



Facultad de Empresariales, ICADE

EVALUACIÓN DE MODELOS DE INVERSIÓN Y EL IMPACTO DE FACTORES ESG EN PERIODOS DE CRISIS ECONÓMICAS

Autor: Cristina Bautista Dixon

Director: Alejandro Rodríguez Gallego

MADRID | Junio 2024

Resumen

El auge del concepto de ESG (ambiental, social y de gobernanza) en el ámbito financiero reciente ha llevado a los inversores a preguntarse si las empresas que se adhieren a estas métricas pueden lograr rendimientos superiores. Este estudio aborda dicha cuestión, explorando además la optimización de la construcción de carteras de inversión. Para ello, se implementan tres modelos distintos: el modelo de Markowitz, el modelo de Black-Litterman y un algoritmo genético. Se analiza su eficacia en tres períodos de crisis económicas claves del siglo XXI: la Crisis Financiera de 2008, la Crisis del Euro de 2010 y la Crisis del COVID-19. Este enfoque no solo busca determinar la correlación entre las métricas ESG y el rendimiento financiero, sino también identificar cuál de los moldeos proporciona estrategias más efectivas para la gestión de carteras en tiempos de incertidumbre económica.

Palabras Clave

ESG, modelos financieros, Crisis Financiera de 2008, Crisis del Euro de 2010, Crisis del COVID-19, Markowitz, Black-Litterman, aprendizaje supervisado, conjunto training, conjunto test, overfitting, underfitting, métricas ESG

Abstract

The rise of the ESG (environmental, social and governance) concept in the recent financial arena has led investors to question whether companies that adhere to these metrics can achieve superior returns. This study addresses that question, while also exploring the optimization of investment portfolio construction. To this end, three different models are implemented: the Markowitz model, the Black-Litterman model and a genetic algorithm. Their effectiveness is analyzed in three key economic crisis periods of the 21st century: the 2008 Financial Crisis, the 2010 Euro Crisis and the COVID-19 Crisis. This approach not only seeks to determine the correlation between ESG metrics and financial performance, but also to identify which of the models provides more effective strategies for portfolio management in times of economic uncertainty.

Key Words

ESG, financial models, 2008 Financial Crisis, 2010 Euro Crisis, COVID-19 Crisis, Markowitz, Black-Litterman, supervised learning, training set, test set, overfitting, underfitting, ESG metrics

1.	Introducción	4
1.1	Presentación del tema	4
1.2	Justificación de la investigación	5
1.3	Metodología y estructura del trabajo	6
2.	Contexto macroeconómico en los diferentes momentos de crisis.....	8
2.1	Crisis financiera de 2008	8
2.2	Crisis del euro de 2010	11
2.3	Crisis del COVID-19	13
3.	Marco Teórico	15
3.1	Concepto de ESG.....	15
3.1.1	Métricas ESG	17
3.2	Índice S&P500.....	22
3.3	Aprendizaje supervisado y la división en conjuntos de Training y Test	22
3.4	Teoría de la cartera de Markowitz y Black-Litterman.....	24
3.5	Algoritmos genéticos en la optimización de carteras	26
4.	Metodología	27
4.1	Recopilación de datos históricos.....	27
4.2	Desarrollo del algoritmo aplicando el modelo de Markowitz, Black-Litterman y algoritmo genético	28
4.3	Evaluación actualizada del desempeño ESG en el S&P500.....	32
5.	Análisis y explicación de los resultados.....	35
5.1	Descripción de las carteras construidas	35
5.2	Análisis de rentabilidad en cada crisis y comparación entre las carteras	43
5.3	Identificación de Líderes ESG	46
6.	Conclusión.....	50
7.	Bibliografía.....	53
8.	Anexo	57

1. Introducción

En el contexto de este estudio, se explorará la optimización de la rentabilidad de carteras conformadas a partir del índice S&P500, además de evaluar aquellas empresas que forman el índice S&P500 en términos de factores ESG. Esta investigación busca determinar si hay algún tipo de relación entre la rentabilidad de las carteras y su ranking ESG en periodos de inestabilidad financiera.

1.1 Presentación del tema

El tema fundamental de este trabajo es analizar la eficacia de tres modelos diferentes de optimización de carteras de inversión durante periodos de crisis financieras, y determinar si existe alguna relación entre el desempeño de estas carteras y el ranking de empresas según sus prácticas ESG (ambientales, sociales y de gobernanza). Esta comparación se centra en tres periodos históricos de gran relevancia en el mundo financiero: la crisis financiera de 2008, la crisis del euro y la crisis provocada por la pandemia del COVID-19, con el fin de evaluar la rentabilidad de carteras optimizadas mediante modelos distintos y seleccionar el más eficiente en términos de rentabilidad.

Iniciando con una contextualización del estudio, se resalta la importancia creciente de la inversión sostenible en el panorama financiero contemporáneo, así como se traza una breve historia de las crisis financieras seleccionadas para el análisis. Se aborda la evolución del interés en las estrategias de inversión que incorporan criterios ESG, destacando su creciente relevancia en la gestión de carteras y decisiones de inversión. Además, se introduce el concepto de aprendizaje supervisado, el cual constituye la base metodológica sobre la que se probarán los modelos de optimización de carteras.

El análisis de los casos de crisis financieras ofrece una visión profunda sobre cada situación, considerando las causas, el desarrollo y las consecuencias de cada crisis, y su impacto en los mercados financieros. Este enfoque permite una evaluación comprensiva de cómo tales eventos han afectado históricamente a las inversiones y qué lecciones pueden extraerse para las estrategias de inversión futuras.

La presentación de los resultados incluye una evaluación detallada de la rentabilidad de las carteras optimizadas mediante diferentes modelos, proporcionando un análisis comparativo y explorando si existe correlación entre las carteras con mejor desempeño y las empresas con altas o bajas puntuaciones ESG durante los periodos de crisis.

1.2 Justificación de la investigación

La presente investigación se justifica por la creciente importancia de las estrategias de inversión sostenibles en el mercado financiero global y su potencial impacto en la rentabilidad de las carteras durante periodos de crisis económica. En un contexto donde la sostenibilidad y la responsabilidad corporativa ganan cada vez más relevancia, es fundamental entender si las inversiones con mayor rentabilidad tienen relación con aquellas empresas que aplican criterios ESG.

Se ha elegido el índice S&P500 como índice de referencia ya que este es uno de los índices más representativos y seguidos a nivel mundial, ofreciendo una visión clara del comportamiento del mercado estadounidense. Este índice es especial relevante en el contexto de las crisis financieras seleccionadas. Estas crisis, por su magnitud y su impacto global, presentan escenarios ideales para analizar la resiliencia y eficacia de diferentes estrategias de inversión.

Esta investigación también responde a una necesidad académica y práctica de comprender mejor la correlación entre la sostenibilidad y la estabilidad financiera en tiempos de incertidumbre. Con un enfoque analítico y empírico, el estudio busca aportar evidencia sobre la viabilidad de las inversiones ESG como un componente clave en la gestión de riesgos y la optimización de la rentabilidad, especialmente en periodos de alta volatilidad en los mercados.

