Facultad de Ciencias Económicas y Empresariales
ICADE

FUNCIÓN DEL REAL ESTATE EN EL PORFOLIO: COMPARATIVA A TRAVÉS DE ENFOQUES TRADICIONALES Y MACHINE LEARNING

Autor: Alejandro Jofre Álvarez
Director: Don Ignacio Cervera SJ.

MADRID | Marzo 2026

Resumen

Este trabajo de fin de grado se centra en evaluar el rol del "Real Estate", también conocido como bienes raíces, a través de los REITs en una cartera de inversión. Para ello se investiga como hace uso de este activo distintos modelos de optimización tanto tradicionales, el modelo de Markowitz o 1/N, como modelos modernos de Machine Learning (ML) como Random Forest (RF) o Deep Neural Networks (DNN).

Los resultados demuestran que el modelo de Random Forest (RF) ha sido más eficiente que el resto, haciendo uso del activo de los REITs como valor refugio pero intercambiándolo con los bonos de forma arbitraria y no durante periodos de alta volatilidad como planteaba este trabajo en su hipótesis inicial.

Conceptos y palabras clave: Gestión de carteras, Real Estate, Machine Learning, Random Forest, Volatilidad.

Abstract

This final degree project focuses on evaluating the role of Real Estate, also known as real estate, through REITs in an investment portfolio. To this end, we investigate how different optimization models make use of this asset, both traditional, the Markowitz model or 1/N, and modern Machine Learning (ML) models such as Random Forest (RF) or Deep Neural Networks (DNN).

The results show that the Random Forest (RF) model has been more efficient than the rest, making use of the REITs' assets as a safe haven but exchanging it with bonds arbitrarily and not during periods of high volatility as this work proposed in its initial hypothesis.

Concepts and keywords: Portfolio Management, Real Estate, Machine Learning, Random Forest, Volatility.

Índice de contenido

1. Introducción 6
Motivación 6
Objetivos del trabajo 6
Importancia del Real Estate en una cartera multiactivo 7
2. Marco Teórico 8
Real Estate 8
Tipos de Activos de Real Estate 8
Real Estate Publico VS Privado 10
Riesgos asociados al Real Estate 11
Real Estate en el marco ESG 12
El Real Estate como valor refugio 13
Modelos de Valoración 14
Modelo de Media Varianza de Markowitz 14
Modelo “Equal weights” (Pesos iguales) 15
Modelo de ML mediante redes neuronales profundas (DNN) 16
Modelo de ML mediante “Random Forest” (RF) 18
3. Metodología 19
Modelo de ML mediante “Deep Neural Network” 20
Modelo de ML mediante “Random Forest” 21
Modelo de media varianza 22
Modelo “Equal weights” 22
Métricas de Evaluación 22
4. Resultados 24
Modelo “Equal weights” 24
Modelo de Markowitz de mínima varianza 25
Modelo Random Forest 26
Modelo DNN 27
Resultados conjuntos 28
Papel de los REITs en periodos de alta volatilidad 29
5. Conclusiones 32
Resumen de los hallazgos 32
Limitaciones del trabajo 32

Recomendaciones para futuras investigaciones 33
Conclusión final 33
6. Declaración de uso de herramientas de inteligencia artificial generativa en Trabajos Fin de Grado 35
7. Bibliografía 36
8. Anexos 39
Anexo 1 39
Anexo 2 42
Anexo 3 45
Anexo 4 47

1. Introducción

Motivación

He decidido realizar mi trabajo de fin de grado sobre el papel del real estate en las carteras multiactivo porque esta área aúna dos de los aspectos que más me han gustado durante el transcurso de mi carrera, la teoría de carteras, y el real estate.

En primer lugar, desde primero de carrera comprobé que las asignaturas de carácter cuantitativo me atraían de forma especial. En primer y segundo curso pude realizar asignaturas como finanzas corporativas, contabilidad o incluso una optativa en fusiones y adquisiciones. Debido a mi interés por todos estos aspectos, inevitablemente me vi atraído por la teoría de carteras. Esta área de las finanzas reúne aspectos de la mayor parte de asignaturas cuantitativas que he realizado en la carrera y existen innumerables formas de aplicarla a la realidad por lo que decidí decantarme por ella a la hora de realizar mi TFG.

Por otro lado, gracias a prácticas extracurriculares que he podido realizar a lo largo de la carrera he podido desarrollar un gran interés en el mundo del Real Estate. Mi paso por JLL como consultor o mi puesto actual como analista de portfolios en un fondo de inversión de Real Estate me han permitido ahondar en esta clase de activo y su papel fundamental a la hora de realizar una cartera.

Objetivos del trabajo

Este trabajo de fin de grado (TFG) tiene por objetivo el de analizar el peso del Real Estate en una cartera multiactivos en periodos de alta volatilidad. Para ello, obtendremos datos sobre la cotización de diferentes activos (acciones, bonos y REITS) a lo largo de periodos de baja y alta volatilidad. Una vez obtenidos estos datos, se realizará una simulación según distintos modelos de carteras para analizar como estos distintos modelos distribuyen el peso del Real Estate a lo largo del tiempo y especialmente en periodos de alta volatilidad.

Se realizará esto porque el objetivo de este trabajo es discernir la naturaleza del Real Estate como activo refugio. La academia y lógica racional defienden que el Real Estate es un activo refugio porque está respaldado por un inmueble tangible, sin embargo, el pasado financiero de occidente, especialmente durante la crisis de las hipotecas subprime de 2008 sugieren que el Real Estate es un activo volátil debido a la alta

regulación a la que está sometido, además de su iliquidez en los mercados lo que dificulta su valoración a corto plazo (Assimakopoulos, 2013) (Günther et al., 2022).

Importancia del Real Estate en una cartera multiactivo

Históricamente el Real Estate ha mostrado una correlación considerablemente baja con otras clases de activos. Este aspecto del Real Estate lo convierte en candidato para reducir la volatilidad global de las carteras. Existen fuentes que afirman que el peso optimo del real Estate en una cartera es de alrededor del 10-15%.

Sin embargo, para que los gestores de carteras puedan hacer uso de este activo deben entender en profundidad distintos aspectos del Real Estate como los tipos que hay y sus diferencias (oficinas, logística, residencial, hospitalidad…etc.), Real Estate publico VS privado, los riesgos del Real Estate o su papel en el marco ESG.

2. Marco Teórico

Real Estate

El sector del Real Estate está conformado por todas aquellas actividades asociadas a los bienes inmuebles. Un bien inmueble es por definición un bien que no puede trasladarse de un lugar a otro sin cambiar su naturaleza, estando unido de forma permanente al suelo en el que se encuentra. Es uno de los sectores más antiguos conocido por el ser humano pues desde la edad antigua han existido formas de propiedad sobre la tierra, aunque el sistema que ha permitido nuestro mercado inmobiliario actual surge en el Reino Unido durante el S. XVII (TIAS School, s. f.).

Durante el feudalismo la propiedad sobre la tierra estaba reservada a la nobleza y al clero, sin embargo, durante la industrialización, distintos factores como la concentración de la población, el aumento del poder adquisitivo de la clase trabajadora o una mayor demanda de derechos básicos como el acceso a una vivienda impulsaron el origen de este sector. Más adelante, durante la era moderna, este sector que era considerado "tierra y ladrillos" se fue desarrollando hasta crear el sector tan diverso y complejo del que gozamos hoy en día, que incluye toda el área de créditos, alquiler, regulación y distintas subclases que veremos a continuación (TIAS School, s. f.).

Tipos de Activos de Real Estate

Es fácil a la hora de pensar en el Real Estate, pensar únicamente en la vivienda y el sector residencial. Sin embargo, el sector del Real Estate engloba muchísimos otros subactivos que poseen igual o mayor importancia que el residencial y condicionan enormemente la salud del sector (TIAS School, s. f.).

Para empezar, es muy importante comprender la importancia del sector de las oficinas dentro del Real Estate. Durante la crisis del COVID el precio de este activo disminuyó enormemente ante la incapacidad de los trabajadores de acudir y a sus puestos de trabajo y la popularización del teletrabajo. Desde entonces, se han desarrollado distintas líneas de investigación para intentar discernir cual es el futuro de las oficinas y si verdaderamente es beneficioso para el trabajador promedio acudir a un puesto de trabajo con los costes que eso conlleva a la empresa.

Desde un punto de vista simplista, muchos podrían considerar que el teletrabajo es una gran ventaja tanto para el trabajador como para el propietario pues permitiría ahorrar grandes costos en términos de alquiler o compra de m2 de oficinas cuando hoy en

día la mayor parte del trabajo se puede hacer a través de un ordenador convencional. Sin embargo, referentes en la industria como Ignacio de la Torre, director del departamento de Research en Arcano, han defendido siempre que el teletrabajo es perjudicial para el trabajo por distintos motivos como la ausencia de sinergias, el deterioro de la confianza o la comunicación dentro de un equipo o incluso la salud psicológica de los trabajadores.

Todos estos debates y distintas tendencias a favor o en contra del teletrabajo se pueden ver reflejados en el precio del activo oficinas dentro del sector Real Estate y es un gran ejemplo de cómo cambios en el comportamiento de la población afectan al sector. Otro subactivo que se ha visto enormemente afectado por cambios recientes es el de la logística.

Los activos dentro del área de la logística hacen uso de su espació para organizar, almacenar, clasificar y/o distribuir productos. Antiguamente estos activos solían consistir en naves espaciosas a las afuera de núcleos urbanos y eran considerados poco valiosos debido a la baja inversión necesaria para construirlos. Todo esto ha cambiado gracias a la inteligencia artificial y compañías como Amazon, que han transformado el sector de la logística para convertirlo en un pilar fundamental de su propuesta de valor para los clientes.

El auge del Ecommerce y la IA han demandado que las naves industriales evolucionen a la hora de almacenar y distribuir los productos. Existen nuevos sistemas robotizados que permiten digitalizar toda la rotación de producto para poder seguir en directo el almacenaje de los productos. También se han desarrollado nuevas tecnologías para facilitar la transición entre punto de almacenaje y vehículo de distribución minimizando la necesidad de personal humano. Todas estas tecnologías deben ser implantadas en espacios que cumplan los requisitos en términos de espacio o electricidad transformando completamente el sector de la logística.

