

## TFG

**Alumno: Manuel Rodríguez Toribio**

**Tutor: Ignacio Cervera Conte**

## ÍNDICE

1.	INTRODUCCIÓN .....	2
1.1	Justificación y motivación.....	2
1.2.	Objetivos .....	4
2.	MARCO TEÓRICO.....	4
2.1.	Diversificación sectorial en carteras .....	4
2.2.	Activos tradicionales .....	5
2.3.	Activos alternativos .....	6
2.4.	Inteligencia artificial en la gestión financiera .....	7
3.	METODOLOGIA .....	8
3.1.	Datos y universo de activos.....	8
3.2.	Enfoque cuantitativo y técnicas tradicionales.....	10
3.3.	Incorporación de activos alternativos en la cartera .....	12
3.4.	Modelización mediante inteligencia artificial.....	13
3.5.	Procedimiento de análisis y criterios de evaluación .....	14
4.	ANÁLISIS Y RESULTADOS.....	15
4.1.	Análisis estadístico de la diversificación sectorial .....	15
4.2.	Construcción de carteras óptimas según el modelo media-varianza .....	18
4.3.	Modelización mediante inteligencia artificial.....	21
4.4.	Discusión de resultados .....	26
5.	CONCLUSIONES Y RECOMENDACIONES .....	29
6.	LIMITACIONES DEL ESTUDIO .....	31
7.	BIBLIOGRAFÍA.....	33
8.	ANEXOS.....	34

**Análisis del impacto de diversificación sectorial y activos alternativos en carteras convencionales, complementado con el estudio del uso de inteligencia artificial para optimizar esa diversificación y la gestión del riesgo.**

# 1. INTRODUCCIÓN

## 1.1 Justificación y motivación

La diversificación es “una opción estratégica que los inversores utilizan para optimizar su cartera con el propósito de minimizar el riesgo o maximizar el retorno” (Jayeola, Ismail & Sufahani, 2019, p.1). Esta estrategia es primordial en la gestión de carteras de inversión de cualquier ámbito, ya que permite reducir los riesgos asociados a la volatilidad y a posibles crisis en mercados específicos.

Diversificar por sectores económicos y tipos de activos constituye una práctica fundamental para equilibrar la exposición a distintas fuentes de riesgo, proteger el capital y fortalecer la estabilidad financiera a largo plazo. Los diferentes tipos de diversificación contribuyen a mitigar distintos tipos de riesgos, lo que convierte esta estrategia en un elemento esencial dentro de la gestión de carteras. En este sentido, “es típicamente más beneficioso diversificar a través de sectores que dentro de ellos” (James, Menzies & Gottwald, 2022, p. 1).

En este contexto, los activos alternativos, como bienes raíces, materias primas o inversiones en mercados no tradicionales, presentan una baja correlación con los activos convencionales. Este comportamiento contribuye a suavizar las fluctuaciones del mercado y a ofrecer retornos diferenciados, además de proporcionar una protección adicional frente a eventos económicos adversos. Tal como se ha señalado, “los bienes raíces y las materias primas han introducido nuevas dimensiones en la construcción de carteras, prometiendo beneficios de diversificación y perfiles de riesgo-retorno únicos” (Diversifying Portfolios Exploring investment strategies and alternative assets in modern markets. *Advances in Economics & Financial Studies*, (1)., 2023, p. 154).

En el desarrollo de este TFG nos centraremos en las inversiones tradicionales como la renta fija, en este caso bonos soberanos, siguiendo el ETF “*iShares Core € Govt Bond UCITS ETF -ISIN: IE00B14X4S71*”, expuesto a los bonos soberanos de la eurozona. También nos adentraremos en la renta variable (centrándonos en un índice bursátil global diversificado como el MSCI World (siguiendo el ETF “*iShares Core MSCI World UCITS ETF (Acc) -ISIN: IE00B4L5Y983-*”). Por último, integraremos 2 inversiones alternativas, empezando por el *real estate* mediante el ETF “*iShares Developed Markets Property Yield UCITS ETF (Acc) -ISIN: IE00B1FZS350-*” que invierte en REITs (Real Estate

Investment Trusts), es decir, sociedades cotizadas cuya actividad principal es la propiedad y gestión de activos inmobiliarios en mercados desarrollados. Como segunda inversión alternativa seleccionaremos las materias primas, mediante el ETF *“Invesco DB Commodity Index Tracking Fund -ISIN: US46090E1038-”* que invierte en contratos futuros sobre materias primas como energía, metales industriales, metales preciosos, agricultura. La razón de invertir en estos 4 ETF es debido a que se trata de inversiones accesibles que no requieren un capital inicial grande, ofreciendo un perfil riesgo-retorno distintivo. A ello se añade que los cuatro instrumentos presentan un Tracking Error reducido respecto a sus índices de referencia, lo que confirma que replican con fidelidad el comportamiento del mercado que cada uno representa, como se detalla en el Anexo 3 y más adelante en el estudio.

Este trabajo surge del creciente interés por los activos alternativos, lo que impulsa el propósito de elaborar un estudio riguroso y actualizado que aporte valor tanto en el plano académico como en el práctico. Como señalan los estudios recientes, “durante las últimas décadas, los inversores institucionales han reducido su exposición a los activos tradicionales y han incrementado la cantidad de inversiones en clases de activos alternativos, atraídos por la promesa de rendimientos superiores y beneficios de diversificación” (Andonov, 2022, p. 1). De este modo, la incorporación de activos alternativos representa una oportunidad para ampliar la visión de la inversión tradicional y adaptarse a las nuevas tendencias del mercado.

Por otra parte, la inteligencia artificial ha emergido como una herramienta indispensable de considerar en múltiples ámbitos, y la gestión financiera es una excepción. Su capacidad para procesar grandes volúmenes de datos en tiempo real, identificar patrones y automatizar decisiones permite afinar los procesos de diversificación, dando lugar a enfoques más flexibles en la estimación de rentabilidades esperadas y la construcción de carteras. En este sentido, Lee et al. (2024, p. 2) destacan que “machine learning has become a vital component in modern portfolio management, enhancing both diversification and risk assessment”.

Integrar la inteligencia artificial en la optimización de carteras va más allá de una tendencia tecnológica en expansión; constituye un paso necesario para mantener la competitividad y la eficiencia en mercados cada vez más dinámicos y complejos, ya que aunque cabe la posibilidad de que en el presente pueda llegar no ser indispensable, su uso en cualquier actividad para poder ser competente es cada vez más crucial. Por estas

razones, en el presente estudio se examinará conjuntamente el impacto de la diversificación sectorial y los activos alternativos en una cartera tradicional, impulsados por la inteligencia artificial, con el objetivo de contribuir a una gestión más rentable y adaptable a las condiciones actuales del entorno financiero.

## 1.2. Objetivos

- Recopilar y analizar los datos necesarios para evaluar el impacto de la diversificación sectorial y los activos alternativos en carteras de inversión convencionales.
- Definir claramente los términos clave relacionados con carteras, diversificación, activos alternativos e inteligencia artificial en el contexto financiero.
- Analizar el impacto de la diversificación sectorial en la gestión de carteras, evaluando cómo distintas combinaciones sectoriales afectan la reducción del riesgo y el rendimiento.
- Estudiar el papel de los activos alternativos dentro de una cartera diversificada, identificando sus beneficios y limitaciones en cuanto a la protección frente a la volatilidad y la generación de retornos diferenciados.
- Investigar el uso de inteligencia artificial como herramienta para optimizar la diversificación de carteras.
- Calcular un modelo que integre la diversificación sectorial, los activos alternativos y la inteligencia artificial para evaluar su efectividad en la gestión adaptativa de carteras en entornos financieros actuales.

## 2. MARCO TEÓRICO

### 2.1. Diversificación sectorial en carteras

Como ya hemos explicado y justificado en la introducción, la diversificación sectorial representa un pilar fundamental de la gestión moderna de carteras de inversión, ya que permite a los inversores mitigar riesgos específicos asociados a la concentración en un

único sector económico. Esta práctica no solo equilibra la exposición a distintas fuentes de volatilidad, sino que también protege el capital ante crisis sectoriales localizadas.

En el contexto de los mercados bursátiles, cada sector responde de forma diferente a los ciclos económicos, lo que genera oportunidades para reducir la correlación entre activos. Por ejemplo, sectores cíclicos como el tecnológico o el financiero amplifican las expansiones y contracciones, mientras que los defensivos como el consumo básico ofrecen estabilidad en periodos de incertidumbre. La teoría de portafolios moderna, desarrollada por Markowitz (1952), establece que los portafolios diversificados son preferibles a los no diversificados, ya que “la diversificación reducirá el riesgo cuando los retornos no están perfectamente positivamente correlacionados”. Markowitz, 1952, p. 77). Este principio se aplica directamente a la distribución sectorial, donde la baja correlación entre sectores económicos permite mitigar la volatilidad total de la cartera. Como ya explicamos en la introducción, los estudios empíricos confirman que diversificar "a través de sectores" genera mayores beneficios que la diversificación interna dentro de un mismo sector. Esta aproximación reduce la volatilidad sistémica y mejora métricas como el ratio de Sharpe, que mide el rendimiento ajustado al riesgo.

Además, la diversificación sectorial adquiere mayor relevancia en carteras globales, donde índices como el MSCI World ya incorporan cierta dispersión, pero requieren ajustes para optimizar el equilibrio riesgo-retorno. En contextos de alta incertidumbre, como crisis financieras, las carteras sectorialmente diversificadas han demostrado mayor resiliencia al suavizar fluctuaciones extremas tales estrategias contribuyen a mitigar distintos tipos de riesgos, como demuestran James, N., Menzies, M., & Gottwald, G. A. (2022). En su trabajo “*On financial market correlation structures and diversification benefits across and within equity sectors*”, convirtiéndola en esencial para inversores institucionales y minoristas por igual.

En síntesis, la diversificación sectorial no es meramente defensiva, sino estratégica.

## 2.2. Activos tradicionales

Los activos tradicionales representan el fundamento de cualquier cartera de inversión convencional, agrupándose principalmente en renta fija y renta variable. La renta fija, ejemplificada por letras del Tesoro o bonos gubernamentales, ofrece rendimientos estables y predecibles que actúan como refugio seguro durante episodios de turbulencia

en los mercados. Por el contrario, la renta variable (a través de acciones individuales o índices representativos como MSCI World (representa las ~1.500 principales empresas de gran y mediana capitalización de 23 países desarrollados) promete mayor potencial de apreciación a largo plazo, aunque conlleva volatilidad ligada a los ciclos económicos.

Estos dos pilares financieros, pese a su complementariedad teórica, revelan limitaciones en escenarios adversos. "Si las correlaciones entre activos cruzados aumentan, el riesgo total de la cartera y las pérdidas resultantes pueden ser mayores o más frecuentes de lo esperado" (ECB, 2022, p. 48). Esta tendencia, observada en crisis recientes, reduce los beneficios de diversificación de equities y bonds.

En el contexto de este TFG, renta fija y variable establecen el punto de partida para analizar cómo la integración de nuevas estrategias puede optimizar el equilibrio riesgo-retorno.

### 2.3. Activos alternativos

En continuidad con los activos tradicionales, los activos alternativos suelen incorporarse a la cartera no tanto para "complicar" el análisis, sino para añadir motores de rentabilidad distintos y, sobre todo, mejorar la diversificación. En este trabajo se analizan dos de los más habituales: real estate y materias primas, que además comparten un rasgo importante: son activos reales, vinculados a la economía física y, por tanto, pueden comportarse de forma diferente frente a acciones y bonos.

En el caso del real estate, su interés en cartera se apoya en que combina renta (alquileres) y revalorización del activo en el largo plazo. La evidencia histórica sugiere que, al menos en economías avanzadas, la vivienda ha sido un activo con retornos de largo recorrido comparables a los de la renta variable. Según Jordà et al. "el resultado más sorprendente de nuestro estudio es que, en el largo plazo, los retornos de la vivienda y de la renta variable se parecen notablemente" (Jordà et al., 2017, p. 55). Ahora bien, el real estate también introduce límites prácticos: su liquidez es reducida y la formación de precio no es tan continua como en activos cotizados, lo que obliga a leer sus métricas de riesgo con prudencia.

Las materias primas, por su parte, suelen incorporarse por un motivo muy concreto: su potencial como diversificador y como activo que puede responder mejor en determinados escenarios macro (por ejemplo, inflación o shocks de oferta). En términos de correlación

con activos tradicionales, Gorton y Rouwenhorst señalan que “los retornos de los futuros sobre materias primas están negativamente correlacionados con los retornos de la renta variable y de los bonos”, lo que ayuda a entender por qué, en algunos marcos de asignación estratégica, aparecen como cobertura parcial frente a pérdida de poder adquisitivo.

En síntesis, real estate y materias primas pueden mejorar una cartera bien planteada porque aportan exposición a activos reales y, potencialmente, comportamientos distintos a los activos tradicionales. Sin embargo, su integración requiere tener presentes dos ideas básicas: el inmobiliario exige considerar la iliquidez y la naturaleza de sus precios, y las materias primas exigen entender que su papel suele ser más de diversificación/cobertura que de rentabilidad estable, además de que su relación con otros activos puede cambiar con el tiempo.