Además, los resultados de este trabajo tendrán implicaciones significativas para inversores, gestores de carteras y responsables de políticas de inversión.

1.3 Metodología y estructura del trabajo

Para alcanzar los objetivos propuestos en esta investigación, se ha optado por un enfoque cuantitativo, centrado en la aplicación de métodos analíticos rigurosos para evaluar la rentabilidad y el riesgo de carteras óptimas basadas en el índice S&P500 durante periodos críticos de crisis financieras. La metodología implementada se desarrolla en varias etapas clave, cada una contribuyendo de manera esencial al análisis comprensivo de la temática abordada.

La investigación inicia con un análisis exhaustivo de las crisis financieras seleccionadas. Este análisis preliminar es fundamental para comprender el contexto económico y financiero en el que se desenvuelven las carteras de inversión durante los periodos de crisis.

Posteriormente, se procede a la recopilación de datos históricos de los índices obtenidos a través de Factset. El enfoque se centra en los periodos que abarcan los años 2006, 2007, 2008, 2009, 2010, 2018, 2019, 2020 y 2021. Para mantener la coherencia en el análisis, se asume que la composición de ambos índices se mantiene constante durante estos periodos.

La construcción de las carteras óptimas se realiza aplicando modelos de inversión consolidados, como los de Markowitz, Black-Litterman y un algoritmo genético, utilizando Python como herramienta de análisis. Cada una de estas modelos se aplica sobre periodos de precrisis para luego testear como de bien ha optimizado cada uno de los modelos para cada una de las crisis en los periodos postcrisis.

Una vez definidas las carteras, el trabajo se enfoca en la evaluación de su rendimiento. Para ello, se emplean diversas métricas de rendimiento y riesgo, incluyendo el índice de volatilidad, la covarianza, la correlación y el ratio de Sharpe. Este análisis permite comparar de manera efectiva la rentabilidad de ambas carteras en los diferentes periodos: antes, durante y después de las crisis financieras.

La estructura del trabajo, por consiguiente, se organiza de esta forma:

1. Introducción
2. Marco Teórico
3. Metodología

4. Análisis de datos y resultados

5. Conclusiones

Cada sección ha sido cuidadosamente diseñada para construir sobre la información presentada anteriormente, proporcionando un enfoque coherente y detallado para el análisis de la rentabilidad y el riesgo de las carteras durante periodos de crisis financiera.

2. Contexto macroeconómico en los diferentes momentos de crisis

El estudio del contexto macroeconómico durante las crisis financieras es crucial para entender las fluctuaciones del mercado y las estrategias de inversión. La crisis financiera de 2008, marcada por la caída del mercado inmobiliario y la desestabilización de instituciones financieras globales, transformó las normativas económicas y la gestión de riesgos (Mckibbin y Stoeckel, 2009). La crisis del euro de 2010 evidenció las limitaciones de la política monetaria en la eurozona, resaltando la necesidad de una mayor integración fiscal (Baldwin y Giavazzi, 2011). Por último, la crisis del COVID-19, causada por una pandemia global, desafió los modelos económicos establecidos y llevó a la implementación de medidas extraordinarias para sostener la economía (Ruesga Benito, 2021). Este análisis establece el marco para explorar cómo estas crisis afectaron la rentabilidad y el riesgo en las carteras de inversión seleccionadas.

2.1 Crisis financiera de 2008

La crisis financiera de 2008 representa un fenómeno de magnitud histórica, cuyas repercusiones se extendieron más allá del ámbito financiero para impactar la economía global. Este episodio evidenció la fragilidad de los sistemas financieros y las políticas económicas de la época. Surgida en el contexto de un mercado hipotecario volátil en Estados Unidos, la crisis rápidamente trascendió fronteras, afectando a instituciones financieras y economías alrededor del mundo.

La crisis tuvo su raíz en una serie de factores interconectados que desencadenaron una secuencia de eventos críticos. Uno de los factores centrales fue el aumento del gasto excesivo por parte de los ciudadanos estadounidenses, que culminó en niveles significativos de endeudamiento. Esta tendencia se vio influenciada por eventos importantes, como el atentado de las torres gemelas y el estallido de la burbuja puntocom en Estados Unidos. La burbuja puntocom fue el resultado de un período de especulación excesiva en las acciones de empresas tecnológicas en la década de 1990, caracterizado por la sobrevaloración de estas compañías. En el año 2000, esta burbuja finalmente

colapsó, provocando graves crisis financieras y pérdidas sustanciales de inversión (Griffin et al., 2011). En respuesta a estos eventos, el gobierno de Estados Unidos optó por reducir la tasa de interés como una medida para estimular la economía (Mosquera, 2020).

Como resultado, se produjo una afluencia considerable de capital del mercado inmobiliario, ya que los inversores percibieron la adquisición de propiedades como una oportunidad altamente rentable, impulsada por las bajas tasas de interés prevalecientes y no en la bolsa debido al estallido de la burbuja punto com. Este enfoque desmedido en la inversión inmobiliaria llevó a muchos individuos a adquirir propiedades que excedían sus capacidades económicas. El aumento en la demanda de viviendas, alimentado por la creencia de que los precios seguirían aumentando, dio lugar a lo que se conoce como la burbuja inmobiliaria (Zurita González et al., 2009). El problema se originó en parte debido a las prácticas de los bancos, quienes otorgaban préstamos, principalmente hipotecas, de gran cuantía a individuos con escasa capacidad crediticia, es decir, aquellos con bajos ingresos (RBA, 2020). Estos préstamos tenían períodos de amortización muy cortos y estaban respaldados por activos de venta lenta, como las propiedades inmobiliarias. Para mitigar el riesgo de impago, los bancos vendían los derechos de cobro a bancos de inversión, lo que incentivaba aún más la concesión de préstamos, ya que los bancos no asumían el riesgo directamente. Las hipotecas con alto riesgo de impago se denominaron Hipotecas Subprime, y sus derechos de cobro se agrupaban en paquetes conocidos como Mortgage-Backed Securities, con diferentes clasificaciones de riesgo, desde AAA para hipotecas de alta solvencia económica hasta C para las subprime (Official Government Edition, 2011). Para paliar la falta de interés de los bancos de inversión en adquirir una hipoteca subprime, los bancos combinaban hipotecas con diferentes clasificaciones de riesgo en estos paquetes. Sin embargo, esta práctica parecía poco relevante debido al crecimiento continuo del valor de los inmuebles, lo que sugería que la venta de estas compensaría cualquier incumplimiento hipotecario (Official Government Edition, 2011).