Pero la IA no solo ha revolucionado sectores antiguos y poco atractivos del Real Estate como el de la logística, sino que ha desarrollado la creación de nuevos sectores, como es el de los Data Centers. Tradicionalmente, el Real Estate se veía principalmente condicionado por los m2 y la disponibilidad de estos en una determinada localización. Todo esto ha cambiado ante el auge de la demanda del almacenamiento de datos y su necesidad de refrigeración. Estas bases de datos que alimentan la IA generativa demandan una densidad de potencia de potencia por metro cuadrado mucho mayor por lo que activos

con licencias de potencia garantizada o fácil disponibilidad de electricidad han visto su demanda crecer exponencialmente permitiendo que hoy en día se estén creando nuevos equipos dedicados únicamente a este activo.

La lista de subactivos dentro del Real Estate es muy larga y podríamos seguir ahondando en activos como el Retail, hoteles, hospitales, Residencias tanto de ancianos como de estudiantes, de uso mixto… y un largo etcétera. No obstante, debemos ceñirnos al Real Estate como inversión, y su efecto en una cartera por lo que debemos explicar las formas que existen de invertir en este sector.

Real Estate Publico VS Privado

Cuando nos imaginamos una inversión en Real Estate, lo habitual es pensar en una inversión directa en un bien inmueble a través de la aportación de capital a una constructora o ejerciendo una compra/venta en activos ya construidos. Sin embargo, este sistema trae una gran cantidad de desventajas que desarrollaremos a continuación (TIAS School, s. f.).

En primer lugar, este método para invertir en Real Estate te daba pocas posibilidades de diversificación. No podías obtener exposición a distintos tipos de bienes inmuebles como los mencionados anteriormente, y además debías centrarte en un punto muy preciso dentro de una ciudad o país lo que generaba grandes riesgos sobre los que el inversor seguramente no estaba acostumbrado.

Además, la inversión de forma privada también obligaba al inversor a llevar a cabo la construcción en si misma, posibles reformas o mantenimiento de los activos, y sumado a la necesidad de grandes sumas de capital para poder acceder a la inversión en este activo hizo que los estados buscaran una forma de democratizar la inversión en activos de Real Estate.

Para alejar a los bancos, aseguradoras y grandes fortunas de este sector, y acercarlo al ciudadano promedio, E.E.U.U permitió la creación de los REITS (Real Estate Investment Trusts) que son sociedades que cotizan en bolsa cuyo propósito social es el de invertir en bienes inmuebles. De esta manera, el ciudadano promedio fue, y es capaz hoy en día, de invertir en real estate de la misma forma que invertiría en una acción que cotice en bolsa.

Para permitir esto, los REITS o SOCIMIS (Sociedades Cotizadas de Inversión en Mercados Inmobiliarios) como se conocen en España, gozan de ciertos privilegios y obligaciones que los separan de una empresa al uso. En primer lugar, la mayor parte de sus activos de encontrarse en forma de alquiler para asegurarse de que el REIT no especule con la vivienda, sino que realice inversiones duraderas con flujos de caja estables para el inversor comercial. Siguiendo esta misma línea, los REITs o SOCIMIs deben realizar un reparto obligatorio de dividendos con porcentajes mínimos que deben repartir respecto a sus ingresos por rentas y plusvalías provocando que no puedan acumular caja como una empresa al uso. Para contrarrestar esta obligación, el estado concede a este tipo de empresas el privilegio de no pagar el Impuesto de Sociedades por lo que el inversor únicamente paga en impuestos lo correspondiente a cobrar los dividendos.

Este tipo de inversión que es el que utilizaremos en este trabajo para la elaboración de nuestras carteras no solo permite el acceso a este tipo de activos al inversor comercial, sino que aporta una liquidez indispensable al sector, teniendo en cuenta la naturaleza de los bienes raíces como veremos más adelante

Riesgos asociados al Real Estate

El sector del Real Estate está altamente regulado tanto a nivel regional, como nacional e internacionalmente. Esto incluye impuestos sobre el patrimonio inmobiliario, requisitos en forma de permisos a la hora de la construcción, categorización del suelo en función de su uso permitido y un largo etcétera. Al final y al cabo, debemos recordar que la vivienda es una necesidad básica de las personas, quedando recogido en la constitución española, por ejemplo, el derecho de todos los españoles a una vivienda digna y adecuada, obligando a los poderes públicos a promover el urbanismo, el planeamiento y el fomento a la vivienda. Esto incluye la lucha contra la especulación lo que dificulta la inversión de forma eficaz en este activo (Bond University, s. f.).

La iliquidez es otro riesgo que vertebra al activo Real Estate (Günther et al., 2022). Es primordial entender que los bienes inmuebles tienen un tiempo de venta prolongado, incluso teniendo en cuenta la aparición de REITS y SOCIMIs debemos tener en cuenta que estas acciones cotizadas están respaldadas por un activo de esta naturaleza y debemos tenerlo en cuenta la hora de realizar nuestros análisis y construcción de carteras. Otro aspecto que suma a la iliquidez de estos activos son los altos costes de transacción. Debido a la legislación asociada a este activo como ya hemos mencionado, existe gran cantidad de barreras a la hora de realizar compra/ventas o contratos de alquiler dentro del sector,

lo que ralentiza la toma de decisiones y aumenta los gastos implícitos (Günther et al., 2022).

Por último, debemos hablar de la volatilidad del sector del Real Estate pues es un aspecto clave de este trabajo. Debemos entender en profundidad la diferencia entre una baja volatilidad aparente y la volatilidad real de los activos. Debido a la iliquidez de este activo como ya hemos explicado, las variaciones en los precios disminuyen proporcionando al inversor una falsa impresión de estabilidad. Esto sumado a la subjetividad a la hora de realizar tasaciones y otros aspectos hace que sea en momentos como crisis o burbujas financieras se puedan apreciar fuertes caídas en la valoración de este activo (Günther et al., 2022).

En contrapartida, debemos recordar que las inversiones de Real Estate siempre estarán respaldadas por un activo tangible, algo que ciertamente es un respaldo a cualquier inversión y defiende la idea del Real Estate como un valor refugio.

Es este debate dentro de la literatura actual lo que ha promovido este trabajo y como ya ha sido mencionado en el apartado de introducción, es el objetivo de este trabajo tratar de aportar datos sobre este tema y poder determinar la naturaleza real de este activo.

Real Estate en el marco ESG

Por último, es importante tener muy en cuenta la relación que tiene el Real Estate dentro del marco ESG, pues condiciona enormemente la forma en la que nos relacionamos tanto con el medioambiente como entre nosotros.

Durante el proceso de construcción es crucial que hoy en día se tengan en cuenta multitud de aspectos relacionados con el ESG. En primer lugar, el mismo diseño de los bienes inmuebles de ahora incluir planes de eficiencia energética. El objetivo es reducir al máximo el consumo de energía en procesos antes muy costosos como la calefacción o ventilación de los espacios. Todo esto ha provocado que hoy en día los arquitectos tengan en cuenta estas consideraciones para buscar minimizar el impacto de sus edificios a nivel medioambiental (Robinson y McIntosh, 2022).

Otro aspecto fundamental es el de la obtención de materiales de calidad y origen certificado. Ya existen clientes que no desean comprar bienes inmuebles en los que los materiales no son reutilizables o perjudiciales para la naturaleza. Ahora más que nunca los inversores buscan realizar decisiones que sean beneficiosas para el planeta y el sector

del Real Estate no es una excepción. Evitar el plástico y productos industriales por otros como la madera son una tendencia ya existente en el mercado que solo aparece crecer al alza.

Además, como ya hemos comentado, la normativa y la ética a la hora de obtener permisos para construir o poner precios al alquiler es clave para que una empresa del sector cumpla los requisitos del marco ESG. Los terrenos deben ser evaluados por peritos para asegurarse de que los proyectos urbanísticos no perjudiquen ni a otras personas ni al medioambiente (Robinson y McIntosh, 2022).

El Real Estate como valor refugio

Existe gran debate en la literatura sobre el uso de los REITS como valor refugio a la hora de realizar carteras de inversión. Aunque los bienes raíces son menos volátiles que las acciones y por tanto deberían ser un refugio en periodos de alta volatilidad existen académicos que creen que los REITs son "acciones disfrazadas" que incluso amplifican el riesgo en momentos de alta volatilidad.

Autores como Mull y Soenen (1977) han argumentado que los REITs son un gran vehículo de diversificación porque el ciclo de inversión del sector inmobiliario es mucho más largo y menos volátil que los clicos bursátiles. Una acción fluctúa en gran medida por noticias o trimestralmente por los resultados presentados mientras que un proyecto inmobiliario posee contratos de arrendamiento a largo plazo que generan flujos de caja mucho más predecibles y estables.

Además de esto, el "real estate" también es considerado por muchos académicos un gran refugio contra la inflación. Esto se debe a que los alquileres suelen estar vinculados al IPC, y los edificios aumentan de valor porque debido al aumento del precio de los materiales el coste de reposición también aumenta lo que provoca que los REITs sean uno de los pocos activos con una correlación positiva con la inflación.

Por otro lado, también existen críticos que se encuentran en contra de estas ideas (Bond University, s. f.). Estudios han demostrado que en momentos de crisis o cisnes negros la correlación de los REITs con el mercado tiende a dispararse a 1. Esto significa que, aunque en periodos estables poseen correlaciones distintas si los REITs durante los periodos de crisis convergen con las acciones pierden todo su valor como activo refugio.

También se ha estudiado el efecto de los tipos de interés en los REITs como un factor muy importante a tener en cuenta a la hora de incluir este activo en nuestra cartera. Los tipos de interés tienen un efecto doblemente negativo en rendimiento de los REITs por dos motivos. En primer lugar, eleva los costes de la financiación de la deuda como el resto de los activos, pero debido a la obligación de los REITs de repartir el 90% de sus beneficios en dividendos también provoca que la rentabilidad por dividendo sea mucho menos atractiva que los bonos libres de riesgo.

