sugieren un cambio estructural en fases avanzadas del EU ETS. Dittmann et al. (2024) aportan evidencia para las Fases III y IV indicando que el poder explicativo de los fundamentos energéticos se reduce de manera sustancial en el periodo más reciente, lo que apunta a una mayor relevancia de factores financieros, de expectativas y de elementos regulatorios en la formación del precio. En esta misma línea, Wegener et al. (2024) concluyen que las subidas recientes del precio reflejan expectativas del mercado sobre una mayor escasez futura y un endurecimiento regulatorio, pero no un comportamiento especulativo irracional. En conjunto, esta literatura respalda el uso de herramientas de cointegración y modelos de corrección de errores como enfoque adecuado para analizar el equilibrio de largo plazo spot–futuro en el EU ETS e investigar si el mercado presenta patrones compatibles con la existencia de convenience yield en un entorno regulado.

III. El Mercado de EU ETS (EUAs)

El Régimen de Comercio de Derechos de Emisión de la Unión Europea (EU ETS) constituye el pilar central de la política climática europea como respuesta a los objetivos establecidos en el Protocolo de Kioto y el mayor mercado de carbono del mundo. Establecido por la Directiva 2003/87/CE del Parlamento y del Consejo, entró en vigor en enero de 2005 con el objetivo de limitar las emisiones de gases de efecto invernadero (GEI) mediante un mecanismo de cap-and-trade, en el cual se fija un límite total de emisiones y se permite a las empresas comerciar con estos derechos de emisión (allowances) en función de sus necesidades. Este enfoque se apoya en los fundamentos teóricos desarrollados por Weitzman (1974), quien demostró que un instrumento basado en cantidades puede resultar más eficiente que los impuestos cuando los costes marginales de reducción son desconocidos. En la misma línea, Goulder y Schein (2013, sec. C) explican que un impuesto al carbono fija el precio de las emisiones y deja que la cantidad se ajuste, mientras que un sistema cap-and-trade fija la cantidad total de emisiones y permite que el precio se determine en el mercado, garantizando así el cumplimiento de los objetivos ambientales establecidos. Otra de las características de este mercado es su diseño, que busca que las reducciones de emisiones se produzcan allí donde resulten más baratas (least-cost abatement), generando incentivos para la innovación y la inversión en tecnologías limpias (Piwowarczyk-Ściebura, 2018). El volumen total de derechos emitidos disminuye cada año conforme a un factor de reducción lineal (LRF por sus siglas en inglés) que ha ido aumentando de forma anual. Por otro lado, de derechos se realiza mediante subastas y asignaciones gratuitas orientadas a los sectores expuestos a riesgo de fuga de carbono (carbon leakage). Desde 2013, más de la mitad de los derechos se asignan

mediante subasta, generando ingresos que los Estados miembros deben destinar a proyectos de mitigación y transición energética (Marcu et al., 2025).

A lo largo de estos años, este mercado ha supuesto importantes desafíos que han condicionado su credibilidad como instrumento de política climática. Durante las dos primeras fases, el exceso de asignaciones gratuitas y la falta de mecanismos de ajuste provocaron una caída abrupta de los precios del carbono, llegando a valores cercanos a cero al final de primera fase y estabilizándose en niveles muy bajos tras la crisis financiera de 2008 (Creti et al., 2012). Como señalan Fischer et al. (2019), la efectividad de un sistema de comercio de emisiones depende de mantener señales de precio suficientemente fuertes y predecibles para sostener las expectativas de rentabilidad y fomentar la innovación tecnológica. Con este objetivo, las reformas introducidas a partir de la Fase III incorporaron mecanismos de estabilización, entre ellos la Market Stability Reserve (MSR), diseñada para absorber o liberar permisos en función del excedente y reducir la volatilidad, así como la posibilidad de establecer precios mínimos en subastas que sirvieran de "suelo" al valor del carbono (Fischer et al., 2019; Quemin, 2020).

En la Fase IV, se impulsa una reestructuración integral del sistema. El incremento del Linear Reduction Factor (LRF) al 4,3 % anual, la extensión del ámbito a sectores como el transporte marítimo y la introducción del ETS2 para calefacción y transporte por carretera reflejan un intento de reforzar la escasez estructural y ampliar la cobertura económica del sistema (Marcu et al., 2025; Nissen et al., 2024). Paralelamente, la Comisión Europea fortaleció la coordinación entre el EU ETS y políticas complementarias como el Carbon Border Adjustment Mechanism (CBAM), que sustituirá gradualmente la asignación gratuita de derechos. En conjunto, estas medidas han dotado al mercado de una mayor resiliencia frente a shocks externos, como la crisis energética de 2022, y consolidado su papel como referencia internacional para la fijación de precios de CO_2. Actualmente, el EU ETS cubre más de 10 000 instalaciones y alrededor del 40 % de las emisiones de gases de efecto invernadero de la Unión Europea (Nissen et al., 2024), situándose como el principal referente global en materia de mercados de carbono.

IV. Datos

Este trabajo utiliza datos diarios del mercado europeo de derechos de emisión (EU ETS), tanto de contratos spot como de contratos de futuros, en los que el precio se expresa en euros por tonelada de CO_2 equivalente (EUR/tCO_2). El período de análisis abarca desde el 2 de enero de 2013 hasta el 31 de enero de 2026, ambos inclusive, y se centra en las Fases III y IV, ya que consideramos como el tramo más representativo desde el punto de vista regulatorio y financiero además de la limitada literatura que hay centrada en estas. El precio spot de EUA se obtiene de la European Energy Exchange (EEX), a mediante la plataforma FactSet. Para los futuros, se adopta como contrato benchmark el EUA Future con vencimiento en diciembre (DEC) de cada año, al estar mejor alineado con el ciclo de cumplimiento del EU ETS, además del volumen negociada se concentra de forma mayoritaria en los vencimientos DEC (más del 90% del volumen), por lo que ofrece una referencia más estable para analizar la relación spot–futuro. Esta elección limita distorsiones derivadas de la rotación frecuente de posiciones en contratos front-month. Las series se trabajan en EUR/tCO_2 y se homogeneizan en días de negociación para asegurar consistencia temporal. Los precios de futuros proceden del mercado ECX (European Climate Exchange), negociado en ICE Futures Europe, donde cada contrato tiene un tamaño estándar de 1 lote = 1.000 EUAs, y el último día de negociación es el último lunes del mes de vencimiento.

V. Metodología

a. Modelo Nelson Siegel (NS)

El modelo de Nelson-Siegel (1987) se utiliza habitualmente para representar la estructura temporal de los tipos de interés (yield curve) en renta fija, ya que sus tres componentes, interpretados como nivel, pendiente y curvatura, reproducen bien las formas típicas de la curva (plana, creciente, decreciente o con «joroba») y explican una parte muy elevada de su variación observada.

Trabajos como los de Heidorn et al. (2015), GrØnborg y Lunde (2016), Karstanje et al. (2015) o, más recientemente, Bianchi et al. (2023), han adaptado el modelo a curvas de futuros de materias primas, y muestran que, de media, este modelo explica más del 95 % de la variación de dichas curvas, lo que lo hace suficientemente robusto para extraer señales de la estructura de vencimientos(Bianchi et al. 2023). Por lo tanto, basándonos en el estudio de Diebold & Li (2006), para cada día t, el precio del futuro con vencimiento τ se aproxima mediante:

$$lnFt(\tau) = \beta_{0,t} + \beta_{1,t} * \left(\frac{1 - e^{-\lambda\tau}}{\lambda\tau}\right) + \beta_{2,t} * (\frac{1 - e^{-\lambda\tau}}{\lambda\tau} - e^{-\lambda\tau}) + \varepsilon_t(\tau)$$

Donde $\beta_{0,t}$ representa el nivel (componente de largo plazo),el cual en commodities, no depende del vencimiento (τ) por lo que puede interpretarse como el precio de largo plazo (límite cuando la madurez tiende a infinito), y sus variaciones capturan desplazamientos paralelos de la curva, es decir, un aumento de $\Delta\beta_{0,t} > 0$ eleva toda la estructura temporal, mientras que $\Delta\beta_{0,t} < 0$ la desplaza hacia abajo. En segundo lugar, $\beta_{1,t}$ representa la pendiente, que recoge movimientos de inclinación de la estructura temporal. una $\beta_{1,t} < 0$ mostrará una curva en contango (pendiente positiva) y una $\beta_{1,t} > 0$, una curva en backwardation (pendiente negativa). Por último, el tercer factor, $\beta_{2,t}$ la curvatura, define la concavidad/convexidad de la curva. El valor del primer factor ($\beta_{0,t}$) es siempre igual a 1. El valor del segundo factor ($\beta_{1,t}$) comienza en 1 cuando el vencimiento es $\tau = 0$ y decrece de forma rápida y monótona, aproximándose a 0 a medida que el vencimiento tiende a infinito. El valor del tercer factor ($\beta_{2,t}$) comienza en 0 cuando $\tau = 0$ posteriormente aumenta, alcanza un máximo y, a continuación, disminuye de forma rápida y monótona, aproximándose también a 0 cuando el vencimiento tiende a infinito.

En la estimación, en lugar de permitir que λ varíe libremente en el tiempo, lo que dificultaría la comparabilidad temporal de los factores estimados, se sigue el procedimiento de Karstanje et al. (2017), que fijan un λ común dentro de cada commodity e introducen un maturity bound destinado a excluir los contratos de vencimiento más largo. De esta forma, acotamos la variación de la dimensión de la estructura temporal a lo largo de la muestra de forma que un λ constante siga siendo coherente, y reducimos el ruido derivado de la menor liquidez de los contratos más lejanos, cuya información de precios suele ser más imprecisa. En el presente trabajo, dado que la curva se construye exclusivamente con contratos de vencimiento DEC (uno por año), el maturity bound se implementa limitando, en cada fecha, la estimación a los K contratos DEC más próximos estableciendo un horizonte máximo τ_{max} de 5 años.

b. Dinámica de factores (OLS /ARX)

Una vez hemos estimado el nivel $(\beta_{0,t})$, pendiente $(\beta_{1,t})$y curvatura $(\beta_{2,t})$ mediante el modelo Nelson-Siegel, el siguiente paso consiste en analizar su dinámica temporal y su relación con los principales drivers del mercado de los derechos de emisión, siguiendo la línea de Dittmann et al.(2024), en el cual estudian los determinantes del precio de los derechos de emisión pero mediante regresiones lineales de series temporales con los precios del crudo, gas natural, carbón y electricidad como regresores. Además, exponen que la influencia de éstos en el precio varía entre fase y fase.

Como punto de partida, estimamos una especificación OLS para cada uno de los tres factores previamente extraídos. Dittmann et al.(2024) expresan las variables en log y evalúan el ajuste con estadísticos con el R^2, el adjusted R^2, el F-statistic y el test de Ljun-Box. Adaptando la fórmula empleada por Dittmann et al.(2024) sobre los precios, a los factores de Nelson-Siegel, la especificación quedaría así:

$$\Delta\beta_{k,t} = \alpha_k + \sum_{j-1}^{J} y_{k,j} * \Delta x_{j,t} + \varepsilon_{k,t}\,,\ k \in \{0,1\}$$

Donde k es el factor NS, α_k es la constante que recoge la tendencia de los cambios diarios de cada factor NS,$y_{k,j}$ es el efecto del driver j sobre el factor k, $\Delta x_{j,t}$ es la variación diaria del driver j en el día t (J = 6 drivers).

Cabe destacar que, dado que los factores estimados presentan persistencia temporal (Figura 3), el análisis se complementa con una especificación ARX (Autoregressive with Exogenous variables) que incorpora lags de la propia variable dependiente junto con los regresores exógenos. Esta extensión sigue la línea de Dittmann et al. (2024), que adoptan una especificación análoga sobre los retornos del EUA spot, con dos lags del activo dependiente y un lag de los drivers energéticos. La inclusión del componente autorregresivo está respaldada por la evidencia documentada por Diebold y Li (2006) sobre la elevada persistencia de los factores Nelson-Siegel. La inclusión de un lag de los drivers se apoya, además, en Zheng et al. (2021), que mediante regresión cuantitativa sobre los retornos de EUA documentan que los shocks energéticos presentan tanto efectos contemporáneos como

retardados, si bien los primeros resultan cuantitativamente predominantes. La fórmula ARX a aplicar es la siguiente:

$$\Delta\beta_{k,t} = \alpha_k + \sum_{i=1}^{2} \phi_{k,i} \cdot \Delta\beta_{k,t-i} + \sum_{j=1}^{6} \gamma_{k,j,0} \cdot \Delta x_{j,t} + \sum_{j=1}^{6} \gamma_{k,j,1} \cdot \Delta x_{j,t-1} + \varepsilon_{k,t}$$

Donde $\phi_{k,i}$y $\gamma_{k,j,l}$son los coeficientes autorregresivos de los drivers respectivamente. Las estimaciones se realizan separadamente para cada factor (β₀ y autorregresivos de EU ETS (Fase III y Fase IV). Se adopta una especificación con dos lags del propio factor y un lag de los drivers siguiendo la convención metodológica de Dittmann et al. (2024); la adecuación del orden de lags se contrasta posteriormente mediante el test de Ljung-Box sobre los residuos.

c. Cointegración spot – futuro y convenience yield

El siguiente paso, el análisis de la relación entre spot y futuros, supone el paso central para evaluar su ambos están vinculados por un equilibrio a largo plazo. Si los contratos actúan como instrumentos eficaces de cobertura, sus precios no deberían divergir de forma persistente del precio spot, sino mantener una relación estable siguiendo la lógica del cost-of-carry. En el caso de este mercado, la literatura ha mostrado que la relación spot-futuro depende esencialmente del diseño regulatorio del sistema (mas concretamente, de las reglas del banking) entre fases. Así, Milunovich & Joyeux (2007) afirman que a existencia de una relación de cointegración entre spot, futuros y tipos de interés es una condición necesaria para que los futuros funcionen como instrumentos adecuados de cobertura.

A nivel teórico, bajo ausencia de arbitraje, el precio del futuro puede expresarse mediante una relación de cost-of-carry. En el contexto del EU ETS, Bredin and Parsons (2014) destacan que, dado que los derechos de emisión no presentan costes físicos de almacenamiento y que el banking está permitido dentro de la fase, el coste de mantener una

posición spot debería aproximarse, en principio, al coste de oportunidad del dinero. El precio del futuro puede expresarse como:

$$F_t t(\tau) = S_t * \ e^{(rt,\tau - \delta t,\tau)\cdot\tau}$$

Donde $F_t(\tau)$ es el precio del futuro con vencimiento τ, S_t es el precio spot, $y_t(\tau)$representa el tipo de interés correspondiente al horizonte de vencimiento y $\delta_t(\tau)$es el convenience yield implícito que representa el rendimiento implícito asociado a mantener una posición spot en lugar de una posición en futuros. Sin embargo, en el mercado del carbono su interpretación no es tan directa como en otras materias primas almacenables. De hecho, Daskalakis et al.(2009) sostienen que, para contratos intra, el convenience yield debería ser esencialmente nulo, dado que almacenar permisos dentro de una misma fase no implica costes y las necesidades de cumplimiento se concentran una vez al año, similar a Bredin D., Parsons J., (2014), aunque documentan que, especialmente desde finales de 2008, el spot de carbono pasa a ser persistentemente barato frente a los futuros. A partir de la expresión anterior, la convenience yield implícita puede obtenerse como:

$$\delta_{t,\tau} = r_{t,\tau} - \frac{lnF_t(\tau) - lnS_t}{\tau}$$

Donde τ se fijará como >= 30 días debido a que el proxy de spot que utilizamos es el front month por lo que el último mes del año coincide con el futuro lo que distorsionaría los resultados del modelo. La existencia de una relación estable de largo plazo entre spot y futuros se contrasta mediante el test de cointegración de Johansen (1988), aplicado separadamente sobre las fases III y IV del EU ETS. La especificación concreta, bivariante entre spot y futuros, o trivariante incorporando el tipo de interés, se decide en función de las propiedades de integración de las variables, contrastadas mediante los tests ADF y KPSS. Bajo la hipótesis de cost-of-carry estricto, se esperaría una relación de cointegración con coeficientes restringidos; el contraste de estas restricciones permite caracterizar la eficiencia de los contratos de futuros como instrumentos de cobertura, en línea con Milunovich y Joyeux (2007), que reportan rechazo parcial de las restricciones de cost-of-carry en su análisis de Fase I.

d. Eficiencia spot – futuro (VECM)

Despues de verificar la existencia de cointegración entre los precios spot y futuros, el siguiente paso consiste en determinar cómo las desviaciones en el corto plazo se corrigen de cara al equilibrio de largo plazo, para lo cual, en este estudio se emplea el modelo de corrección de vectores de error (VECM por sus siglas en inglés) que permite identificar cuál de los dos precios corrige el desequilibrio cuando la relación spot-futuro se aleja del nivel de equilibrio y por tanto, cuál influye en mayor medida en el proceso de price Discovery. La aplicación de VECM proviene del Teorema de Representación de Granger (Engle y Granger, 1987), según el cual si un conjunto de variables I(1) está cointegrado, entonces existe una representación VECM equivalente que combina la dinámica de corto plazo con un mecanismo de ajuste hacia el equilibrio de largo plazo

Siguiendo Engle y Granger (1987), la fórmula de VECM se expresa como:

$$\Delta Y_t = \mu + \alpha\beta' Y_{t-1} + \sum_{i-1}^{p-1} \Gamma_i \Delta Y_{t-1} + \varepsilon_t$$

donde Y_t es el vector de variables endógenas, $\beta' Y_{t-1}$ representa el término de corrección del error (error correction term, ECT), que mide la desviación respecto al equilibrio de largo plazo en el periodo anterior . αContiene los coeficientes de ajuste que indican la velocidad y dirección con que cada variable corrige las desviaciones, $\Gamma_i$recoge la dinámica de corto plazo y $\varepsilon_t$es el vector de perturbaciones. Esta es la formulación estándar del modelo y aparece de forma explícita en la especificación de Milunovich y Joyeux (2007). Seguimos una especificación trivariante con Y_t = (s_t, f_t, r_t)', donde s_t = ln(S_t), f_t = ln(F_t) y r_t es el Euribor 12M, siguiendo el planteamiento de Milunovich y Joyeux (2007) que se basa en los resultados de Brenner y Kroner (1995) quienes determinan que la cointegración entre spot y futuros depende críticamente de las propiedades de serie temporal

del cost-of-carry, de manera que cuando el tipo de interés es I(1), la inclusión de éste en el sistema es necesaria.