A pesar de ello, los bancos de inversión se protegieron mediante la contratación de Credit Default Swaps (CDS), instrumentos financieros que transfieren el riesgo de crédito entre los participantes del mercado, potencialmente facilitando una mayor eficiencia y distribución del riesgo (Bomfim, 2022). Sin embargo, el exceso de oferta en el mercado inmobiliario provocó una disminución en el valor de las propiedades, lo que llevó a

muchos titulares de hipotecas a dejar de pagarlas, ya que el valor de las hipotecas era inferior al de las propiedades asociadas. Esto resultó en una acumulación de propiedades no deseadas y con un valor de mercado depreciado, lo que generó grandes déficits en los balances de los bancos.

Ante esta situación, el gobierno de Estados Unidos optó por no rescatar a los bancos, lo que llevó a la quiebra de grandes instituciones financieras como Lehman Brothers (Conférence des Nations Unies sur le commerce et le développement, 2010), desencadenando una gran incertidumbre económica que tuvo un impacto negativo significativo en el mercado bursátil, donde los inversores comenzaron a deshacerse de sus activos. Como resultado, los bancos supervivientes se volvieron muy selectivos en la concesión de créditos, lo que provocó despidos masivos e incluso la bancarrota de muchas empresas, lo que a su vez contribuyó al aumento del desempleo en Estados Unidos. Esta crisis tuvo repercusiones a nivel mundial, ya que Estados Unidos redujo drásticamente sus importaciones extranjeras, afectando así al comercio internacional y, por ende, provocando una crisis global (Conférence des Nations Unies sur le commerce et le développement, 2010).

La realidad es que los mercados financieros ya estaban emitiendo señales de alerta antes de que la crisis se manifestara plenamente, manifestado en un incremento notable de la volatilidad que rompía con los patrones históricos establecidos (Figura 1). Índices bursátiles claves en Estados Unidos, como el NASDAQ-100 y el S&P500, reflejaron esta inestabilidad con incrementos en su volatilidad del 43,7% y 60,1% respectivamente. Este aumento no era meramente un evento aislado, sino la señal de una inminente y profunda transformación en la dinámica de los mercados de valores. Este fenómeno de creciente incertidumbre no se detuvo ahí, sino que se mantuvo y se intensificó durante el año siguiente al estallido de la crisis, marcando la progresiva propagación de las turbulencias del sector financiera hacia la economía mundial en su conjunto, de acuerdo con Wrobel (2017).

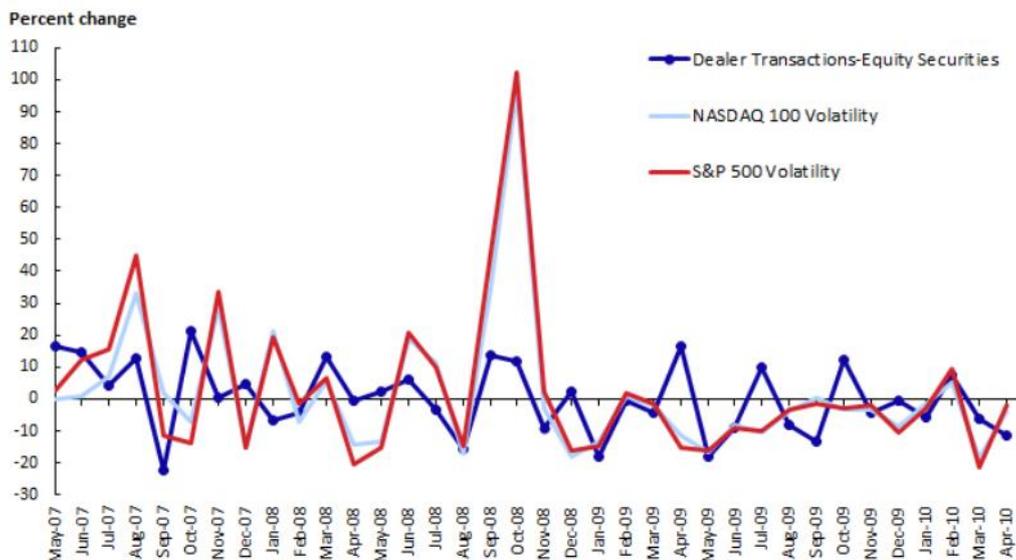


Figura 1. Índice de Precios al Productor para los márgenes de transacción de distribuidores en valores de renta variable, volatilidad esperada NASDAQ-100, volatilidad esperada S&P500 (Fuente: Wrobel, 2017)

2.2 Crisis del euro de 2010

La crisis del euro de 2010, derivada de la crisis financiera global de 2008, se destaca como una de las más grandes en la historia europea (Kräussl et al., 2016). Emergiendo a fines de 2009, su epicentro se ubicó en Grecia, un país que había inflado su crecimiento económico previo para cumplir con los requisitos de ingreso a la zona euro (FRANCOIS et al., 2015). Sin embargo, cuando estalló la crisis de 2008, Grecia se encontró con una deuda masiva de 280 mil millones que no podía pagar (James, 2024).

Esta situación llevó a una crisis de confianza, con los prestamistas retirando su apoyo y exigiendo tasas de interés exorbitantes para continuar otorgando préstamos a Grecia. En un intento desesperado por aliviar su deuda, Grecia consideró imprimir más dinero, pero al estar dentro de la eurozona, su política monetaria estaba contralada por el Banco Central Europeo (Becker & Ivashina, 2018).

Ante la inminente quiebra griega, la Troika compuesta por la Comisión Europea, el Fondo Monetario Internacional y el Banco Central Europeo intervinieron, proporcionando financiamiento a cambio de duras medidas de austeridad, incluyendo recortes de gastos y aumentos de impuestos (Szczepanski, 2019). Estas políticas resultaron en una recesión profunda y un alto desempleo en Grecia.

La crisis griega provocó una desconfianza generalizada en el sistema bancario europeo, provocada por la quiebra de Lehman Brothers. Otros países como España e Irlanda enfrentaron problemas similares debido a inversiones excesivas en el mercado inmobiliario (Baldwin & Giavazzi, 2015). La Troika también intervino en estos países, imponiendo medidas similares de austeridad. Aunque dichos rescates aliviaron las finanzas de estos países, la recesión persistió, exacerbando la deuda y la dependencia de préstamos externos. La incertidumbre resultante condujo a la creación del concepto de prima de riesgo, que reflejaba el interés adicional impuesto a aquellos países con alta probabilidad de impago.

En 2012, Europa estaba dividida entre países con economías estables, como los nórdicos, y aquellos, del sur, enfrentando recesiones profundas (James, 2024). A pesar de los rescates, la especulación sobre la solidez económica de estos países persistió (Figura 2), reflejada en la volatilidad del índice EuroStox50 durante 2011 (BME, 2011).