#### 2.4. Inteligencia artificial en la gestión financiera

Tras haber revisado los enfoques tradicionales de gestión de carteras, resulta evidente que presentan limitaciones importantes en contextos de mercado complejos. La teoría media-varianza de Markowitz, aunque fundamental desde el punto de vista teórico, se apoya en supuestos como la estabilidad de las correlaciones y la linealidad de los retornos, que no siempre se cumplen en la práctica. En situaciones de estrés financiero, estas hipótesis tienden a fallar, reduciendo la efectividad de la diversificación clásica. En este sentido, “las distribuciones de los retornos financieros suelen ser no lineales, variables en el tiempo e inestables, lo que limita la efectividad de los métodos tradicionales de optimización de carteras” (Lee et al., 2024, p. 2).

En este contexto, la inteligencia artificial ha ganado peso como herramienta de apoyo en la gestión de carteras, no como sustituto de la teoría financiera clásica, sino como complemento que permite explorar nuevas formas de estimar rentabilidades esperadas. En este trabajo se ha optado por una aproximación sencilla y transparente: una regresión lineal regularizada conocida como Ridge. La elección no es casual, antes de recurrir a modelos más complejos, tiene sentido comprobar si una técnica simple ya es capaz de aportar algo frente al enfoque tradicional.

Lo que hace el modelo es aprender, a partir del histórico de cada activo, si existe alguna relación entre la información reciente (retornos del día anterior, media de los últimos

cinco días y volatilidad de los últimos veinte) y el retorno del día siguiente. Con esas estimaciones se construye un nuevo vector de rentabilidades esperadas ( $\mu$ ) que sustituye a las medias históricas en el proceso de optimización de Markowitz. Se mantiene la estructura del optimizador media-varianza, modificando únicamente la forma de estimar el vector de rentabilidades esperadas ( $\mu$ ), que pasa de calcularse mediante medias históricas a estimarse mediante el modelo predictivo. Como señalan Lee et al. (2024, p. 2), "el aprendizaje automático se ha convertido en un componente vital en la gestión moderna de carteras, mejorando tanto la diversificación como la evaluación del riesgo".

Dicho esto, conviene no perder de vista las limitaciones. Como señalan Heaton, Polson y Witte (2016, p. 2), en la práctica el uso de modelos predictivos complejos puede dar lugar a "a plethora of predictive models, many with little theoretical justification and subject to over-fitting and poor predictive out-of-sample performance". En este sentido, la potencia de las técnicas de aprendizaje automático no garantiza por sí sola una mejora estructural en la capacidad predictiva, especialmente en entornos financieros caracterizados por elevada incertidumbre y baja señal informativa. En este trabajo, la regularización propia del Ridge y la separación estricta entre periodo de entrenamiento y periodo de test constituyen las principales medidas adoptadas para mitigar ese riesgo.

En definitiva, el objetivo no es demostrar que la inteligencia artificial supera a Markowitz, sino analizar de forma honesta si una estimación alternativa de rentabilidades aporta algo frente al uso de medias históricas. Los resultados del análisis son los que responden a esa pregunta.

### 3. METODOLOGIA

#### 3.1. Datos y universo de activos

El análisis empírico de este trabajo se basa en datos financieros correspondientes al periodo 2010–2025, con una frecuencia diaria, lo que permite trabajar con un número elevado de observaciones (cerca de 3.900 días hábiles) y obtener estimaciones estadísticamente robustas de las medias y volatilidades anualizadas. La elección de este intervalo temporal permite trabajar con series históricas consistentes y comparables, evitando sesgos asociados a periodos excesivamente cortos o específicos.

El universo de activos seleccionado combina activos tradicionales y activos alternativos, en coherencia con los objetivos del estudio. Todos los vehículos de inversión son ETFs, ya que permiten una representación diversificada, líquida y replicable de cada clase de activo, garantizan homogeneidad metodológica en los datos, reducen el riesgo idiosincrático y aportan coherencia entre el modelo teórico de Markowitz y su aplicación práctica en mercados reales. Los datos se obtienen a través de Yahoo Finance, utilizando los tickers disponibles en dicha plataforma como proxies de cada clase de activo.

Dentro de los activos tradicionales se consideran la renta fija y la renta variable. La renta fija se representa mediante el ETF iShares Core € Govt Bond UCITS ETF (ticker: IEGA.L, ISIN: IE00B14X4S71), cotizado en la Bolsa de Londres, que replica el comportamiento de los bonos soberanos de la Eurozona y se utiliza como aproximación a un activo de bajo riesgo. La renta variable se incorpora a través del iShares Core MSCI World UCITS ETF (ticker: IWDA.L, ISIN: IE00B4L5Y983), que recoge el comportamiento agregado de aproximadamente 1.500 empresas de gran y mediana capitalización de 23 países desarrollados.

En segundo lugar, se incluyen dos activos alternativos. El real estate se representa mediante el iShares Developed Markets Property Yield UCITS ETF (ticker: IWDP.L, ISIN: IE00B1FZS350), que invierte en REITs y empresas inmobiliarias cotizadas de mercados desarrollados. Las materias primas se incorporan a través del Invesco DB Commodity Index Tracking Fund (ticker: DBC, ISIN: US46090E1038), que replica un índice diversificado de futuros sobre energía, metales y agricultura. Este último es la versión americana del vehículo, seleccionada por su mayor disponibilidad y continuidad de datos históricos en Yahoo Finance respecto a alternativas UCITS europeas equivalentes.

Como criterio adicional de validación de la selección, se ha calculado el Tracking Error anualizado de cada ETF respecto al benchmark de referencia más cercano disponible en Yahoo Finance, seleccionado tras comparar sistemáticamente múltiples candidatos. Para los bonos soberanos (IEGA.L) se ha utilizado el Xtrackers Eurozone Government Bond UCITS ETF (XGLE.L), que replica el mismo mercado de deuda soberana de la eurozona. Para la renta variable global (IWDA.L) se ha empleado el Xtrackers MSCI World UCITS ETF (XDWD.L), que sigue el mismo índice MSCI World. Para el real estate (IWDP.L) se ha usado el HSBC FTSE EPRA/NAREIT Developed UCITS ETF (H4ZL.DE), que replica el mismo índice de empresas inmobiliarias cotizadas en mercados desarrollados.

Para las materias primas (DBC) se ha tomado como referencia el Invesco Optimum Yield Diversified Commodity ETF (PDBC), producto del mismo proveedor que sigue una metodología equivalente. Los resultados muestran valores del 1,99% para IEGA.L, 2,43% para IWDA.L, 5,77% para IWDP.L y 5,40% para DBC. Los dos primeros presentan los niveles de Tracking Error más reducidos del conjunto, lo que sugiere una replicación razonablemente cercana de sus respectivos índices de referencia. Para IWDP.L y DBC el Tracking Error es más elevado, esto no refleja directamente una deficiencia en la capacidad de réplica de estos ETFs sino la ausencia de un benchmark idéntico disponible en Yahoo Finance: las diferencias de divisa entre mercados, la política de distribución de dividendos y la naturaleza de los contratos de futuros en el caso de las materias primas introducen divergencias estructurales que elevan el TE sin que el ETF deje de replicar fielmente su índice subyacente.

En conjunto, el universo de activos definido constituye una base adecuada para analizar el impacto de la diversificación sectorial y la inclusión de activos alternativos en carteras convencionales, así como para el posterior desarrollo del análisis cuantitativo y la modelización propuesta en los apartados siguientes.

### 3.2. Enfoque cuantitativo y técnicas tradicionales

El enfoque metodológico adoptado en este trabajo es de naturaleza cuantitativa, apoyado en herramientas clásicas de la teoría financiera ampliamente aceptadas en la literatura académica. Estas técnicas permiten analizar de forma objetiva la relación entre rentabilidad, riesgo y diversificación, y constituyen el punto de partida para evaluar posteriormente el valor añadido de enfoques más avanzados basados en inteligencia artificial.

En primer lugar, se emplea el modelo media-varianza de Markowitz (1952) como marco básico para la construcción y evaluación de carteras. Este modelo establece que un inversor racional debe seleccionar combinaciones de activos que maximicen la rentabilidad esperada para un nivel dado de riesgo o, de forma equivalente, minimicen el riesgo para un nivel dado de rentabilidad, dando lugar al concepto de *frontera eficiente*. La aportación central de Markowitz fue demostrar formalmente que la diversificación permite reducir el riesgo total de una cartera cuando los activos no están perfectamente correlacionados. En palabras del propio autor, “la diversificación reducirá el riesgo

cuando los retornos no estén perfectamente correlacionados de forma positiva” (Markowitz, 1952, p. 77). Este principio constituye la base teórica sobre la que se construyen las carteras analizadas en este estudio.

No obstante, mientras que en el enfoque tradicional los rendimientos esperados suelen estimarse mediante medias históricas, en este trabajo se incorpora, en una fase posterior, un modelo predictivo basado en técnicas de aprendizaje automático con el objetivo de estimar dichos rendimientos de forma alternativa. De este modo, se mantiene la estructura de optimización media-varianza, pero se modifica el procedimiento de estimación del parámetro de rentabilidad esperada ( $\mu$ ), permitiendo comparar los resultados obtenidos bajo el enfoque clásico frente al enfoque ampliado con inteligencia artificial.

De forma complementaria, se realiza un análisis de correlaciones entre los distintos activos incluidos en el universo de inversión. La correlación permite medir el grado en que los rendimientos de dos activos se mueven conjuntamente y resulta esencial para evaluar la efectividad real de la diversificación. Desde un punto de vista metodológico, el cálculo de matrices de correlación facilita la identificación de relaciones de dependencia entre activos tradicionales y alternativos, permitiendo comprobar hasta qué punto la incorporación de nuevas clases de activos contribuye a reducir la volatilidad agregada de la cartera. Este análisis resulta especialmente relevante en carteras multiactivo, donde la reducción del riesgo no depende únicamente de la volatilidad individual de cada activo, sino también de su comportamiento conjunto.

Asimismo, para evaluar el desempeño de las carteras desde una perspectiva de rentabilidad ajustada al riesgo, se utiliza el ratio de Sharpe, propuesto por Sharpe (1966). Este indicador relaciona el exceso de rentabilidad de una cartera respecto al activo libre de riesgo con su volatilidad, ofreciendo una medida sintética del retorno obtenido por cada unidad de riesgo asumido. El ratio de Sharpe es una de las métricas más utilizadas en la literatura financiera y en la práctica profesional para comparar la eficiencia de distintas estrategias de inversión. Su empleo en este trabajo permite contrastar de forma clara si la diversificación sectorial y la inclusión de activos alternativos mejoran la relación riesgo-retorno de las carteras analizadas (Sharpe, 1966).

Junto a la volatilidad y al ratio de Sharpe, se incorpora el Valor en Riesgo (Value at Risk, VaR) como medida adicional de riesgo. En concreto, se calcula el VaR histórico al 95%, que estima la pérdida diaria que únicamente se supera el 5% de los días, es decir,

aproximadamente uno de cada veinte días de mercado. Esta métrica complementa al ratio de Sharpe porque mientras este mide la variabilidad promedio de los rendimientos, el VaR se centra en el comportamiento en los días malos, permitiendo comparar cuánto riesgo de pérdida puntual asume cada estrategia. Tal como señala Jorion (2007), el VaR se ha consolidado como una herramienta estándar en la gestión del riesgo financiero por su capacidad de cuantificar de forma intuitiva la exposición a escenarios adversos.

En conjunto, el uso del modelo de Markowitz, el análisis de correlaciones, el ratio de Sharpe y el Value at Risk configura un marco metodológico sólido y coherente con la práctica habitual en estudios empíricos sobre carteras de inversión. Estas herramientas constituyen el estándar de referencia en finanzas cuantitativas y permiten establecer una base comparativa clara para el análisis posterior. De este modo, los resultados obtenidos mediante estas técnicas tradicionales sirven como punto de contraste frente al modelo ampliado que incorpora estimaciones de rentabilidad obtenidas mediante técnicas de aprendizaje automático, facilitando una evaluación rigurosa de su aportación real en términos de diversificación y gestión del riesgo.

### 3.3. Incorporación de activos alternativos en la cartera

La incorporación de activos alternativos en este trabajo se plantea desde un enfoque estrictamente metodológico, con el objetivo de analizar cómo su inclusión modifica el comportamiento de una cartera tradicional compuesta por renta variable y renta fija. Los activos alternativos considerados son el real estate y las materias primas, seleccionados por su relevancia práctica y por la disponibilidad de índices representativos con series históricas consistentes.

Desde el punto de vista operativo, el análisis se realiza sobre el universo completo de cuatro activos desde el inicio, combinando activos tradicionales (bonos y renta variable global) con activos alternativos (real estate y materias primas). La contribución de cada clase de activo a la diversificación se evalúa a través de la matriz de correlaciones y de los pesos asignados por el optimizador, lo que permite identificar qué activos aportan mayor eficiencia al perfil riesgo-retorno de la cartera.

El real estate se introduce en el análisis mediante el ETF iShares Developed Markets Property Yield UCITS ETF (IWDPL, ISIN: IE00B1FZS350), que agrupa compañías

inmobiliarias cotizadas y vehículos tipo REIT de mercados desarrollados globales. El uso de un vehículo cotizado en bolsa permite tratar el real estate como un activo financiero líquido, con precios observables y series temporales continuas, garantizando la comparabilidad con el resto de activos incluidos en la cartera.

Por su parte, las materias primas se incorporan a través del Invesco DB Commodity Index Tracking Fund (DBC, ISIN: US46090E1038), que replica el índice DBIQ Optimum Yield Diversified Commodity Index e incluye futuros sobre energía, metales industriales, metales preciosos y agricultura. Se trata de la versión americana del vehículo, seleccionada por su mayor disponibilidad y continuidad de datos históricos en Yahoo Finance.