Por último, existe un problema a la hora de valorar los activos inmobiliarios (Assimakopoulos, 2013). Mientras que una empresa puede ser analizada rápidamente teniendo en cuenta su contabilidad, los REITs están respaldados por bienes raíces que se caracterizan por la dificultad a la hora de ser valorados. Debido a la iliquidez de los mercados inmobiliarios es complicado valorar mediante el uso de comparables (Günther et al., 2022). Aunque se han creado modelos como el "Hedonic pricing" que se basan en la valoración de activos a través de una serie de características cuantitativas (ventanas, m2, piso, distancia a transporte publico…etc.) la realidad es que existe cierta opacidad a la hora de valorar un inmueble lo que dificulta por extensión la valoración de un REIT (Assimakopoulos, 2013).

Modelos de Valoración

Para poder analizar los pesos asignados al Real Estate en una cartera durante periodos de alta y baja volatilidad haremos uso de modelos de construcción de carteras, que iremos actualizando a lo largo del tiempo para comprobar como hacen uso estos del activo Real Estate, y como varían su peso en la cartera en periodos de alta volatilidad.

Para realizar esto haremos uso de modelos tanto tradicionales como de "Machine learning" para poder hacer uso de una gran variedad de modelos dentro de la literatura.

Modelo de Media Varianza de Markowitz

El modelo de media varianza de Markowitz fue uno de los grandes impulsores de la teoría moderna de carteras. Se basa en maximizar la rentabilidad para un nivel de riesgo dado o viceversa, minimizar el riesgo para un nivel de rentabilidad específico. La media se refiere a la rentabilidad esperada de la cartera mientras que la varianza trata de medir el riesgo a través de la desviación típica, cuantificando la desviación de los distintos valores respecto a la media (Markowitz, 1952).

Este modelo se fundamenta en la construcción de carteras eficientes optimizando de forma simultánea los dos factores ya mencionados, la rentabilidad esperada y la varianza de los rendimientos de los activos.

Al resolver este modelo para distintos riesgos deseados obtenemos la frontera eficiente que muestra el binomio riesgo-rentabilidad y las distintas combinaciones que existen de este teniendo en cuenta n activos (Markowitz, 1952).

Modelo "Equal weights" (Pesos iguales)

El modelo de "Equal weights" también conocido como modelo 1/N representa el modelo más básico que sirve como base para la comparación a la hora de modelizar carteras de inversión. En diferencia a modelos como el de Markowitz que se basan en parámetros estadísticos, el modelo 1/N se basa en asignar pesos alícuotas al universo de activos disponibles en un modelo específico.

Una de las grandes cualidades de este modelo es que al no utilizar predictores o estadísticas pasadas sirve como un robusto benchmark contra el que comparar otros modelos. De hecho, el uso de este modelo en este trabajo no es otro que el de comparar el resto de los modelos (Markowitz, DNN y Random Forest) a este para poder analizar cuál es el performance de estos modelos respecto al modelo más "básico" y usado históricamente.

Un punto importante que considerar sobre este modelo es que la gestión de esta estrategia de inversión no es tan pasiva como se pudiera pensar en un primer momento. En el modelo de "Equal weights" se debe realiza un rebalanceo mensual para mantener los pesos iguales entre los activos del universo de inversión. Esto implica que el inversor deberá vender los activos "ganadores" que han incrementado de precio y por tanto han aumentado su precio dentro de la cartera y comprar "perdedores" que han perdido valor y por tanto deberás comprar para aumentar su peso.

Esta estrategia parece contraintuitiva y es especialmente dañina en ciertos casos. En primer lugar, esta estrategia es subóptima cuando los mercados poseen tendencias fuertes y prolongadas. Por ejemplo, en un mercado alcista muy fuerte este modelo de "Equal weights" cortará las alas muy pronto a estos activos que se encuentran alza, y cada mes venderá los activos alcistas para mantener los pesos iguales y por tanto limitando los beneficios que este activo podría aportar a la cartera.

Otro escenario en el que este modelo no es optimo es el de las crisis sistemáticas. Durante las crisis, este modelo no reconoce el momentum del mercado y en vez de refugiarse en activos como los bonos mantendrá la inversión en activos volátiles, aunque estos activos se mantengan bajistas. Esto provoca que la cartera experimente el drawdown máximo de los activos haciendo que tu cartera sea mucho más volátil.

A pesar de todas estas desventajas y la simplicidad de este modelo, cantidad de artículos como DeMiguel, Garlappi y Uppal (2009) defienden que esta estrategia puede llegar a ser superior a muchos modelos más complejos en muchos aspectos. Ciertos académicos afirman que este modelo al dar por sentado que no conoce que activos serán alcistas o bajistas decide estar expuesto a todos por igual lo que provoca que sea especialmente robusto en casos de incertidumbre extrema. Además, ha sido demostrado que cuando el universo de activos es reducido y bien escogido los rendimientos de este modelo baten a modelos más complejos.

Modelo de ML mediante redes neuronales profundas (DNN)

El modelo de redes neuronales profundas representa el enfoque completamente opuesto al modelo de Equal Weights. Se basa en la utilización de machine learning para intentar replicar relaciones matemáticas por confusas que parezcan (Olanrewaju, 2023). El funcionamiento de este modelo de ML se basa en tres elementos muy diferenciados que son esenciales para comprender el funcionamiento de este modelo:

1. Capa de entrada: En esta capa se introducen las variables predictoras que aunque en este trabajo serán solo los retornos históricos y la volatilidad, también se pueden utilizar otras muchas variables como índices que siguen la situación geopolítica o por el estilo.
2. Capas ocultas: Es aquí donde el modelo de redes neuronales adquiere la etiqueta de profundas. A diferencia de otros modelos en los que solo existe una única capa funcional, en este modelo existen varias capas con distintas funciones. Cada capa trata de detectar patrones distintos desde tendencias simples a patrones abstractos de gran complejidad matemática. Para después tomar decisiones entre distintas capas este modelo utiliza dos funciones clave que son ReLU (Rectified Linear Unit) o Leaky ReLU. Estas funciones juzgan los resultados de las capas y asignan grados de significatividad para llegar a tomar las decisiones de inversión.
3. Capa de salida: esta capa aparte de implementar restricciones como que la inversión sume 1 o no tome posiciones negativas también hace uso de una función

denominada Softmax que se encarga de tomar las decisiones de inversión de las capas intermedias y asigna pesos en función de esto.

La clave de modelos de ML como este se basa en la retro propagación (Olanrewaju, 2023). Esto quiere decir que el modelo o red neuronal en este caso asigna pesos iniciales aleatorios y calcula el error que hay entre las decisiones que ha tomado y el resultado real. Es por esto que los modelos de ML incluido este necesita un periodo de entrenamiento para poder entrenar sus modelos.

Las ventajas de este modelo son variadas. En primer lugar, cuanto más datos y periodos de entrenamiento demos a los modelos mejor será su redito por lo que a medida que pase el tiempo este modelo debería mejorar sus resultados. Otro elemento clave que diferencia a este modelo de otros más básicos como el modelo de Markowitz o de pesos iguales es que el modelo de DNN identifica aglomeraciones de volatilidad que pueden representar crisis u otros fenómenos financieros y actuar en consecuencia. Es decir, puede aprender que en un "Régimen A" que se caracteriza por ciertos parámetros se debe actuar de una manera diferente a un "Régimen B" aunque compartan ciertos aspectos (Olanrewaju, 2023).

Este modelo posee sin embargo muchos desafíos como por ejemplo el coste computacional de este cuando se realiza a gran escala o problemas en la programación como la decisión del modelo de prescindir de ciertas capas cuando las considera ruido a pesar de que el inversor las haya introducido específicamente para que se tengan en cuenta. A pesar de todo esto, los dos errores más importantes de este modelo son los siguientes:

1. Sobreajuste: Una red con demasiadas neuronas puede aprenderse el pasado de forma demasiado específica teniendo en cuenta factores que se deberían considerar irrelevantes o ruido. Si durante el entrenamiento el modelo se ajusta demasiado y maximiza los rendimientos después cuando se expone a la realidad, (valores fuera del conjunto de entrenamiento) muchas veces puede fracasar de forma contundente porque a lo mejor el modelo de DNN ha establecido patrones demasiado específicos que no tienen sentido y han sido producto de la coincidencia. Esto se da especialmente cuando los mercados cambian de estilo por factores geopolíticos o incluso de salud como en el caso del COVID-19 porque

los mercados cambian de patrones de forma radical haciendo que el periodo de entrenamiento del modelo quede obsoleto (Olanrewaju, 2023).

2. Caja negra: Este problema se refiere a la dificultad o incapacidad de las personas de entender la lógica detrás de un modelo de DNN. Mientras que un modelo tradicional es fácil de seguir por una persona pues utiliza funciones simples en un modelo de DNN existen miles de multiplicaciones matriciales no lineales que imposibilita al inversor a hacer un seguimiento matemático de las conclusiones del modelo. Esto hace que los datos no puedan ser interpretados de forma fehaciente. Por ejemplo, si el modelo vende una gran cantidad de acciones en un momento dado porque una de las neuronas ha dado un valor especifico el inversor no podría incluir estos resultados en una narrativa macroscópica debido a la opacidad del modelo. Esto provoca que si no entendemos el razonamiento detrás de las decisiones de una red de neuronas no podamos hacer una auditoria de las decisiones de incluso pudiendo caer en un sesgo de confirmación. (cuando el modelo nos da beneficio lo aceptamos como correcto a pesar de que no sabemos cómo reaccionaria ante un evento nunca visto como un cisne negro) (Olanrewaju, 2023).

Modelo de ML mediante "Random Forest" (RF)

Este modelo es completamente distinto al modelo de ML mediante redes neuronales profundas pues se basa en la construcción de gran cantidad de árboles de decisión. Cada árbol aprende con un universo de datos distintos lo que le llevará a tomar decisiones ligeramente distintas. La lógica detrás de este modelo es que las decisiones de todos los árboles se ponen en común para tratar de obtener la solución y las mejores decisiones (Olanrewaju, 2023).

Los árboles de decisión suelen sobre ajustar demasiado por lo que se añade se componente de aleatoriedad a la hora de elegir el universo de datos que se le presenta y además se añade un componente de agregación.

Para reducir la varianza y la correlación de los árboles no solo se escogen muestras aleatorias dentro de conjunto total de datos, sino que en cada nodo del árbol se toma variables aleatorias también para disminuir la correlación. Cada árbol vota por una decisión y la predicción final es el promedio de todos los árboles.