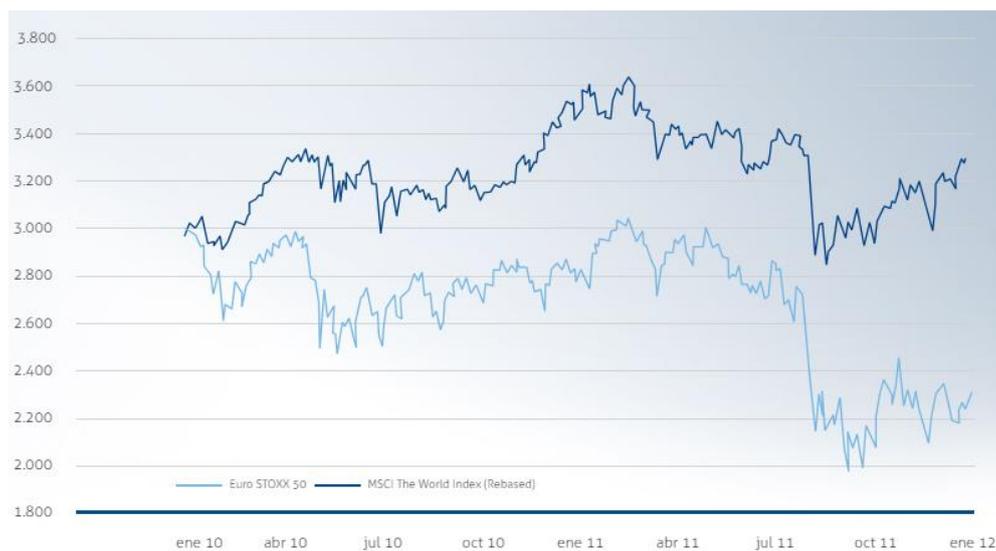


Figura 2. El efecto bursátil de la crisis del área euro (Fuente: BME, 2011)

2.3 Crisis del COVID-19

Antes de la llegada del Covid-19, la economía mundial estaba en una situación estable. Según datos del Banco Mundial (<https://www.bancomundial.org/es/home>), en 2018 el Producto Interior Bruto (PIB) Mundial alcanzó los 3,3 trillones de dólares americanos, lo que se consideraba un logro positivo después de los impactos de la crisis financiera de 2008. Sin embargo, con la llegada repentina del Covid-19 en 2019, el panorama cambió drásticamente. El mundo se detuvo de golpe y solo las empresas consideradas esenciales pudieron seguir operando, lo que provocó una caída en los ingresos de muchas compañías y afectó los salarios de los trabajadores. En situaciones extremas, numerosos negocios se vieron obligados a cerrar, generando una gran inestabilidad económica a nivel mundial (World Development Report 2022, 2022).

Ante esta crisis, los bancos tuvieron que intervenir para evitar una catástrofe humanitaria, adoptando medidas similares a las implementadas durante la crisis de 2008, como la inyección de dinero en la economía. En la Unión Europea, se decidió impulsar el gasto público a través de los fondos Next Generation (Comisión Europea, 2020), mientras que Estados Unidos llevó a cabo un programa de infraestructuras para potenciar la construcción. Sin embargo, para implementar estas medidas, fue necesario imprimir cantidades excesivas de dinero a tasas de interés muy bajas (Dolan & Nguyen, 2021).

Inicialmente, esta estrategia pareció funcionar (Figura 3), ya que las bolsas comenzaron a recuperarse después de los peores momentos de la pandemia (Adrian et al., 2022).

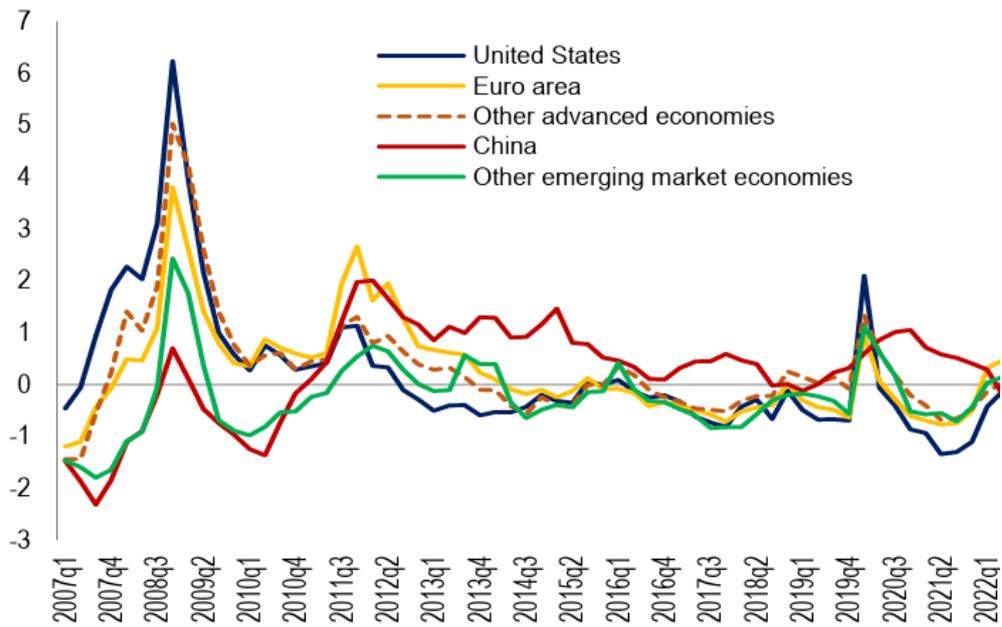


Figura 3. Índice de condiciones financieras en mercados avanzados y emergentes (Fuente: Adrian et al., 2022)

Sin embargo, la aplicación de políticas monetarias expansivas trajo consigo al aumento de la inflación, que también fue impulsada por otros factores como los cuellos de botella en las cadenas de producción. Los cuellos de botella son puntos en el proceso de producción donde la actividad se ralentiza debido a una acumulación excesiva de trabajo, lo que resulta en una oferta insuficiente para satisfacer la demanda (Informe trimestral de la economía española, 2021). Además, la crisis energética desencadenada por los conflictos bélicos contribuyó a agravar aún más la situación de inflación.

3. Marco Teórico

Para garantizar un seguimiento eficaz y detallado del trabajo, es esencial establecer y explicar los fundamentos teóricos y prácticos que sustentan esta investigación. En primer lugar, se abordará el concepto de Inversión Socialmente Responsable o Environmental, Social and Governance (ESG), junto con las métricas específicas empleadas para evaluar si una compañía cumple con los criterios ESG establecidos. Seguidamente, se describirán el índice de referencia que fundamentará el análisis: el S&P500. Por último, se explicará la base en la que se van a desarrollar los modelos, el aprendizaje supervisado y se expondrán los modelos de optimización de carteras que utilizarán para la construcción y análisis de la cartera de inversión: el modelo de Markowitz, que introduce la teoría moderna de carteras basadas en la diversificación; el modelo de Black-Litterman, que permite integrar expectativas de rendimiento específicas con el equilibrio del mercado; y los algoritmo genéticos, que ofrecen una metodología de optimización basada en principios de evolución natural y selección, adaptados para encontrar la combinación óptima de activos en una cartera de inversión.