Desde el punto de vista del análisis cuantitativo, los rendimientos de los activos alternativos se integran en la cartera utilizando las mismas métricas que los activos tradicionales, incluyendo volatilidad, correlaciones, ratio de Sharpe y Value at Risk. De este modo, su contribución a la diversificación se evalúa de forma comparable y sin introducir tratamientos diferenciados que puedan sesgar los resultados.

En síntesis, la metodología aplicada permite evaluar de manera objetiva cómo la inclusión del real estate y de las materias primas altera el perfil riesgo-retorno de una cartera tradicional, proporcionando una base empírica clara para el análisis posterior de resultados y para la comparación con el modelo ampliado que incorpora estimaciones de rentabilidad obtenidas mediante técnicas de aprendizaje automático, desarrollado en los apartados siguientes.

### 3.4. Modelización mediante inteligencia artificial

Una vez establecido el modelo de Markowitz como base del análisis, se incorpora una extensión apoyada en inteligencia artificial. El enfoque clásico estima los rendimientos esperados usando medias históricas, lo que implica asumir que el pasado se va a repetir. En mercados financieros eso no siempre ocurre, y por eso tiene sentido explorar si una estimación más dinámica puede mejorar los resultados.

Para ello se implementa un modelo de regresión Ridge, una técnica de aprendizaje automático supervisado que aprende a estimar el rendimiento futuro de cada activo a

partir de información reciente: el retorno del día anterior, la media de los últimos cinco días y la volatilidad de los últimos veinte. Esas estimaciones sustituyen a las medias históricas como parámetro  $\mu$  en el optimizador de Markowitz, sin cambiar nada más de la estructura del modelo.

La implementación se realiza en Python, dividiendo los datos en un periodo de entrenamiento (2010–2019) y un periodo de test fuera de muestra (2020–2025). Esta separación es importante porque permite comprobar si el modelo funciona realmente en datos que no ha visto antes, y no solo en los que usó para aprender.

En definitiva, la inteligencia artificial no entra aquí para sustituir a Markowitz, sino para hacerle una pregunta concreta: ¿mejoran los resultados si en lugar de usar medias históricas usamos estimaciones predictivas? Los resultados del análisis son los que responden.

### 3.5. Procedimiento de análisis y criterios de evaluación

Una vez construidas las distintas configuraciones de cartera (tanto bajo el enfoque tradicional como bajo el modelo ampliado con estimaciones predictivas) se establece un procedimiento de análisis orientado a comparar de forma objetiva sus resultados.

En primer lugar, se calculan las carteras óptimas utilizando el modelo media-varianza con medias históricas como estimación de los rendimientos esperados. Posteriormente, se repite el mismo proceso de optimización sustituyendo dichas medias por las estimaciones obtenidas mediante el modelo de aprendizaje automático desarrollado en el apartado anterior. De este modo, ambas carteras son comparables, ya que comparten la misma estructura matemática y difieren únicamente en el método de estimación del parámetro  $\mu$ .

El análisis se realiza diferenciando entre periodo de entrenamiento y periodo fuera de muestra (out-of-sample), con el fin de evaluar el comportamiento real de las carteras en un entorno no utilizado para la estimación. Esta distinción permite comprobar si la incorporación de inteligencia artificial aporta mejoras consistentes o si los resultados responden únicamente a un ajuste excesivo sobre los datos históricos.

Los criterios de evaluación utilizados son homogéneos para ambos enfoques e incluyen: rentabilidad media, volatilidad, ratio de Sharpe y Value at Risk (VaR). Estas métricas permiten analizar tanto el rendimiento absoluto como el rendimiento ajustado al riesgo,

así como la exposición a pérdidas potenciales en escenarios adversos. Asimismo, se observa la estabilidad de los pesos asignados a cada activo, con el objetivo de valorar si el modelo predictivo genera asignaciones más coherentes o, por el contrario, introduce mayor variabilidad.

En conjunto, este procedimiento permite determinar de forma rigurosa si la estimación de rendimientos mediante inteligencia artificial mejora el perfil riesgo–retorno de la cartera frente al enfoque tradicional, manteniendo un marco de comparación claro y metodológicamente consistente.

## 4. ANALISIS Y RESULTADOS

### 4.1. Análisis estadístico de la diversificación sectorial

El análisis se realiza utilizando datos diarios comprendidos entre febrero de 2010 y diciembre de 2025, lo que permite trabajar con un número elevado de observaciones (cerca de 3.900 días hábiles) y obtener estimaciones estadísticamente más robustas de las medias y volatilidades. A partir de los rendimientos diarios se calculan valores anualizados, facilitando así una interpretación económica homogénea de los resultados.

**Tabla 1. Rentabilidad media anual y volatilidad por activo (periodo de entrenamiento 2010–2019)**

Activo	Rentabilidad Media Anual	Volatilidad Anual	Periodo
<b>Bonos soberanos (IEGA.L)</b>	3,39%	4,00%	Train 2010–2019
<b>Renta variable (IWDA.L)</b>	10,55%	14,33%	Train 2010–2019
<b>Real estate (IWDP.L)</b>	11,65%	28,76%	Train 2010–2019
<b>Materias primas (DBC)</b>	-2,33%	15,70%	Train 2010–2019

Fuente: elaboración propia a partir de datos de Yahoo Finance.

En términos de rentabilidad media anual, el real estate cotizado es el activo con mayor rendimiento del periodo de entrenamiento, con un 11,65%, seguido de cerca por la renta variable global (MSCI World) con un 10,55%. Ambos resultados reflejan la fase prolongada de expansión que caracterizó los mercados desarrollados entre 2010 y 2019.

Los bonos soberanos de la Eurozona muestran un rendimiento más moderado del 3,39%, coherente con el entorno de tipos de interés reducidos que predominó durante buena parte del periodo. Las materias primas son el único activo con rentabilidad negativa, registrando un -2,33% anual, lo que refleja la debilidad estructural de las commodities durante esa década.

Desde la perspectiva del riesgo, los bonos son claramente el activo más estable, con una volatilidad del 4,00%. La renta variable global presenta una volatilidad del 14,33%, seguida de las materias primas con un 15,70%. El real estate es el activo más volátil con un 28,76%, lo que evidencia que pese a su alta rentabilidad en ese periodo, también concentra el mayor riesgo del conjunto.

Si se calcula el ratio de Sharpe individual de cada activo, se obtiene una perspectiva adicional sobre la eficiencia de cada clase de activo. Los bonos y la renta variable global presentan ratios prácticamente idénticos (0,71 y 0,70 respectivamente), pero los bonos lo consiguen con una volatilidad casi cuatro veces menor. El real estate, pese a ser el activo más rentable, presenta un Sharpe de apenas 0,38 debido a su elevada volatilidad. Las materias primas, con un Sharpe negativo de -0,18, son el único activo que no compensa el riesgo asumido durante este periodo.

En conjunto, los resultados muestran perfiles claramente diferenciados en términos de rentabilidad y riesgo, lo que constituye la base necesaria para construir una estrategia de diversificación eficaz mediante el modelo de Markowitz.

**Tabla 2. Matriz de correlaciones entre activos (periodo de entrenamiento 2010–2019)**

Activo	Bonos	MSCI World	Inmobiliario	Materias
Bonos	1.0000	0.0018	0.0599	-0.0695

Activo	Bonos	MSCI World	Inmobiliario	Materias
MSCI World	0.0018	<b>1.0000</b>	0.2050	0.3248
Inmobiliario	0.0599	0.2050	<b>1.0000</b>	0.1350
Materias	-0.0695	0.3248	0.1350	<b>1.0000</b>

Fuente: elaboración propia a partir de datos de Yahoo Finance. Valores negativos en rojo. Correlaciones superiores a 0,20 en azul oscuro.

El análisis de la matriz de correlaciones permite profundizar en el verdadero potencial diversificador de los activos seleccionados. En primer lugar, los bonos soberanos de la Eurozona muestran correlaciones prácticamente nulas con el resto de activos, situándose en 0,002 frente a la renta variable global y 0,060 frente al real estate. Incluso presentan una correlación ligeramente negativa con las materias primas (-0,070). Estos resultados refuerzan su papel tradicional como activo estabilizador dentro de una cartera diversificada, ya que su comportamiento tiende a diferenciarse claramente del de los activos de mayor riesgo.

En el caso de la renta variable global y el real estate cotizado, la correlación se sitúa en 0,205, lo que indica una relación moderada. Este resultado sugiere que, aunque el sector inmobiliario posee características propias vinculadas al mercado de activos reales, su cotización bursátil provoca que comparta parte del ciclo financiero con la renta variable. Por tanto, su capacidad de diversificación es parcial, pero no nula.

La correlación más elevada del conjunto se da entre la renta variable global y las materias primas (0,325), lo que sugiere que ambos activos comparten cierta sensibilidad a factores macroeconómicos comunes como el ciclo económico global. No obstante, esta correlación sigue siendo moderada y no elimina el potencial diversificador de las materias primas. Por su parte, la correlación entre materias primas y real estate es la más baja entre activos alternativos (0,135), lo que refuerza su complementariedad dentro de la cartera.

En conjunto, la matriz de correlaciones evidencia que los activos analizados no se mueven de forma perfectamente sincronizada. Esta falta de correlación perfecta constituye la base teórica que permite aplicar el modelo media-varianza de Markowitz y obtener combinaciones de activos capaces de reducir el riesgo total sin renunciar necesariamente

a rentabilidad. En consecuencia, los resultados obtenidos respaldan la idoneidad del universo de inversión seleccionado para el posterior análisis de optimización de carteras.

Conviene señalar que el análisis anterior se realiza exclusivamente sobre los activos riesgosos que conforman el universo invertible. La introducción de un activo libre de riesgo se reserva para el apartado siguiente, donde se incorpora como referencia para el cálculo del ratio de Sharpe y la construcción de la Capital Market Line, sin formar parte directa de la optimización entre activos riesgosos.

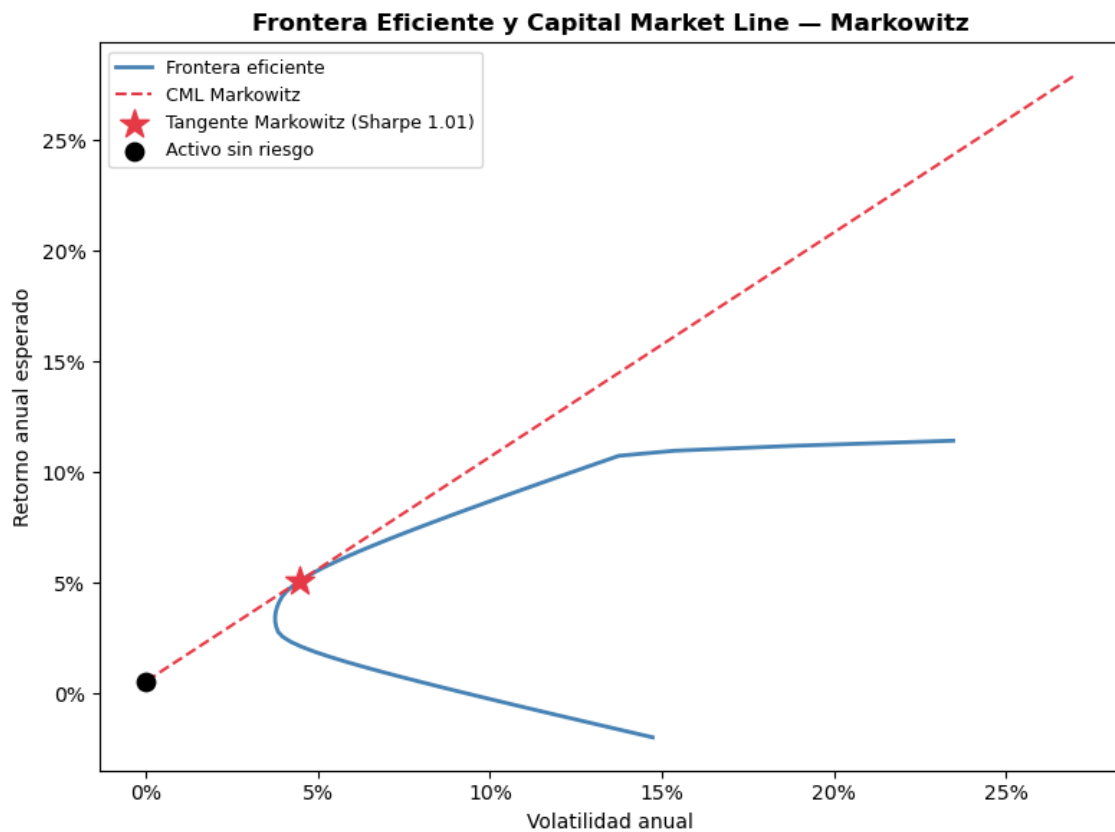
#### 4.2. Construcción de carteras óptimas según el modelo media-varianza

Una vez calculados los rendimientos diarios de los activos y anualizados los parámetros necesarios (vector de rentabilidades esperadas y matriz de covarianzas), se procede a aplicar el modelo media-varianza. Con el fin de dar un paso adicional respecto al planteamiento clásico, se introduce un activo libre de riesgo, lo que permite calcular el ratio de Sharpe en su formulación estándar y construir la Capital Market Line (CML).

Para ello se emplea como proxy una serie de tipo de interés a corto plazo (T-Bill a 13 semanas,  $\hat{IRX}$ ), obteniendo una tasa libre de riesgo anual aproximada del **0,56%**, coherente con el entorno de tipos reducidos que predominó durante buena parte del periodo analizado.