3. Metodología

Para realizar este trabajo se ha decidido desarrollar cuatro modelos de optimización de carteras, dos de ellos haciendo uso de ML para contrastarlos con dos modelos tradicionales (modelo de Markowitz y de pesos iguales). Para todos los modelos se ha utilizado la misma base de datos diarios obtenida en Yahoo finance y han sido evaluadas bajo las mismas condiciones.

Nuestro porfolio está compuesto por 3 activos que representan las oportunidades más típicas a las que tiene acceso un inversor: Acciones Estadounidenses, bonos estadounidenses y REITS.

1. Renta variable estadounidense: representada por el ticker ^GSPC, que corresponde con el índice S&P500. Este activo representa los rendimientos de las 500 mayores empresas de Estados Unidos por capitalización. Es un índice.
2. Renta fija estadounidense: representada por el ticker TLT. Este activo representa los rendimientos de los bonos del Tesoro estadounidense con vencimientos superiores a 20 años. Es un ETF.
3. Real Estate (REITs): representada por el ticker VN. Este activo representa los rendimientos del mercado inmobiliario. Es un ETF.

Este universo de activos permite a los modelos elegir entre activos más volátiles como las acciones y activos considerados menos volátiles como los bonos. El objetivo de este trabajo es analizar como los distintos modelos hacen uso del activo REITs para poder concluir si los activos inmobiliarios son un activo refugio o no.

En cuanto al horizonte temporal y la frecuencia de los datos, se utilizarán los datos diarios de cada índice desde 2007 a 2022 realizando rebalanceos de forma mensual. Se ha decidido realizar los rebalanceos de forma mensual porque, aunque no se tenga en cuenta durante el trabajo, en la realidad existen costes de transacción que volverían ineficiente un rebalanceo en una periodicidad inferior a la establecida. Los datos diarios permiten analizar en profundidad la evolución de los mercados y los 15 años que abarca la base datos incluye distintas épocas de alta volatilidad como la crisis de 2008 o la crisis de las subprime.

Es importante anotar que en los modelos de ML se ha utilizado como periodo de entrenamiento los datos diarios entre el 1 de enero de 2007 y el 31 de diciembre de 2017

para realizar la simulación o test desde 2018 a 2022. Esta decisión se ha tomado para que en ambos periodos exista un "cisne negro". En el periodo de entrenamiento nos encontramos con la crisis de 2008 y en el del test tenemos la crisis del covid. Es por todo esto que los modelos tradicionales también están realizados desde 2018 a 2022 para poder comparar los 4 modelos en el mismo periodo.

Modelo de ML mediante "Deep Neural Network"

Este modelo es considerado por muchos un modelo de ML de caja negra. Este término se utiliza para señalar aquellos modelos de ML que, debido a su complejidad, los usuarios no son capaces de entender por completo las decisiones del modelo lo que provoca que se deba tener una fe ciega en el modelo sin la capacidad de poder identificar posibles errores que se estén produciendo.

A pesar de esto, se explicará brevemente cual es la arquitectura de este modelo. El DNN se basa en un Perceptrón Multicapa (MLP) que divide los datos entre aquellos que son de entrada y de salida. En el caso de este trabajo se han realizado dos DNN:

DNN A:

1. La capa de entrada recibe los retornos rezagados en el momento t-1. En el caso de este trabajo, se descargan los precios de cierre de Yahoo! finance de los 3 activos (VNQ, TLT, ^GSPC). También en esta fase se calculan los rendimientos mensuales y se aplica el StandardScaler que se aplica para que las escalas de los rendimientos no afecten. Si no se realizara esto, el ^GSPC podría dominar las carteras en todo momento debido a sus rendimientos en términos absolutos.

2. Las capas ocultas utilizan una función de activación que permiten al modelo identificar relaciones no lineales entre los datos de entrada. Es en este punto en el que podríamos decir que se da el efecto de caja negra. Se han utilizado dos capas ocultas. La primera de 64 neuronas artificiales se basa en patrones básicos y la segunda de 32 recibe la información de la primera y busca patrones más complejos.

3. Esta capa genera la predicción final basándose en las relaciones lineales que las capas ocultas han identificado y decide si el régimen es alcista o bajista.

DNN B:

Es un modelo igual que el DNN A pero de 32 y 16 neuronas en las capas ocultas. El objetivo de este modelo es discernir que activo utilizar como refugio cuando el DNN A ha decidido que nos encontramos en un régimen bajista.

Este modelo como todos los modelos de ML requiere de entrenamiento. En el caso de nuestro modelo de DNN, nuestro modelo asigna pesos aleatorios, calcula su error y mediante un algoritmo de optimización vuelve a realizar el mismo testeo de forma constante.

Además, nuestro modelo en particular está clasificado de forma jerárquica. Está programado para que inicialmente el programa de DNN clasifique el régimen en el que nos encontramos (DNN A). Si es un régimen "bullish" asignará más peso a acciones (SP500) o si es "bearish" asignará más peso a activos refugio (bonos o REITS). Una vez establecido este p y 1-p, se realiza una tarea de regresión para determinar que activo refugio tendrá un retorno esperado mayor, los bonos o los REITS (DNN B).

El código utilizado para realizar este modelo se encuentra en el anexo 1 de este trabajo, en caso de que se quiera analizar, supervisar o replicar los resultados obtenidos.

Modelo de ML mediante "Random Forest"

El objetivo de este conjunto de árboles de decisión se basa en predecir la naturaleza de los mercados durante el próximo periodo o la asignación optima del capital para maximizar los retornos durante ese periodo. Los árboles de decisión no son capaces de predecir retornos de una manera precisa con bases de datos pequeñas como la que estaremos utilizando en este trabajo por lo que el objetivo de estos árboles será el de predecir si los REITS serán más rentables que los bonos durante el próximo periodo. Está decisión ha sido tomada con el fin de obtener más información cuantitativa respecto a la naturaleza de los REITs como valor refugio. Los comparamos con los bonos para analizar cual da un mayor retorno teniendo en cuenta que ambos son menos volátiles que las acciones.

Este sistema binario se entrena para que esencialmente los árboles del modelo predigan 1 si los REITs superarán a los bonos durante el próximo periodo o 0 si los bonos superaran a los REITs. Esta predicción no basta para poder determinar pesos en un porfolio, por lo que se creará otro modelo "Random Forest" para determinar la magnitud

de la ventaja entre un activo u otro. Si el modelo está al 95% seguro de que los REITs sobrepasarán a los bonos, se invertirá en acciones y REITs en un 95% y un 5% en bonos.

Para que este modelo no elija solo entre bonos o REITs se ha establecido un modelo de RF previo que como en el caso de DNN establece si nos encontramos en un mercado "bullish" o "bearish" asignado un peso a las acciones en función de esto.

El código utilizado para realizar este modelo se encuentra en el anexo 2 de este trabajo, en caso de que se quiera analizar, supervisar o replicar los resultados obtenidos.

Modelo de media varianza

Este modelo se basa en crear un sistema de "ventana corredera" que utiliza los datos históricos de esta ventana que se va modificando cada periodo para asignar pesos de forma mensual. La ventana es de 3 años por lo que cada mes se calcula el retorno medio y la covarianza de las 3 clases utilizando los datos diarios pertinentes. Después maximizamos la ratio de Sharpe vetando las posiciones en corto.

Este modelo no tiene en cuenta la ciclicidad del mercado ni es capaz de prever "clusters" de volatilidad por lo que será utilizado como un modelo base sobre el que comparar el resto de las opciones.

El código utilizado para realizar este modelo se encuentra en el anexo 3 de este trabajo, en caso de que se quiera analizar, supervisar o replicar los resultados obtenidos.

Modelo "Equal weights"

El objetivo de este modelo es el de tener un modelo que nos pueda servir como "benchmark" con los que comparar el resto de los modelos. Los pesos son constantes y el modelo no utiliza ni datos del pasado como el modelo de Markowitz, ni predicciones como los modelos de ML (Random Forest y DLL).

El código utilizado para realizar este modelo se encuentra en el anexo 4 de este trabajo, en caso de que se quiera analizar, supervisar o replicar los resultados obtenidos.

Métricas de Evaluación

Para evaluar el desempeño de los 4 modelos anteriormente mencionados se hará uso de 4 métricas:

1. Retornos anualizados durante el periodo de testeo (este periodo no incluye el periodo de entrenamiento en los modelos de ML)
2. Volatilidad anualizada
3. Ratio de Sharpe
4. Drawdawn máximo

Todas estas métricas serán obtenidas gracias a las carteras mensuales de cada modelo.

4. Resultados

Para analizar los resultados obtenidos utilizando los distintos modelos de este trabajo. Haremos uso de una gráfica con los distintos pesos y las métricas de evaluación.

Modelo "Equal weights"

Como hemos explicado en la metodología, el modelo de pesos iguales nos servirá como benchmark con el que comparar al resto de modelos de este trabajo. Su gráfica sería la siguiente:

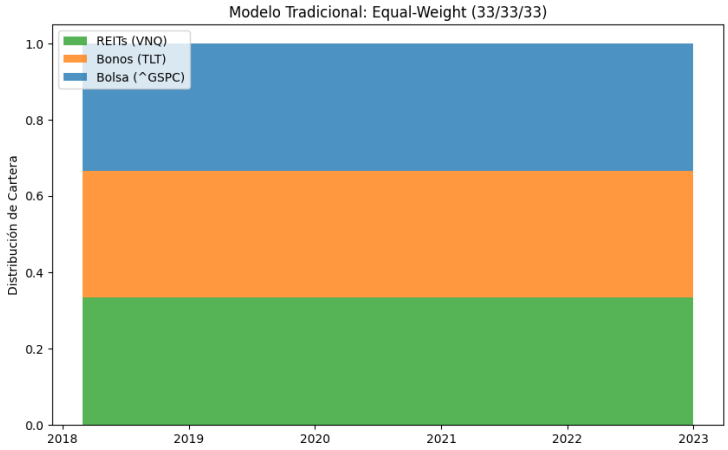

Gráfico 1. Modelo Tradicional Equal Weights (33/33/33)

Esta gráfica no es de gran utilidad pues como ya ha sido mencionado este modelo no tiene en cuenta datos ni pasados ni predicciones a lo largo del tiempo a la hora de asignar pesos. Sin embargo, es de gran interés observar sus métricas de evaluación:

Modelo	Retorno Anual	Volatilidad	Sharpe Ratio	Max Drawdown
Equal-Weight (33/33/33)	4.56%	13.69%	0.33	-27.80%

Tabla 1. Modelo Tradicional Equal Weights (33/33/33)

Podemos apreciar como el retorno anual y ratio de Sharpe es positivo. Este modelo que representa el máximo exponente de gestión pasiva muestra retornos moderados que en realidad muestran los periodos alcistas de 2019 a 2021 en contraposición con el periodo de crisis de 2020.