3.1 Concepto de ESG

De acuerdo con Morrison (2021) el término ESG apareció por primera vez en 2004 en el informe publicado por las Naciones Unidas (ONU). Desde entonces, dicho término se ha introducido en marcos como los Principios de Inversión Responsable (PRI) así como en el mundo de las finanzas y actualmente, lo podemos ver en investigaciones financieras, ratings e incluso en productos financieros. En la actualidad más de 100 trillones de dólares americanos están invertidos en fondos dedicados al ESG.

Las finanzas sostenibles son el proceso de considerar factores medioambientales (E), sociales (S) y de gobernanza (G) al tomar decisiones de inversión para convertir las inversiones a largo plazo en actividades y proyectos económicos sostenibles (Boffo & Patalano, 2020).

Aunque esta es la definición que explica el concepto de ESG, actualmente su uso ha

evolucionado y ahora se puede incluso considerar una herramienta de gestión de riesgos, como sinónimo de Responsabilidad Social Corporativa (CSR) o incluso como una preferencia o actividad específica (Pollman, 2022).

Por un lado, ESG puede ser contemplado como gestión de riesgos ya que al considerar cómo una empresa maneja sus impactos ambientales, cómo se relaciona con la sociedad y cómo se gobierna a sí misma, un inversor puede obtener una visión más completa de los riesgos potenciales a los que podría estar expuesta la empresa. Este enfoque sugiere que los factores ESG pueden influir directamente en el desempeño financiero de la empresa, y, por tanto, en el valor de la inversión. De hecho, un estudio realizado por Van Duuren et al (2016) sobre la integración de ESG en la gestión de inversiones reveló que muchos gestores de fondos convencionales ya incorporan prácticas de inversión responsable en sus procesos. Se encontró que la inversión ESG y la inversión convencional comparten muchas similitudes ya que en ambas se realiza un análisis detallado de las empresas donde se incluyen factores no financieros. Además, se descubrió que efectivamente, la información ESG se utiliza principalmente para la identificación y gestión de riesgos.

Por otro lado, ESG también se interpreta como un paso hacia un mundo mejor, vinculado a resultados sociales beneficiosos a largo plazo, llegando a equipararse o combinarse conceptualmente con la CSR. Esta interpretación refleja una comprensión de que los beneficios sociales amplios pueden derivarse del uso de ESG como herramienta para un análisis de inversión mejorado.

Por último, ESG se puede ver como una preferencia entre algunas empresas o inversores. En este plano, ESG se convierte en una manera de expresar una preferencia, actuando como vehículo para alinear actividades con valores políticos, éticos o sociales.

3.1.1 Métricas ESG

En la actualidad no hay unas métricas exactas que especifiquen si una empresa cumple con los criterios ESG o no. Existen los llamados Objetivos de Desarrollo Sostenible (ODS) que expuso la ONU en la Agenda 2030 para el Desarrollo Sostenible en 2015 cuyos propósitos fueron diseñados para ser implementados durante los siguientes 15 años (Naciones Unidas, 2015).

Los ODS están compuestos por 17 objetivos y 169 metas que tienen como fin erradicar la pobreza, introducir estrategias que mejoren la salud y la educación, reducir la desigualdad y estimular el crecimiento económico garantizando, la protección del medio ambiente (UNESCO, 2015). Las empresas o inversiones que contribuyen a cualquiera de estos objetivos se consideran que siguen criterios ESG, ya que sus acciones tienen un impacto directo en los 3 pilares fundamentales: sostenibilidad, bienestar social y ambiental.

Ilustración 1: Objetivos de Desarrollo Sostenible



Fuente: Naciones Unidas (<https://sdgs.un.org/goals>)

Los 17 objetivos se pueden resumir en:

1. Fin de la pobreza: Erradicar la pobreza en todas sus formas.
2. Hambre cero: Acabar con el hambre, lograr la seguridad alimentaria y promover la agricultura sostenible.
3. Salud y bienestar: Garantizar una vida sana y promover el bienestar para todos en todas las edades.

4. Educación y calidad: Garantizar una educación inclusiva, equitativa y de calidad.
5. Igualdad de género: Lograr la igualdad de género y empoderar a todas las mujeres y niñas.
6. Agua limpia y saneamiento: Garantizar la disponibilidad de agua y su gestión sostenible y el saneamiento para todos.
7. Energía asequible y no contaminante: Garantizar el acceso de una energía asequible, segura, sostenible y moderna.
8. Trabajo decente y crecimiento económico: Promover el crecimiento económico sostenido, inclusivo y sostenible.
9. Industria, innovación e infraestructura: Construir infraestructuras resilientes, promover la industrialización sostenible y fomentar la innovación.
10. Reducción de las desigualdades: Reducir la desigualdad en y entre los países.
11. Ciudades y comunidades sostenibles: Hacer que las ciudades y los asentamientos humanos sean inclusivos, seguros, resilientes y sostenibles.
12. Consumo y producción responsables: Garantizar modalidades de consumo y producción sostenibles.
13. Acción por el clima: Tomar medidas urgentes para combatir el cambio climático y sus efectos.
14. Vida submarina: Conservar y utilizar de manera sostenible los océanos, los mares y los recursos marinos.
15. Vida de ecosistemas terrestres: Gestionar sosteniblemente los bosques, combatir la desertificación, detener e invertir la degradación de la tierra y detener la pérdida de biodiversidad.
16. Paz, justicia e instituciones sólidas: Promover sociedad pacíficas e inclusivas para el desarrollo sostenible.
17. Alianzas para lograr los objetivos: Revitalizar la Alianza Mundial para el Desarrollo Sostenible.

La conexión entre los criterios ESG y los ODS sirven para orientar las inversiones hacia una mayor sostenibilidad global, promoviendo prácticas empresariales que no solo buscan el beneficio económico, sino que también tienen en cuenta el impacto ambiental y social de sus operaciones.

El problema de estos objetivos es que son difíciles de cuantificar. Por ello, para este trabajo se ha decidido tomar como referencia de métricas ESG las que cuantifica FacSet

Research Systems Inc (2021) a partir de la metodología de contenido de Truvalue SASB (Sustainability Accounting Standards Board) que explica cómo se utilizan la inteligencia artificial y el aprendizaje automático para capturar y analizar datos no estructurados y generar métricas ESG.

Según FacSet Research System Inc (2023), Truvalue utiliza un método para calcular los rankings ESG y los percentiles por industria de las empresas de su universo de datos. Para las empresas con bajos volumen de información donde no se han escrito más de 4 artículos durante los últimos 12 meses, se utilizan las puntuaciones medias de la industria, mientras que para aquellas empresas que tienen más de cinco artículos se realiza un cálculo individualizado. Finalmente, los rankings ESG se calculan en base a la puntuación de percentil por industria (Tabla 1).