Nos centramos en los resultados de α_s, α_f y α_r Si α_s resulta estadísticamente significativo y $\alpha_f$no, ello indicaría que el mercado spot corrige las desviaciones respecto al equilibrio, mientras que el mercado de futuros incorpora la información más rápidamente. De lo contrario, sería el precio spot el que incorpora antes la información. Si ambos coeficientes son estadísticamente significativos, la corrección del desequilibrio se repartiría entre ambos mercados, lo que sería consistente con un proceso de price Discovery conjunto, como es el caso del estudio de Milunovich y Joyeux (2007). El coeficiente α_r del tipo de interés se espera no significativo (exogeneidad débil) ya que Euribor lo determina la política monetaria del BCE y no debería responder a desviaciones del cost-of-carry de los EUAs.

VI. Resultados

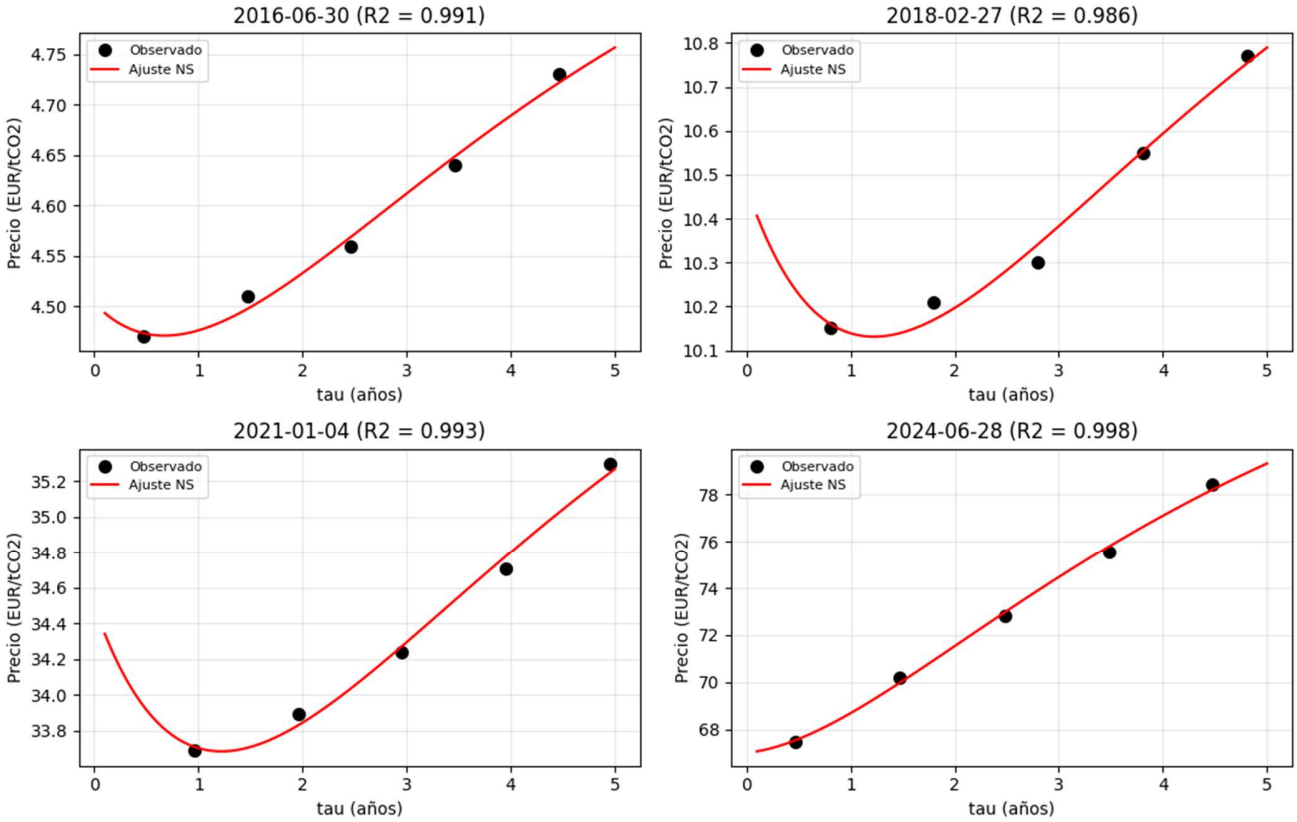
Como comentamos, la primera parte consiste en modelar, mediante el modelo Nelson Siegel de Diebold & Li (2006) , el nivel pendiente y la curva de los futuros de EUAS en fases III y IV. La estimación del modelo Nelson-Siegel se realiza mediante Mínimos Cuadrados Ordinarios (OLS, por sus siglas en inglés) sobre el conjunto de datos previamente definidos, asumiendo un parámetro λ fijo de 0.7308, siguiendo la lógica de Diebold & Li (2006), quienes sitúan el máximo del loading de β_2 (curvatura) un vencimiento de 2.5 años, punto medio del rango de vencimientos cubierto. Los resultados muestran un R^2 medio diario de 99.3%, superior al 95% medio reportado por Bianchi et al. (2023), pero inferior al 99.7% de Karstanje et al.(2015). La Figure **1** muestra el ajuste a la curva observada en cuatro fechas representativas de distintos momentos regulatorios y de mercado, más concretamente:

- junio de 2016 (Fase III estable, régimen de precios bajos previos a la reforma del MSR)
- febrero de 2018 (Consejo aprueba formalmente la reforma del EU ETS para el periodo post-2020)

- enero de 2021 (primer día hábil de la Fase IV)
- junio de 2024 (Fase IV ya consolidada y post Fit for 55 de 2023)

En las cuatro fechas el R^2 supera 98%, lo que indica que los tres factores capturan prácticamente toda la información de la estructura temporal de los EUAS en el periodo observado. En segundo lugar, esta comparación entre eventos muestra cómo el nivel de la curva responde a la evolución del marco regulatorio del EU ETS. Adicionalmente, la forma que adquiere la curva ante shocks (Figure 1), sugiere que el factor β_2 recoge información económica relevante especialmente sobre desajustes de la curva, particularmente durante de cambios de fase tanto en el momento en el que se anuncia el cambio como el de su entrada en vigor, lo cual es especialmente interesante dado que, cabría esperar que el mercado descontase el efecto una sola vez pero se puede deber a que en el anuncio, se descontó de forma parcial debido a la incertidumbre sobre la implementación de esta nueva fase y los cambios que conllevaba.

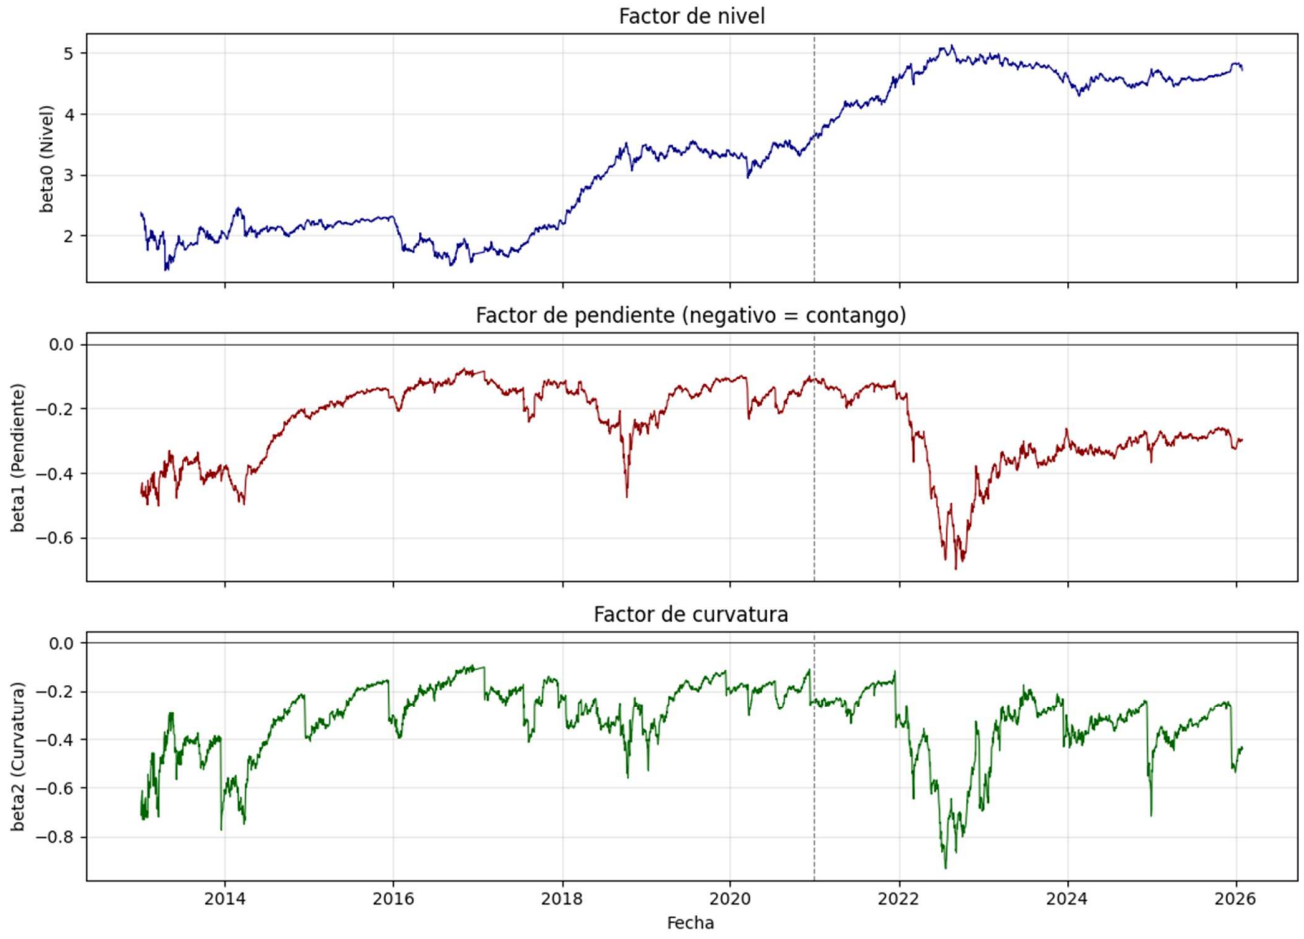
Figure 1: Ajuste del modelo NS sobre fechas seleccionadas



La Figura 2 muestra la trayectoria diaria de los tres factores estimados, con una línea vertical indicando el final de la Fase III. β_0 describe una tendencia escalonada coherente con las reformas regulatorias del EU ETS, donde, tras un período prolongado en torno a $\beta_0 = 2$ hasta 2017 equivalente a un precio implícito de largo plazo de 7-8 EUR/tCO_2 y coherente con el período de sobreoferta estructural tras la crisis financiera de 2008, el factor inicia una tendencia ascendente con la reforma del MSR y alcanza valores próximos a 5 a partir de 2023, lo que equivale a un precio de largo plazo superior a 100 EUR/tCO_2. Por otro lado, β_1 se mantiene persistentemente negativo durante toda la muestra, confirmando la presencia continuada de contango documentada por Bredin and Parsons (2014). En la teoría clásica de la estructura temporal de commodities almacenables, el contango se asocia con una

convenience yield baja o negativa, ya que los costes financieros y de almacenamiento son mayores que el beneficio implícito de mantener el activo físico. Sin embargo, como argumentan Daskalakis et al. (2009) y Bredin y Parsons (2014), los EUAs no presentan costes de almacenamiento físico, lo que elimina uno de los dos componentes habituales del cost-of-carry. En consecuencia, el contango observado en la curva de los EUAs debe interpretarse, en condiciones de eficiencia, como reflejo del coste de oportunidad del capital únicamente, es decir, el precio del futuro supera al spot en una magnitud aproximada a $r \cdot \tau$, sin necesidad de invocar una convenience yield distinta de cero, lo que implica que el contango persistente no equivale a convenience yield nula, sino que es compatible con ella. La cuestión es de qué magnitud es ese contango ya que, si su pendiente coincide con $r \cdot \tau$, la convenience yield del EUA es estadísticamente nula y el cost-of-carry se cumple, mientras que si la pendiente excede sistemáticamente $r \cdot \tau$, existe una convenience yield negativa que indica que el mercado valora el futuro por encima de lo que justifica el coste financiero del capital (los "spot baratos" documentados por Bredin y Parsons en Fase II). Es por ello que más adelante, se aplica el análisis de cointegración trivariante (Tabla 3), donde el coeficiente del tipo de interés en el vector de equilibrio permite contrastar si la pendiente observada coincide con $r \cdot \tau$ teórico. β_2 presenta una dinámica más ruidosa que tratamos más abajo con la Tabla 5.

Figure 2: β_0, β_1 y β_2 estimados a lo largo del periodo muestral



La Tabla 5 muestra los estadísticos descriptivos de los factores por fase, junto con los p-valores del test t de Welch sobre la igualdad de medias y del test de Levene sobre la igualdad de varianzas que nos permiten contrastar si los factores presentan medias y dispersiones estadísticamente distintas entre las dos fases regulatorias. Es significativa la reducción de la dispersión de β_0 que pasa de 0.65 a 0.30, lo cual indica que el mercado ha estabilizado sus expectativas de largo plazo en torno al nuevo régimen de precios elevados. Adicionalmente, esta caída en la incertidumbre sobre el valor fundamental del EUA es

coherente con el fortalecimiento progresivo del marco regulatorio del EU ETS. En segundo lugar, el factor β_1 pasa de -0.22 a -0.31 (t-pval < 0.001), lo que confirma la profundización del contango ya identificada en la trayectoria temporal del factor. Sin embargo, el cambio en la varianza es significativo al 5% pero no al 1% (Levene-pval = 0.04), lo que sugiere que la intensidad de las fluctuaciones de la pendiente se mantiene relativamente estable entre fases, pese al desplazamiento del nivel medio. Cabe destacar que el valor mínimo de β_1 en la fase IV (-0.70) corresponde al periodo de máxima tensión del segundo semestre de 2022, durante la crisis energética europea provocada por la guerra de Ucrania. Junto a éste, β_2 también presenta un cambio significativo en la media (-0.29 a -0.36, t-pval < 0.001), pero sin variación estadísticamente significativa en su varianza (Levene-pval = 0.51). Este shock revela un patrón interesante ya que, pese al incremento extremo del precio del gas, el tramo corto de la curva de los EUAs se ve negativamente presionado, en sentido contrario al que predeciría el canal energético directo. La caída del front se puede explicar como la respuesta a las expectativas de menor demanda industrial de cumplimiento y, sobre todo, al adelanto de oferta de subastas en el marco de REPowerEU [2]concebido para financiar la sustitución de gas ruso, que inyecta oferta cercana sin alterar la escasez estructural de largo plazo y, por tanto, profundiza el contango (β_1 y β_2 marcadamente negativos). Esta interpretación se ve reforzada por la sección siguiente donde se muestra la pérdida de poder explicativo de los drivers energéticos sobre el precio de los EUAs. El análisis de la matriz de correlaciones entre factores (Tabla 6) revela una correlación muy elevada entre β_1 y β_2 (0.92 en la Fase III; 0.83 en la Fase IV), indicando que ambos factores no son dimensiones independientes de la curva. Cabe destacar el cambio de signo de la correlación entre β_0 y β_1, que pasa de 0.21 en la Fase III a -0.79 en la Fase IV donde se puede interpretar como que la pendiente deja de reflejar factores de escasez independientes y pasa a estar gobernada por el tipo de interés, que durante el ciclo de subidas de 2022-2023 se elevó en paralelo al precio del derecho, al contrario que en la Fase III, con tipos próximos a cero y constantes y una pendiente

[2] Plan elaborado por la Comisión Europea para eliminar gradualmente las importaciones de combustibles fósiles rusos. Entre las medidas tomadas, está la venta de derechos de emisión en virtud del régimen de comercio de derechos de emisión (RCDE).

determinada por el superávit de derechos y el backloading. Adicionalmente, en el gráfico histórico de β_2 (véase Figure 2) se identifican discontinuidades sistemáticas en torno a las fechas de vencimiento del DEC1, atribuibles al desplazamiento debido al rolling de contratos. Estos resultados dan lugar a multicolinealidad e inestabilidad entre β_1 y β_2, por lo que el análisis desarrollado en la siguiente sección se centra exclusivamente en los factores β_0 y β_1, excluyendo β_2 del modelo y siguiendo la línea de Karstanje et al. (2015), que encuentran este mismo problema en los factores de los metales.