En términos de rentabilidad esperada anualizada, como ya hemos presentado anteriormente, el real estate cotizado presenta el mayor rendimiento estimado, con un 11,65%, seguido de la renta variable global (MSCI World) con un 10,55% y los bonos soberanos con un 3,39%. Las materias primas son el único activo con rentabilidad negativa, registrando un -2,33%. Sobre esta base, se calcula la cartera tangente, definida como aquella combinación de activos riesgosos que maximiza el ratio de Sharpe, es decir, el exceso de rentabilidad sobre el activo libre de riesgo por unidad de volatilidad.

**Figura 1. Frontera eficiente y Capital Market Line (CML)**



La estrella roja representa la cartera tangente Markowitz, que maximiza el ratio de Sharpe (1,01) combinando los cuatro activos disponibles. La línea discontinua roja es la Capital Market Line, que recoge todas las combinaciones posibles entre el activo libre de riesgo (punto negro) y la cartera tangente.  
 Fuente: elaboración propia a partir de datos de Yahoo Finance

**Tabla 3. Métricas de la cartera tangente Markowitz (periodo de entrenamiento 2010–2019)**

Métrica	Valor
Rentabilidad anual esperada	5,10%
Volatilidad anual	4,48%
Ratio de Sharpe	1,01

Fuente: elaboración propia a partir de datos de Yahoo Finance.

**Tabla 4. Composición y métricas de la cartera tangente Markowitz (periodo de entrenamiento 2010–2019)**

Activo	Peso en cartera	Sharpe individual
<b>Bonos soberanos (IEGA.L)</b>	76,62%	0,71
<b>Renta variable (IWDA.L)</b>	20,15%	0,70
<b>Real estate (IWDP.L)</b>	3,23%	0,38
<b>Materias primas (DBC)</b>	0,00%	-0,18

Fuente: elaboración propia a partir de datos de Yahoo Finance. El Sharpe individual se calcula como  $(\text{rentabilidad} - r_f) / \text{volatilidad}$ , con  $r_f = 0,56\%$ .

Los resultados muestran que la cartera tangente asigna un peso predominante a los bonos soberanos de la Eurozona, con un 76,6%, seguido de la renta variable global con un 20,1%, el real estate con un 3,2% y las materias primas con un peso nulo. Esta composición refleja el comportamiento del periodo de entrenamiento 2010–2019, caracterizado por una tendencia sostenida a la baja en los tipos de interés europeos, que elevó artificialmente el retorno de los bonos soberanos con una volatilidad reducida. En ese contexto, el optimizador identifica los bonos como el activo con mejor relación rentabilidad-riesgo en términos de exceso sobre la tasa libre de riesgo. La cartera tangente obtenida presenta una rentabilidad anual esperada del 5,1%, una volatilidad del 4,5% y un ratio de Sharpe de 1,01.

A partir de esta cartera se construye la Capital Market Line, que representa todas las combinaciones posibles entre el activo libre de riesgo y la cartera tangente. La CML permite interpretar el proceso de asignación de activos de manera intuitiva: un inversor más conservador puede situarse en un punto cercano al activo libre de riesgo (menor volatilidad), mientras que un inversor más agresivo puede aumentar exposición a la cartera tangente para buscar una mayor rentabilidad esperada asumiendo más riesgo. En paralelo, se obtiene la frontera eficiente de activos riesgosos, que recoge las carteras óptimas dentro del conjunto de activos disponibles, mostrando cómo la diversificación entre clases de activos define el conjunto de combinaciones eficientes antes de introducir el activo libre de riesgo.

En conjunto, este análisis proporciona una referencia cuantitativa sólida: por un lado, describe el comportamiento eficiente de las carteras en el espacio riesgo–retorno y, por

otro, permite identificar una estrategia óptima en términos de rentabilidad ajustada al riesgo (cartera tangente). Estos resultados sirven como punto de comparación para los enfoques posteriores basados en inteligencia artificial, evaluando si un modelo predictivo es capaz de mejorar la asignación de pesos o la eficiencia alcanzada por el enfoque tradicional.

### 4.3. Modelización mediante inteligencia artificial

Con el objetivo de evaluar si un enfoque predictivo puede mejorar la asignación de activos obtenida mediante el modelo media-varianza tradicional, se implementa un modelo de regresión lineal regularizada (Ridge). Este modelo pertenece al ámbito del aprendizaje supervisado y permite estimar rentabilidades esperadas a partir de información histórica reciente.

Para cada activo se construyen variables explicativas basadas en rendimientos pasados, medias móviles de corto plazo y volatilidad reciente. La muestra se divide en un periodo de entrenamiento (2010–2019) y un periodo de evaluación fuera de muestra (2020–2025), reduciendo así problemas de look-ahead bias.

A partir de las predicciones generadas en el periodo de test se obtiene un nuevo vector de rentabilidades esperadas, que sustituye a las medias históricas en el proceso de optimización. La matriz de covarianzas se mantiene estimada de forma histórica, de acuerdo con la práctica habitual en modelos de asignación estratégica.

**Tabla 5. R<sup>2</sup> de los modelos Ridge por activo (periodo de entrenamiento 2010–2019)**

Activo	R <sup>2</sup> entrenamiento
Bonos soberanos (IEGA.L)	0,78%
Renta variable (IWDA.L)	2,83%
Real estate (IWDP.L)	12,46%
Materias primas (DBC)	0,83%

*Fuente: elaboración propia a partir de datos de Yahoo Finance.*

Los modelos Ridge entrenados para cada activo presentan, como era de esperar, una capacidad predictiva modesta. Los R<sup>2</sup> obtenidos oscilan entre el 0,78% de los bonos y el 12,46% del real estate, siendo este último el único activo donde el modelo captura una fracción algo más significativa de la variabilidad. La renta variable global y las materias

primas se sitúan en valores intermedios, con un 2,83% y un 0,83% respectivamente. Estos resultados no son sorprendentes: la dificultad de predecir retornos financieros con variables técnicas simples es bien conocida en la literatura, y unos  $R^2$  bajos no invalidan el enfoque, sino que reflejan la naturaleza esencialmente aleatoria de los mercados.

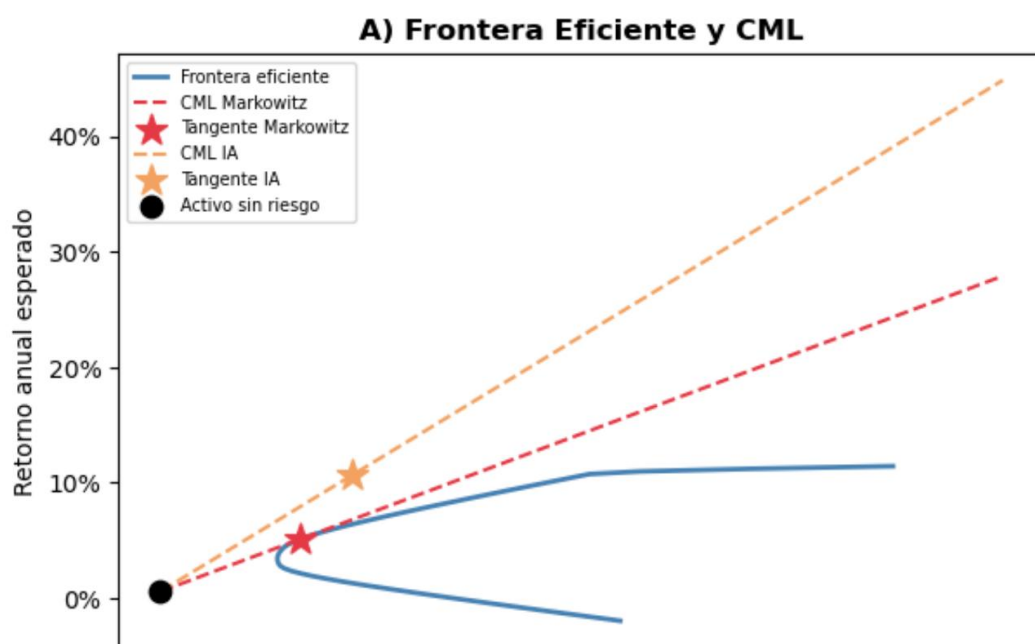
**Tabla 6. Rentabilidades predichas por el modelo Ridge, anualizadas (periodo de test 2020–2025)**

Activo	Rentabilidad predicha anual
Bonos soberanos (IEGA.L)	2,61%
Renta variable (IWDA.L)	13,37%
Real estate (IWDP.L)	16,85%
Materias primas (DBC)	23,09%

*Fuente: elaboración propia a partir de datos de Yahoo Finance.*

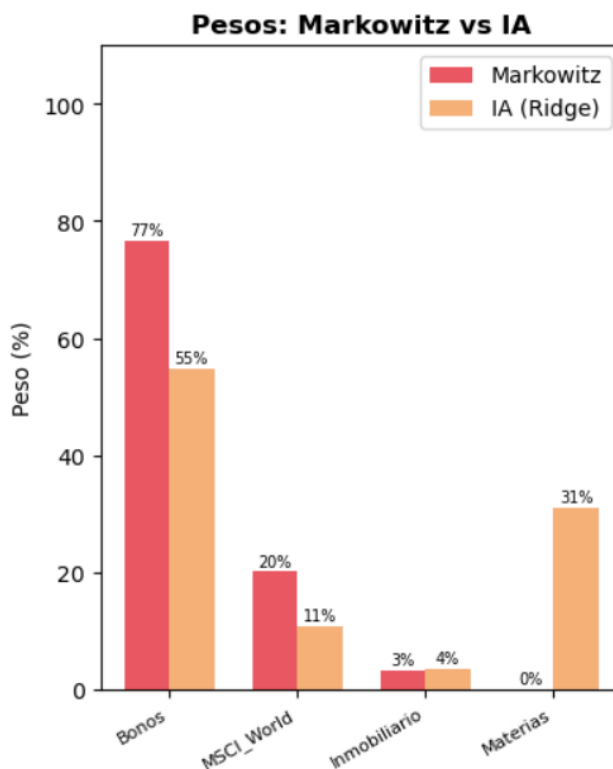
A partir de estos modelos se obtiene el vector de rentabilidades esperadas que sustituye a las medias históricas en la optimización. Las predicciones anualizadas sitúan a las materias primas como el activo con mayor rentabilidad esperada (23,09%), seguido del real estate (16,85%), la renta variable global (13,37%) y los bonos soberanos (2,61%). Este vector difiere notablemente del histórico, especialmente en el caso de las materias primas, cuya rentabilidad predicha contrasta con el -2,33% registrado durante el entrenamiento.

**Figura 2. Frontera eficiente y Capital Market Line (CML)**



La estrella roja representa la cartera tangente Markowitz (Sharpe 1,01) y la estrella naranja la cartera tangente IA Ridge (Sharpe 1,64 con  $\mu$  predicho), cuya construcción se detalla en el apartado 4.3. La tangente IA queda fuera de la frontera eficiente porque se optimiza con un vector de rentabilidades esperadas distinto al histórico.. Fuente: elaboración propia a partir de datos de Yahoo Finance.

**Figura 3. Comparativa de pesos: Markowitz vs IA (Ridge)**

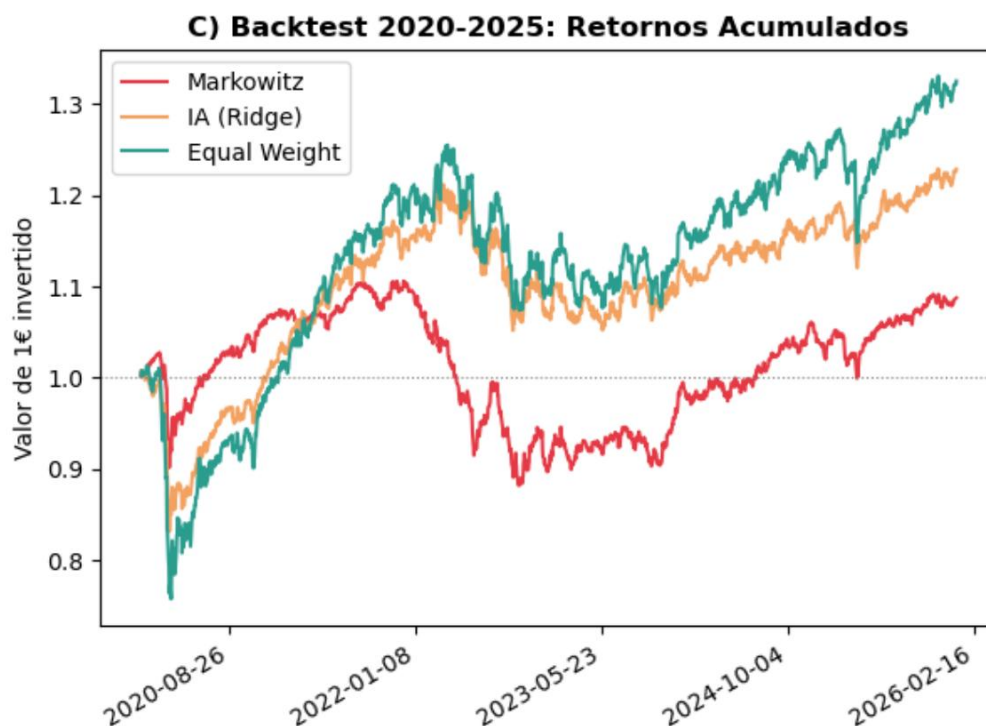


El gráfico muestra la distribución de pesos entre ambas carteras. La estrategia IA reduce significativamente el peso en bonos (del 77% al 55%) y en renta variable global (del 20% al 11%), destinando un 31% a materias primas, activo al que el modelo Ridge asigna una rentabilidad esperada

elevada. Markowitz asigna peso nulo a materias primas. Fuente: elaboración propia a partir de datos de Yahoo Finance.