“**Tabla 1. Escala ranking ESG** (Fuente: Informe Facset (www.facset-com))”

90%-100%	Líder
70%- 89,9%	Por encima de la media
30%- 69,9%	Promedio
10%- 29,9%	Por debajo de la media
0%- 9,9%	Rezagado

De esta forma, Truvalue clasifica toda la información que recopila en 26 categorías definidas por SASB, que se agrupan en 5 grupos diferentes:

- Environment o Medio Ambiente
 - “Air Quality”- Mide la calidad general del aire.
 - “Ecological Impacts”- Evalúa cómo una empresa gestiona y minimiza su impacto ambiental en sus diferentes áreas de actividad.
 - “Energy Management” - Evalúa cómo una empresa gestiona su consumo de energía.
 - “GHG Emissions” - Hace referencia a los gases de efecto invernadero. Indica el impacto ambiental directo de la empresa y su compromiso con la reducción de carbono.
 - “Waste & Hazardous Materials Management” - Mide cómo una empresa gestiona los residuos y materiales peligrosos generados por sus

operaciones.

- “Water & Wastewater Management” - Evaluación de cómo la empresa gestiona los recursos hídricos, crucial en industrias como la manufactura y la química.

- Social Capital o Capital Social
 - “Access & Affordability” - Mide la capacidad de una empresa para asegurar la accesibilidad de sus productos y servicios a mercados o grupos de población desatendida.
 - “Customer Privacy” - Mide cómo una empresa protege la información personal sus clientes.
 - “Customer Welfare” - Evalúa cómo una empresa prioriza el bienestar y la satisfacción de sus clientes en sus prácticas comerciales.
 - “Data Security” - Mide la capacidad de una empresa para proteger la información sensible y confidencial.
 - “Human Rights & Community Relations” - Refleja cómo una empresa respeta y promueve los derechos humanos en sus operaciones y en las comunidades donde opera.
 - “Product Quality & Safety” - Mide cómo una empresa garantiza la calidad y seguridad de sus productos para los consumidores.
 - “Selling Practices & Product Labeling” - Refleja cómo una empresa comercializa y etiqueta sus productos de manera ética y transparente.

- Human Capital o Capital Humano
 - “Employee Engagement, Diversity & Inclusion” - Mide cómo la empresa fomenta la participación activa de los empleados a la vez que aborda la diversidad y la inclusión en el trabajo.
 - “Employee Health & Safety” - Refleja cómo la empresa protege la salud y seguridad de sus trabajadores.
 - “Labor Practices” - Mide cómo una empresa trata a sus empleados y promueve prácticas laborales justas y éticas.

- Business Model & Innovation o Modelo de negocio e innovación
 - “Business Model Resilience” - Mide la capacidad que tiene una empresa

para adaptarse frente a cambios desafiantes en el mercado o en la economía. Un ejemplo de esto puede ser la guerra de Ucrania.

- “Materials Sourcing & Efficiency” - Hace referencia a cómo una empresa gestiona el suministro y uso de materiales en sus operaciones.
 - “Physical Impacts of Climate Change” - Mide cómo una empresa aborda y gestiona los impactos físicos del cambio climático en sus operaciones y en las comunidades donde opera.
 - “Product Design & Lifecycle Management” - Evalúa cómo una empresa diseña sus productos teniendo en cuenta consideraciones ambientales y sociales a lo largo de todo su ciclo de vida.
 - “Supply Chain Management” - Hace referencia a cómo una empresa gestiona su cadena de suministro para garantizar prácticas éticas, sostenibles y socialmente responsables en todas las etapas de producción y distribución.
- Leadership & Gobernanza o Liderazgo y Gobernanza
 - “Critical Incident Risk Management” - Evalúa cómo una empresa planifica, previene, responde y se recupera de eventos inesperados (Deloitte, 2019).
 - “Competitive Behaviour” - Mide como las empresas se comportan con sus competidores, para así analizar si dicha competencia es leal o no.
 - “Business Ethics” - Mide la ética empresarial, incluyendo a la corrupción, los sobornos y las estrategias anticompetitivas.
 - “Management of the legal & Regulatory Environment” - Evalúa cómo una empresa gestiona y cumple con el entorno legal y regulatorio en el que opera.
 - “Accident and Safety Management” – Hace referencia a cómo las empresas gestionan los accidentes y garantizan la seguridad de sus empleados.

3.2 Índice S&P500

“El S&P500 es ampliamente considerado el mejor indicador de las acciones de alta capitalización de EE.UU. El índice incluye 500 empresas líderes en todos los sectores del mercado de capitales estadounidenses” (La brújula del mercado de alta capitalización de EE. UU., 2023, p.1). Más allá de su papel como indicador clave de la salud y el rendimiento del mercado de valores de EE.UU., y, por ende, de la economía del país, representa alrededor del 80%-85% del mercado de capitales de EE.UU. y constituye más de la mitad del mercado de valores a nivel mundial (Gunzberg & Edwards, 2018).

El S&P500 es parte integral de S&P Dow Jones Índices, una entidad con más de 65 años de experiencia en ofrecer soluciones de índices icónicos e innovadores. La metodología de cálculo del índice se basa en el número de acciones multiplicadas por el precio actual de la acción, ajustando el valor en tiempo real durante las horas de mercado (*S&P U.S. Índices Metodología*, 2024). Este enfoque proporciona un punto de referencia para comparar rendimientos antes de invertir, con, de acuerdo con Dow Jones (<https://www.spglobal.com/spdji/es/>), empresas de renombre como: Walmart, Walt Disney, Coca Cola, Facebook.

A nivel global, el S&P500 es considerado un barómetro del desempeño de las acciones estadounidenses, destacándose por su liquidez y por ser el índice base para una variedad de productos financieros como futuros u opciones (Gunzberg & Edwards, 2018). La importancia del índice también se refleja en su historial de dificultad para ser superado por gestores de fondos activos. Más de la mitad de estos gestores no han logrado superar el S&P500 en 18 de los últimos 21 años, destacando la eficacia del índice como medida de rendimiento a largo plazo (La brújula del mercado de alta capitalización de EE. UU., 2023).

3.3 Aprendizaje supervisado y la división en conjuntos de Training y Test

El aprendizaje supervisado se enfoca en la predicción de resultados específicos a partir de datos previamente etiquetados (Das et al., 2019). Su principal objetivo es crear un

modelo que, a partir de un conjunto de datos, tome como entrada un vector de ciertas características y así pueda asociar ciertos patrones de entrada a producir una etiqueta para esos datos (Haider, 2023).

Pero para implementar de forma efectiva el aprendizaje supervisado a un conjunto de datos, de acuerdo con Moreno et al., (1994), es necesario dividir estos en dos conjuntos principales: el conjunto de training o entrenamiento y el conjunto de test o de prueba. Esta separación se lleva a cabo para poder evaluar la capacidad que tiene el modelo para generalizar a nuevos datos que no se utilizaron en la parte de training.

El conjunto de training se utiliza para construir y afinar el modelo. Durante esta fase, el algoritmo ajusta sus parámetros internos para minimizar el error entre las predicciones del modelo y los valores reales observados en los datos del training. Este ajuste se realiza mediante técnicas de optimización que iteran a través de los datos múltiples veces, de tal forma, que va mejorando progresivamente la capacidad predictiva del modelo (Das et al., 2019).