Antes de especificar el modelo de regresión, se examina el orden de integración de los factores estimados. La elección entre trabajar con los factores en niveles o con sus primeras diferencias depende de su estacionariedad, ya que aplicar regresión a series no estacionarias en niveles expondría las estimaciones al problema de regresión espuria documentado por Granger y Newbold (1974), invalidando la inferencia estadística. Como se muestra en la Figura 3, las autocorrelaciones de primer orden entre los factores reflejan una persistencia (β_0=0.9997 y β_1=0.9975). Este patrón es indistinguible del de un proceso de raíz unitaria y coincide con el documentado por Diebold y Li (2006) para los factores Nelson-Siegel sobre las cruvas de tipos. Sin embargo, las correlaciones de las primeras diferencias $\Delta\beta_0$,t y $\Delta\beta_1$,t son próximas a cero en la mayoría de los lags (véase figura 4), consistentes con procesos estacionarios. Para reforzar dicha conclusión aplicamos el test ADF y el KPSS como muestra la Tabla 7 donde el test ADF presenta p-valores de 0.88 (β_0) y 0.13 (β_1), no rechazando la hipótesis nula de raíz unitaria en ninguno de los dos casos mientras que el test KPSS rechaza la hipótesis nula de estacionariedad con p-valores de 0.01 en ambas series por lo que ambos test 3caracterizar a β_0 y β_1 como series no estacionarias en niveles por lo que optamos por especificar sobre las diferencias entre β_0 y β_1. Adicionalmente, las cuatro commodities (TTF, carbón, electricidad y Brent) son inequívocamente I(1) en niveles e I(0) en cuanto a sus variaciones logarítmicas, que pueden interpretarse como retornos diarios. Por otro lado, las variables de incertidumbre EPU y GPR presentan resultados ambiguos dado, que el test ADF se aproxima al rechazo de la raíz unitaria, mientras que el test KPSS rechaza con fuerza la estacionariedad. Ante este resultado mixto, se opta por su uso en primeras diferencias (en lugar de usar sus niveles absolutos), lo que además mantiene la coherencia

metodológica con los demás drivers y replica el procedimiento adoptado por Liu et al. (2021) y Lu et al. (2024).

Los resultados de la estimación por OLS (Tabla 8) muestran que el R^2 ajustado del modelo cae sustancialmente entre fase III y fase IV (9% vs 41% para el factor de nivel β_0, y del 1% vs 15% para el factor de pendiente $\beta)_1$. Esta reducción indica que los drivers que la literatura previa identifica como determinantes del precio de los EUA (Dittmann et al., 2024; Lovcha et al., 2022) pierden la mayor parte de su poder explicativo en el régimen actual del mercado (Fase IV). Cabe destacar el retorno del índice de electricidad alemán, driver dominante en ambas fases, pero con sensibilidad radicalmente distinta. Como se muestra en la Tabla 8, el coeficiente sobre $\Delta\beta_0$ cae de 1.27 en la fase III a 0.12 en la fase IV (reducción del 91%), manteniéndose significativo al 1% en ambos casos. Sobre $\Delta\beta_1$ pasa de 0.23 a 0.02 y pierde toda significatividad. Este patrón refleja la transformación del mecanismo de transmisión entre el mercado eléctrico y el de emisiones: en la tercera fase, el sector eléctrico, el principal emisor cubierto por el EU ETS, transmitía sus condiciones de coste al EUA vía cost pass-through. Sin embargo, en la fase IV, la mayor penetración de renovables, la salida progresiva del carbón del mix y el creciente peso de factores regulatorios y especulativos (MSR reforzado, Fit for 55) han evidenciado una mayor autonomía del precio del carbono respecto a drivers eléctricos tradicionales. Cabe destacar que los residuos de los cuatro modelos OLS presentan kurtosis muy elevada (8.7-17.5) y niveles de Jarque-Bera con $p < 0.001$, indicando la presencia de outliers asociados a eventos regulatorios y de mercado extremos no capturados por la especificación lineal.

Siguiendo con los resultados del modelo ARX, el primer resultado que llama la atención es que los lags propios de $\Delta\beta_0$ y $\Delta\beta_1$ no son significativos en ninguno de los cuatro modelos. En el modelo de β_0 para la fase III, por ejemplo, los dos lags tienen coeficientes de 0.0004 y 0.044, y solo el segundo alcanza significatividad al 5% con una magnitud demasiado pequeña para considerarla relevante en términos económicos. Lo mismo ocurre en la fase IV y en los dos modelos de β_1, lo cual nos indica que la persistencia que se observaba en los factores en niveles desaparece en cuanto se trabaja con diferencias, y por tanto los R^2 del

OLS no estaban inflados por la propia serie. Donde sí aporta algo nuevo, el ARX es en los lags de los drivers. En el modelo de β_0 para Fase III aparece un efecto del carbón con un lag que el OLS no detectaba: coeficiente negativo y significativo al 5% (−0.074, p = 0.017). Lo interesante es el signo, ya que según la intuición más directa (sube el carbón, se quema más carbón, suben las emisiones, sube el precio del EUA), el coeficiente debería ser positivo. Lo que se observa es justo lo contrario, cuando el carbón se encarece, β_0 cae al día siguiente. La explicación más razonable es que el mercado anticipa el fuel switching, es decir, si el carbón sube, las utilities sustituyen carbón por gas en la generación, lo que reduce las emisiones esperadas y arrastra a la baja la componente de largo plazo del precio del carbono. El efecto no se ve en el mismo día porque la decisión de despacho (dispatching) y el ajuste del mix no son instantáneos. Esta interpretación encaja con la idea de que el carbón no afecta al EUA tanto por las emisiones que provoca como por las expectativas que genera sobre el mix futuro.

Tabla 1: R^2 y R^{2*} de los modelos OLS y ARX por factor y fase

	R2_OLS	**R2*_OLS**	**R2_ARX**	**R2*_ARX**	**Mejora R2***
$\Delta\beta_0$ Fase III	0.408	0.406	0.418	0.414	0.008
$\Delta\beta_0$ Fase IV	0.091	0.086	0.113	0.103	0.016
$\Delta\beta_1$ Fase III	0.147	0.145	0.163	0.156	0.012
$\Delta\beta_1$ Fase IV	0.014	0.010	0.038	0.028	0.018

Como se muestra en la Tabla 1, en la fase IV el R^2 ajustado del modelo de β_0 es 0.103 frente al 0.414 de Fase III, y casi todos los regresores contemporáneos pierden significatividad salvo Power, cuyo coeficiente cae a 0.13. El único driver dinámico que sigue siendo significativo es el carbón con un lag, con un coeficiente prácticamente idéntico al de Fase III (−0.069, p = 0.009). Que este efecto sobreviva al cambio de fase es interesante porque indica que, aunque el vínculo entre el mix energético y el EUA se ha debilitado en la fase IV, las utilities siguen tomando decisiones diarias de despacho entre centrales de carbón y de gas en función de los precios relativos de ambos combustibles (fuel switching), lo que se traduce en cambios en la demanda de allowances con un día de retraso (lag). Que solo uno

de los doce drivers con lag conserve significatividad en Fase IV refuerza la idea, ya planteada en la sección OLS, de que el precio del carbono se ha desacoplado en gran medida de sus fundamentos energéticos tradicionales. Este desacople se puede deber a la transformación estructural del mix energético europeo con el desarrollo de las renovables, que ha reducido la elasticidad histórica entre demanda eléctrica y emisiones de CO_2, debilitando la influencia del precio de la electricidad sobre los EUAs. En segundo lugar, el endurecimiento progresivo del cap regulatorio (LRF al 4.3% anual desde 2024) introduce una restricción de oferta cada vez más vinculante que opera con independencia de los niveles de actividad sectorial. Cuando el determinante principal del precio es la escasez regulatoria impuesta de manera predeterminada, los shocks transitorios del mix energético pierden capacidad explicativa relativa. En tercer lugar, la estandarización [3]progresiva del mercado del carbono, con mayor presencia de operadores institucionales, como muestran Marcu et al., (2025), asegurando que el número de fondos con posiciones en EUAs aumentó 10% YoY en 2024. Esta evolución introduce dinámicas de precio derivadas de expectativas regulatorias forward-looking que no están capturadas por los drivers energéticos tradicionales, coherente con la evidencia de Wegener et al. (2024), quienes argumentan que el precio del EUA en Fase IV refleja crecientemente expectativas sobre escasez futura y endurecimiento regulatorio, y con la de Dittmann et al. (2024), que documentan la desaparición de la cointegración entre el EUA y las variables energéticas en la Fase IV.

El modelo de β_1 muestra un patrón similar. En la fase III, el carbón aparece dos veces, ambos con signo negativo y significativos (−0.024 y −0.030), lo que sugiere que un encarecimiento del carbón aplana β_1 tanto en el día del shock como al día siguiente. Y aparece un detalle interesante en Power: el coeficiente es positivo (0.227, fuertemente significativo), pero el del lag es negativo y significativo al 5% (−0.048, $p = 0.022$). Este patrón se puede interpretar como que el shock de electricidad inclina la curva en t y se corrige parcialmente en t+1. Es lo que cabe esperar en un mercado que digiere rápido la información energética. Sin embargo, en la fase IV, el modelo prácticamente se cae, con R^2 ajustado de 0.028 y solo

[3] Con estandarización nos referimos a la evolución del mercado de EUAs hacia un mercado más similar al de los derivados financieros con mayor influencia de bancos, fondos de inversión,etc…

el carbón con un lag conserva significatividad clara. La variable power se queda al límite del 10% y el resto de los drivers no aportan información significativa. Por lo tanto, la dinámica de β_1 en Fase IV no se puede explicar con los drivers energéticos a frecuencia diaria, y lo más probable es que esté desplazada por factores que el modelo no observa como expectativas regulatorias sobre el techo, las reglas de banking y la evolución del MSR. Este resultado conecta directamente con la siguiente sección del trabajo, porque apunta a que existe un componente del precio relativo entre vencimientos que no responde a fundamentales y que es compatible con un convenience yield de origen regulatorio.

Antes de aplicar el procedimiento de Johansen, es necesario confirmar que las tres series del sistema (ln(S), ln(F) y r) son individualmente I(1) (no estacionarias), condición necesaria para que la cointegración tenga sentido como concepto. Para ello se aplican los mismos tests ADF y KPSS empleados previamente en el análisis ARX, con especificación constante ('c') para las tres series. Esta es la especificación apropiada dado que estas series no presentan una tendencia determinística (una trayectoria lineal sistemática en el tiempo), por lo que el contraste se plantea frente a la alternativa de estacionariedad en torno a una media constante, es decir, ADF-'c' contrasta H_0 = "hay raíz unitaria" frente a H_1 = "es estacionaria alrededor de una constante". el análisis de robustez llevado a cabo en la Tabla 9 confirma además que la inclusión de tendencia no mejora el ajuste y solo reduce la potencia del contraste, lo que respalda empíricamente esta especificación.

Los resultados expuestos en la Tabla 2 confirman que las tres series son inequívocamente I(1) en la fase III donde el ADF no rechaza la raíz unitaria en niveles ($p > 0.40$ en todos los casos) y el KPSS rechaza la estacionariedad ($p < 0.01$). Las primeras diferencias son I(0) por ambos tests. En Fase IV, el tipo de interés es igualmente I(1), mientras que el spot y el futuro, según el ADF con constante, rechazan la raíz unitaria al 5% ($p = 0.011$ y 0.012), pero el rechazo no se sostiene al 1% ni bajo especificaciones con tendencia ('ct') donde, el p-valor asciende a 0.090-0.09 (Tabla 9), mientras que el KPSS rechaza la estacionariedad ($p < 0.01$). Ante esta evidencia conflictiva, tratamos s y f como I(1) ya que el rechazo del ADF-'c' es frágil y el tratamiento es coherente con la Fase III,

donde las mismas series son claramente I(1). Como demuestran Brenner y Kroner (1995), si r es I(1), spot y futuros no pueden estar cointegrados entre sí, sino únicamente en un sistema trivariante que incorpore explícitamente el tipo. Esto motiva la especificación trivariante adoptada en este trabajo, en línea con Milunovich y Joyeux (2007), y contrasta con el enfoque bivariante de Figuerola-Ferretti y Gonzalo (2010) en commodities tradicionales, donde la asunción de cost-of-carry estacionario es razonable pero no se sostiene en el caso del EU ETS durante Fases III y IV, dado el cambio de régimen del Euribor en ese periodo, donde se pasa de tipos negativos a tipos del 2% - 4%.

Tabla 2: Tests de estacionariedad ADF y KPSS sobre las variables del modelo de cointegración[4]

Fase	Serie	ADF	ADF p-val	KPSS	KPSS p-val
III	s = ln(S)	-0.363	0.916	5.230	< 0.01
III	Δs = ln(S)	-39.664	< 0.001	0.134	> 0.10
III	f = ln(F)	-0.279	0.928	5.183	< 0.01
III	Δf = ln(F)	-38.779	< 0.001	0.157	> 0.10
III	r	-1.641	0.462	4.811	< 0.01
III	Δr	-6.122	< 0.001	0.236	> 0.10
IV	s = ln(S)	-3.390	0.011	1.279	< 0.01
IV	Δs = ln(S)	-22.848	< 0.001	0.209	> 0.10
IV	f = ln(F)	-3.381	0.012	1.349	< 0.01
IV	Δf = ln(F)	-32.811	< 0.001	0.219	> 0.10
IV	r	-1.511	0.528	3.152	< 0.01
IV	Δr	-6.373	< 0.001	1.104	< 0.01

El test de Johansen requiere especificar el orden del VAR subyacente sobre el sistema (s, f, r), que se determina mediante los cuatro criterios de información habituales: AIC, BIC, FPE y HQIC, explorando órdenes entre 0 y 10 lags (Tabla 10). En la fase III, AIC y FPE

[4] *Los p-valores del KPSS se obtienen por interpolación de una tabla acotada al rango [0,01–0,10]; los valores fuera de ese rango se reportan como < 0,01 o > 0,10 según la dirección que indica el contraste*

definen 8 lags, HQIC selecciona 7 y BIC se queda en 2 mientras que en la fase IV la divergencia es menor (AIC, FPE y HQIC convergen en 4 lags, mientras que BIC sugiere 3). Se opta por el criterio HQIC (Hannan-Quinn) como referencia para ambas fases dado que es un criterio que ofrece un punto intermedio entre el AIC y el BIC, evitando los sesgos extremos de ambos, además de ser el criterio recomendado por Lütkepohl (2005) para la especificación de VAR en aplicaciones de cointegración, donde el sobreajuste de AIC puede comprometer la inferencia posterior sobre el rango de cointegración. Por lo tanto, se adopta un VAR de orden 7 en la fase III y de orden 4 en la fase IV. No obstante, la validación de los residuos mediante el test de Portmanteau revela que, mientras el VAR de orden 4 produce residuos no auto correlacionados en la Fase IV, el orden seleccionado en la Fase III no logra eliminar la autocorrelación residual, resultado que persiste al aumentar el orden hasta 12, lo que apunta a una inestabilidad dinámica dentro de la fase, posiblemente asociada a cambios de régimen regulatorio, más que a una insuficiencia de lags. Por este motivo, los resultados de la Fase III se interpretan con cautela y el análisis se concentra en la Fase IV.