Un factor muy importante de este modelo es el drawdown, porque al no poseer estrategias de mitigación de riesgos como los modelos de ML este debería ser el mayor drawdawn de los 4 modelos analizados en este trabajo.

Por último, el ratio de Sharpe de este modelo de 0.33 no sirve como base para analizar el resto de los modelos. Si el ratio de Sharpe de alguno de los modelos posteriores fuera inferior a este, el modelo se consideraría obsoleto pues una gestión pasiva superaría su rendimiento.

Modelo de Markowitz de mínima varianza

A diferencia del modelo 33/33/33 anteriormente mencionado, el modelo de Markowitz si que tiene en cuenta rendimientos pasados para optimizar los pesos de una cartera. En el caso de este trabajo, se utilizan ventanas móviles de 36 meses con los datos históricos de los activos que se analizan para determinar los pesos óptimos.

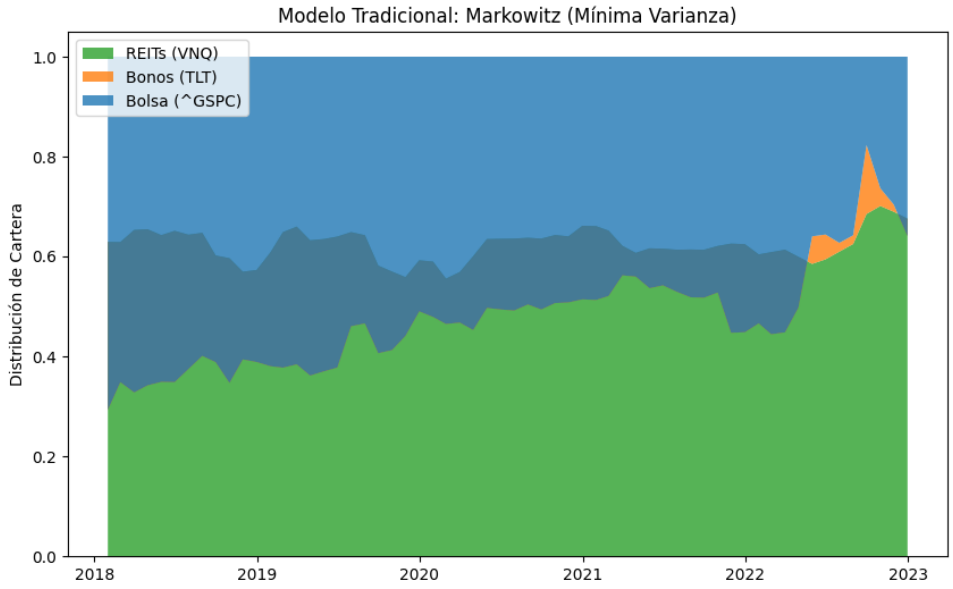

Gráfico 2. Modelo Tradicional Markowitz (Mínima Varianza)

A diferencia de los modelos de ML, como veremos más adelante, el modelo de Markowitz mantiene varios activos en cartera en todo momento. Se puede apreciar como dominan los REITs pues históricamente han aportado una combinación de retorno y baja volatilidad que el modelo prioriza a los bonos.

También podemos apreciar como los activos (SP500) dominan la asignación de pesos incluso durante periodos de alta volatilidad como en el caso de 2020, y no reaccionan hasta 2023 incluyendo bonos más defensivos en la cartera. Esto se puede ver explicado debido a la ventana móvil de 3 años que hemos asignado al modelo.

Modelo	Retorno Anual	Volatilidad	Sharpe Ratio	Max Drawdown
Markowitz (Mín. Var.)	8.39%	20.75%	0.40	-26.71%

Tabla 2. Modelo Tradicional Markowitz (Mínima Varianza)

El retorno anual de este modelo es sólido, duplicando casi al del modelo de pesos iguales. Esto demuestra que el modelo de Markowitz es capaz de captar el crecimiento de los mercados. Sin embargo, si nos centramos en la volatilidad anualizada del modelo podemos ver como esta es superior al modelo de pesos igual. El motivo de esto puede ser el de los "clusters" de volatilidad, como mencionamos en la metodología.

Un modelo que se basa en retornos pasados no es capaz de identificar momentos en los que la volatilidad se vuelve anormalmente elevada provocando una asignación de pesos en base a volatilidades que no representan el momento actual de la cartera. El modelo de pesos iguales al mantener sus partes iguales tiene asegurada una diversificación que el modelo de Markowitz pierde al realizar la optimización. A pesar de todo esto, podemos ver como el ratio de Sharpe aumenta haciendo uso de este modelo.

Modelo Random Forest

Ahora pasamos a los modelos de Machine Learning, que se caracterizan por las asignaciones agresivas de pesos y se basan no solo en retornos pasados sino en predicciones del comportamiento futuro de los activos.

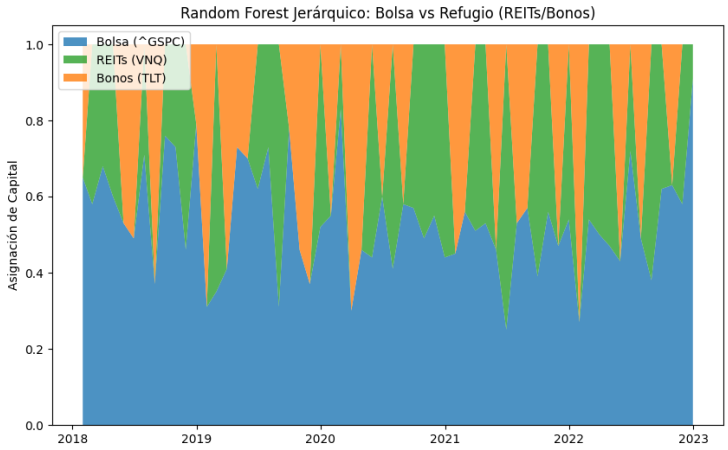

Gráfico 3. Modelo Random Forest Jerárquico

Si comparamos este gráfico al de Markowitz, podemos ver como el modelo de Random forest tiene una naturaleza binaria. Esto se debe a que el modelo confía en sus predicciones y asigna el capital al activo que cree que proporcionará el mayor rendimiento en base al entrenamiento recibido. En el caso de nuestro modelo, se ha creado una jerarquía para que el modelo establezca si nos encontramos en un mercado alcista o bajista y podemos apreciar como constantemente asigna un peso relativamente importante a las acciones. Sin embargo, a la hora de decidir entre REITs o bonos posee un carácter mucho más binario, constantemente saltando entre un activo y el otro lo que podría ser

considerado “Market timing”. El modelo establece cuando es más rentable utilizar el REIT o los bonos como activo refugio.

Este modelo primero determina a que nivel está expuesto a la renta variable y simultáneamente optimiza dentro de los activos refugio cual será el de mayor rentabilidad lo que se podría considerar una estrategia de gestión activa jerárquica.

Modelo	Retorno Anual	Volatilidad	Sharpe Ratio	Max Drawdown
Random Forest (Jerárquico)	6.65%	15.07%	0.44	-26.24%

Tabla 3. Modelo Random Forest Jerárquico

Si pasamos a analizar las métricas de evaluación, podemos ver como el retorno anual de RF a pesar de ser un poco menor al del modelo de Markowitz es más eficiente si tenemos en cuenta el ratio de Sharpe.

También se puede apreciar una reducción drástica de la volatilidad de más de un 5% respecto al modelo de Markowitz, aunque mayor al modelo de pesos iguales. A pesar de esto, el modelo de RF no supo predecir la caída producida por el COVID lo que denota que incluso los modelos de ML poseen problemas a la hora de lidiar con eventos macroeconómicos no predecibles.

Modelo DNN

Este modelo basado en redes neuronales debería ser el más preciso de todos debido a su complejidad. Sin embargo, podemos apreciar que este no ha sido el caso.

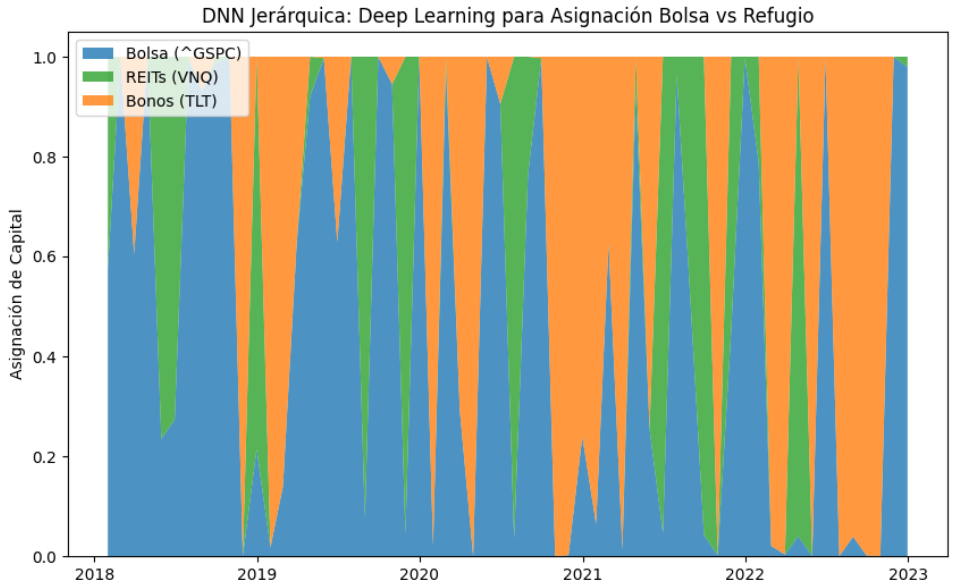

Gráfico 4. Modelo Deep Neural Networks (DNN)

En primer lugar, es de gran interés apreciar que mientras que Markowitz prioriza los REITS, y el modelo de RF utilizaba REITs o bonos en función del momento, el modelo de DNN prioriza en gran medida los bonos salvo en pequeños periodos alcistas en los que utiliza los REITs como complemento de las acciones. Esto contradice la literatura habitual que presenta al Real Estate como activo refugio.