Los resultados muestran que la cartera derivada del modelo predictivo presenta una composición diferente a la tradicional, con un peso dominante en bonos soberanos (54,7%), seguido de materias primas (31,0%), renta variable global (10,8%) y real estate (3,5%). La inclusión de un peso significativo en materias primas (activo al que el modelo Ridge asigna una rentabilidad esperada anualizada del 23%, frente al 2,3% histórico) constituye la diferencia más relevante respecto a la cartera tradicional y refleja una limitación del modelo: el Ridge, al generar predicciones sobre el periodo de test, recibe como inputs retornos recientes del propio periodo 2020–2025, captando el momentum excepcional de las materias primas en 2022 (impulsado por la inflación y el conflicto en Ucrania) y extrapolándolo como señal estructural cuando en realidad responde a un régimen excepcional.

**Figura 4. Backtest 2020-2025: Markowitz vs IA (Ridge)**



El gráfico muestra la evolución del valor de 1€ invertido en cada estrategia a lo largo del periodo fuera de muestra. Las tres carteras arrancan en enero de 2020 y reflejan de inmediato el impacto del COVID-19, con una caída pronunciada en los primeros meses. A partir de ahí, las trayectorias toman rumbos claramente distintos: la cartera equiponderada lidera el crecimiento y cierra 2025 en 1,33€, la cartera IA se queda en 1,23€, y Markowitz se queda más rezagada, en 1,09€. Fuente: elaboración propia a partir de datos de Yahoo Finance.

Como referencia adicional se incluye una cartera equiponderada (Equal Weight), que asigna un 25% a cada activo sin ningún tipo de optimización. Su inclusión permite evaluar si la sofisticación metodológica de los modelos anteriores aporta valor frente a una diversificación simple y neutral.

Lo que el gráfico deja ver con claridad es que el entorno de 2020–2025 fue especialmente duro para una cartera tan concentrada en bonos como la de Markowitz. Tras la recuperación del shock inicial del COVID, la llegada de la inflación y la posterior subida de tipos en 2022 golpearon con fuerza a la renta fija soberana, que había sido el gran protagonista del periodo de entrenamiento. La cartera IA, al incorporar materias primas, se benefició parcialmente de ese ciclo inflacionista, lo que explica su mejor comportamiento relativo. La equiponderada, pese a sufrir más en las caídas por su mayor exposición a activos de riesgo, demostró una capacidad de recuperación superior y mantuvo una tendencia más sólida a lo largo de todo el periodo.

**Tabla 7. Métricas de riesgo por estrategia (periodo de test 2020–2025)**

Estrategia	Ret. Anual (%)	Vol. Anual (%)	Sharpe	Max Drawdown (%)	VaR 95% (diario %)
Markowitz	1,67%	6,75%	0,163	-20,24%	-0,643%
IA (Ridge)	3,91%	7,94%	0,412	-17,52%	-0,749%
Equal Weight	5,54%	10,78%	0,448	-25,26%	-0,963%

Fuente: elaboración propia a partir de datos de Yahoo Finance.

Los números confirman lo que el gráfico ya anticipaba. La equiponderada gana en rentabilidad, pero lo hace asumiendo la mayor volatilidad y el mayor drawdown de las tres. La cartera IA encuentra un punto intermedio razonable: rentabilidad moderada, volatilidad controlada y, sobre todo, la menor caída máxima del conjunto, lo que sugiere

que su composición aguantó mejor los momentos de tensión del mercado. Markowitz, en cambio, paga cara su apuesta por los bonos: la estrategia más conservadora en papel acaba siendo la que peor rentabilidad genera en un periodo que no se pareció en nada al entorno tranquilo de tipos bajos para el que fue diseñada.

En definitiva, la comparación más relevante entre estrategias es la del backtest fuera de muestra, donde la cartera IA obtiene un Sharpe de 0,41 frente a 0,16 de Markowitz, invirtiéndose el resultado respecto al periodo de entrenamiento. Ambas quedan, no obstante, por debajo de la equiponderada (0,45), resultado que se analiza en detalle en el apartado de discusión.

#### 4.4. Discusión de resultados

El análisis realizado a lo largo de este trabajo permite extraer conclusiones relevantes sobre el comportamiento de tres estrategias de inversión bien diferenciadas: la optimización clásica de Markowitz, el enfoque predictivo basado en regresión Ridge y la cartera equiponderada como referencia neutral. Lejos de ofrecer una respuesta única, los resultados muestran que el desempeño de cada estrategia depende en gran medida del entorno macroeconómico en el que opera, lo que obliga a interpretar las métricas con cautela y en su contexto.

El punto de partida es el periodo de entrenamiento (2010–2019), donde la cartera de Markowitz obtiene un ratio de Sharpe de 1,01, concentrando el 76,6% del peso en bonos soberanos. Este resultado no es casual: durante esa década, la renta fija europea vivió un entorno excepcionalmente favorable, con tipos de interés en caída sostenida que impulsaron su rentabilidad manteniendo una volatilidad muy reducida. En ese contexto, el optimizador hace exactamente lo que se le pide: identificar la mejor relación rentabilidad-riesgo disponible, y los bonos la ofrecían con claridad. El problema, como se verá, es que ese entorno no duró.

La cartera IA, construida con el vector de rentabilidades predichas por el modelo Ridge, llega a una composición distinta. Al captar el momentum de las materias primas durante el periodo de test (especialmente su fuerte subida en 2022 impulsada por la inflación y el conflicto en Ucrania) el modelo les asigna una rentabilidad esperada del 23%, lo que eleva su peso hasta el 31% en la cartera. Comparada con Markowitz usando el mismo referente histórico del train, la cartera IA obtiene un Sharpe de 0,35, por debajo del 1,01 de la

estrategia clásica. Sin embargo, esta comparación en muestra no es la más relevante ni la más justa, ya que ambas estrategias se construyeron para operar fuera de ella.

Donde realmente se pone a prueba cada estrategia es en el backtest fuera de muestra (2020–2025), y aquí los resultados se invierten de forma significativa. El periodo analizado no pudo ser más convulso: una pandemia global en 2020, una recuperación económica acelerada, el mayor repunte inflacionista en décadas y una subida de tipos de interés sin precedentes en Europa. Este cambio de régimen afectó de forma radicalmente distinta a cada estrategia.

Markowitz, tan dependiente de los bonos, sufre con dureza el giro del entorno macroeconómico. La renta fija soberana, que había sido el motor de la cartera durante el entrenamiento, se convierte en su principal lastre cuando los tipos suben y los precios de los bonos caen. Con una rentabilidad anual del 1,67%, una volatilidad del 6,75% y un Sharpe de apenas 0,16, la estrategia clásica es la que peor se comporta de las tres. Su máximo drawdown del -20,24% y un VaR diario del -0,64% reflejan que, pese a ser la cartera más conservadora sobre el papel, el cambio de régimen la expuso a pérdidas relevantes que no estaban anticipadas en su diseño.

La cartera IA, en cambio, se beneficia parcialmente del ciclo inflacionista gracias a su exposición a materias primas, alcanzando una rentabilidad anual del 3,91% y un Sharpe de 0,41. Además, presenta el menor drawdown de las tres estrategias (-17,52%), lo que sugiere que su composición aguantó mejor los momentos de mayor tensión del mercado. Su VaR diario del -0,75% es ligeramente superior al de Markowitz, pero queda compensado por una rentabilidad bastante más alta. En términos de eficiencia riesgo-retorno, la cartera IA supera claramente a la clásica en el periodo fuera de muestra, aunque esta mejora no fue producto de una predicción estructural acertada, sino más bien de haber capturado por inercia un ciclo excepcional de materias primas que el modelo interpretó como una tendencia sostenible.

El resultado más llamativo, sin embargo, es el de la cartera equiponderada. Sin ningún tipo de optimización, asignando simplemente un 25% a cada activo, obtiene la mayor rentabilidad anual (5,54%), el mejor Sharpe (0,45) y el valor final más alto al cierre de 2025 (1,33€ por cada euro invertido). Lo hace asumiendo también la mayor volatilidad (10,78%) y el mayor drawdown (-25,26%), así como el VaR diario más elevado (-0,96%), lo que confirma que su mayor rentabilidad tiene como contrapartida un perfil de riesgo

más exigente. Este resultado no es una anomalía puntual: la literatura financiera ha documentado en numerosas ocasiones que, en presencia de incertidumbre sobre los parámetros, una diversificación simple y robusta puede superar a estrategias sofisticadas que dependen de estimaciones sensibles al periodo de entrenamiento. DeMiguel, Garlappi y Uppal (2009) demostraron en un estudio de referencia que la cartera equiponderada supera sistemáticamente a las carteras optimizadas en términos de Sharpe fuera de muestra, precisamente porque evita el error de estimación que introduce la optimización.

Este fenómeno conecta directamente con uno de los debates más arraigados en la gestión de carteras: la hipótesis de eficiencia de mercado. Si ni una estrategia optimizada con datos históricos ni un modelo de inteligencia artificial son capaces de superar de forma consistente a una simple asignación equitativa, ello sugiere que la información contenida en los precios pasados está ya incorporada en los mercados y que obtener ventajas sistemáticas a partir de ella es extremadamente difícil. Los bajos  $R^2$  obtenidos por el modelo Ridge —entre el 0,78% de los bonos y el 12,46% del real estate— son consistentes con esta interpretación: los retornos financieros tienen una componente aleatoria dominante que los modelos lineales simples apenas logran capturar.

Desde una perspectiva práctica, los resultados ofrecen reflexiones útiles para cualquier inversor. En primer lugar, la concentración excesiva en un único tipo de activo, aunque óptima bajo ciertas condiciones de mercado, puede convertirse en una fuente de riesgo relevante cuando el entorno cambia. La cartera de Markowitz es el ejemplo más claro: diseñada para un mundo de tipos bajos, quedó expuesta cuando ese mundo desapareció. En segundo lugar, la incorporación de modelos predictivos puede aportar valor en determinados contextos, pero no como sustituto del criterio inversor, sino como herramienta complementaria que enriquece el proceso de toma de decisiones. Y en tercer lugar, la diversificación simple sigue siendo una estrategia difícil de batir cuando el horizonte temporal es suficientemente largo y el entorno suficientemente incierto.

En conjunto, los resultados ponen de manifiesto que la sofisticación metodológica no garantiza per se mejores resultados. Lo que sí queda claro es que la elección del periodo de entrenamiento, el entorno macroeconómico posterior y la robustez del modelo ante cambios de régimen condicionan enormemente el desempeño de cualquier estrategia. Markowitz funcionó bien en el entorno para el que fue calibrado y falló cuando ese entorno cambió radicalmente. La IA mejoró relativamente, pero tampoco fue capaz de anticipar la magnitud del cambio de régimen. Y la equiponderada, precisamente por no

depender de ninguna estimación, resultó ser la más robusta ante la incertidumbre. Una conclusión que, paradójicamente, invita a reflexionar sobre los límites de la complejidad en finanzas.

## 5. CONCLUSIONES Y RECOMENDACIONES

Este trabajo partía de una doble pregunta: ¿qué impacto tiene incorporar activos alternativos a una cartera convencional? ¿Y puede la inteligencia artificial mejorar esa diversificación y la gestión del riesgo? Los resultados obtenidos permiten responder a ambas cuestiones con evidencia empírica, aunque las conclusiones que se derivan son más complejas de lo que cabría esperar en un primer momento.

En lo que respecta al primer eje del análisis, la incorporación de activos alternativos a una cartera convencional demuestra tener un impacto positivo y consistente sobre el perfil riesgo-retorno. La matriz de correlaciones del periodo de entrenamiento revela que los bonos soberanos operan de forma prácticamente independiente al resto de clases de activos, con correlaciones cercanas a cero frente a la renta variable y ligeramente negativas frente a las materias primas. El real estate, pese a compartir parte del ciclo financiero con la renta variable, mantiene dinámicas propias que lo diferencian en determinados entornos. Las materias primas, por su parte, ofrecen una fuente de rentabilidad especialmente relevante en contextos inflacionistas, como quedó de manifiesto durante 2022. Esta combinación de activos con perfiles claramente diferenciados permite reducir la correlación global de la cartera y acceder a combinaciones riesgo-retorno que una cartera convencional de renta variable y renta fija difícilmente podría alcanzar. El backtest lo corrobora: incluso la estrategia más sencilla, la equiponderada, logra un Sharpe de 0,45 aprovechando esa diversificación entre clases de activos heterogéneas.

En cuanto al segundo punto, el uso de la inteligencia artificial para optimizar la diversificación y la gestión del riesgo arroja resultados que invitan a la reflexión. El modelo Ridge generó una asignación más diversificada que la de Markowitz, con un peso relevante en materias primas que resultó beneficioso durante el ciclo inflacionista del periodo de test. En términos de backtest, la cartera IA obtuvo una rentabilidad anual del 3,91% frente al 1,67% de Markowitz, con un Sharpe de 0,41 frente a 0,16, y presentó

además el menor drawdown de las tres estrategias (-17,52%), lo que apunta a una mejor contención del riesgo a la baja en momentos de tensión. Sin embargo, los bajos  $R^2$  del modelo, que oscilan entre el 0,78% y el 12,46%, revelan que su capacidad predictiva es modesta, y que parte de la mejora obtenida se explica por haber capturado un régimen excepcional de mercado más que por una estimación estructuralmente sólida.