Los resultados del test de Johansen aplicado al sistema trivariante (s, f, r) se presentan en la Tabla 3. La especificación incluye una constante restringida al espacio de cointegración y sin tendencia determinística (det_order = 0), consistente con la especificación empleada en los contrastes de raíz unitaria ('c') y en la posterior estimación del VECM ('ci'). El número de lags en diferencias se establece en 3 para la fase IV (VAR de orden 4) y en 6 para la fase III (VAR de orden 7), según el criterio HQIC previamente seleccionado y restándole un lag, según la reparametrización de la fórmula VECM de statsmodels.

Tabla 3: Resultados Test de cointegración de Johansen[5]

	Fase III		Fase IV	
Hipótesis nula	**test de traza**	**test máx. autovalor**	**test de traza**	**test máx. autovalor**
r = 0	59.926***	55.643***	82.914***	61,370***
r ≤ 1	4.283	4.272	21.545**	16.125**
r ≤ 2	0.011	0.011	5.420**	5.420**

Vector de Cointegración	**Fase III**	**Fase IV**
βs	-1.0084	-0.9947
βf	1.0000	1.0000
βr	-7.4192	-0.4815
Rango de cointegración	r=1	r=1

Los resultados confirman la existencia de cointegración entre spot, futuro y tipo de interés en ambas fases, aunque con un alcance distinto. En la fase III, el sistema presenta cointegración, pero con un único vector (r = 1). El coeficiente sobre el spot es próximo al valor teórico (βs = −1.008), pero el del tipo de interés se aleja sustancialmente del esperado: βr = −7.35 frente a un valor teórico próximo a −0.53. Esta desviación de magnitud indica que, aunque existe una relación estable de largo plazo, no responde a la lógica del no arbitraje puro, en línea con las desviaciones del cost-of-carry documentadas por Milunovich y Joyeux (2007) y Bredin y Parsons (2014) para fases anteriores. No obstante, la magnitud de βr debe interpretarse con cautela ya que el carácter prácticamente constante y nulo del tipo de interés en la Fase III debilita su identificación, por lo que el coeficiente refleja esa imprecisión más que un parámetro estructuralmente estimado.

[5] *Valores críticos al 95%: traza 29,80 (r=0), 15,49 (r≤1), 3,84 (r≤2); máx. autovalor 21,13, 14,26, 3,84. *** p<0,01, ** p<0,05.*

Por el contrario, en la Fase IV, como muestra la Tabla 3, los tests de la traza y del máximo autovalor coinciden en rechazar las tres hipótesis del rango ($r \leq 0$, $r \leq 1$ y $r \leq 2$), lo que apuntaría a un rango pleno. Este resultado se debe a que el procedimiento de Johansen identifica las relaciones de cointegración contabilizando las direcciones estacionarias del sistema, el hecho de que s y f se sitúen en la frontera entre I(1) e I(0) lleva al contraste a contabilizar esa casi-estacionariedad como relaciones de equilibrio adicionales, sobreestimando el rango. Adicionalmente, el rechazo de $r \leq 2$ es el más débil de los tres (estadístico de 5.420 frente al valor crítico de 3.841), situándose en el límite de la significatividad, y únicamente el primer vector presenta coeficientes económicamente interpretables. Por ello, el rango pleno se interpreta como reflejo de esta distorsión, y se impone un rango unitario (coint_rank = 1) reteniendo el primer vector, único con interpretación económica directa en el marco del cost-of-carry. El primer vector, normalizado sobre el precio del futuro, presenta coeficientes notablemente próximos a los teóricos del cost-of-carry: $\beta s = -0.995$ frente al valor teórico de -1, y $\beta r = -0.4815$ frente al valor teórico aproximado de $-\tau_medio = -0.53$ (horizonte medio de 195 días en la muestra). Este resultado no debe interpretarse como evidencia de ausencia absoluta de convenience yield, sino como evidencia de que, en promedio durante la Fase IV, la relación de equilibrio entre spot, futuro y tipo de interés es estadísticamente compatible con el cost-of-carry teórico sin necesidad de incorporar un término adicional de convenience yield. Este hallazgo es coherente con la naturaleza de los propios EUAs, al carecer de almacenamiento físico, el único componente del coste de mantenimiento es el financiero ($r \cdot \tau$), de modo que el equilibrio no exige un convenience yield adicional.

Vemos que en la fase III, la cointegración existe, pero el cost-of-carry teórico no se cumple, lo que reproduce de manera directa el hallazgo central de Milunovich y Joyeux (2007). En la fase IV, por el contrario, los coeficientes del primer vector convergen hacia los valores teóricos, sugiriendo que el mercado de los EUAs ha evolucionado hacia un comportamiento más alineado con la teoría financiera estándar. Dittmann et al. (2024) encuentran que los EUAs pierden cointegración con sus drivers energéticos en la fase IV, mientras que en este trabajo se encuentra que éstos ganan cointegración con su estructura

financiera (spot, futuro, tipo) en la fase IV, es decir, el precio del carbono se desacopla de sus fundamentales exógenos y se ancla a su equilibrio financiero. Esta lectura enlaza con Creti et al.,(2012), que aplican el mismo marco de cointegración de Johansen a las Fases I y II del EU ETS y concluyen que la naturaleza del equilibrio cambia entre fases, con un papel creciente de los fundamentales en la Fase II. La transición III→IV analizada aquí prolonga ese resultado una etapa más, si bien en sentido distinto ya que donde Creti et al., (2012) observa un estrechamiento en torno a los fundamentales energéticos, en la Fase IV el equilibrio se rearticula en torno a la estructura financiera del cost-of-carry. Estos resultados refuerzan aquellos de Wegener et al.(2024) quienes argumentan que las subidas del precio reflejan expectativas forward-looking sobre escasez futura y endurecimiento regulatorio. El análisis posterior del VECM se centra exclusivamente en el primer vector de cointegración por su interpretación económica directa.

Confirmada la existencia de cointegración en ambas fases, el siguiente paso consiste en analizar el mecanismo de ajuste hacia el equilibrio mediante la estimación del VECM. Los resultados se presentan en la Tabla 4, complementados con los pesos de Gonzalo-Granger (1995), que cuantifican la contribución de cada mercado al proceso de price discovery.

Tabla 4: Resultados VECM y de Gonzalo-Granger

Coeficientes de ajuste	**Fase III**	**Fase IV**
α_s	−0.2551*** (−3,646)	−0.1820** (−2.374)
α_f	−0.1042 (−1,516)	0.0737 (0,925)
α_r	0.0002 (1,232)	0.0002 (0,164)
Pesos Gonzalo-Granger[67]		
GG_s	n.d.[a]	28,82%
GG_f	n.d.[a]	71,18%

Los resultados revelan un patrón estable entre fases. En ambas, el coeficiente de ajuste del precio spot resulta significativo y negativo (α_s = −0.182 en la fase IV con t = −2.37; α_s = −0.255 en la fase III con t = −3.65), mientras que los coeficientes del futuro y del tipo de interés son estadísticamente indistinguibles de cero. Estos resultados indican que cuando el sistema se aleja del equilibrio de largo plazo, es el precio spot el que se ajusta para corregir la desviación, mientras que el futuro permanece inalterado, patrón que identifica al mercado de futuros como líder del price discovery, ya que es el precio futuro que no reacciona al desequilibrio el que incorpora la información primero y arrastra al otro. El tipo de interés se comporta, por tanto, como variable exógena débil (α_r no significativo en ambas fases), lo que es coherente con su naturaleza de input determinado por la política monetaria del BCE y no por la dinámica del mercado del carbono. La magnitud del coeficiente α_s implica una velocidad de ajuste moderadamente rápida, por ejemplo, en la fase IV, aproximadamente el 18.2% de cualquier desviación del equilibrio se corrige en un día, lo que equivale a una vida media del desequilibrio de aproximadamente 3.5 días hábiles. La asignación del peso de cada

[6] *Pesos calculados según la descomposición Permanente-Transitoria de Gonzalo y Granger (1995), en la especificación de Figuerola-Ferretti y Gonzalo (2010): α⊥' = (α_f/(−α_s+α_f), −α_s/(−α_s+α_f)). GG_s y GG_f suman la unidad. En la Fase III, ambos coeficientes de ajuste (α_s y α_f) presentan el mismo signo negativo, por lo que la descomposición de Gonzalo-Granger arroja pesos fuera del rango válido [0,1] (GG_s = −69,0%, GG_f = 169,0%). El resultado no es económicamente interpretable, en consonancia con la inestabilidad dinámica de la Fase III documentada en la sección de limitaciones.*

mercado en el price discovery mediante los pesos de Gonzalo-Granger nos muestra que, en la Fase IV el mercado de futuros aporta el 71.2% del price discovery mientras que el peso del spot es notablemente menor (28.8%). En la Fase III, en cambio, la descomposición no produce pesos económicamente interpretables, ya que ambos coeficientes de ajuste presentan el mismo signo negativo, lo que genera ponderaciones fuera del rango válido [0,1]. Este resultado es consistente con la inestabilidad dinámica de la Fase III ya señalada, cuya estructura de ajuste no permite un reparto limpio entre un mercado líder y uno seguidor, y motiva que el análisis del price discovery se concentre en la Fase IV. La comparación con la literatura previa permite contextualizar estos hallazgos. Milunovich y Joyeux (2007) estiman un VECM trivariante similar al aquí desarrollado para Fase I del EU ETS, y encuentran en el contrato DEC-2007 que el coeficiente de ajuste del futuro es −0.689 (t = −3.38), significativo, mientras que el del spot es −0.084 (t = −0.41), no significativo, y para el contrato DEC-2006, ambos resultan no significativos, lo que les lleva a concluir que el price discovery en Fase I del EU ETS se distribuía entre los dos mercados sin un líder informacional claro. Los resultados del presente análisis muestran, por tanto, una transformación cualitativa del proceso de price discovery entre Fase I y las fases posteriores. Mientras Milunovich y Joyeux documentaban un mercado donde el spot y el futuro compartían la formación del precio de manera bidireccional, los resultados aquí obtenidos muestran un patrón mucho más cercano al estándar de los mercados de commodities maduros donde el precio de los futuros lidera de forma clara el price discovery y el spot se ajusta a posteriori. Este cambio sugiere que el mercado de EUAs ha evolucionado desde un mercado en desarrollo con estructura informacional difusa, hacia un mercado financiero maduro. Del mismo modo, Figuerola-Ferretti y Gonzalo (2010), aplicando la misma descomposición de Gonzalo y Granger (1995) a los cinco metales no férreos del LME, encuentran que en los contratos con futuros líquidos (Al, Ni, Zn) el futuro es el dominante en el price discovery, coincidente con el peso del futuro en los EUA durante la Fase IV (72%) se sitúa de lleno en ese rango y resulta próximo al 75% que Garbade y Silber (1983) identifican como referencia de mercados de futuros maduros. Es relevante subrayar que esta dominancia del futuro es un fenómeno de liquidez que se concentra en el mercado con mayor número de participantes

con la diferencia de que los metales del LME se hallan mayoritariamente en backwardation y los EUAs en contango. En conjunto, los resultados describen un mercado de EUAs en el que el futuro lidera de forma clara el price discovery y cuyo equilibrio de largo plazo es coherente con el cost-of-carry teórico.

VII. Conclusiones

El presente trabajo ha abordado el comportamiento financiero del mercado del carbono europeo desde una doble perspectiva: la estructura temporal de la curva de futuros, modelada mediante el modelo Nelson-Siegel, y la relación de equilibrio entre los precios spot y futuros, analizada mediante cointegración de Johansen y VECM. El periodo muestral abarca las Fases III y IV del EU ETS, lo que ha permitido contrastar empíricamente cómo dos regímenes regulatorios distintos y los cambios de éstos, afectan a la formación de precios del carbono.

El análisis de los factores de Nelson-Siegel revela una clara reestructuración del mercado entre fases. El factor de nivel β_0, que captura la expectativa de largo plazo sobre el precio del carbono, multiplica por más del doble su media entre Fase III y Fase IV y reduce sustancialmente su dispersión, reflejando un anclaje firme del mercado en el nuevo régimen de precios elevados. El factor de pendiente β_1, que recoge la diferencia entre el corto y el largo plazo de la curva, se mantiene mayoritariamente negativo, lo que indica una curva en contango estructural compatible con la reducción progresiva de la oferta inducida por el Linear Reduction Factor y la Market Stability Reserve. El análisis de regresión sobre los drivers fundamentales muestra una pérdida sustancial del poder explicativo de las variables energéticas en Fase IV, con caídas del R^2 ajustado del 41% al 10% para β_0 y del 15% al 3% para β_1. Esta evolución, coherente con los hallazgos de Dittmann et al. (2024), sugiere que los drivers físicos del sector energético han dejado de ser los principales determinantes del precio del carbono en el régimen actual.

El análisis de cointegración trivariante aporta una pieza complementaria de la misma narrativa. En ambas fases existe cointegración entre el spot, el futuro y el tipo de interés, lo

que confirma la presencia de relaciones de equilibrio estables de largo plazo entre las tres variables. Sin embargo, la naturaleza del equilibrio cambia cualitativamente entre regímenes. En la Fase III, la relación de cointegración existe, pero los coeficientes del vector se alejan sustancialmente del cost-of-carry teórico, reproduciendo el hallazgo de Milunovich y Joyeux (2007) para la Fase I mientras que en la cuarta fase los coeficientes del primer vector de cointegración convergen hacia los valores teóricos del cost-of-carry puro lo que constituye evidencia inédita en la literatura sobre el EU ETS y es que el mercado del carbono cumple, en su fase actual, la estructura financiera estándar de no arbitraje entre spot, futuro y tipo de interés. El análisis del VECM y los pesos de Gonzalo-Granger confirman además que el mercado de futuros lidera el price discovery en la Fase IV, aportando el 71% éste, un patrón propio de los mercados de commodities financieros maduros que contrasta con el descubrimiento compartido que Milunovich y Joyeux (2007) documentaron para la Fase I del EU ETS, lo que sugiere una mayor integración informacional entre los dos mercados.

Por lo tanto, podemos concluir que el mercado del carbono europeo ha experimentado en Fase IV una transformación estructural que puede caracterizarse como un proceso de estandarización con un cambio informacional del precio del EUA que se ha desplazado desde los drivers físicos del sector energético hacia la estructura financiera interna de no arbitraje. Este desplazamiento es coherente entre los distintos enfoques metodológicos empleados. En el corto plazo, las variables energéticas pierden capacidad explicativa sobre los cambios diarios del precio mientras que, en el largo plazo, el precio deja de cointegrar con los fundamentales energéticos (Dittmann et al., 2024) y comienza a cointegrar de forma compatible con el cost-of-carry teórico. En conjunto, la evidencia sugiere que el EU ETS ha madurado hacia un mercado financiero estándar, en el que la formación del precio responde a expectativas regulatorias incorporadas en la curva de futuros, a la estructura del cost-of-carry y a un proceso de price discovery liderado por el mercado de futuros.

Como toda investigación empírica, este trabajo presenta limitaciones que conviene reconocer y que abren líneas futuras de análisis. En primer lugar, la heterogeneidad estructural de Fase III (con subperiodos diferenciados como el régimen pre-MSR, la

recuperación post-2018 y el shock COVID) introduce autocorrelación residual en el VAR subyacente, lo que obliga a interpretar con cautela los resultados de esa fase. Esta misma inestabilidad dinámica impide obtener pesos de Gonzalo-Granger interpretables en la Fase III, al compartir signo ambos coeficientes de ajuste, lo que a su vez impide contrastar formalmente la existencia de una transformación del proceso de price discovery entre la Fase III y la Fase IV dentro del periodo analizado. En segundo lugar, el análisis se ha centrado en el sistema trivariante spot-futuro-tipo, dejando fuera variables relevantes como el sentimiento del mercado, los flujos especulativos o la dinámica del Carbon Border Adjustment Mechanism (CBAM), cuya influencia sobre el precio de los EUA es previsiblemente creciente. En tercer lugar, sería de interés extender el análisis del price discovery al conjunto de la curva (sistema multivariante), estimando un VECM sobre varios vencimientos DEC y aplicando la descomposición de Gonzalo-Granger sobre dicho sistema que permitiría identificar qué punto de la curva incorpora primero la información y si los vencimientos posteriores reflejan la señal de escasez de largo plazo frente al front más sensible a shocks de oferta de corto plazo. Finalmente, la próxima implementación plena del CBAM y la entrada en vigor del ETS2 mostrarán si la estandarización del mercado en la fase IV se consolida o se modifica como respuesta a estos cambios regulatorios.