Modelo	Retorno Anual	Volatilidad	Sharpe Ratio	Max Drawdown
Deep Neural Network (DNN)	-3.91%	14.48%	-0.27	-39.03%

Tabla 4. Modelo Deep Neural Networks (DNN)

Analizando las métricas de evaluación de este modelo podemos ver los aspectos menos deseables de utilizar un modelo de ML. Retornos anuales y un ratio de Sharpe negativos e incluso el mayor drawdawn de todos los modelos utilizados incluyendo el de pesos iguales. Estos resultados tan negativos se deben a dos motivos.

El "overfitting" o sobreajuste es un error que cometen los modelos de ML debido a que establece relaciones no lineales demasiado específicas durante los periodos de entrenamiento volviéndose demasiado sensibles a ciertas situaciones lo que conlleva a errores.

En 2022 se dio un Cisne negro en el que cayeron acciones y bonos a la vez, y el modelo en vez de refugiarse en los REITs o el Risk free, debido al periodo en el que fue entrenado, entra en un bucle de grandes pérdidas que explican ese máximo drawdawn del -39%.

Resultados conjuntos

Aunque ya han sido mencionados de forma individual los resultados de cada modelo, es interesante analizar todos los resultados en conjunto para poder analizar cuáles han sido los resultados relativos de cada uno de ellos y si hay métricas de evaluación en la que han podido coincidir en mayor o menor medida.

Modelo	Retorno Anual	Volatilidad	Sharpe Ratio	Max Drawdown
Equal-Weight (33/33/33)	4.56%	13.69%	0.33	-27.80%
Markowitz (Mín. Var.)	8.39%	20.75%	0.40	-26.71%
Random Forest (Jerárquico)	6.65%	15.07%	0.44	-26.24%
Deep Neural Network (DNN)	-3.91%	14.48%	-0.27	-39.03%

Tabla 5. Resultados de los modelos

El claro ganador de este trabajo es el modelo de Random Forest Jerárquico. Aunque el modelo de Markowitz posee un retorno anualizado mayor podríamos decir que el modelo de Random Forest ha sido mucho más eficiente a la hora de ajustar el riesgo a lo largo del tiempo.

Posee el mejor ratio de Sharpe que se podría considerar el ratio de mayor importancia en finanzas pues relativiza el retorno a la volatilidad experimentada superando en 4 puntos porcentuales al modelo de Markowitz. También presenta el menor drawdown por lo que supo enfrentarse a la crisis del COVID minimizando perdidas frente al resto de modelos.

El modelo de DNN es la gran sorpresa negativa pues a pesar de su complejidad no ha sabido optimizar los retornos durante este periodo y ha obtenido retornos absolutos negativos. Esto se puede deber como hemos comentado en el apartado de marco teórico a problemas como el overfitting o el cambio de paradigma tras cisnes negros como lo fue la crisis del COVID.

El resto de los modelos (Markowitz y 1/N) muestran la robustez de los modelos tradicionales con resultados positivos y drawdowns similares, aunque muy distintos en cuanto a volatilidad y retorno anual. Por un lado, Markowitz cumple con el objetivo de maximizar retorno, pero a costa de una volatilidad muy alta mientras que el modelo de equal weights es el modelo de menor volatilidad, pero posee el retorno más de bajo de los modelos con resultados positivos.

Papel de los REITs en periodos de alta volatilidad

El hecho de que el modelo Random Forest haya sido el más exitoso nos anima a fijarnos en como ha asignado los pesos de los REITs durante periodos de volatilidad, en el caso de este trabajo durante la crisis del COVID en 2020. La lógica jerárquica de este modelo divide entre mercados alcistas o bajistas y solo en los momentos bajistas pone a competir a los REITs contra los bonos.

Esto implica que los REITs si actúan como valor refugio de forma efectiva, sin embargo, su utilización en sustitución de los bonos no viene condicionada por los periodos de alta volatilidad como la crisis del COVID, sino que se debe a otros motivos que exceden el alcance de este trabajo. Podría ser como hemos mencionado en el marco

teórico que se deba a los tipos de interés y como afectan estos a los REITS de forma especialmente negativa.

Otro argumento que defiende el hecho de que los REITs tienen un carácter refugio es que el modelo de “equal weights” fue el de menor volatilidad total lo que sugiere que cuando este activo se añade al binomio acción / bono la cartera tiende a ser más conservadora con menor volatilidad y rendimiento.

Por otro lado, es cierto que el modelo de Markowitz que asigna pesos altos durante todo el periodo a los REITs posee la mayor volatilidad del conjunto de modelos, pero esto se puede deber a la ausencia de predicción de este modelo y su incapacidad de adaptarse a shocks como la crisis del COVID debido a su ventana rodante. Hasta que el mercado bajista no domina la ventana el modelo no asigna pesos mayores a los bonos. Todo esto se puede ver claramente si analizamos los pesos mensuales asignados por cada modelo durante el periodo de prueba al activo REITs:

Fecha	DNN	1/N	Markowit	Random Fores
31/01/2018	0,42	0,33	0,63	0,00
28/02/2018	0,00	0,33	0,63	0,42
31/03/2018	0,00	0,33	0,65	0,32
30/04/2018	0,00	0,33	0,65	0,40
31/05/2018	0,77	0,33	0,64	0,00
30/06/2018	0,73	0,33	0,65	0,00
31/07/2018	0,01	0,33	0,64	0,29
31/08/2018	0,00	0,33	0,65	0,00
30/09/2018	0,01	0,33	0,60	0,24
31/10/2018	0,00	0,33	0,60	0,27
30/11/2018	0,00	0,33	0,57	0,54
31/12/2018	0,79	0,33	0,57	0,00
31/01/2019	0,00	0,33	0,61	0,00
28/02/2019	0,00	0,33	0,65	0,65
31/03/2019	0,00	0,33	0,66	0,00
30/04/2019	0,08	0,33	0,63	0,00
31/05/2019	0,00	0,33	0,63	0,00
30/06/2019	0,00	0,33	0,64	0,38
31/07/2019	0,00	0,33	0,65	0,27
31/08/2019	0,92	0,33	0,64	0,69
30/09/2019	0,00	0,33	0,58	0,00
31/10/2019	0,00	0,33	0,57	0,00
30/11/2019	0,96	0,33	0,56	0,00
31/12/2019	0,00	0,33	0,59	0,48
31/01/2020	0,00	0,33	0,59	0,00
29/02/2020	0,02	0,33	0,56	0,17
31/03/2020	0,00	0,33	0,57	0,00
30/04/2020	0,00	0,33	0,60	0,00
31/05/2020	0,00	0,33	0,63	0,56
30/06/2020	0,00	0,33	0,64	0,00
31/07/2020	0,97	0,33	0,64	0,59
31/08/2020	0,24	0,33	0,64	0,00
30/09/2020	0,00	0,33	0,64	0,43
31/10/2020	0,00	0,33	0,64	0,51
30/11/2020	0,00	0,33	0,64	0,45
31/12/2020	0,00	0,33	0,66	0,56
31/01/2021	0,00	0,33	0,66	0,00
28/02/2021	0,00	0,33	0,65	0,00
31/03/2021	0,00	0,33	0,62	0,49
30/04/2021	0,07	0,33	0,61	0,47
31/05/2021	0,00	0,33	0,62	0,00
30/06/2021	0,95	0,33	0,62	0,75
31/07/2021	0,03	0,33	0,61	0,00
31/08/2021	0,49	0,33	0,61	0,00
30/09/2021	0,96	0,33	0,61	0,61
31/10/2021	0,00	0,33	0,62	0,44
30/11/2021	0,55	0,33	0,63	0,00
31/12/2021	0,00	0,33	0,62	0,46
31/01/2022	0,21	0,33	0,60	0,00
28/02/2022	0,00	0,33	0,61	0,46
31/03/2022	0,00	0,33	0,61	0,50
30/04/2022	0,96	0,33	0,60	0,53
31/05/2022	0,00	0,33	0,59	0,00
30/06/2022	0,00	0,33	0,59	0,28
31/07/2022	0,00	0,33	0,61	0,00
31/08/2022	0,00	0,33	0,62	0,62
30/09/2022	0,00	0,33	0,68	0,38
31/10/2022	0,00	0,33	0,70	0,00
30/11/2022	0,00	0,33	0,69	0,42
31/12/2022	0,02	0,33	0,68	0,09

Tabla 6. Pesos mensuales del activo REITs en los 4 modelos

5. Conclusiones

Resumen de los hallazgos

En este trabajo hemos podido analizar distintos modelos, su rentabilidad, eficiencia, volatilidad y máximo drawdawn pero sobre todo poniendo énfasis en como estos han asignado pesos al activo de referencia que es de los REITs.

Se puede apreciar como los distintos modelos utilizan el activo REITs de forma distinta. Markowitz lo otorga un poder fundamental, RF lo utiliza de forma intercambiable a los bonos y DNN lo utiliza como un complemento a las acciones. Esta evidencia se posiciona en contra de la literatura tradicional que establece que el Real Estate es un activo refugio y se puede apreciar tanto en el modelo de Markowitz como de RF los bonos son la respuesta de ambos modelos a la crisis de 2020 por el COVID.

Otro hallazgo de relevancia para este trabajo es el del fracaso del modelo de DNN. Esto se puede deber a los periodos de datos escogidos pues la crisis de 2020 no tenía relación alguna con los mercados financieros o debido al uso de ventanas de entrenamiento demasiado cortas. Sea por los motivos que sean, queda demostrado que los modelos más complejos no siempre son los más efectivos y que una estrategia simple muchas veces puede sobrepasar aquellas que no están correctamente diseñadas.

A pesar de esto, es cierto que el modelo con mayor Sharpe es el modelo de Random forest de gestión activa jerarquizada lo que demuestra que modelos de ML adecuados a la calidad y cantidad de datos si que pueden batir a los métodos tradicionales como el modelo de Markowitz.