Una vez que el modelo ha pasado por la fase del training, se utiliza el conjunto de test para evaluar su rendimiento. Este conjunto funciona como una simulación de datos futuros y ayuda a evaluar cómo se desempeñará el modelo en situaciones reales que no ha visto antes (Moreno et al., 1994). De esta forma, se puede verificar la capacidad que tiene el modelo para generalizar.

La utilización de estos dos conjuntos de training y test ayuda a evitar problemas de overfitting y underfitting (Haider, 2023). El overfitting ocurre cuando un modelo predice perfectamente sobre el conjunto de datos de training pero falla al enfrentarse a nuevos datos. El underfitting, por otro lado, ocurre cuando un modelo es demasiado simple para capturar la complejidad de los datos sobre los que se entrena. Esto resulta en un rendimiento deficiente tanto en el conjunto de training como en el conjunto de test.

De esta manera, el aprendizaje supervisado es una herramienta poderosa en el campo del análisis de datos y por ello, su implementación es necesaria para garantizar una correcta predicción del objeto de cuestión en estudio.

3.4 Teoría de la cartera de Markowitz y Black-Litterman

La teoría de la cartera de Markowitz, formulada por Harry Markowitz revolucionó la forma de entender la inversión en los mercados financieros al introducir el concepto de diversificación. Dicho concepto va a ser utilizado en este trabajo para así poder obtener la cartera de inversión con un mejor ratio de rentabilidad/ riesgo.

De acuerdo con Markowitz (1952), a la hora de elegir los elementos que van a integrar una cartera de inversión, no solo hay que fijarse en la rentabilidad que dan cada uno sino también en el riesgo de cada elemento, el cual es medido a través de la varianza de los retornos. Según su teoría, una cartera óptima es aquella que da el máximo retorno para un riesgo determinado o el mínimo riesgo para un retorno determinado. Esto se lleva a cabo combinando diferentes activos financieros que no se comportan de la misma manera, es decir, no están perfectamente correlacionados, para que así se pueda diversificar el riesgo de la cartera.

Este modelo explica que el proceso de selección de una cartera óptima se divide en dos etapas: la primera es determinar que activos financieros van a poder tener un buen rendimiento en el futuro, para ello te puedes basar en su performance histórico; y la segunda, es combinar esos activos teniendo en cuenta tanto su rendimiento como su riesgo (medido por la varianza). Con toda esta información, el modelo otorga pesos a cada uno de los activos financieros en función de los parámetros de rentabilidad o riesgo establecidos. Para poder analizar si la cartera es eficiente en términos de rentabilidad y riesgo, Markowitz utiliza la frontera eficiente. Esta es el conjunto de carteras con mayor rentabilidad para cada uno de los niveles de riesgo. Es por ello, que, una vez obtenida la cartera óptima, el rendimiento esperado (1) y el riesgo (2) se ven definidos por:

$$\bar{r}_p = \sum_{i=1}^n \omega_i r_i \quad (1)$$

donde r_p es el retorno esperado de la cartera, ω_i es el peso invertido en el activo i en la cartera, r_i es el retorno esperado del activo i y n es el número total de activos de la cartera.

$$\sigma_p^2 = \sum_{i=1}^n \sum_{j=1}^n \omega_i \omega_j \sigma_{ij} \quad (2)$$

donde σ_p^2 es la varianza de la cartera y σ_{ij} es la covarianza entre los retornos de los activos.

En este trabajo también se incorporará el modelo de Black-Litterman el cual es una forma avanzada del modelo de Markowitz que permite incorporar la visión subjetiva del inversor dentro del equilibrio del mercado.

Según Black y Litterman (1992) se parte de la base que hay un equilibrio de mercado, representado por el modelo de fijación de precios de activo de capital (CAPM), donde el peso de cada uno de los activos que forman el porfolio es proporcional a las capitalizaciones del mercado. A partir de este equilibrio, el inversor puede ajustar sistemáticamente los rendimientos esperados de cada uno de los activos. A continuación, la visión del inversor se combina con el equilibrio de mercado del que se ha partido utilizando una matriz de covarianza para reflejar la confianza de la visión del inversor con el riesgo del equilibrio de mercado. De este proceso se obtiene un conjunto ajustado de rendimiento esperados. Con los rendimientos esperados ajustados y la matriz de covarianza se procede a obtener los pesos óptimos de la cartera que maximizan el Sharpe ratio. Este ratio sirve para medir la rentabilidad esperada por unidad de riesgo para una estrategia de inversión (Sharpe, 1994). Con lo cual, cuanto mayor sea el Sharpe Ratio, más rentabilidad se estará obteniendo por unidad de riesgo.

El modelo de Black-Litterman es de especial interés en este trabajo porque ayuda a evitar decisiones extremas que pueden surgir de confiar demasiado en predicciones inciertas. Al comenzar con el equilibrio del mercado y ajustar basándose en las visiones del inversor con un nivel de confianza asociado, se puede crear una cartera que refleje tanto el conocimiento del mercado como las expectativas del inversor. Donde el rendimiento esperado de la cartera (3) viene dado por:

$$\overline{E[R]} = [(\tau\Sigma)^{-1} + P'\Omega^{-1}P]^{-1}[(\tau\Sigma)^{-1}\Pi + P'\Omega^{-1}Q] \quad (3)$$

donde: Π indica los retornos de equilibrio del mercado basados en las capitalizaciones del mercado, Σ es la matriz de covarianza de los activos, τ es el parámetro de confianza en el equilibrio del mercado, P es la matriz que describe qué elementos de Π están siendo ajustados por las vistas del inversor, Q es el vector con las vistas del inversor y Ω la matriz de covarianza de las vistas del inversor.

Por lo que la primera parte de la definición (3) ajusta la matriz de covarianza del mercado basándose en las vistas del inversor, y la segunda parte, combina los retornos de equilibrio

del mercado ajustados por la confianza del mercado con las expectativas del retorno ajustadas por la confianza en las vistas del inversor.

3.5 Algoritmos genéticos en la optimización de carteras

Los algoritmos genéticos son una técnica de metaheurística inspirada en la teoría de la evolución natural, diseñada para resolver problemas de optimización (Herrera, 2009). Estos algoritmos se utilizan para explorar eficientemente grandes espacios de soluciones en búsqueda de las combinaciones óptimas, como por ejemplo encontrar la mejor combinación de inversiones en una cartera financiera (Holland, 1992).

Siguiendo la teoría de la evolución natural donde la naturaleza selecciona a los individuos más fuertes para sobrevivir y reproducirse, los algoritmos genéticos hacen algo parecido con las posibles soluciones a un problema, seleccionando las mejores soluciones después de varias simulaciones para encontrar la mejor combinación posible (Sefiane & Benbouziane, 2012). En el contexto de las inversiones, estos algoritmos ayudan a elegir qué activos incluir en una cartera de inversiones para maximizar el retorno y minimizar el riesgo. El proceso comienza con un grupo de soluciones aleatorias. Cada solución es evaluada para ver qué tan buena es. Las mejores soluciones luego se cruzan entre sí para crear nuevas soluciones, que también se evalúan. Algunas veces, para añadir nuevas combinaciones, se hacen pequeños cambios en estas soluciones. Este proceso se repite hasta que se encuentra la mejor solución (Fahria & Kustiawan, 2021).