VIII. Bibliografía

- Aspinall, T., Gepp, A., Harris, G., Kelly, S., Southam, C., & Vanstone, B. (2021). Estimation of a term structure model of carbon prices through state space methods: The European Union emissions trading scheme. *Accounting And Finance*, *61*(2), 3797-3819. https://doi.org/10.1111/acfi.12708
- Balietti, A. C. (2016). Trader types and volatility of emission allowance prices. Evidence from EU ETS Phase I. *Energy Policy*, *98*, 607-620. https://doi.org/10.1016/j.enpol.2016.09.006
- Bianchi, R. J., Fan, J. H., Miffre, J., & Zhang, T. (2023). Exploiting the dynamics of commodity futures curves. *Journal Of Banking & Finance*, *154*, 106965. https://doi.org/10.1016/j.jbankfin.2023.106965
- *BOE.es - DOUE-L-2023-80664 Directiva (UE) 2023/959 del Parlamento Europeo y del Consejo de 10 de mayo de 2023 que modifica la Directiva 2003/87/CE por la que se establece un régimen para el comercio de derechos de emisión de gases de efecto invernadero en la Unión y la Decisión (UE) 2015/1814, relativa al establecimiento y funcionamiento de una reserva de estabilidad del mercado en el marco del régimen para el comercio de derechos de emisión de gases de efecto invernadero en la Unión. (s. f.).* https://www.boe.es/buscar/doc.php?id=DOUE-L-2023-80664

- Bredin, Don and Parsons, John E., Why Is Spot Carbon so Cheap and Future Carbon So Dear? The Term Structure of Carbon Prices (2014). USAEE Working Paper No. 14-188, http://dx.doi.org/10.2139/ssrn.2531807
- Brenner, R. J., & Kroner, K. F. (1995). Arbitrage, Cointegration, and Testing the Unbiasedness Hypothesis in Financial Markets. *Journal Of Financial And Quantitative Analysis*, *30*(1), 23. https://doi.org/10.2307/2331251
- Brink, C., Vollebergh, H. R., & Van Der Werf, E. (2016). Carbon pricing in the EU: Evaluation of different EU ETS reform options. *Energy Policy*, *97*, 603-617. https://doi.org/10.1016/j.enpol.2016.07.023
- Carbon Market Watch. (2024). *Mercados de carbono 101: La guía definitiva sobre mecanismos climáticos basados en el mercado*. https://carbonmarketwatch.org/wp-content/uploads/2024/11/101-report-layout-carbon-markets-ES.pdf
- Chung, C. Y., Jeong, M., & Young, J. (2018). The Price Determinants of the EU Allowance in the EU Emissions Trading Scheme. *Sustainability*, *10*(11), 4009. https://doi.org/10.3390/su10114009
- Creti, A., Jouvet, P., & Mignon, V. (2012). Carbon price drivers: Phase I versus Phase II equilibrium? *Energy Economics*, *34*(1), 327-334. https://doi.org/10.1016/j.eneco.2011.11.001
- Daskalakis, G., Psychoyios, D., & Markellos, R. N. (2009). Modeling CO2 emission allowance prices and derivatives: Evidence from the European trading scheme. *Journal Of Banking & Finance*, *33*(7), 1230-1241. https://doi.org/10.1016/j.jbankfin.2009.01.001

- Diebold, F. X. and C. Li, 2006: Forecasting the term structure of government bond yields. Journal of Econometrics. https://doi.org/10.1016/j.jeconom.2005.03.005
- Dittmann, B., Lauter, T., Prokopczuk, M., & Sibbertsen, P. (2024). What Determines the Price of Carbon? New Evidence From Phase III and IV of the EU ETS. *SSRN Electronic Journal*. https://doi.org/10.2139/ssrn.5053285
- Engle, R. F., & Granger, C. W. J. (1987). Co-Integration and Error Correction: Representation, Estimation, and Testing. *Econometrica*, *55*(2), 251. https://doi.org/10.2307/1913236
- Feng, L., & Wang, J. (2023). Random sources correlations and carbon futures pricing. *International Review Of Financial Analysis*, *86*, 102529.https://doi.org/10.1016/j.irfa.2023.102529
- Fezzi, C. (2006). Econometric analysis of the interaction between the european emission trading scheme and energy prices. *Preliminary and incomplete draft). London Business School, Department of Decision Science*. https://www.feem-web.it/ess/ess06/files/fezzi-fp.pdf
- Figuerola-Ferretti, I., & Gonzalo, J. (2010). Modelling and measuring price discovery in commodity markets. Journal Of Econometrics, 158(1), 95-107. https://doi.org/10.1016/j.jeconom.2010.03.013
- Fischer, C., Reins, L., Burtraw, D., Langlet, D., Löfgren, Å., Mehling, M., Weishaar, S. E., Zetterberg, L., Van Asselt, H., & Kulovesi, K. (2019). The Legal and Economic Case for an Auction Reserve Price in the EU Emissions Trading System. *SSRN Electronic Journal*. https://doi.org/10.2139/ssrn.3477716

- Gibson, R., & Schwartz, E. S. (1990). Stochastic Convenience Yield and the Pricing of Oil Contingent Claims. *The Journal Of Finance*, *45*(3), 959-976. https://doi.org/10.1111/j.1540-6261.1990.tb05114.x
- Gonzalo, J., & Granger, C. (1995). Estimation of Common Long-Memory Components in Cointegrated Systems. *Journal Of Business And Economic Statistics*, *13*(1), 27-35. https://doi.org/10.1080/07350015.1995.10524576
- Goulder, L., & Schein, A. (2013). Carbon Taxes vs. cap and Trade: A Critical review. *NATIONAL BUREAU OF ECONOMIC RESEARCH*, 19338. https://doi.org/10.3386/w19338
- GrØnborg, N. S., Lunde, A., 2016. Analyzing oil futures with a dynamic Nelson-Siegel model. *Journal of Futures Markets*, *36*(2), 153-173.
- Heidorn, T., Mokinski, F., Rühl, C., & Schmaltz, C. (2015). The impact of fundamental and financial traders on the term structure of oil. *Energy Economics*, *48*, 276-287. https://www.sciencedirect.com/science/article/pii/S0140988315000158
- Hobbie, H., Schmidt, M., & Möst, D. (2019). Windfall profits in the power sector during phase III of the EU ETS: Interplay and effects of renewables and carbon prices. *Journal Of Cleaner Production*, *240*, 118066. https://doi.org/10.1016/j.jclepro.2019.118066
- Ji, Q., Zhang, D., & Geng, J. (2018). Information linkage, dynamic spillovers in prices and volatility between the carbon and energy markets. *Journal Of Cleaner Production*, *198*, 972-978. https://doi.org/10.1016/j.jclepro.2018.07.126

- Johansen, S. (1988). Statistical analysis of cointegration vectors. *Journal Of Economic Dynamics And Control*, *12*(2-3), 231-254. https://doi.org/10.1016/0165-1889(88)90041-3
- Karstanje, D., Van Der Wel, M., & Van Dijk, D. J. C. (2015). Common Factors in Commodity Futures Curves. *SSRN Electronic Journal*. https://doi.org/10.2139/ssrn.2558014
- Lovcha, Y., Perez-Laborda, A., & Sikora, I. (2021). The determinants of CO2 prices in the EU emission trading system. *Applied Energy*, *305*, 117903. https://doi.org/10.1016/j.apenergy.2021.117903
- Lu, H., Gao, Q., Xiao, L., & Dhesi, G. (2024). Forecasting EUA futures volatility with geopolitical risk: evidence from GARCH-MIDAS models. *Review Of Managerial Science*, *18*(7), 1917-1943. https://doi.org/10.1007/s11846-023-00722-0
- Liu, J., Zhang, Z., Yan, L., & Wen, F. (2021). Forecasting the volatility of EUA futures with economic policy uncertainty using the GARCH-MIDAS model. *Financial Innovation*, *7*(1). https://doi.org/10.1186/s40854-021-00292-8
- Lütkepohl, H. (2013). Vector autoregressive models. En *Edward Elgar Publishing eBooks*. https://doi.org/10.4337/9780857931023.00012
- Marcu, A., Coker, E., Bourcier, F., Caneill, J.-Y., Schleicher, S., López Hernández, J. F., Caruana, N., Chawah, P., & Finlayson, R. (2025). 2025 State of the EU ETS report. European Roundtable on Climate Change and Sustainable Transition

(ERCST). https://ercst.org/wp-content/uploads/2025/05/2025-State-of-the-EU-ETS-Report.pdf

- Milunovich, George and Joyeux, Roselyne, Market Efficiency and Price Discovery in the EU Carbon Futures Market (May 28, 2007). Applied Financial Economics, Vol. 20, No. 10, 2010, https://ssrn.com/abstract=989272
- Nelson, C. R., & Siegel, A. F. (1987). Parsimonious Modeling of Yield Curves. *The Journal of Business*, *60*(4), 473–489. http://www.jstor.org/stable/2352957
- Nissen, C., Cludius, J., Gores, S., Hermann, H., & Wissner, N. (2024). Trends and projections in the EU ETS in 2024. The EU Emissions Trading System in numbers. En *Zenodo (CERN European Organization For Nuclear Research)*. https://doi.org/10.5281/zenodo.14062099
- Piwowarczyk-Ściebura, K. (2018). The importance of the Market Stability Reserve (MSR)for the reform of the CO2 emissionallowance trading system. *Polityka Energetyczna – Energy Policy Journal*, *21*(3), 111-122. https://doi.org/10.33223/epj/103680
- Quemin, S. (2020). *Using supply-side policies to raise ambition: the case of the EU ETS and the 2021 review*. Grantham Research Institute on Climate Change and the Environment. Obtenido de: https://www.lse.ac.uk/granthaminstitute/wp-content/uploads/2020/03/working-paper-335-Quemin-1.pdf
- Trück, S., Hardle, W., & Weron, R. (2012). The Relationship between Spot and Futures CO2 Emission Allowance Prices in the EU-ETS. *SSRN Electronic Journal*. https://doi.org/10.2139/ssrn.2137346

- Wagner, Michael Wolfgang and Uhrig-Homburg, Marliese, Futures Price Dynamics of CO2 Emission Certificates - An Empirical Analysis (2009). Journal of Derivatives, Vol. 17, No. 2, pp. 73-88, 2009, Available at SSRN: https://ssrn.com/abstract=941167
- Wegener, Christoph and Kruse-Becher, Robinson and Klein, Tony, EU ETS Market Expectations and Rational Bubbles (May 30, 2024). Forthcoming in *Journal of Money, Credit and Banking*, Obtenido de: https://ssrn.com/abstract=4848176
- Weitzman, M. L. (1974). Prices vs. Quantities. *The Review Of Economic Studies*, *41*(4), 477. https://doi.org/10.2307/2296698
- Zheng, Y., Yin, H., Zhou, M., Liu, W., & Wen, F. (2021). Impacts of oil shocks on the EU carbon emissions allowances under different market conditions. *Energy Economics*, *104*, 105683. https://doi.org/10.1016/j.eneco.2021.105683

IX. Anexo

I. Tablas y gráficos

Tabla 5: Estadísticos descriptivos de los factores Nelson-Siegel por fase.

Factor	μ (Fase III)	μ (Fase IV)	σ (Fase III)	(Fase IV)	Min (Fase III)	Min (Fase IV)	Max (Fase III)	Max (Fase IV)	p_Welch	p_Levene
β0	2.466	4.578	0.650	0.297	1.421	3.599	3.643	5.132	< 0,001	< 0,001
β1	-0.215	-0.311	0.107	0.123	-0.503	-0.699	-0.075	-0.107	< 0,001	0.040
β2	-0.292	-0.363	0.134	0.153	-0.775	-0.932	-0.091	-0.116	< 0,001	0.514

Tabla 6: Matriz de correlaciones entre los factores Nelson-Siegel por fase

Fase III			
Factor	β0	β1	β2
β0	1.000	0.210	0.226
β1	0.210	1.000	0.917
β2	0.226	0.917	1.000

Fase IV			
Factor	β0	β1	β2
β0	1.000	-0.790	-0.582
β1	-0.790	1.000	0.828
β2	-0.582	0.828	1.000

Figura 3: Correlogramas de los factores Nelson-Siegel β_0 y β_1 en niveles

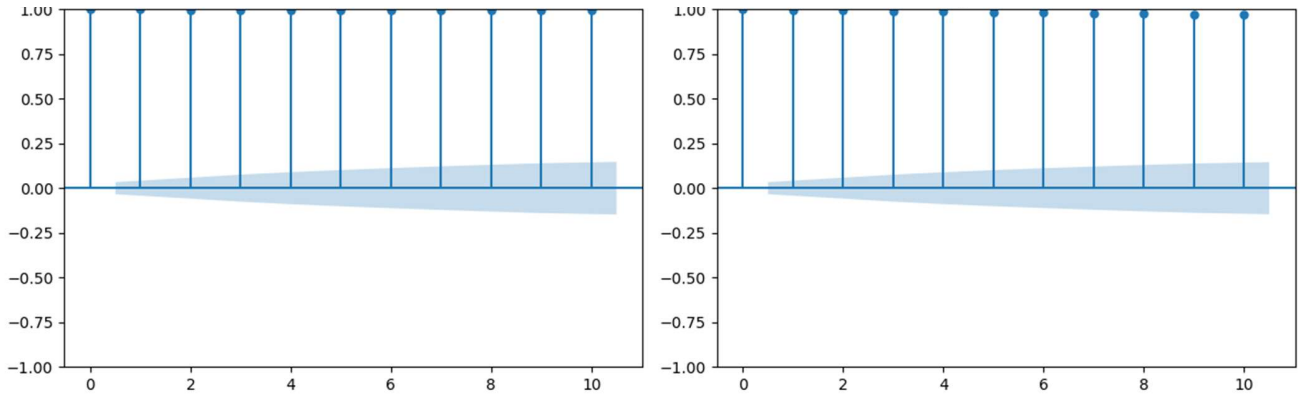


Figura 4:Correlogramas de las primeras diferencias $\Delta\beta_0$ y $\Delta\beta_1$

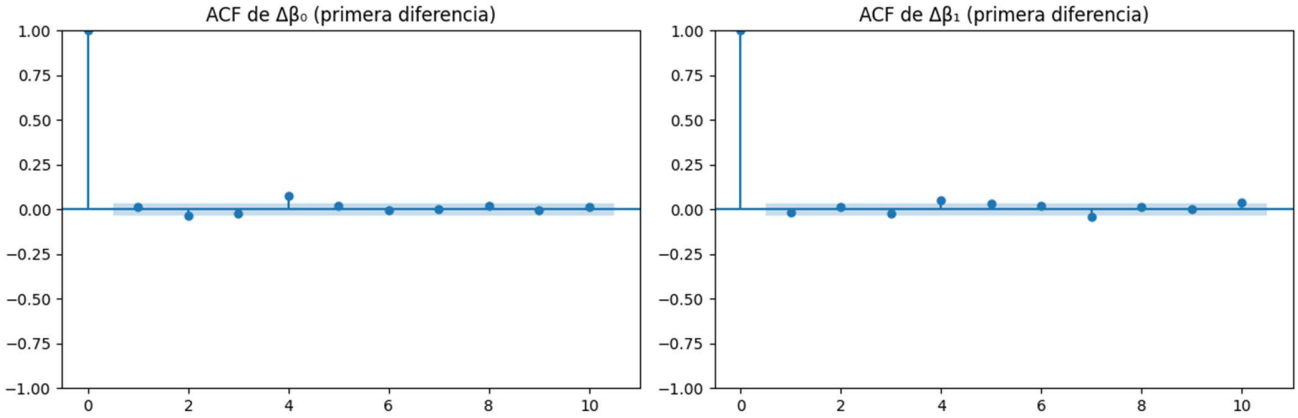


Tabla 7: Tests de estacionariedad ADF y KPSS para factores Nelson-Siegel y drivers.