Todo esto nos lleva a suponer que el activo REITs si se puede considerar un activo refugio pero no siempre durante periodos de alta volatilidad, sino que se utilizará en sustitución de los bonos en situaciones específicas que exceden al alcance de este trabajo.

Limitaciones del trabajo

A lo largo de este trabajo se han podido evidenciar varias limitaciones que sería importante destacar para comprender la profundidad y fiabilidad de este trabajo.

En primer lugar, es importante denotar que para que los modelos de ML no fueran especialmente radicales a la hora de asignar pesos ha sido necesario implementar una estrategia jerárquica en estos. Si no se hubiese hecho esto, los modelos hubieses escogido las acciones, bonos o REITs de manera unitaria y muy cambiante abusando de supuestos como el coste nulo de transacciones que implementamos en este trabajo.

También es importante recalcar que el modelo de DNN no ha sido exitoso en absoluto, pues a obtenido rendimientos negativos debido a fenómenos que ya hemos explicado como el sobreajuste. Existen estrategias para poder atenuar el efecto del sobreajuste, pero exceden el nivel de este trabajo y por tanto no han sido utilizadas para tratar de mejorar el rendimiento del modelo de DNN.

Por último, también se debe informar que los modelos de ML mejoran su funcionamiento en gran medida con bases de datos más amplias por lo que hay que tener en cuenta el tamaño de la base de datos utilizada en este trabajo a la hora de evaluar los rendimientos de estos modelos.

Recomendaciones para futuras investigaciones

Una vez explicadas las limitaciones de este trabajo procedo a explicar las recomendaciones que haría para futuras investigaciones en esta área.

Utilizaría una base de datos mayor, aunque fuera necesario el uso de capacidad computacional que exceda la de un ordenador convencional. Para ello se pueden solicitar CPUs externos que procesan los modelos de ML de forma más eficiente.

También sería interesante explorar otros modelos jerárquicos a la hora de programar los modelos de ML. En este trabajo se han dividido en dos partes en las que se predecía e régimen y luego se asignaban pesos en función de eso, pero existen otros modelos más complejos en los que se puede incluso utilizar predictores externos más haya de los datos históricos para crear jerarquías más complejas.

Por último, también seria de especial relevancia incluir otros activos refugio en los modelos como “commodities” u oro para analizar no solo como se comportan los REITs en relación a los bonos sino también respecto al oro y otros activos considerados refugio.

Conclusión final

Después de analizar los 4 modelos de este trabajo, sus diferencias y cómo estás pueden afectar a la asignación de pesos y, en específico, al activo REITs podemos sugerir basándonos en los resultados que este activo es efectivamente un activo refugio como sugieren ciertos académicos. Esto se puede deber a su comportamiento frente a la inflación o la contraposición entre el ciclo inmobiliario y el ciclo bursátil.

Sin embargo, también los resultados sugieren que la utilización del activo REITs frente a los bonos como activo refugio no es siempre superior, sino que dependerá de factores que exceden el alcance de este trabajo (se podría deber a los tipos de interés u otros factores) que activo es más eficiente como reserva de valor en periodos de alta volatilidad.

6. Declaración de uso de herramientas de inteligencia artificial generativa en Trabajos Fin de Grado

Por la presente, yo, Alejandro Jofre Álvarez, estudiante del Grado en Administración y Dirección de Empresas con Mención Internacional (E-4) de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Función del Real Estate en un porfolio: comparativa a través de modelos tradicionales y machine learning", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa *ChatGPT* u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

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

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

Fecha: 10/03/2026

Firma: Alejandro Jofre Álvarez

7. Bibliografía

1. Assimakopoulos, V. (2013). *Real estate appraisal: A review of valuation methods*. ResearchGate. https://www.researchgate.net/profile/Vassilis-Assimakopoulos/publication/241684887_Real_estate_appraisal_A_review_of_valuation_methods/links/5abcb3eba6fdcccaa6658885/Real-estate-appraisal-A-review-of-valuation-methods.pdf
2. Bond University. (s. f.). *Risk management in the real estate development industry*.https://pure.bond.edu.au/ws/portalfiles/portal/18265475/Risk_Management_in_the_Real_Estate_Development_Industry.pdf
3. DeMiguel, V., Garlappi, L., y 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
4. Eke, P. (2023). A review of real estate valuation and optimal pricing techniques. **Asian Economic and Financial Review**. https://www.researchgate.net/profile/Patrick-Eke/publication/370419338_A_REVIEW_OF_REAL_ESTATE_VALUATION_AND_OPTIMAL_PRICING_TECHNIQUES/links/644f957a97449a0e1a6d04a6/A-REVIEW-OF-REAL-ESTATE-VALUATION-AND-OPTIMAL-PRICING-TECHNIQUES-Asian-Economic-and-Financial-Review.pdf
5. Günther, C., et al. (2022). *The role of real estate in a mixed-asset portfolio and the impact of illiquidity* [PDF].

6. İksad Yayın. (2021). *Modern methods approach in real estate valuation*. [https://iksadyayinevi.com/wp-content/uploads/2021/11/MODERN-METHODS-APPROACH-IN-REAL-ESTATE-VALUATION.pdf] (https://iksadyayinevi.com/wp-content/uploads/2021/11/MODERN-METHODS-APPROACH-IN-REAL-ESTATE-VALUATION.pdf)
7. Ling, D., y Naranjo, A. (2015). *Real estate investment performance*. REIT.com.https://www.reit.com/sites/default/files/media/PDFs/LingNaranjo2015.pdf
8. Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, *7*(1), 77-91. https://doi.org/10.2307/2975974
9. Mull, S. R., y Soenen, L. A. (1997). U.S. REITs as an Asset Class in International Investment Portfolios. *Financial Analysts Journal, 53*(2), 55-61. https://doi.org/10.2469/faj.v53.n2.2072
10. Olanrewaju, A. (2023). *AI-driven adaptive asset allocation: A machine learning approach to dynamic portfolio* [ResearchGate preprint]. [https://www.researchgate.net/profile/Ayobami-Olanrewaju/publication/390442801_AI-Driven_Adaptive_Asset_Allocation_A_Machine_Learning_Approach_to_Dynamic_Portfolio/links/67fa79860241d5400b9aa1/AI-Driven-Adaptive-Asset-Allocation-A-Machine-Learning-Approach-to-Dynamic-Portfolio.pdf] (https://www.researchgate.net/profile/Ayobami-Olanrewaju/publication/390442801_AI-Driven_Adaptive_Asset_Allocation_A_Machine_Learning_Approach_to_Dynamic_Portfolio/links/67fa79860241d5400b9aa1/AI-Driven-Adaptive-Asset-Allocation-A-Machine-Learning-Approach-to-Dynamic-Portfolio.pdf)
11. Robinson, S., y McIntosh, M. G. (2022). A Literature Review of Environmental, Social, and Governance (ESG) in Commercial Real Estate. *Journal of Real Estate Literature*, *30*(1-2), 54-67. https://doi.org/10.1080/09277544.2022.2106639
12. TIAS School for Business and Society. (s. f.). *Why real estate?* [https://www.tias.edu/docs/default-source/Kennisartikelen/why-real-

estate.pdf](https://www.tias.edu/docs/default-source/Kennisartikelen/why-real-estate.pdf)

8. Anexos

Anexo 1

```
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.neural_network import MLPClassifier, MLPRegressor
from sklearn.preprocessing import StandardScaler


# 1. Descarga de datos
tickers = ["VNQ", "TLT", "^GSPC"]
print("Descargando datos para la Red Neuronal...")
data = yf.download(tickers, start="2007-01-01", end="2022-12-31")['Close']
returns = data.resample('ME').last().pct_change().dropna()


# 2. Preparación de Features (Entradas de la red)
X = returns.shift(1).dropna()
# Escalamos los datos (vital para Redes Neuronales)
scaler = StandardScaler()
X_scaled = pd.DataFrame(scaler.fit_transform(X), index=X.index, columns=X.columns)


X_train = X_scaled[:"2017"]
X_test = X_scaled["2018":]


# 3. Construcción de las Redes Neuronales (Arquitectura DNN)
# Modelo A: Clasificador de Régimen (Bolsa vs Refugio)
y_class = (returns['^GSPC'] > returns[['VNQ', 'TLT']].mean(axis=1)).astype(int).loc[X_train.index]
dnn_clf = MLPClassifier(hidden_layer_sizes=(64, 32), activation='relu', max_iter=1000, random_state=42)
dnn_clf.fit(X_train, y_class)


# Modelo B: Regresor para elegir dentro de Refugio (REITs vs Bonos)
y_refugio = returns.loc[X_train.index, ['VNQ', 'TLT']]
dnn_regr = MLPRegressor(hidden_layer_sizes=(64, 32), activation='relu', max_iter=1000, random_state=42)
dnn_regr.fit(X_train, y_refugio)
```

- # 4. Ejecución de la lógica Jerárquica
- probs_bolsa = dnn_clf.predict_proba(X_test)[:, 1]
- pred_refugio = dnn_regr.predict(X_test) # Devuelve predicciones para [VNQ, TLT]

- pesos_lista = []
- for i in range(len(X_test)):
- p_bolsa = probs_bolsa[i]
- w_sp5 = p_bolsa
- w_bloque_refugio = 1 - p_bolsa

- # Decisión interna del refugio basada en la predicción de la DNN
- if pred_refugio[i, 0] > pred_refugio[i, 1]: # Si Pred VNQ > Pred TLT
- w_vnq = w_bloque_refugio
- w_tlt = 0.0
- else:
- w_vnq = 0.0
- w_tlt = w_bloque_refugio

- pesos_lista.append([w_vnq, w_tlt, w_sp5])

- df_pesos = pd.DataFrame(pesos_lista, index=X_test.index, columns=tickers)

- # 5. Métricas Finales
- portfolio_rets = (returns.loc[X_test.index] * df_pesos).sum(axis=1)
- ann_ret = (1 + portfolio_rets.mean())**12 - 1
- ann_vol = portfolio_rets.std() * np.sqrt(12)
- sharpe = ann_ret / ann_vol
- cum_ret = (1 + portfolio_rets).cumprod()
- max_dd = ((cum_ret / cum_ret.cummax()) - 1).min()