El resultado que más merece atención crítica es el de la cartera equiponderada. Sin optimización, sin modelo predictivo y sin ninguna estimación de parámetros, esta estrategia obtuvo la mayor rentabilidad del periodo (5,54% anual), el mejor Sharpe (0,45) y el valor acumulado más alto al cierre de 2025. Este hallazgo no es una anomalía puntual, sino un resultado coherente con lo que la literatura financiera ha documentado en repetidas ocasiones: en presencia de incertidumbre sobre los parámetros, una diversificación robusta y no dependiente de estimaciones tiende a superar a estrategias de mayor sofisticación metodológica. La penalización que introduce el error de estimación puede ser más costosa que el beneficio teórico de la optimización.

De todo ello se derivan tres conclusiones de fondo. La primera es que la diversificación entre clases de activos heterogéneas, incluyendo activos alternativos, mejora de forma robusta el perfil de las carteras convencionales, siendo este el resultado más sólido y generalizable del análisis. La segunda es que la inteligencia artificial puede enriquecer el proceso de construcción de carteras y aportar valor en la gestión del riesgo, pero su utilidad depende críticamente de la calidad del modelo, las variables empleadas y el contexto de mercado, sin que quepa asumir mejoras automáticas por el mero hecho de incorporar técnicas más avanzadas. La tercera es que ninguna estrategia está blindada frente a cambios de régimen macroeconómico, y que la robustez ante escenarios no anticipados es una dimensión tan relevante como la eficiencia en muestra.

Como líneas futuras de investigación, sería pertinente explorar modelos no lineales con mayor capacidad de adaptación, incorporar variables macroeconómicas como señales adelantadas o implementar técnicas de rebalanceo dinámico que permitan ajustar la cartera conforme evoluciona el entorno. Los resultados de este trabajo no cierran el debate, sino que ponen de relieve hasta qué punto la intersección entre teoría clásica de carteras e inteligencia artificial es un campo abierto con mucho recorrido por delante.

## 6. LIMITACIONES DEL ESTUDIO

### **Disponibilidad y calidad de los datos**

La precisión del análisis depende de la calidad y consistencia de los datos financieros utilizados. Aunque se han empleado fuentes ampliamente reconocidas, la necesidad de armonizar calendarios de negociación entre mercados europeos y estadounidenses, así como el recurso a proxies —como el tipo de las letras del Tesoro estadounidense para aproximar el activo libre de riesgo— introduce posibles distorsiones en los resultados. Asimismo, la representación de clases de activos mediante ETFs implica asumir que dichos instrumentos reflejan adecuadamente el comportamiento de los mercados subyacentes, supuesto que en la práctica puede no cumplirse de forma estricta.

### **Limitaciones metodológicas del modelo media-varianza**

El enfoque de Markowitz se basa en la estimación de medias y covarianzas históricas, asumiendo estabilidad en los parámetros y una distribución aproximadamente normal de los rendimientos. En la práctica, los mercados financieros presentan cambios estructurales, distribuciones con colas gruesas y episodios de volatilidad extrema que este marco teórico no está plenamente equipado para capturar. La elevada concentración en bonos soberanos derivada del proceso de optimización ilustra, además, la conocida sensibilidad del modelo de Markowitz a pequeñas variaciones en los inputs, lo que puede traducirse en carteras poco robustas ante cambios en el entorno.

### **Limitaciones del modelo de inteligencia artificial**

El modelo Ridge implementado es un modelo lineal regularizado que utiliza variables técnicas simples basadas en retornos pasados, medias móviles de corto plazo y volatilidad reciente. Su capacidad predictiva en mercados financieros caracterizados por elevada eficiencia informativa es, por construcción, limitada, como ponen de manifiesto los bajos  $R^2$  obtenidos, comprendidos entre el 0,78% de los bonos y el 12,46% del real estate. Si bien la cartera IA supera a Markowitz en el backtest en términos de Sharpe (0,41 frente a 0,16), esta mejora no debe interpretarse como evidencia de una capacidad predictiva estructuralmente sólida, sino como el resultado, en parte, de haber capturado un régimen excepcional de mercado durante el periodo de test.

El caso más representativo de esta limitación es la sobreestimación de la rentabilidad esperada de las materias primas, a las que el modelo asigna un retorno anualizado del 23%, frente al -2,33% histórico registrado durante el periodo de entrenamiento. Al tratarse de un modelo estático, sin capacidad de actualizar sus parámetros conforme evolucionan las condiciones de mercado, el Ridge no distingue entre una tendencia estructural sostenible y un régimen extraordinario como el registrado en 2022. Esta limitación se traduce en una posición del 31% en materias primas que, aunque resultó beneficiosa en ese contexto concreto, difícilmente se sostendría desde un análisis fundamental riguroso.

### **Riesgo de sobreajuste y estabilidad temporal**

Aunque la división entre muestra de entrenamiento y periodo de evaluación fuera de muestra permite evitar el look-ahead bias, la estabilidad de los coeficientes estimados no está garantizada ante cambios en el entorno macroeconómico. Variaciones en los regímenes de tipos de interés, en la dinámica de inflación o en la correlación entre activos pueden reducir de forma significativa la capacidad predictiva del modelo, como ha quedado de manifiesto en el periodo analizado.

### **Alcance temporal y generalización**

El periodo analizado (2010–2025) abarca fases muy diferenciadas del ciclo económico, desde el entorno de política monetaria expansiva posterior a la crisis financiera global hasta el endurecimiento monetario más reciente. Esta heterogeneidad enriquece el análisis, pero limita la extrapolabilidad de los resultados a otros horizontes temporales, mercados o universos de inversión distintos al considerado en este trabajo.

### **Look-ahead bias estructural en la estimación de $\mu$**

Una limitación relevante del modelo IA reside en que los pesos de la cartera se obtienen optimizando sobre la media de todas las predicciones del periodo de test completo (2020–2025). Esto implica que, en la práctica, se está utilizando información agregada de un periodo que aún no ha transcurrido en su totalidad en el momento de tomar la decisión de inversión. Un inversor real en enero de 2020 no dispondría de las predicciones correspondientes a años posteriores, ya que estas requieren como input retornos aún no observados.

Cabe matizar que este sesgo difiere del look-ahead bias clásico: no se emplean retornos reales futuros, sino predicciones de un modelo ya entrenado. Sin embargo, los pesos

resultantes no son estrictamente replicables en tiempo real. Una extensión más rigurosa consistiría en adoptar un esquema de rebalanceo dinámico con ventana móvil, recalculando los pesos periódicamente con la información disponible hasta cada fecha. Dado el alcance comparativo de este trabajo, se ha optado por un enfoque estático que permite aislar el efecto de la estimación alternativa de  $\mu$ , dejando la implementación de esquemas rolling estrictamente fuera de muestra como línea futura de investigación.

## 7. BIBLIOGRAFÍA

Andonov, A. (2022). Delegated Investment Management in Alternative Assets. *The Review of Corporate Finance Studies*, 13(1), 264-301.

<https://doi.org/10.1093/rcfs/cfac027>

DeMiguel, V., Garlappi, L., & Uppal, R. (2009). Optimal versus naive diversification: How inefficient is the 1/N portfolio strategy? *The Review of Financial Studies*, 22(5), 1915–1953.

<https://doi.org/10.1093/rfs/hhm075>

ECB. (2022). Cross-asset correlations in a more inflationary environment and challenges for diversification strategies. *Financial Stability Review*, noviembre 2022.

<https://www.ecb.europa.eu/pub/pdf/fsr/ecb.fsr202211~6383d08c21.en.pdf>

Gorton, G., & Rouwenhorst, K. G. (2006). Facts and fantasies about commodity futures. *Financial Analysts Journal*, 62(2), 47–68.

[https://www.nber.org/system/files/working\\_papers/w10595/w10595.pdf](https://www.nber.org/system/files/working_papers/w10595/w10595.pdf)

Heaton, J., Polson, N. G., & Witte, J. H. (2017). Deep learning for finance: deep portfolios. *Applied Stochastic Models in Business and Industry*, 33(1), 3–12.

<https://arxiv.org/pdf/1602.06561>

James, N., Menzies, M., & Gottwald, G. A. (2022). On financial market correlation structures and diversification benefits across and within equity sectors. *Physica A: Statistical Mechanics and its Applications*, 604, 127682. <https://arxiv.org/pdf/2202.10623>

Jayeola, D., Ismail, Z., & Sufahani, S. F. (2019). Effects of diversification of assets in optimizing risk of portfolio. *Malaysian Journal of Fundamental and Applied Sciences*, 15(2), 286–290. <https://mjfas.utm.my/index.php/mjfas/article/view/567/pdf>

Jordà, Ò., Knoll, K., Kuvshinov, D., Schularick, M., & Taylor, A. M. (2017). *The rate of return on everything, 1870–2015* (Working Paper 2017-25). Federal Reserve Bank of San Francisco. [https://www.nber.org/system/files/working\\_papers/w24112/w24112.pdf](https://www.nber.org/system/files/working_papers/w24112/w24112.pdf)

Jorion, P. (2007). *Value at risk: The new benchmark for managing financial risk* (3rd ed.). McGraw-Hill. [Philippe Jorion Value at Risk The New Be.pdf](#)

Lee, Y., Kim, J. H., Kim, W. C., & Fabozzi, F. J. (2024). An overview of machine learning for portfolio optimization. *The Journal of Portfolio Management*, 50(4), 35–55. <https://www.pm-research.com/content/ijpormgmt/51/2/131>

Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77–91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>

Rama Syahputra. (2023). Diversifying portfolios: Exploring investment strategies and alternative assets in modern markets. *Advances in Economics & Financial Studies*, 1(1). <https://advancesinresearch.id/index.php/AEFS/article/view/217/254>

Sharpe, W. F. (1966). Mutual fund performance. *The Journal of Business*, 39(1), 119–138. <https://doi.org/10.1086/294846>

## 8. ANEXOS

### **Anexo 1: Declaración uso IA**

**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, Manuel Rodríguez Toribio, estudiante de E4 de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado “Análisis del impacto de diversificación sectorial y activos alternativos en carteras convencionales,

complementado con el estudio del uso de inteligencia artificial para optimizar esa diversificación y la gestión del riesgo.", 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. **Referencias:** Usado conjuntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.

Prompts utilizadas:

**Prompt 1:**

*Estoy realizando un TFG sobre diversificación sectorial, activos alternativos (real estate y materias primas) y optimización de carteras con inteligencia artificial. ¿Qué artículos académicos recientes (últimos 10 años) me recomiendas para fundamentar el uso de machine learning en gestión de carteras?*

**Prompt 2:**

*Necesito referencias académicas sólidas sobre el papel de las materias primas como elemento diversificador en carteras tradicionales. Si es posible, que sean artículos publicados en revistas financieras reconocidas.*

**Prompt 3:**

*¿Qué autores han trabajado la comparación entre optimización clásica de Markowitz y modelos basados en machine learning? Dame referencias preliminares para que pueda revisarlas.*

2. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.

Prompts utilizadas:

**Prompt 4:**

*Te paso este párrafo de mi TFG. ¿Puedes mejorar la redacción manteniendo el tono académico y sin cambiar el contenido?*

**Prompt 5:**

*Revisa este apartado metodológico y hazlo más claro y fluido, pero sin simplificar en exceso el contenido técnico.*

**Prompt 6:**

*¿Puedes ajustar este texto para que tenga un tono más natural y menos repetitivo, manteniendo coherencia con un trabajo universitario?*

3. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.

Prompts utilizadas:

**Prompt 7:**

*Explícame de forma clara el modelo media-varianza de Markowitz para poder explicarlo bien antes de redactarlo en mi TFG.*

**Prompt 8:**

*Estoy leyendo un artículo sobre deep learning aplicado a optimización de carteras y me resulta complejo. ¿Puedes explicarme los conceptos clave de forma más sencilla pero rigurosa?*

4. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.

Prompts utilizadas:

**Prompt 9:**

*Lee este apartado de metodología y dime de forma objetiva si tiene suficiente profundidad para un TFG en finanzas. Indícame posibles mejoras.*

**Prompt 10:**

*Actúa como un profesor exigente y dime qué debilidades ves en este capítulo y cómo podría reforzarlo.*

**Prompt 11:**

*¿Crees que la comparación entre el modelo clásico y el modelo con IA está metodológicamente bien planteada? Señala posibles fallos o riesgos de crítica.*

5. **Traductor:** Para traducir textos de un lenguaje a otro.

Prompt utilizada:

**Prompt 12:**

Necesito traducir esta cita/artículo académica respetando el sentido original y manteniendo formalidad.

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

Fecha: 23/10/2025

Firma:



## **Anexo 2: Activos, instrumentos y fuentes de datos**

La siguiente tabla recoge los instrumentos financieros utilizados en el análisis, con sus respectivos tickers, fuentes de descarga y periodos de datos empleados.

**Tabla. Activos e instrumentos utilizados en el análisis**

Clase de activo	Instrumento	Ticker	Fuente	Periodo
Bonos soberanos Eurozona	iShares Core Euro Govt Bond UCITS ETF	IEGA.L	Yahoo Finance	2010–2025
Renta variable global	iShares Core MSCI World UCITS ETF	IWDA.L	Yahoo Finance	2010–2025
Real estate cotizado	iShares Developed Markets Property Yield UCITS ETF	IWDP.L	Yahoo Finance	2010–2025
Materias primas	Invesco DB Commodity Index Tracking Fund	DBC	Yahoo Finance	2010–2025
Tasa libre de riesgo	T-Bill 13 semanas (proxy activo sin riesgo)	^IRX	Yahoo Finance	2010–2025

Fuente: elaboración propia a partir de datos de Yahoo Finance.