Serie	ADF	p-valor	KPSS	p-valor	Orden
β_0	−0.56	0.88	8.23	< 0.01	**I(1)**
β_1	−2.44	0.13	1.32	< 0.01	**I(1)**
$\Delta\beta_0$	−14.27	0.00	0.17	> 0.10	**I(0)**
$\Delta\beta_1$	−13.84	0.00	0.13	> 0.10	**I(0)**
log TTF	−1.65	0.46	2.44	< 0.01	**I(1)**

Δlog TTF	−27.47	0.00	0.11	> 0.10	**I(0)**
log Coal	−1.62	0.47	2.91	< 0.01	**I(1)**
Δlog Coal	−11.38	0.00	0.09	> 0.10	**I(0)**
log Power	−1.06	0.73	5.77	< 0.01	**I(1)**
Δlog Power	−17.47	0.00	0.12	> 0.10	**I(0)**
log Brent	−2.39	0.14	0.90	< 0.01	**I(1)**
Δlog Brent	−8.76	0.00	0.11	> 0.10	**I(0)**
EPU	−2.77	0.06	4.74	< 0.01	Mixto
ΔEPU	−15.45	0.00	0.02	> 0.10	**I(0)**
GPR	−5.44	0.00	2.40	< 0.01	Mixto
ΔGPR	−15.79	0.00	0.02	> 0.10	**I(0)**

Tabla 8: Estimación OLS de los determinantes de $\Delta\beta_0$ y $\Delta\beta_1$ por fase.[8]

	$\Delta\beta_0$ Fase III	**$\Delta\beta_0$ Fase IV**	**$\Delta\beta_1$ Fase III**	**$\Delta\beta_1$ Fase IV**
Constante	0.0006	0.0008	0.0001	−0.0002
Δlog TTF	−0.0007	0.0389*	−0.0037	0.0085
Δlog Coal	−0.0639	0.0189	−0.0299***	−0.0032
Δlog Power	**1.2694***	**0.1188***	**0.2271***	0.0161
Δlog Brent	0.0384*	0.0237	0.0002	0.0015
ΔEPU	0.0000	−0.0001	0.0000	0.0000
ΔGPR	−0.0000**	0.0000	0.0000	0.0000
R^2	0.408	0.091	0.147	0.014
R^2 ajustado	0.406	0.086	0.145	0.010
F-statistic	128.7***	6.83***	17.78***	2.52**
Kurtosis	8.67	9.86	17.53	15.52

[8] *Niveles de significancia: *** p < 0,01; ** p < 0,05; * p < 0,10. Los contrastes de significatividad se basan en el estimador de la matriz de covarianzas consistente ante heterocedasticidad y autocorrelación de Newey y West (1987).*

Tabla 9: Análisis de robustez del ADF — comparación de especificaciones 'c' y 'ct' sobre S y F

Fase	Serie	ADF 'c' (stat)	ADF 'c' (p-val)	ADF 'ct' (stat)	ADF 'ct' (p-val)
III	s = ln(S)	−0.363	0.916	−1.692	0.754
III	f = ln(F)	−0.279	0.928	−1.718	0.743
IV	s = ln(S)	−3.390	0.011	−3.171	0.09
IV	f = ln(F)	−3.381	0.012	−3.151	0.095

Tabla 10: Selección lags óptimos

Criterio	Fase III	Fase IV
AIC	8	4
BIC	2	3
FPE	8	4
HQIC	**7**	**4**

II. Código Python

Carga de librerías y archivos excel

```
from google.colab import drive

drive.mount('/content/drive')

import pandas as pd

import numpy as np

import matplotlib.pyplot as plt

from IPython.display import display

from scipy.stats import kurtosis

from statsmodels.stats.stattools import durbin_watson
```

```
import statsmodels.api as sm

from statsmodels.tsa.stattools import adfuller, kpss

from statsmodels.tsa.api import VAR

import matplotlib.dates as mdates

from statsmodels.tsa.vector_ar.vecm import coint_johansen, VECM

from scipy import stats


ruta_base = '/content/drive/MyDrive/TFG_EUETS'

ruta_datos ='/content/drive/MyDrive/TFG_EUETS/datos'

#función para leer todos los archivos que cargamos (en lugar de ir uno por uno)

def leer_datos(nombre_archivo, nombre_serie): (optimizada por Gemini)


    df = pd.read_excel(f'{ruta_datos}/{nombre_archivo}', sheet_name='Datos')

    df['Date'] = pd.to_datetime(df['Date'])

    df = df.sort_values('Date')

    datos = pd.Series(df['Price'].values, index=df['Date'], name=nombre_serie)

    return datos

# Carga de datos de los drivers

EUA_spot = leer_datos('EUAA spot.xlsx', 'precio spot')

EUR_12M = leer_datos('EURIBOR12M.xlsx', 'Euribor 12M')

TTF = leer_datos('TTF_front_month.xlsx', 'TTF')

Coal = leer_datos('API2 Coal.xlsx', 'Coal')

Power = leer_datos('Bloomberg German Power price.xlsx', 'Power')

Brent = leer_datos('Brent.xlsx', 'Brent')

EPU = leer_datos('EUEPUINDXM.xlsx', 'EPU')

GPR = leer_datos('data_gpr_daily.xlsx', 'GPR')
```

```
#lo mismo para los contratos de futuros de EUAs
ruta_dec = '/content/drive/MyDrive/TFG_EUETS/datos/EUA DEC prices.xlsx'

contratos_dec = {}

for año in range(2013, 2031):

    nombre_hoja = 'MOZ' + str(año)[-2:]



    try:

        df = pd.read_excel(ruta_dec, sheet_name=nombre_hoja)

        df['Date'] = pd.to_datetime(df['Date'])

        df = df.sort_values('Date')

        serie = pd.Series(df['Price'].values, index=df['Date'],

                          name='DEC_' + str(año))

        contratos_dec[año] = serie

    except Exception as e:

        print('ERROR')
```

Construcción curva de futuros DEC de EUAs

```
calendario = pd.bdate_range(fecha_inicio, fecha_fin)

curva = pd.DataFrame(index=calendario)

for k in range(1, K+1):

    curva['DEC' + str(k) + '_precio'] = np.nan

    curva['DEC' + str(k) + '_tau'] = np.nan

    curva['DEC' + str(k) + '_año'] = np.nan

años_disponibles = sorted(contratos_dec.keys())

# Pre-calculamos la fecha de vencimiento de cada contrato (ultima fecha

# con dato observado). Lo hacemos una sola vez fuera del bucle principal

# para no recalcularlo en cada iteracion.

def vencimiento_eua(año, serie_contrato):
```

```
    # Vencimiento teorico: ultimo lunes antes del 25 de diciembre
    contrato = pd.Timestamp(year=año, month=12, day=24)
    while contrato.weekday() != 0:  # 0 = lunes
        contrato = contrato - pd.Timedelta(days=1)

    # Si tenemos datos hasta cerca del vencimiento teorico (>= noviembre
    # del año del contrato), el contrato ya casi venció por lo que usamos la ultima
    # fecha real observada (mas precisa que la teorica).
    ultima_f_observada = serie_contrato.index.max()
    limite_noviembre = pd.Timestamp(year=año, month=11, day=1)

    if ultima_f_observada >= limite_noviembre:
        return ultima_f_observada
    else:
        return contrato

vencimientos = {}
for año in años:
    vencimientos[año] = vencimiento_eua(año, contratos_dec[año])
for fecha in calendario:
    contratos_vivos = []
    for año in años:
        vencimiento = vencimientos[año]
        if vencimiento > fecha:
            if fecha in contratos_dec[año].index:
                precio = contratos_dec[año].loc[fecha]
```

```
                tau = (vencimiento - fecha).days / 365.0
                contratos_vivos.append((año, vencimiento, precio, tau))
    contratos_vivos.sort(key=lambda x: x[1])

    for k in range(min(K, len(contratos_vivos))):
        año, venc, precio, tau = contratos_vivos[k]
        curva.loc[fecha, 'DEC' + str(k+1) + '_precio'] = precio
        curva.loc[fecha, 'DEC' + str(k+1) + '_tau'] = tau
        curva.loc[fecha, 'DEC' + str(k+1) + '_año'] = año

# Cobertura de cada posicion
for k in range(1, K+1):
    cobertura = curva['DEC' + str(k) + '_precio'].notna().mean() * 100
    print('  DEC' + str(k) + ': cobertura =', round(cobertura, 1), '%')
#juntamos todas las columnas de datos
conjunto = curva.copy()
for nombre, serie in [('TTF', TTF), ('Coal', Coal), ('Power', Power),
                      ('Brent', Brent), ('EPU', EPU), ('GPR', GPR)]:
    conjunto[nombre] = serie.reindex(calendario, method='ffill')
print('Panel construido:', conjunto.shape)
print('Rango:', conjunto.index.min().date(), 'a', conjunto.index.max().date())
```

Estimación de los factores Nelson-Siegel

```
#Definimos los loadings  del modelo Nelson-Siegel (nivel,pendiente y curvatura)
def loadings_NS(tau, lam): #en este bloque, me he apoyado en Gemini a falta de encontrar fuentes que me ayudaran para desarrollar el código de 0
```

```
    z = lam * tau

    z = np.where(z < 0.0001, 0.0001, z)  # para evitar dividir entre 0

    #loadings de la formula

    L0 = np.ones(len(tau))

    L1 = (1 - np.exp(-z)) / z

    L2 = L1 - np.exp(-z)



    return L0, L1, L2

#fijamos Lamda siguiendo a Diebold et al. y Kartsanje et al.

lambda_NS = 0.7308

# Estimacion de los factores con lambda fijo Diebold-Li y mediante OLS

beta0 = []

beta1 = []

beta2 = []

R2 = []

fechas= []

for fecha in conjunto.index: #recorremos el conjunto para extraer la columnas de los futuros de EUAs
y estimar sobre éstas

    precios_dia = np.array([conjunto.loc[fecha, 'DEC' + str(k) + '_precio']

                            for k in range(1, K+1)])

    taus_dia = np.array([conjunto.loc[fecha, 'DEC' + str(k) + '_tau']

                         for k in range(1, K+1)])

    if np.any(np.isnan(precios_dia)) or np.any(np.isnan(taus_dia)): #para evitar los NaN

        continue

    B0, B1, B2 = loadings_NS(taus_dia, lambda_NS) #llamamos a la función de los loadings

    X = np.column_stack([B0, B1, B2])

    y = np.log(precios_dia)
```

```
    modelo = sm.OLS(y, X).fit()
    b0, b1, b2, r2 = modelo.params[0], modelo.params[1], modelo.params[2], modelo.rsquared
    beta0.append(b0)
    beta1.append(b1)
    beta2.append(b2)
    R2.append(r2)
    fechas.append(fecha)
factores = pd.DataFrame({
    'beta0_nivel': beta0,
    'beta1_pendiente': beta1,
    'beta2_curvatura': beta2,
    'R2': R2,
}, index=pd.DatetimeIndex(fechas))
print(len(factores), 'dias estimados')
print('R2 medio:', round(factores['R2'].mean(), 4))
# Estadisticos descriptivos de los factores
descriptivos_factores = factores[['beta0_nivel', 'beta1_pendiente',
                                  'beta2_curvatura']].describe().round(4)
descriptivos_factores
# Correlacion entre factores
factores[['beta0_nivel', 'beta1_pendiente', 'beta2_curvatura']].corr().round(3)


# Representación de los 3 factores a lo largo del tiempo
fig, axes = plt.subplots(3, 1, figsize=(11, 8), sharex=True)
axes[0].plot(factores.index, factores['beta0_nivel'], color='navy', linewidth=0.8)
axes[0].axvline(fin_fase_3, color='gray', linestyle='--', linewidth=0.8)
```

```
axes[0].set_ylabel('beta0 (Nivel)')

axes[0].set_title('Factor de nivel')

axes[0].grid(alpha=0.3)


axes[1].plot(factores.index, factores['beta1_pendiente'], color='darkred', linewidth=0.8)

axes[1].axhline(0, color='black', linewidth=0.5)

axes[1].axvline(fin_fase_3, color='gray', linestyle='--', linewidth=0.8)

axes[1].set_ylabel('beta1 (Pendiente)')

axes[1].set_title('Factor de pendiente (negativo = contango)')

axes[1].grid(alpha=0.3)


axes[2].plot(factores.index, factores['beta2_curvatura'], color='darkgreen', linewidth=0.8)

axes[2].axhline(0, color='black', linewidth=0.5)

axes[2].axvline(fin_fase_3, color='gray', linestyle='--', linewidth=0.8)

axes[2].set_ylabel('beta2 (Curvatura)')

axes[2].set_title('Factor de curvatura')

axes[2].set_xlabel('Fecha')

axes[2].grid(alpha=0.3)

plt.tight_layout()

plt.show()

#ajuste NS vs curva observada en fechas seleccionadas (explicadas en la seccion de resultados el por
qué de éstas)

fechas = ['2016-06-30', '2018-02-27', '2021-01-04', '2024-06-28']


fig, axes = plt.subplots(2, 2, figsize=(11, 7))


for i, fecha_str in enumerate(fechas): #para montar los 4 graficos en formato matriz 2x2
```

```
fila = i // 2

columna = i % 2

ax = axes[fila, columna]


fecha = pd.Timestamp(fecha_str)

if fecha not in factores.index:

    continue


precios_muestra = [conjunto.loc[fecha, 'DEC' + str(k) + '_precio'] for k in range(1, K+1)]

taus_muestra = [conjunto.loc[fecha, 'DEC' + str(k) + '_tau'] for k in range(1, K+1)]

b0 = factores.loc[fecha, 'beta0_nivel']

b1 = factores.loc[fecha, 'beta1_pendiente']

b2 = factores.loc[fecha, 'beta2_curvatura']

r2 = factores.loc[fecha, 'R2']


taus_grid = np.linspace(0.1, 5, 100)

L0, L1, L2 = loadings_NS(taus_grid, lambda_NS)

log_precios_aj = b0 * L0 + b1 * L1 + b2 * L2

precios_aj = np.exp(log_precios_aj) #devolvemos los precios a escala originial

ax.plot(taus_muestra, precios_muestra, 'o', color='black', markersize=7, label='Observado')

ax.plot(taus_grid, precios_aj, '-', color='red', linewidth=1.5, label='Ajuste NS')

ax.set_title(fecha_str + ' (R2 = ' + str(round(r2, 3)) + ')')

ax.set_xlabel('τ (años)')

ax.set_ylabel('Precio (EUR/tCO2)')

ax.legend(fontsize=8)

ax.grid(alpha=0.3)
```

```
plt.tight_layout()

plt.show()
```

Comparación de los factores NS entre fases

```
# Comparacion de los factores Nelson-Siegel entre Fase III y Fase IV

# Aplicamos test t de Welch para igualdad de medias y test de Levene para igualdad de varianzas,
como en la seccion 4

mask_F3 = factores.index <= fin_fase_3

mask_F4 = factores.index > fin_fase_3

filas_fases = []

for col in ['beta0_nivel', 'beta1_pendiente', 'beta2_curvatura']:

    serie_F3 = factores.loc[mask_F3, col].dropna()

    serie_F4 = factores.loc[mask_F4, col].dropna()

    if len(serie_F3) < 10 or len(serie_F4) < 10:

        continue

    t_stat, t_pval = stats.ttest_ind(serie_F3, serie_F4, equal_var=False)

    l_stat, l_pval = stats.levene(serie_F3, serie_F4)

    filas_fases.append({

        'Factor': col,

        'Media_FIII': round(serie_F3.mean(), 4),

        'Media_FIV': round(serie_F4.mean(), 4),

        'Std_FIII': round(serie_F3.std(), 4),

        'Std_FIV': round(serie_F4.std(), 4),

        'Min_FIII': round(serie_F3.min(), 4),

        'Min_FIV': round(serie_F4.min(), 4),

        'Max_FIII': round(serie_F3.max(), 4),

        'Max_FIV': round(serie_F4.max(), 4),
```

```
        't_pval': round(t_pval, 4),
        'Levene_pval': round(l_pval, 4),
    })

tabla_factores_fases = pd.DataFrame(filas_fases)
tabla_factores_fases
#Correlaciones de los factores en cada fase
display(factores.loc[mask_F3, ['beta0_nivel', 'beta1_pendiente',
'beta2_curvatura']].corr().round(3))
display(factores.loc[mask_F4, ['beta0_nivel', 'beta1_pendiente',
'beta2_curvatura']].corr().round(3))
# Verificar persistencia de los factores
ac_b0 = factores['beta0_nivel'].autocorr(lag=1)
ac_b1 = factores['beta1_pendiente'].autocorr(lag=1)

print(f"Autocorrelación lag-1:")
print(f"β₀ {ac_b0:.4f}")
print(f"β₁: {ac_b1:.4f}")
```