- # 6. Exportación y Gráfica
- df_pesos.to_excel("Pesos_DNN_Final.xlsx")

- plt.figure(figsize=(10, 6))
- plt.stackplot(df_pesos.index, df_pesos['^GSPC'], df_pesos['VNQ'], df_pesos['TLT'],
    - labels=['Bolsa (^GSPC)', 'REITs (VNQ)', 'Bonos (TLT)'],
    - colors=['#1f77b4', '#2ca02c', '#ff7f0e'], alpha=0.8)
- plt.title("DNN Jerárquica: Deep Learning para Asignación Bolsa vs Refugio")
- plt.ylabel("Asignación de Capital")
- plt.legend(loc='upper left')
- plt.savefig("Grafica_DNN_Final.png")

- print("\n" + "="*40)
- print("   RESULTADOS FINALES: DEEP NEURAL NETWORK (DNN)")
- print("="*40)
- print(f"1. Retorno Anualizado: {ann_ret:.2%}")
- print(f"2. Volatilidad Anualizada: {ann_vol:.2%}")
- print(f"3. Ratio de Sharpe: {sharpe:.2f}")
- print(f"4. Max Drawdown: {max_dd:.2%}")
- print("="*40)
- plt.show()

Anexo 2

```
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.ensemble import RandomForestClassifier, RandomForestRegressor


# 1. Descarga de datos
tickers = ["VNQ", "TLT", "^GSPC"]
print("Descargando datos...")
data = yf.download(tickers, start="2007-01-01", end="2022-12-31")['Close']
returns = data.resample('ME').last().pct_change().dropna()


# 2. Preparación de Modelos
X = returns.shift(1).dropna()
X_train = X[:"2017"]
X_test = X["2018":]


# MODELO A: Clasificador para decidir peso de Bolsa (p)
# Label: 1 si el S&P500 rinde más que el promedio de VNQ y TLT
y_class = (returns['^GSPC'] > returns[['VNQ', 'TLT']].mean(axis=1)).astype(int).loc[X_train.index]
clf = RandomForestClassifier(n_estimators=100, random_state=42)
clf.fit(X_train, y_class)


# MODELO B: Regresores para el bloque de "Refugio" (REITs vs Bonos)
regr_vnq = RandomForestRegressor(n_estimators=100, random_state=42)
regr_tlt = RandomForestRegressor(n_estimators=100, random_state=42)
regr_vnq.fit(X_train, returns.loc[X_train.index, 'VNQ'])
regr_tlt.fit(X_train, returns.loc[X_train.index, 'TLT'])


# 3. Ejecución de la lógica Jerárquica
probs_bolsa = clf.predict_proba(X_test)[:, 1]
pred_vnq = regr_vnq.predict(X_test)
pred_tlt = regr_tlt.predict(X_test)


pesos_lista = []
```

- for i in range(len(X_test)):
- p_bolsa = probs_bolsa[i]
- w_sp5 = p_bolsa # Peso de la Bolsa

- w_bloque_refugio = 1 - p_bolsa

- # Dentro del refugio, elegimos el ganador
- if pred_vnq[i] > pred_tlt[i]:
- w_vnq = w_bloque_refugio
- w_tlt = 0.0
- else:
- w_vnq = 0.0
- w_tlt = w_bloque_refugio

- pesos_lista.append([w_vnq, w_tlt, w_sp5])

- df_pesos = pd.DataFrame(pesos_lista, index=X_test.index, columns=tickers)

- # 4. Cálculo de Métricas Finales
- portfolio_rets = (returns.loc[X_test.index] * df_pesos).sum(axis=1)
- ann_ret = (1 + portfolio_rets.mean())**12 - 1
- ann_vol = portfolio_rets.std() * np.sqrt(12) # <--- Volatilidad Anualizada
- sharpe = ann_ret / ann_vol
- cum_ret = (1 + portfolio_rets).cumprod()
- max_dd = ((cum_ret / cum_ret.cummax()) - 1).min()

- # 5. Exportación y Gráfica
- df_pesos.to_excel("Pesos_RF_Bolsa_Refugio.xlsx")

- plt.figure(figsize=(10, 6))
- plt.stackplot(df_pesos.index, df_pesos['^GSPC'], df_pesos['VNQ'], df_pesos['TLT'],
    - labels=['Bolsa (^GSPC)', 'REITs (VNQ)', 'Bonos (TLT)'],
    - colors=['#1f77b4', '#2ca02c', '#ff7f0e'], alpha=0.8)
- plt.title("Random Forest Jerárquico: Bolsa vs Refugio (REITs/Bonos)")
- plt.ylabel("Asignación de Capital")

- plt.legend(loc='upper left')
- plt.savefig("Grafica_RF_Final.png")

- print("\n" + "="*40)
- print("   RESULTADOS FINALES: RANDOM FOREST")
- print("="*40)
- print(f"1. Retorno Anualizado: {ann_ret:.2%}")
- print(f"2. Volatilidad Anualizada: {ann_vol:.2%}")
- print(f"3. Ratio de Sharpe: {sharpe:.2f}")
- print(f"4. Max Drawdown: {max_dd:.2%}")
- print("="*40)
- plt.show()

Anexo 3

```
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt


# 1. Descarga de datos (Periodo completo para tener histórico de 36 meses antes de 2018)
tickers = ["VNQ", "TLT", "^GSPC"]
data = yf.download(tickers, start="2015-01-01", end="2022-12-31")['Close']
returns = data.resample('ME').last().pct_change().dropna()


# 2. Definición del periodo de testeo (2018-2022) para que sea comparable con ML
fechas_test = returns.index[returns.index >= "2018-01-01"]


# 3. Cálculo de Pesos de Markowitz (Mínima Varianza)
pesos_lista = []
for fecha in fechas_test:
# Miramos los 36 meses anteriores a la fecha actual
ventana = returns.loc[:fecha].iloc[-37:-1]
cov = ventana.cov()
inv_cov = np.linalg.pinv(cov)
ones = np.ones(len(inv_cov))
# Fórmula de la cartera de mínima varianza global
w = (inv_cov @ ones) / (ones.T @ inv_cov @ ones)
pesos_lista.append(w)


df_pesos = pd.DataFrame(pesos_lista, index=fechas_test, columns=tickers)
# Asegurar que sumen 1 (evitar errores de redondeo)
df_pesos = df_pesos.div(df_pesos.sum(axis=1), axis=0)


# 4. Cálculo de Métricas de Rendimiento
portfolio_rets = (returns.loc[fechas_test] * df_pesos).sum(axis=1)


ann_ret = (1 + portfolio_rets.mean())**12 - 1
ann_vol = portfolio_rets.std() * np.sqrt(12)
```

- sharpe = ann_ret / ann_vol

- cum_ret = (1 + portfolio_rets).cumprod()
- max_dd = ((cum_ret / cum_ret.cummax()) - 1).min()

- # --- RESULTADOS ---

- # A. Guardar Excel
- df_pesos.to_excel("Pesos_Markowitz_Final.xlsx")

- # B. Generar Gráfica
- plt.figure(figsize=(10, 6))
- plt.stackplot(df_pesos.index, df_pesos['VNQ'], df_pesos['TLT'], df_pesos['^GSPC'],
    - labels=['REITs (VNQ)', 'Bonos (TLT)', 'Bolsa (^GSPC)'],
    - colors=['#2ca02c', '#ff7f0e', '#1f77b4'], alpha=0.8)
- plt.title("Modelo Tradicional: Markowitz (Mínima Varianza)")
- plt.ylabel("Distribución de Cartera")
- plt.legend(loc='upper left')
- plt.savefig("Grafica_Markowitz_Final.png")
- plt.show()

- # C. Mostrar Métricas por pantalla
- print("\n--- MÉTRICAS MARKOWITZ (Periodo Test: 2018-2022) ---")
- print(f"1. Retorno Anualizado: {ann_ret:.2%}")
- print(f"2. Volatilidad Anualizada: {ann_vol:.2%}")
- print(f"3. Ratio de Sharpe: {sharpe:.2f}")
- print(f"4. Max Drawdown: {max_dd:.2%}")

Anexo 4

```
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt


# 1. Descarga de datos
tickers = ["VNQ", "TLT", "^GSPC"]
data = yf.download(tickers, start="2018-01-01", end="2022-12-31")['Close']
returns = data.resample('ME').last().pct_change().dropna()


# 2. Asignación de Pesos (Fijos al 33.33%)
fechas_test = returns.index
weights_fixed = [1/3, 1/3, 1/3]
df_pesos = pd.DataFrame([weights_fixed] * len(fechas_test), index=fechas_test, columns=tickers)


# 3. Cálculo de Métricas de Rendimiento
portfolio_rets = (returns * df_pesos).sum(axis=1)


ann_ret = (1 + portfolio_rets.mean())**12 - 1
ann_vol = portfolio_rets.std() * np.sqrt(12)
sharpe = ann_ret / ann_vol


cum_ret = (1 + portfolio_rets).cumprod()
max_dd = ((cum_ret / cum_ret.cummax()) - 1).min()


# --- EXPORTACIÓN Y GRÁFICA ---


# A. Guardar Excel
df_pesos.to_excel("Pesos_EqualWeight_Final.xlsx")


# B. Generar Gráfica
plt.figure(figsize=(10, 6))
```

- plt.stackplot(df_pesos.index, df_pesos['VNQ'], df_pesos['TLT'], df_pesos['^GSPC'],
    - labels=['REITs (VNQ)', 'Bonos (TLT)', 'Bolsa (^GSPC)'],
    - colors=['#2ca02c', '#ff7f0e', '#1f77b4'], alpha=0.8)
- plt.title("Modelo Tradicional: Equal-Weight (33/33/33)")
- plt.ylabel("Distribución de Cartera")
- plt.legend(loc='upper left')
- plt.savefig("Grafica_EqualWeight_Final.png")
- plt.show()

- # C. Mostrar Métricas
- print("\n--- MÉTRICAS EQUAL-WEIGHT (Periodo Test: 2018-2022) ---")
- print(f"1. Retorno Anualizado: {ann_ret:.2%}")
- print(f"2. Volatilidad Anualizada: {ann_vol:.2%}")
- print(f"3. Ratio de Sharpe: {sharpe:.2f}")
- print(f"4. Max Drawdown: {max_dd:.2%}")