### Anexo 3: Tracking Error anualizado de los ETFs respecto a sus benchmarks (2010–2025)

Tabla. Tracking Error anualizado de los ETFs respecto a sus benchmarks (2010–2025)

ETF	Ticker	Benchmark de referencia	Tracking Error (%)
Bonos soberanos	IEGA.L	XGLE.L – Xtrackers Eurozone Govt Bond	1,99%
Renta variable global	IWDA.L	XDWD.L – Xtrackers MSCI World UCITS ETF	2,43%
Real estate cotizado	IWDP.L	H4ZL.DE – HSBC FTSE EPRA/NAREIT Developed	5,77%
Materias primas	DBC	PDBC – Invesco Optimum Yield Div. Commodity	5,40%

Fuente: elaboración propia a partir de datos de Yahoo Finance.

### Anexo 4: Código Python — Implementación del modelo de optimización y regresión Ridge



CODIGO\_TFG\_PYTHON (1).py

En el caso de que no se cargue el link al código:

```
# TFG - Análisis del impacto de diversificación sectorial y activos
alternativos en carteras convencionales, complementado con el estudio
del uso de inteligencia artificial para optimizar esa diversificación
y la gestión del riesgo.

# Alumno: Manuel Rodríguez Toribio

# Importo las librerías necesarias
import warnings

warnings.filterwarnings("ignore")

import numpy as np
import pandas as pd
```

```

import matplotlib.pyplot as plt
import matplotlib.gridspec as gridspec

from scipy.optimize import minimize
from sklearn.linear_model import Ridge
from sklearn.preprocessing import StandardScaler
from tabulate import tabulate
import yfinance as yf

np.random.seed(42)

# Fechas y activos

fecha_inicio = "2010-01-01"
fecha_fin     = "2025-12-31"

# Divido los datos en entrenamiento y test
fin_train     = "2019-12-31"
inicio_test   = "2020-01-01"

rf_ticker = "^IRX" # letras del tesoro americano como proxy de rf
n_puntos  = 60     # puntos de la frontera eficiente

# ETFs que analizo en el TFG
etfs = {
    "Bonos":          "IEGA.L", # bonos soberanos eurozona
    "MSCI_World":    "IWDA.L", # renta variable global
    "Inmobiliario":  "IWDP.L", # real estate cotizado
    "Materias":      "DBC",    # materias primas
}
activos = list(etfs.keys())

# Función auxiliar para imprimir tablas con estilo consistente en
consola

```

```

def imprimir_tabla(df, titulo=""):
    if titulo:
        print(f"\n{' '*60}")
        print(f" {titulo}")
        print(f"{' '*60}")
    print(tabulate(
        df,
        headers="keys",
        tablefmt="rounded_outline",
        floatfmt=".4f",
        showindex=False
    ))

# FUNCIÓN 1: Descargar datos

def descargar_datos(etfs, rf_ticker, fecha_inicio, fecha_fin):
    # Descargo precios ajustados de los ETFs desde Yahoo Finance
    precios = yf.download(
        list(etfs.values()),
        start=fecha_inicio, end=fecha_fin,
        auto_adjust=True, progress=False
    )["Close"]
    precios = precios.rename(columns={v: k for k, v in etfs.items()})
    precios = precios.dropna() # elimino días donde falta algún
    precio

    # Descargo la tasa libre de riesgo
    rf_raw = yf.download(rf_ticker, start=fecha_inicio,
end=fecha_fin,
                        auto_adjust=True, progress=False)
    rf_yield = rf_raw["Close"].squeeze()
    rf_diario = (rf_yield / 100.0) / 252.0 # convierto yield anual a
    retorno diario

```

```

# Calculo retornos diarios de los ETFs
retornos = precios.pct_change().dropna()

# Uno retornos de ETFs con la tasa libre de riesgo por fecha
datos = retornos.join(rf_diario.rename("rf_diario"), how="inner")

print(f" Observaciones totales: {len(datos):,}")

return datos

# FUNCIÓN 2: Calcular rentabilidad media y riesgo

def calcular_parametros(datos, activos):
    # Anualizo multiplicando por 252 días hábiles
    mu = datos[activos].mean() * 252 # rentabilidad media
    anualizada

    sigma = datos[activos].cov() * 252 # matriz de covarianzas
    anualizada

    rf = float(datos["rf_diario"].mean() * 252) # tasa libre de
    riesgo anual

    return mu, sigma, rf

# FUNCIÓN 3: Cartera con mayor Sharpe (cartera tangente)

def cartera_max_sharpe(mu, sigma, rf):
    # Busco los pesos que dan la mejor relación rentabilidad-riesgo
    # No permito pesos negativos (sin ventas en corto)
    n = len(mu)

    exceso = (mu - rf).values # rentabilidad por encima del activo
    sin riesgo

    S = sigma.values

    limites = [(0, 1)] * n

    rest = ({"type": "eq", "fun": lambda w: w.sum() - 1},)

    def neg_sharpe(w):

```

```

    ret = w @ exceso
    vol = np.sqrt(w @ S @ w)
    return -(ret / vol) if vol > 1e-9 else 0.0

# Empiezo con pesos iguales y optimizo
res = minimize(neg_sharpe, np.ones(n) / n,
               method="SLSQP", bounds=limites, constraints=rest)
w = res.x

ret_c    = float(w @ mu.values)
vol_c    = float(np.sqrt(w @ S @ w))
sharpe_c = float((ret_c - rf) / vol_c)

return w, ret_c, vol_c, sharpe_c

# FUNCIÓN 4: Frontera eficiente

def frontera_eficiente(mu, sigma, n_puntos=60):
    # Para cada rentabilidad objetivo calculo la cartera menos
    arriesgada
    n        = len(mu)
    S        = sigma.values
    limites  = [(0, 1)] * n
    rest_suma = {"type": "eq", "fun": lambda w: w.sum() - 1}

    ret_min  = float(mu.min()) * 0.85
    ret_max  = float(mu.max()) * 0.98
    objetivos = np.linspace(ret_min, ret_max, n_puntos)

    puntos = []
    for obj in objetivos:
        rest = (
            rest_suma,

```

```

        {"type": "eq", "fun": lambda w, r=obj: float(w @
mu.values) - r},
    )
    res = minimize(lambda w: w @ S @ w, np.ones(n) / n,
                  method="SLSQP", bounds=limites,
constraints=rest)
    if res.success:
        w = res.x
        puntos.append([np.sqrt(w @ S @ w), float(w @ mu.values)])

    return np.array(puntos)

```

*# FUNCIÓN 5: Crear variables para el modelo Ridge*

```

def crear_variables(datos, activos):
    # Creo variables con información histórica de cada activo para
predecir retornos

    # retorno de ayer
    # media de los últimos 5 días
    # volatilidad de los últimos 20 días
    df = datos.copy()
    for a in activos:
        df[f"{a}_ayer"] = df[a].shift(1)
        df[f"{a}_media5"] = df[a].rolling(5).mean().shift(1)
        df[f"{a}_vol20"] = df[a].rolling(20).std().shift(1)
    df["rf_ayer"] = df["rf_diario"].shift(1)

    return df.dropna()

```

*# FUNCIÓN 6: Entrenar modelo Ridge*

```

def entrenar_ridge(train, activos):
    # Entreno un modelo por cada activo para predecir su retorno del
día siguiente

```

```

modelos = {}
scalers = {}

columnas = (
    [f"{a}_ayer" for a in activos] +
    [f"{a}_media5" for a in activos] +
    [f"{a}_vol20" for a in activos] +
    ["rf_ayer"]
)

for a in activos:
    X = train[columnas].values
    y = train[a].values

    # Normalizo los datos antes de entrenar
    scaler = StandardScaler()
    X_norm = scaler.fit_transform(X)

    # Alpha alto para evitar sobreajuste en datos financieros
    ruidosos
    modelo = Ridge(alpha=10.0)
    modelo.fit(X_norm, y)

    modelos[a] = modelo
    scalers[a] = scaler

# Muestro los R2 de todos los modelos en una tabla
tabla_r2 = pd.DataFrame({
    "Activo": activos,
    "R2 entrenamiento": [modelos[a].score(
        scalers[a].transform(train[columnas].values),
        train[a].values
    ) for a in activos]
})

imprimir_tabla(tabla_r2, "R2 de los modelos Ridge:")

```

```

    return modelos, scalers, columnas

# FUNCIÓN 7: Predicciones

def predecir(test, modelos, scalers, columnas, activos):
    # Uso los modelos para predecir retornos en el período de test
    pred = pd.DataFrame(index=test.index)
    for a in activos:
        X = test[columnas].values
        X_norm = scalers[a].transform(X)
        pred[a] = modelos[a].predict(X_norm)
    return pred

# FUNCIÓN 8: Backtest

def backtest(retornos_test, pesos, activos):
    # Simulo cómo evoluciona 1 euro invertido en cada estrategia
    resultados = pd.DataFrame(index=retornos_test.index)
    for nombre, w in pesos.items():
        ret_diario = retornos_test[activos] @ w
        resultados[nombre] = (1 + ret_diario).cumprod()
    return resultados

# FUNCIÓN 9: Métricas de riesgo

def calcular_metricas(retornos_test, pesos, activos, rf_anual):
    rf_diario = rf_anual / 252
    filas = []

    for nombre, w in pesos.items():
        r = retornos_test[activos] @ w

```

```

# Sharpe anualizado
sharpe = float((r.mean() - rf_diario) / r.std() *
np.sqrt(252))

# Máximo Drawdown
acumulado = (1 + r).cumprod()
maximo     = acumulado.cummax()
caida      = (acumulado - maximo) / maximo
max_dd     = float(caida.min())

# VaR al 95%
var95 = float(np.percentile(r, 5))

ret_anual = float((1 + r.mean()) ** 252 - 1)
vol_anual = float(r.std() * np.sqrt(252))

filas.append({
    "Estrategia":      nombre,
    "Ret. Anual (%)":  round(ret_anual * 100, 2),
    "Vol. Anual (%)":  round(vol_anual * 100, 2),
    "Sharpe":          round(sharpe, 3),
    "Max Drawdown (%)": round(max_dd * 100, 2),
    "VaR 95% (diario %)": round(var95 * 100, 3),
})

return pd.DataFrame(filas).set_index("Estrategia")

# FUNCIÓN 10a: Gráfico Frontera Eficiente solo Markowitz (para sección
4.2)

def grafico_frontera_markowitz(puntos_frontera, vol_mkt, ret_mkt,
sharpe_mkt, rf):
    fig, ax = plt.subplots(figsize=(8, 6))

```

```

color_mkt = "#e63946"
vol_max   = max(puntos_frontera[:, 0]) * 1.15
vols      = np.linspace(0, vol_max, 200)

ax.plot(puntos_frontera[:, 0], puntos_frontera[:, 1],
        color="steelblue", linewidth=2, label="Frontera
eficiente")
ax.plot(vols, rf + sharpe_mkt * vols,
        linestyle="--", color=color_mkt, label="CML Markowitz")
ax.scatter([vol_mkt], [ret_mkt], marker="*", s=220,
          color=color_mkt, zorder=5, label=f"Tangente Markowitz
(Sharpe {sharpe_mkt:.2f})")
ax.scatter([0], [rf], marker="o", s=80, color="black", zorder=5,
label="Activo sin riesgo")

ax.set_xlabel("Volatilidad anual")
ax.set_ylabel("Retorno anual esperado")
ax.set_title("Frontera Eficiente y Capital Market Line -
Markowitz", fontweight="bold")
ax.legend(fontsize=9)
ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda x, _:
f"{x:.0%}"))
ax.xaxis.set_major_formatter(plt.FuncFormatter(lambda x, _:
f"{x:.0%}"))

plt.tight_layout()
plt.savefig("grafico_4_2_frontera_markowitz.png", dpi=150,
bbox_inches="tight")
plt.show()

# FUNCIÓN 10b: Gráfico Frontera Eficiente Markowitz + IA (para sección
4.3)

def grafico_frontera_comparativa(puntos_frontera, vol_mkt, ret_mkt,
sharpe_mkt,
                                vol_ia, ret_ia, sharpe_ia, rf):
    fig, ax = plt.subplots(figsize=(8, 6))

```

```

color_mkt = "#e63946"
color_ia = "#f4a261"
vol_max = max(puntos_frontera[:, 0]) * 1.15
vols = np.linspace(0, vol_max, 200)

ax.plot(puntos_frontera[:, 0], puntos_frontera[:, 1],
        color="steelblue", linewidth=2, label="Frontera
eficiente")
ax.plot(vols, rf + sharpe_mkt * vols,
        linestyle="--", color=color_mkt, label="CML Markowitz")
ax.scatter([vol_mkt], [ret_mkt], marker="*", s=220,
          color=color_mkt, zorder=5, label=f"Tangente Markowitz
(Sharpe {sharpe_mkt:.2f})")
ax.plot(vols, rf + sharpe_ia * vols,
        linestyle="--", color=color_ia, label="CML IA")
ax.scatter([vol_ia], [ret_ia], marker="*", s=220,
          color=color_ia, zorder=5, label=f"Tangente IA (Sharpe
{sharpe_ia:.2f} con  $\mu$  predicho)")
ax.scatter([0], [rf], marker="o", s=80, color="black", zorder=5,
label="Activo sin riesgo")

ax.set_xlabel("Volatilidad anual")
ax.set_ylabel("Retorno anual esperado")
ax.set_title("Frontera Eficiente y CML – Markowitz vs IA Ridge",
fontweight="bold")
ax.legend(fontsize=9)
ax.yaxis.set_major_formatter(plt.FuncFormatter(lambda x, _:
f"{x:.0%}"))
ax.xaxis.set_major_formatter(plt.FuncFormatter(lambda x, _:
f"{x:.0%}"))

plt.tight_layout()
plt.savefig("grafico_4_3_frontera_comparativa.png", dpi=150,
bbox_inches="tight")
plt.show()