Dinámica de los factores (OLS/ARX)

```
#tests de raiz unitaria sobre los factores para demostrar que los factores son I(1) (raíz unitaria
en nivel, estacionarios en diferencia
resultados_raiz_unitaria = []
series_a_testear = {
    'beta0_nivel': factores['beta0_nivel'].dropna(),
    'beta1_pendiente': factores['beta1_pendiente'].dropna(),
    'd_beta0_nivel': factores['beta0_nivel'].diff().dropna(),
    'd_beta1_pendiente': factores['beta1_pendiente'].diff().dropna(),
}
```

```
# Iteramos sobre cada serie y aplicamos ADF y KPSS
for nombre, serie in series_a_testear.items():

    # Test ADF
    adf_result = adfuller(serie, autolag='AIC')
    adf_stat = adf_result[0]
    adf_pval = adf_result[1]
    # Test KPSS
    kpss_result = kpss(serie, nlags='auto')
    kpss_stat = kpss_result[0]
    kpss_pval = kpss_result[1]
    resultados_raiz_unitaria.append({
        'Serie': nombre,
        'ADF_stat': round(adf_stat, 4),
        'ADF_pval': round(adf_pval, 4),
        'KPSS_stat': round(kpss_stat, 4),
        'KPSS_pval': round(kpss_pval, 4),
    })
tabla_unit_root_factores = pd.DataFrame(resultados_raiz_unitaria)
tabla_unit_root_factores
# mismo test sobre los drivers (tanto sobre el nivel como sobre las diferencias en log)
drivers_lista = ['TTF', 'Coal', 'Power', 'Brent', 'EPU', 'GPR']
resultados_drivers = []
for driver in drivers_lista:
    serie_nivel = conjunto[driver].dropna()
    if driver in ['TTF', 'Coal', 'Power', 'Brent']:
```

```
    serie_test_nivel = np.log(serie_nivel)
    etiqueta_nivel = f'log({driver})'
else:
    serie_test_nivel = serie_nivel
    etiqueta_nivel = drive

serie_test_dif = serie_test_nivel.diff().dropna()
etiqueta_dif = f'd_{etiqueta_nivel}'
# Test ADF y KPSS sobre los valores
adf_nivel = adfuller(serie_test_nivel, autolag='AIC')
kpss_nivel = kpss(serie_test_nivel, nlags='auto')
# Test ADF y KPSS sobre las diferencias
adf_dif = adfuller(serie_test_dif, autolag='AIC')
kpss_dif = kpss(serie_test_dif, nlags='auto')
resultados_drivers.append({
    'Serie': etiqueta_nivel,
    'ADF_stat': round(adf_nivel[0], 4),
    'ADF_pval': round(adf_nivel[1], 4),
    'KPSS_stat': round(kpss_nivel[0], 4),
    'KPSS_pval': round(kpss_nivel[1], 4),
})
resultados_drivers.append({
    'Serie': etiqueta_dif,
    'ADF_stat': round(adf_dif[0], 4),
    'ADF_pval': round(adf_dif[1], 4),
    'KPSS_stat': round(kpss_dif[0], 4),
```

```
        'KPSS_pval': round(kpss_dif[1], 4),
    })
tabla_unit_root_drivers = pd.DataFrame(resultados_drivers)
tabla_unit_root_drivers


# matriz de correlaciones entre drivers
drivers_transformados = pd.DataFrame({
    'd_log_TTF': np.log(conjunto['TTF']).diff(),
    'd_log_Coal': np.log(conjunto['Coal']).diff(),
    'd_log_Power': np.log(conjunto['Power']).diff(),
    'd_log_Brent': np.log(conjunto['Brent']).diff(),
    'd_EPU': conjunto['EPU'].diff(),
    'd_GPR': conjunto['GPR'].diff(),
})


drivers_transformados = drivers_transformados.dropna()
matriz_correlaciones = drivers_transformados.corr()
matriz_correlaciones_redondeada = matriz_correlaciones.round(3)
matriz_correlaciones_redondeada


# Creamos un nuevo conjunto de datos con las variables transformadas
dataset = pd.DataFrame(index=conjunto.index)
dataset['d_beta0'] = factores['beta0_nivel'].diff()
dataset['d_beta1'] = factores['beta1_pendiente'].diff()
dataset['d_log_TTF']   = np.log(conjunto['TTF']).diff()
dataset['d_log_Coal']  = np.log(conjunto['Coal']).diff()
```

```
dataset['d_log_Power'] = np.log(conjunto['Power']).diff()

dataset['d_log_Brent'] = np.log(conjunto['Brent']).diff()

dataset['d_EPU'] = conjunto['EPU'].diff()

dataset['d_GPR'] = conjunto['GPR'].diff()

print(dataset.head())

# generamos los lags para el modelo ARX


# 2 lags para lso factores (según el criterio AIC )

dataset['d_beta0_lag1'] = dataset['d_beta0'].shift(1)

dataset['d_beta0_lag2'] = dataset['d_beta0'].shift(2)

dataset['d_beta1_lag1'] = dataset['d_beta1'].shift(1)

dataset['d_beta1_lag2'] = dataset['d_beta1'].shift(2)


# 1 lag para los drivers (siguiente los reusltados de Zhenh et al.)

dataset['d_log_TTF_lag1']   = dataset['d_log_TTF'].shift(1)

dataset['d_log_Coal_lag1']  = dataset['d_log_Coal'].shift(1)

dataset['d_log_Power_lag1'] = dataset['d_log_Power'].shift(1)

dataset['d_log_Brent_lag1'] = dataset['d_log_Brent'].shift(1)

dataset['d_EPU_lag1'] = dataset['d_EPU'].shift(1)

dataset['d_GPR_lag1'] = dataset['d_GPR'].shift(1)

dataset_limpio = dataset.dropna()


# dividimos en Fase III y Fase IV

F3 = dataset_limpio.index <= fin_fase_3

F4 = dataset_limpio.index > fin_fase_3

dataset_F3 = dataset_limpio[F3].copy()
```

```
dataset_F4 = dataset_limpio[F4].copy()
```

OLS

```
# funcion para estimar OLS con errores Newey-West

def estimar_ols_nw(y, X, nlags=5):

    # Añadimos la  constante al regresor

    constante = sm.add_constant(X)

    # OLS

    modelo = sm.OLS(y, constante)

    # Ajustamos con errores Newey-West (HAC)

    resultado = modelo.fit(cov_type='HAC', cov_kwds={'maxlags': nlags})

    return resultado

# Aplicamos los 4 modelos OLS para cada fase y factor

drivers = [

    'd_log_TTF',

    'd_log_Coal',

    'd_log_Power',

    'd_log_Brent',

    'd_EPU',

    'd_GPR'


# OLS para d_beta0 y d_beta0 en Fase III

y_b0_p3 = dataset_F3['d_beta0']

X_b0_p3 = dataset_F3[drivers]

ols_b0_p3 = estimar_ols_nw(y_b0_p3, X_b0_p3)

y_b1_p3 = dataset_F3['d_beta1']

X_b1_p3 = dataset_F3[drivers]
```

```
ols_b1_p3 = estimar_ols_nw(y_b1_p3, X_b1_p3)

# OLS para d_beta0 y d_beta0 en Fase IV

y_b0_p4 = dataset_F4['d_beta0']

X_b0_p4 = dataset_F4[drivers]

ols_b0_p4 = estimar_ols_nw(y_b0_p4, X_b0_p4)


y_b1_p4 = dataset_F4['d_beta1']

X_b1_p4 = dataset_F4[drivers]

ols_b1_p4 = estimar_ols_nw(y_b1_p4, X_b1_p4)


print("="*70)

print("MODELO OLS: d_beta0 en FASE III")

print("="*70)

print(ols_b0_p3.summary())


print("\n\n" + "="*70)

print("MODELO OLS: d_beta0 en FASE IV")

print("="*70)

print(ols_b0_p4.summary())


print("\n\n" + "="*70)

print("MODELO OLS: d_beta1 en FASE III")

print("="*70)

print(ols_b1_p3.summary())


print("\n\n" + "="*70)
```

```
print("MODELO OLS: d_beta1 en FASE IV")

print("="*70)

print(ols_b1_p4.summary())


#Tabla resumen OLS

#Creamos una función para representar ocn asteriscos

def fmt_coef(coef, pval, decimals=4):

    if pd.isna(coef):

        return '—'

    s = '***' if pval < 0.01 else '**' if pval < 0.05 else '*' if pval < 0.10 else ''

    val = f'{coef:.{decimals}f}'.replace('.', ',')

    return f'{val}{s}'


modelos_ols = {

    'Δβ₀ Fase III': ols_b0_F3,

    'Δβ₀ Fase IV':  ols_b0_F4,

    'Δβ₁ Fase III': ols_b1_F3,

    'Δβ₁ Fase IV':  ols_b1_F4,

}

orden = ['const', 'd_log_TTF', 'd_log_Coal', 'd_log_Power',

         'd_log_Brent', 'd_EPU', 'd_GPR']

etiquetas = {

    'const': 'Constante', 'd_log_TTF': 'Δlog TTF',

    'd_log_Coal': 'Δlog Coal', 'd_log_Power': 'Δlog Power',

    'd_log_Brent': 'Δlog Brent', 'd_EPU': 'ΔEPU', 'd_GPR': 'ΔGPR',

}
```

```
tabla = pd.DataFrame(index=[etiquetas[v] for v in orden],

                     columns=list(modelos_ols.keys()))

for col, res in modelos_ols.items():

    for var in orden:

        tabla.loc[etiquetas[var], col] = fmt_coef(

            res.params[var], res.pvalues[var])

# Añadimos los diagnósticos

diag = pd.DataFrame(index=['R²', 'R² ajustado', 'F-statistic',

                           'Durbin-Watson', 'Kurtosis residuos',

                           'N° observaciones'],

                    columns=tabla.columns)

#sustiuimos los . por ,

for col, res in modelos_ols.items():

    fstars = '***' if res.f_pvalue < 0.01 else '**' if res.f_pvalue < 0.05 else '*'

    diag.loc['R²', col] = f'{res.rsquared:.3f}'.replace('.', ',')

    diag.loc['R² ajustado', col] = f'{res.rsquared_adj:.3f}'.replace('.', ',')

    diag.loc['F-statistic', col] = f'{res.fvalue:.2f}{fstars}'.replace('.', ',')

    diag.loc['Durbin-Watson', col] = f'{durbin_watson(res.resid):.3f}'.replace('.', ',')

    diag.loc['Kurtosis residuos', col] = f'{kurtosis(res.resid, fisher=False):.2f}'.replace('.',
',')

    diag.loc['N° observaciones', col] = f'{int(res.nobs):,}'.replace(',', '.')

tabla_final = pd.concat([tabla, diag])

tabla_final.to_excel('tabla_OLS.xlsx')

print(tabla_final)
```

Modelo ARX

```
# creamos la lista de lags de los drivers

drivers_lag1 = [
```

```
    'd_log_TTF_lag1',
    'd_log_Coal_lag1',
    'd_log_Power_lag1',
    'd_log_Brent_lag1',
    'd_EPU_lag1',
    'd_GPR_lag1'
]
# Estiramos los 4 modelos ARX (a partir de la función de OLS más el componente AR que son los lags
de los factores, y los lags de los drivers )
# Modelo ARX para d_beta0 y d_beta1 en Fase III
y_b0_F3 = dataset_F3['d_beta0']
X_b0_F3 = dataset_F3[
    ['d_beta0_lag1', 'd_beta0_lag2'] +
    drivers +
    drivers_lag1
]
arx_b0_F3 = estimar_ols_nw(y_b0_F3, X_b0_F3)
y_b1_F3 = dataset_F3['d_beta1']
X_b1_F3 = dataset_F3[
    ['d_beta1_lag1', 'd_beta1_lag2'] +
    drivers +
    drivers_lag1
]
arx_b1_F3 = estimar_ols_nw(y_b1_F3, X_b1_F3)
# Modelo ARX para d_beta0 y d_beta1 en Fase IV
y_b0_F4 = dataset_F4['d_beta0']
X_b0_F4 = dataset_F4[
```

```
    ['d_beta0_lag1', 'd_beta0_lag2'] +
    drivers +
    drivers_lag1
]
arx_b0_F4 = estimar_ols_nw(y_b0_F4, X_b0_F4)
y_b1_F4 = dataset_F4['d_beta1']
X_b1_F4 = dataset_F4[
    ['d_beta1_lag1', 'd_beta1_lag2'] +
    drivers +
    drivers_lag1
]
arx_b1_F4 = estimar_ols_nw(y_b1_F4, X_b1_F4)

# montamos la tabla comparativa de los R2 de ambos modelos
comparativa_ols_arx = pd.DataFrame({
    'Modelo': ['b0 F3', 'b0 F4', 'b1 F3', 'b1 F4'],
    'R2_OLS': [
        round(ols_b0_F3.rsquared, 4),
        round(ols_b0_F4.rsquared, 4),
        round(ols_b1_F3.rsquared, 4),
        round(ols_b1_F4.rsquared, 4)
    ],
    'R2_ajust_OLS': [
        round(ols_b0_F3.rsquared_adj, 4),
        round(ols_b0_F4.rsquared_adj, 4),
        round(ols_b1_F3.rsquared_adj, 4),
```

```
        round(ols_b1_F4.rsquared_adj, 4)
    ],
    'R2_ARX': [
        round(arx_b0_F3.rsquared, 4),
        round(arx_b0_F4.rsquared, 4),
        round(arx_b1_F3.rsquared, 4),
        round(arx_b1_F4.rsquared, 4)
    ],
    'R2_ajust_ARX': [
        round(arx_b0_F3.rsquared_adj, 4),
        round(arx_b0_F4.rsquared_adj, 4),
        round(arx_b1_F3.rsquared_adj, 4),
        round(arx_b1_F4.rsquared_adj, 4)
    ],
})
# Añadimos la mejora en R2 ajustado
comparativa_ols_arx['Mejora_R2_ajust'] = (
    comparativa_ols_arx['R2_ajust_ARX'] - comparativa_ols_arx['R2_ajust_OLS']
).round(4)
comparativa_ols_arx
# Montamos la tabla resumen del Modelo ARX sobre los factores y drivers
modelos_arx = {
    'Δβ₀ Fase III': arx_b0_F3,
    'Δβ₀ Fase IV':  arx_b0_F4,
    'Δβ₁ Fase III': arx_b1_F3,
    'Δβ₁ Fase IV':  arx_b1_F4,
```

```
}


orden = ['const',
         'd_beta0_lag1', 'd_beta0_lag2',
         'd_beta1_lag1', 'd_beta1_lag2',
         'd_log_TTF', 'd_log_Coal', 'd_log_Power', 'd_log_Brent',
         'd_EPU', 'd_GPR',
         'd_log_TTF_lag1', 'd_log_Coal_lag1', 'd_log_Power_lag1', 'd_log_Brent_lag1',
         'd_EPU_lag1', 'd_GPR_lag1']


etiquetas = {
    'const': 'Constante',
    'd_beta0_lag1': 'Δβ₀ lag₁', 'd_beta0_lag2': 'Δβ₀ lag₂',
    'd_beta1_lag1': 'Δβ₁ lag₁', 'd_beta1_lag2': 'Δβ₁ lag₂',
    'd_log_TTF': 'Δlog TTF', 'd_log_Coal': 'Δlog Coal',
    'd_log_Power': 'Δlog Power', 'd_log_Brent': 'Δlog Brent',
    'd_EPU': 'ΔEPU (×1.000)', 'd_GPR': 'ΔGPR (×1.000)',
    'd_log_TTF_lag1': 'Δlog TTF lag₁', 'd_log_Coal_lag1': 'Δlog Coal lag₁',
    'd_log_Power_lag1': 'Δlog Power lag₁', 'd_log_Brent_lag1': 'Δlog Brent lag₁',
    'd_EPU_lag1': 'ΔEPU lag₁ (×1.000)', 'd_GPR_lag1': 'ΔGPR lag₁ (×1.000)',
}
# Variables a reescalar ×1000 para eliminar decimales
rescale = {'d_EPU', 'd_GPR', 'd_EPU_lag1', 'd_GPR_lag1'}
tabla = pd.DataFrame(index=[etiquetas[v] for v in orden],
                     columns=list(modelos_arx.keys()))
for col, res in modelos_arx.items():
```

```
    for var in orden:
        if var in res.params.index:
            coef = res.params[var]
            pval = res.pvalues[var]
            if var in rescale:
                coef = coef * 1000
                dec = 3
            else:
                dec = 4
            tabla.loc[etiquetas[var], col] = fmt_coef(coef, pval, decimals=dec)
        else:
            tabla.loc[etiquetas[var], col] = '—'
# Diagnósticos
diag = pd.DataFrame(index=['R²', 'R² ajustado', 'F-statistic',
                           'Durbin-Watson', 'Kurtosis residuos',
                           'N° observaciones'],
                    columns=tabla.columns)
#sustituimos los . por ,
for col, res in modelos_arx.items():
   # añadimos los asteriscos de significatividad del F-statistic
  fstars = '***' if res.f_pvalue < 0.01 else '**' if res.f_pvalue < 0.05 else '*' if res.f_pvalue <
0.10 else ''
    diag.loc['R²', col] = f'{res.rsquared:.3f}'.replace('.', ',')
    diag.loc['R² ajustado', col] = f'{res.rsquared_adj:.3f}'.replace('.', ',')
    diag.loc['F-statistic', col] = f'{res.fvalue:.2f}{fstars}'.replace('.', ',')
    diag.loc['Durbin-Watson', col] = f'{durbin_watson(res.resid):.3f}'.replace('.', ',')
```

```
    diag.loc['Kurtosis residuos', col] = f'{kurtosis(res.resid, fisher=False):.2f}'.replace('.',
',')

    diag.loc['N° observaciones', col] = f'{int(res.nobs):,}'.replace(',', '.')

tabla_final = pd.concat([tabla, diag])

print(tabla_final)

# Tabla resumen con los resultados de ambos modelos para cada factor en cada fase

tabla_comparativa = comparativa_ols_arx.copy()

tabla_comparativa.columns = ['Modelo', 'R² OLS', 'R² ajust. OLS',

                             'R² ARX', 'R² ajust. ARX', 'Δ R² ajust.']

filas = {'b0 P3': 'β₀ — Fase III',

         'b0 P4': 'β₀ — Fase IV',

         'b1 P3': 'β₁ — Fase III',

         'b1 P4': 'β₁ — Fase IV'}

tabla_comparativa['Modelo'] = tabla_comparativa['Modelo'].map(filas)

for col in tabla_comparativa.columns[1:]:

    tabla_comparativa[col] = tabla_comparativa[col].apply(lambda x: f'{x:.3f}')

# Añadir signo + a las mejoras positivas

tabla_comparativa['Δ R² ajust.'] = tabla_comparativa['Δ R² ajust.'].apply(

    lambda x: f'+{x}' if not x.startswith('-') else x)

print(tabla_comparativa)
```