```

```

# FUNCIÓN 10c: Gráficos restantes – pesos, backtest y métricas (para
sección 4.3/4.4)

def hacer_graficos(tabla_pesos, backtest_df, metricas_df):

    fig = plt.figure(figsize=(16, 6))

    gs = gridspec.GridSpec(1, 3, figure=fig, hspace=0.38,
wspace=0.38)

    colores = {
        "Markowitz": "#e63946",
        "IA (Ridge)": "#f4a261",
        "Equal Weight": "#2a9d8f",
    }

    # Gráfico B: Pesos de cada estrategia
    ax2 = fig.add_subplot(gs[0, 0])
    x = np.arange(len(tabla_pesos))
    ancho = 0.35
    ax2.bar(x - ancho/2, tabla_pesos["Markowitz"] * 100,
            width=ancho, color=colores["Markowitz"],
label="Markowitz", alpha=0.85)
    ax2.bar(x + ancho/2, tabla_pesos["IA (Ridge)"] * 100,
            width=ancho, color=colores["IA (Ridge)"], label="IA
(Ridge)", alpha=0.85)
    ax2.set_xticks(x)
    ax2.set_xticklabels(tabla_pesos.index, rotation=20, ha="right",
fontsize=8)
    ax2.set_ylabel("Peso (%)")
    ax2.set_title("Pesos: Markowitz vs IA", fontweight="bold")
    ax2.legend()
    ax2.set_ylim(0, 110)

    for xi, (vm, vi) in enumerate(zip(tabla_pesos["Markowitz"],
tabla_pesos["IA (Ridge)"])):
        ax2.text(xi - ancho/2, vm * 100 + 1, f"{vm:.0%}", ha="center",
fontsize=7)
        ax2.text(xi + ancho/2, vi * 100 + 1, f"{vi:.0%}", ha="center",
fontsize=7)

```

```

# Gráfico C: Evolución del valor acumulado
ax3 = fig.add_subplot(gs[0, 1])
for col in backtest_df.columns:
    color = colores.get(col, "gray")
    ax3.plot(backtest_df.index, backtest_df[col], label=col,
color=color, linewidth=1.5)
    ax3.axhline(1, linestyle=":", color="gray", linewidth=0.8)
    ax3.set_title("Backtest 2020-2025: Retornos Acumulados",
fontweight="bold")
    ax3.set_ylabel("Valor de 1€ invertido")
    ax3.set_xlabel("Fecha")
    ax3.legend()
    ax3.xaxis.set_major_locator(plt.MaxNLocator(6))
fig.autofmt_xdate(rotation=30)

# Gráfico D: Tabla de métricas
ax4 = fig.add_subplot(gs[0, 2])
ax4.axis("off")
cabeceras = ["Estrategia"] + metricas_df.columns.tolist()
tbl = ax4.table(
    cellText = metricas_df.reset_index().values.tolist(),
    colLabels = cabeceras,
    cellLoc = "center",
    loc = "center",
)
tbl.auto_set_font_size(False)
tbl.set_fontsize(7)
tbl.scale(1, 1.6)
for j in range(len(cabeceras)):
    tbl[(0, j)].set_facecolor("#2c3e50")
    tbl[(0, j)].set_text_props(color="white", fontweight="bold")
for i in range(1, len(metricas_df) + 1):
    for j in range(len(cabeceras)):
        tbl[(i, j)].set_facecolor("#eaf0fb" if i % 2 == 0 else
"white")

```

```

    ax4.set_title("Métricas de Riesgo (Test 2020-2025)",
fontweight="bold", pad=14)

    plt.suptitle("TFG: Análisis del impacto de diversificación
sectorial y activos alternativos",
                fontsize=11, fontweight="bold", y=1.02)

    plt.savefig("grafico_4_4_resultados.png", dpi=150,
bbox_inches="tight")

    plt.show()

# FUNCIÓN 11: Tracking Error de los ETFs respecto a sus benchmarks

def calcular_tracking_error(etfs_tickers, benchmarks, fecha_inicio,
fecha_fin):

    # Calculo la desviación típica anualizada de la diferencia de
retornos ETF-benchmark

    # Un TE bajo confirma que el ETF replica fielmente su índice de
referencia

    resultados = []

    for nombre, (ticker_etf, ticker_bench, nombre_bench) in
benchmarks.items():

        try:

            df = yf.download(

                [ticker_etf, ticker_bench],

                start=fecha_inicio, end=fecha_fin,

                auto_adjust=True, progress=False

            )["Close"].dropna()

            ret_etf = df[ticker_etf].pct_change().dropna()

            ret_bench = df[ticker_bench].pct_change().dropna()

            diferencia = ret_etf - ret_bench

            te_anual = diferencia.std() * np.sqrt(252)

            resultados.append({

                "ETF": nombre,

                "Ticker ETF": ticker_etf,

                "Índice referencia": nombre_bench,

                "Tracking Error (anual)": te_anual

```

```

    })

    except Exception as e:

        resultados.append({

            "ETF": nombre, "Ticker ETF": ticker_etf,

            "Índice referencia": nombre_bench,

            "Tracking Error (anual)": float("nan")

        })

    return pd.DataFrame(resultados)

# PROGRAMA PRINCIPAL

def main():

    print("=" * 50)

    print(" TFG – Análisis del impacto de diversificación sectorial y
    activos alternativos")

    print("=" * 50)

    # Descargo los datos

    datos = descargar_datos(etfs, rf_ticker, fecha_inicio, fecha_fin)

    # Calculo el Tracking Error de cada ETF respecto a su índice de
    referencia

    # Se usa el benchmark con menor TE de entre los candidatos
    probados

    benchmarks_te = {

        "Bonos (IEGA.L)": ("IEGA.L", "XGLE.L", "Xtrackers
        Eurozone Govt Bond (XGLE.L)"),

        "MSCI World (IWDA.L)": ("IWDA.L", "XDWD.L", "Xtrackers MSCI
        World UCITS ETF (XDWD.L)"),

        "Inmobiliario (IWDP.L)": ("IWDP.L", "H4ZL.DE", "HSBC FTSE
        EPRA/NAREIT Dev. (H4ZL.DE)"),

        "Materias primas (DBC)": ("DBC", "PDBC", "Invesco
        Optimum Yield Diversified Commodity (PDBC)"),

    }

    df_te = calcular_tracking_error(etfs, benchmarks_te, fecha_inicio,
    fecha_fin)

```

```

    imprimir_tabla(df_te, "Tracking Error anualizado de cada ETF
respecto a su benchmark:")

    print("\nInterpretación: un Tracking Error < 2% indica que el ETF
replica")

    print("con gran fidelidad a su índice de referencia.")

# Preparo las variables para el modelo
datos_ml = crear_variables(datos, activos)
train    = datos_ml.loc[:fin_train]
test     = datos_ml.loc[inicio_test:]

    print(f"\nTrain: {train.index[0].date()} → {train.index[-
1].date()}  ({{len(train):,}} obs)")

    print(f"Test:  {test.index[0].date()} → {test.index[-1].date()}
({{len(test):,}} obs)")

# Parámetros de mercado con datos de entrenamiento
mu, sigma, rf = calcular_parametros(train, activos)
print(f"\nTasa libre de riesgo anual: {rf:.4f} ({{rf*100:.2f}}%)")

# Tabla de rentabilidades medias anualizadas
tabla_mu = pd.DataFrame({
    "Activo": activos,
    "Rentabilidad media anual": mu.values
})
imprimir_tabla(tabla_mu, "Rentabilidad media anualizada (train):")

# Volatilidades individuales anualizadas
vol_ind = pd.DataFrame({
    "Activo": activos,
    "Volatilidad anual": [np.sqrt(sigma.loc[a, a]) for a in
activos]
})
imprimir_tabla(vol_ind, "Volatilidades individuales anualizadas
(train):")

# Matriz de correlaciones

```

```

corr = train[activos].corr().round(4)

imprimir_tabla(corr.reset_index().rename(columns={"index":
"Activo"}),

               "Matriz de correlaciones (train 2010-2019):")

# Cartera Markowitz

print("\n-- Cartera Markowitz --")

w_mkt, ret_mkt, vol_mkt, sharpe_mkt = cartera_max_sharpe(mu,
sigma, rf)

tabla_mkt = pd.DataFrame({

    "Activo": activos,

    "Peso": w_mkt,

})

imprimir_tabla(tabla_mkt, "Pesos cartera Markowitz:")

print(f" Ret: {ret_mkt:.4f} | Vol: {vol_mkt:.4f} | Sharpe:
{sharpe_mkt:.4f}")

# Frontera eficiente

puntos_frontera = frontera_eficiente(mu, sigma, n_puntos)

# Modelo Ridge

print("\n-- Entrenando modelos Ridge --")

modelos, scalers, columnas = entrenar_ridge(train, activos)

# Predicciones

pred = predecir(test, modelos, scalers, columnas, activos)

mu_ia = pred.mean() * 252

tabla_mu_ia = pd.DataFrame({

    "Activo": activos,

    "Rentabilidad predicha anual": mu_ia.values

})

imprimir_tabla(tabla_mu_ia, "Rentabilidad predicha por la IA
(anualizada):")

# Cartera IA

# Los pesos se optimizan con mu_ia (predicho por Ridge)

```

```

print("\n-- Cartera IA --")

w_ia, ret_ia, vol_ia, sharpe_ia = cartera_max_sharpe(mu_ia, sigma,
rf)

tabla_ia = pd.DataFrame({
    "Activo": activos,
    "Peso": w_ia,
})

imprimir_tabla(tabla_ia, "Pesos cartera IA (optimizados con  $\mu$ 
predicho por Ridge):")

# Métricas in-sample con  $\mu$  predicho – las que usa el optimizador
internamente

tabla_metricas_ia_pred = pd.DataFrame([
    "Concepto": "In-sample con  $\mu$  predicho (lo que ve el
optimizador)",
    "Ret": round(ret_ia, 4),
    "Vol": round(vol_ia, 4),
    "Sharpe": round(sharpe_ia, 4),
])

imprimir_tabla(tabla_metricas_ia_pred, "Métricas IA con  $\mu$ 
predicho:")

# Métricas con  $\mu$  histórico del train – para comparar en igualdad
con Markowitz

ret_ia_real = float(w_ia @ mu.values)
vol_ia_real = float(np.sqrt(w_ia @ sigma.values @ w_ia))
sharpe_ia_real = float((ret_ia_real - rf) / vol_ia_real)

tabla_metricas_ia_hist = pd.DataFrame([
    "Concepto": "Con  $\mu$  histórico train (comparación justa vs
Markowitz)",
    "Ret": round(ret_ia_real, 4),
    "Vol": round(vol_ia_real, 4),
    "Sharpe": round(sharpe_ia_real, 4),
])

imprimir_tabla(tabla_metricas_ia_hist, "Métricas IA con  $\mu$ 
histórico (base comparativa):")

print(" → La comparación definitiva entre estrategias se realiza
en el backtest fuera de muestra (2020-2025)")

```

```

# Cartera equiponderada como referencia
w_eq = np.ones(len(activos)) / len(activos)

# Tabla comparativa de pesos
tabla_pesos = pd.DataFrame({
    "Markowitz": w_mkt,
    "IA (Ridge)": w_ia,
    "Equal Weight": w_eq,
}, index=activos)

imprimir_tabla(tabla_pesos.reset_index().rename(columns={"index":
"Activo"}),
               "Comparativa de pesos:")

# Backtest
print("\n-- Backtest 2020-2025 --")
pesos_dict = {
    "Markowitz": w_mkt,
    "IA (Ridge)": w_ia,
    "Equal Weight": w_eq,
}

backtest_df = backtest(test, pesos_dict, activos)

imprimir_tabla(backtest_df.tail(5).reset_index(), "Últimos 5 días
del backtest:")

# Métricas
metricas_df = calcular_metricas(test, pesos_dict, activos, rf)

imprimir_tabla(metricas_df.reset_index(), "Métricas de riesgo
(Test 2020-2025):")

# Gráfico 4.2: Frontera eficiente solo Markowitz
grafico_frontera_markowitz(puntos_frontera, vol_mkt, ret_mkt,
sharpe_mkt, rf)

# Gráfico 4.3: Frontera eficiente comparativa Markowitz vs IA
grafico_frontera_comparativa(

```

```

    puntos_frontera,
    vol_mkt, ret_mkt, sharpe_mkt,
    vol_ia, ret_ia, sharpe_ia,
    rf,
)

# Gráficos 4.3/4.4: Pesos, backtest y métricas
hacer_graficos(
    tabla_pesos[["Markowitz", "IA (Ridge)"]],
    backtest_df,
    metricas_df,
)

print("\nAnálisis completado.")
return datos, tabla_pesos, backtest_df, metricas_df

if __name__ == "__main__":
    datos, tabla_pesos, backtest_df, metricas_df = main()

```