Cointegración spot- futuro (Johansen trivariante) y cálculo del convenience yield

```
#Definimos la funcion para construir el front month (el contrato DEC más cercano) para cada día de
la muestra


def contrato_F(fecha, vencimientos, contratos_dec):
```

```
    años = sorted(vencimientos.keys())

    #montamos bucle para recorrer los años de menor a mayor y devuelve el primer contrato cuyo
vencimiento aún no ha pasado que sera el front.

    for año in años:

        if vencimientos[año] > fecha:

            if fecha in contratos_dec[año].index:

                return año, vencimientos[año], contratos_dec[año].loc[fecha]

            else:

                return None, None, None  # natural pero no cotiza ese día

    return None, None, None



# Reconstruir el front desde cero

front_data = []

for fecha in calendario:

    año, venc, precio = contrato_F(fecha, vencimientos, contratos_dec)

    if año is not None and not pd.isna(precio): #para  descartar días en que el contrato aparece en
el índice pero no tiene precio válido

        tau_days = (venc - fecha).days

        front_data.append({

            'Date': fecha,

            'F_raw': precio,

            'tau_days': tau_days,

            'tau_years': tau_days / 365,

            'año_contrato': año

        })

front = pd.DataFrame(front_data).set_index('Date')
```

```
# Juntamos las variables spot, futuro (front-month) y tipo de interés en un dataframe

#Empezamos desde 2014 dado que los datos del spot de 2013 obtenidos de Facset tieen valor constante
de  2.77 y generra distorsiones

spot_futuro = (front.loc['2014-09-03':'2026-01-30', ['Front', 'tau_days', 'tau_years']]

                .join(EUA_spot.rename('S'), how='inner')

                .join((EUR_12M / 100).rename('r'), how='inner'))

spot_futuro = spot_futuro[

    (spot_futuro['tau_days'] >= 30) & #descartamos los días más cercanos al vencimiento del front,
donde la iliquidez y los efectos del rolling distorsionan

    (spot_futuro['S'] != spot_futuro['S'].shift(1)) # elimnamos las observaciones con spot idéntico
al día previo porque suele ser por  ausencia cotización

].dropna().copy()

#pasamos a log

spot_futuro['s'] = np.log(spot_futuro['S'])

spot_futuro['f'] = np.log(spot_futuro['Front'])

#definimos la separacion de las fases

spot_futuro['fase'] = np.where(spot_futuro.index <= '2020-12-31', 'III', 'IV')

print(f"Observaciones: {len(spot_futuro)}")

print(f"  Fase III: {(spot_futuro['fase']=='III').sum()}")

print(f"  Fase IV:  {(spot_futuro['fase']=='IV').sum()}")

print(f"\nRango temporal: {spot_futuro.index.min().date()} a {spot_futuro.index.max().date()}")

print(f"\nEstadísticas descriptivas:")

print(spot_futuro[['S', 'Front', 'r', 'tau_days']].describe().round(3))

print(f"\nEstadísticas por fase:")

print(spot_futuro.groupby('fase')[['S', 'Front', 'r']].agg(['mean', 'std']).round(2))
```

```
#Antes aplicamos los tests de ADF y KPSS contrastamos el orden de integración de las tres series ¡
(s, f, r) en cada fase, en sus valores como las diferencias entre estos (similar al paso de raiz
unitaria en la seccion de OLS/ARX)

fase3 = spot_futuro[spot_futuro['fase'] == 'III']

fase4 = spot_futuro[spot_futuro['fase'] == 'IV']

# Variables a testear

variables = {

    's = ln(S)': 's',

    'f = ln(F)': 'f',

    'r': 'r'

}



resultados = []

for fase_label, df_fase in [('III', fase3), ('IV', fase4)]:

    for nombre, columna in variables.items():

        # ADF y KPSS sobre los valores

        serie = df_fase[columna].dropna()

        adf_stat, adf_p = adfuller(serie, autolag='AIC')[:2]

        kpss_stat, kpss_p = kpss(serie, regression='c', nlags='auto')[:2]

        resultados.append({

            'Fase': fase_label,

            'Serie': nombre,

            'ADF': round(adf_stat, 3),

            'ADF p': round(adf_p, 3),

            'KPSS': round(kpss_stat, 3),

            'KPSS p': round(kpss_p, 3)

        })
```

```
        # ADF y KPSS sobre las primeras diferencias
        serie_diff = df_fase[columna].diff().dropna()
        adf_stat, adf_p = adfuller(serie_diff, autolag='AIC')[:2]
        kpss_stat, kpss_p = kpss(serie_diff, regression='c', nlags='auto')[:2]
        resultados.append({
            'Fase': fase_label,
            'Serie': 'Δ' + nombre,
            'ADF': round(adf_stat, 3),
            'ADF p': round(adf_p, 3),
            'KPSS': round(kpss_stat, 3),
            'KPSS p': round(kpss_p, 3)
        })
tabla = pd.DataFrame(resultados)
print(tabla.to_string(index=False))


#dado que, según los resultados anteriores, comprobamos si el rechazo de raíz unitaria en s y f en
fase IV es robusto o solo aparece bajo 'c'. (iniciativa propuesta por la IA para reforzar el
análisis)
for fase_label, df_fase in [('III', fase3), ('IV', fase4)]:
    for var in ['s', 'f']:
        serie = df_fase[var].dropna()
        # Default (constante)
        stat_c, p_c = adfuller(serie, regression='c', autolag='AIC')[:2]
        # Con tendencia
        stat_ct, p_ct = adfuller(serie, regression='ct', autolag='AIC')[:2]
        print(f"Fase {fase_label} - {var}:")
        print(f"   'c':  stat={stat_c:.3f}, p={p_c:.3f}")
```

```
        print(f"   'ct': stat={stat_ct:.3f}, p={p_ct:.3f}")

  #el rechazo no es robusto y justifica tratar la serie como I(1).

# Seleccionamos el orden de Var

for fase_label in ['III', 'IV']:

    df_fase = spot_futuro[spot_futuro['fase'] == fase_label][['s', 'f', 'r']].dropna()

    modelo_var = VAR(df_fase)

    seleccion = modelo_var.select_order(maxlags=10) #numero de lags intermedio. ( apuntes de
econometria3)



    print(seleccion.summary())



#Seleccionamos el orden HQIC porque es el más equilibrado y chequeamos autocorrelación de los
residuos con un test Ljung-Box

ordenes_var = {'III': 7, 'IV': 4}

for fase_label in ['III', 'IV']:

    df_fase = spot_futuro[spot_futuro['fase'] == fase_label][['s', 'f', 'r']].dropna()

    # Estimar VAR con el orden elegido

    modelo_var = VAR(df_fase)

    resultados = modelo_var.fit(ordenes_var[fase_label])



    print(f"FASE {fase_label} (VAR de orden {ordenes_var[fase_label]})")

    # Test de Portmanteau (Ljung-Box multivariante)

    # H0: no hay autocorrelación residual hasta el lag h

    for h in [10, 20]:

        test = resultados.test_whiteness(nlags=h, signif=0.05)

        print(f"\nPortmanteau test (h={h}):")

        print(f"  Estadístico: {test.test_statistic:.3f}")
```

```
        print(f"  p-valor:     {test.pvalue:.4f}")

        print(f"  ¿Rechaza H0? {'Sí (hay autocorrelación)' if test.pvalue < 0.05 else 'No (residuos limpios)'}")



    # Test de normalidad de los residuos

    test_norm = resultados.test_normality(signif=0.05)

    print(f"\nTest de normalidad multivariante (Jarque-Bera):")

    print(f"  Estadístico: {test_norm.test_statistic:.3f}")

    print(f"  p-valor:     {test_norm.pvalue:.4f}")

#Nos centramos en la Fase IV dado que el test de Portmanteau reveló autocorrelación residual a ese orden, y aun aumentando el orden, sigue saliendo autocorrelación de los residuos. (se desarrolla en el trabajo)

#Aplicamos el Test de Johansen de Statsmodels

from statsmodels.tsa.vector_ar.vecm import coint_johansen

# Lags VECM = lags VAR - 1

ordenes_var = {'III': 7, 'IV': 4}

for fase_label in ['IV', 'III']:  # Fase IV primero por ser el foco principal

    df_fase = spot_futuro[spot_futuro['fase'] == fase_label][['s', 'f', 'r']].dropna()

    k_ar_diff = ordenes_var[fase_label] - 1



    # Test de Johansen con det_order=0 (según hemos visto en el test de raiz unitaria)

    resultado = coint_johansen(df_fase, det_order=0, k_ar_diff=k_ar_diff)



    # Valores críticos al 95% (nivel de significancia convencional)

    cvt_traza = resultado.cvt[:, 1]

    cvm_max = resultado.cvm[:, 1]
```

```
print(f"FASE {fase_label} (n={len(df_fase)}, k_ar_diff={k_ar_diff})")


# Test de la traza (trace test)
print(f"\nTest de la TRAZA:")
print(f"{'H0':<12}{'Estadístico':<15}{'C(95%)':<12}{'¿Rechaza?':<12}")
print('-' * 55)
for i, (stat, cvt) in enumerate(zip(resultado.lr1, cvt_traza)):
    rechaza = "Sí" if stat > cvt else "No"
    print(f"r ≤ {i}       {stat:<15.3f}{cvt:<12.3f}{rechaza}")


# Test del máximo autovalor (Max Eigenvalue)
print(f"\nTest del MÁXIMO AUTOVALOR:")
print(f"{'H0':<12}{'Estadístico':<15}{'C(95%)':<12}{'¿Rechaza?':<12}")
print('-' * 55)
for i, (stat, cvm) in enumerate(zip(resultado.lr2, cvt_max)):
    rechaza = "Sí" if stat > cvm else "No"
    print(f"r = {i}       {stat:<15.3f}{cvm:<12.3f}{rechaza}")


# Vector de cointegración (primer autovector)
print(f"\nVector de cointegración β (primer autovector):")
beta = resultado.evec[:, 0]
# Normalizar sobre f (para que el coeficiente de f sea 1)
beta_norm = beta / beta[1]
print(f"  β_s: {beta_norm[0]:.4f}")
print(f"  β_f: {beta_norm[1]:.4f}  (normalización)")
print(f"  β_r: {beta_norm[2]:.4f}")
```

Modelo VECM y Price Discovery

```
# VECM para Fase III

df_fase3 = spot_futuro[spot_futuro['fase'] == 'III'][['s', 'f', 'r']].dropna()

# r=1 (un único vector según Johansen)

# k_ar_diff=6 (VAR de orden 7)

vecm_fase3 = VECM(df_fase3,k_ar_diff=6,coint_rank=1, deterministic='ci')

res3 = vecm_fase3.fit()


print("VECM FASE III — Coeficientes de ajuste (α) y vector β")

print("\nVector de cointegración β (normalizado sobre f):")

beta = res3.beta.flatten()

beta_norm = beta / beta[1]

print(f"  β_s: {beta_norm[0]:.4f}")

print(f"  β_f: {beta_norm[1]:.4f}")

print(f"  β_r: {beta_norm[2]:.4f}")

print("\nCoeficientes de ajuste α (velocidad de corrección):")

print(f"  α_s: {res3.alpha[0,0]:.4f}  (t = {res3.alpha[0,0]/res3.stderr_alpha[0,0]:.3f})")

print(f"  α_f: {res3.alpha[1,0]:.4f}  (t = {res3.alpha[1,0]/res3.stderr_alpha[1,0]:.3f})")

print(f"  α_r: {res3.alpha[2,0]:.4f}  (t = {res3.alpha[2,0]/res3.stderr_alpha[2,0]:.3f})")


# Aplicamos la misma lógica para VECM para Fase IV

df_fase4 = spot_futuro[spot_futuro['fase'] == 'IV'][['s', 'f', 'r']].dropna()

vecm_fase4 = VECM(df_fase4,k_ar_diff=3,coint_rank=1, deterministic='ci')

res4 = vecm_fase4.fit()
```

```
print("VECM FASE IV — Coeficientes de ajuste (α) y vector β")

print("\nVector de cointegración β (normalizado sobre f):")

beta = res4.beta.flatten()

beta_norm = beta / beta[1]

print(f"  β_s: {beta_norm[0]:.4f}")

print(f"  β_f: {beta_norm[1]:.4f}")

print(f"  β_r: {beta_norm[2]:.4f}")

print("\nCoeficientes de ajuste α (velocidad de corrección):")

print(f"  α_s: {res4.alpha[0,0]:.4f}  (t = {res4.alpha[0,0]/res4.stderr_alpha[0,0]:.3f})")

print(f"  α_f: {res4.alpha[1,0]:.4f}  (t = {res4.alpha[1,0]/res4.stderr_alpha[1,0]:.3f})")

print(f"  α_r: {res4.alpha[2,0]:.4f}  (t = {res4.alpha[2,0]/res4.stderr_alpha[2,0]:.3f})")


#Price discovery mediante el modelo de Gonzalo Granger aplicado por Figuerola-Ferretti y Gonzalo
(2010)

#donde Pesos: alpha_perp' = (a2/(-a1+a2), -a1/(-a1+a2)) ; a1 = coef. de ajuste del SPOT ; a2 = coef.
de ajuste del FUTURO

ordenes_var = {'III': 7, 'IV': 4} #que obtenemos del HQIC

for fase_label in ['III', 'IV']:

    df_fase = spot_futuro[spot_futuro['fase'] == fase_label][['s', 'f','r']].dropna()

    k_ar_diff = ordenes_var[fase_label] - 1



    # VECM coherente con Johansen: deterministic='ci', mismo k_ar_diff

    vecm = VECM(df_fase, k_ar_diff=k_ar_diff, coint_rank=1, deterministic='ci')

    res = vecm.fit()

    # Coeficientes de ajuste alpha (columna del primer vector de cointegración)

    # Orden de filas = orden de columnas del df: [s, f]

    alpha_s = res.alpha[0, 0]
```

```
alpha_f = res.alpha[1, 0]

alpha_r = res.alpha[2, 0]


# formula de pesos de Gonzalo Granger

denominador = -alpha_s + alpha_f

gg_s = alpha_f / denominador

gg_f = -alpha_s / denominador


print(f"\nFASE {fase_label} — Gonzalo-Granger price discovery")

print(f"\nCoeficientes de ajuste α:")

print(f"  α_s (spot):   {alpha_s:.4f}  (t = {alpha_s/res.stderr_alpha[0,0]:.3f})")

print(f"  α_f (futuro): {alpha_f:.4f}  (t = {alpha_f/res.stderr_alpha[1,0]:.3f})")

print(f"\nPesos de price discovery (Gonzalo-Granger):")

print(f"  GS_s (spot):   {gg_s:.4f}")

print(f"  GS_f (futuro): {gg_f:.4f}")
```

X. 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, Mario Laureano Simón Alonso, estudiante de E2 + BA de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado ***Estructura temporal y***

eficiencia del mercado europeo de derechos de emisión (EU ETS): un análisis de la curva de futuros y del convenience yield, declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Metodólogo:** Para descubrir métodos aplicables a problemas específicos de investigación (i.e: Nelson Siegel)
2. **Interpretador de código:** para realizar análisis de datos preliminares.
3. **Constructor de plantillas:** para diseñar formatos de visualizaciones.
4. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
5. **Sintetizador y traductor de libros complicados:** Para resumir y comprender literatura compleja.
6. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.

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 qué 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: 11/06/2026

Firma: ____Mario Laureano Simón Alonso