Mediante la aplicación de estos tres métodos diferentes: Markowitz, Black-Litterman y algoritmos genéticos, se pretende analizar y determinar qué tipo de cartera ofrece un rendimiento superior con el menor riesgo posible. Después, se comparará cómo se desempeña una cartera formada por empresas con un ranking ESG bajo frente a una cartera formada con empresas con ranking ESG alto durante los periodos específicos de crisis que se ha seleccionado. Este análisis nos ayudará a entender que enfoque de inversión resulta más efectivo en tiempos de incertidumbre económica.

4. Metodología

4.1 Recopilación de datos históricos

Se han obtenido de Facset los precios históricos de las empresas que forman del S&P500 del segundo trimestre de 2024 junto con otras variables como el dividendo repartido de cada empresa, el número de acciones o el volumen.

Para los modelos elegidos, se tiene que seleccionar los precios históricos de cada una de las empresas y para ello, hay que trasponer la información de tal manera que se obtenga un dataset donde la primera columna sean las fechas de los precios históricos y a partir de ahí, los precios de cada una de las empresas que forman parte del índice. Como ya se ha mencionado antes, para simplificar, se va a suponer que el S&P500 ha estado compuesto de las mismas empresas para todos los periodos seleccionados. Esta premisa, hace que muchas de las empresas que hoy por hoy forman parte del índice, no cotizasen en los periodos elegidos para el análisis.

En este contexto, se ha comenzado el código con la limpieza de datos, una fase preliminar en este análisis ya que elimina las anomalías y garantiza la calidad de los datos. Para ello, se han eliminado las columnas con datos no numéricos o vacíos, lo que se interpreta como la exclusión de empresas con precios históricos incompletos. Posteriormente, se sustituyen valores infinitos por valores no disponibles, en caso de haber, utilizando el método `replace` y se realiza otra limpieza para descartar posibles columnas que hayan resultado con todos sus valores transformados a 'NaN' después del reemplazo.

A continuación, se procede a definir una función para filtrar las empresas con datos de cotización completos dentro de un intervalo de fechas específicos, que en este caso serán, los periodos previos a las crisis seleccionadas para luego ver como las carteras creadas se comportan en periodos posteriores a las crisis, teniendo de esta forma definido el conjunto de datos `training` y `test`. Esta parte es importante para el estudio de períodos de crisis que se va a realizar ya que los precios de las acciones son particularmente volátiles y relevantes para la modelización de riesgo y retorno. La función utiliza el rango de fechas para ubicar las cotizaciones relevantes y para eliminar, nuevamente, cualquier empresa que no tenga datos disponibles en todo el periodo, garantizando así la integridad de los conjuntos de datos temporales.

Por último, para poder evaluar la capacidad de generalización de cada uno de los modelos

propuestos, se divide el conjunto de datos en seis segmentos distintos: uno para el entrenamiento y otro para la prueba. El conjunto de training incluye los precios históricos de los períodos anteriores a cada una de las crisis. Para la crisis de 2008 se seleccionan los periodos previos del 1 de enero de 2006 al 1 de septiembre de 2008, para la crisis griega se seleccionan los periodos previos del 1 de enero de 2009 al 30 de junio de 2011 y para la crisis del Covid19 se ha tomado del 1 de enero de 2018 al 1 de marzo de 2020. Estos intervalos son cuidadosamente elegidos para abarcar fechas antes de cada crisis financiera, permitiendo una evaluación de la performance de las empresas antes de estar bajo condiciones de estrés financiero. El conjunto de test estará formado por los datos de los períodos posteriores a las diferentes crisis. Esta división estratégica permite al modelo aprender bajo condiciones de mercado pre-crisis y validar su eficacia en un escenario post-crisis.

El rigor de estos pasos radica en la creación de un conjunto de datos confiable y representativo que sirve como base sólida para aplicar los modelos seleccionados en este análisis.

4.2 Desarrollo del algoritmo aplicando el modelo de Markowitz, Black-Litterman y algoritmo genético

Una vez se obtienen los precios históricos de cada uno de los periodos de crisis, se comienza con la implementación de la función ‘Markowitz’, la cual encapsula la lógica del modelo de optimización de carteras propuesto por Harry Markowitz, previamente explicado. El objetivo es seleccionar un conjunto de activos financieros de manera que se maximice el retorno esperado para un nivel dado de riesgo. Comenzamos con una función que calcula los retornos logarítmicos de una serie de precios de activos financieros. Los retornos logarítmicos se utilizan para análisis financieros ya que son simétricos y pueden ser sumados a lo largo del tiempo para obtener retornos acumulativos (Crespo Espert & Mir Fernández, 2009). A continuación, se define una nueva función que selecciona los 10 activos con el mayor ratio de Sharpe, una medida que se ha explicado previamente y que ajusta el riesgo de un activo a su rendimiento. Después se define otra función que

calcula el retorno esperado y la volatilidad de una cartera dado un conjunto de pesos, los retornos esperados y la matriz de covarianza de los activos, la cual se utiliza para entender cómo los precios de los activos se mueven juntos (Brownlees et al., 2021). El siguiente paso es definir la función que implementa la optimización de Markowitz para determinar los pesos de los activos en una cartera que maximizan el ratio de Sharpe. Por último, si el proceso de optimización es exitoso, se generará un DataFrame que muestra los activos seleccionados, sus ponderaciones en la cartera y su retorno.

Posterior a definir la función Markowitz, el código aplica este modelo al conjunto de datos que se ha filtrado con los periodos de crisis que se están estudiando para que genere una lista de carteras optimizadas para cada conjunto de datos.

El siguiente código que se ha aplicado al conjunto de datos seleccionado es el modelo de Black-Litterman, una extensión del modelo de Markowitz. Para este modelo se han considerado las capitalizaciones de cada una de las empresas que forman el S&P500, por ello, se procede a limpiar valores no válidos como NaN o infinitos y se eliminan aquellas capitalizaciones que son cero, ya que para este set de datos surge el mismo problema que para los precios históricos. En muchas de las fechas, la capitalización de las empresas del S&P500 no existían. Una vez limpios los datos de las capitalizaciones, se almacenan en un diccionario para su uso posterior.

A continuación, se intentó filtrar los datos por los períodos previos de las crisis seleccionadas. Sin embargo, surgieron complicaciones al no encontrar coincidencias exactas para algunas de las fechas especificadas en nuestro DataFrame. Esto nos llevó a desarrollar una función especial que identifica la fecha más cercana disponible. Esta herramienta resultó esencial para aplicar correctamente el modelo de Black-Litterman, permitiendo ajustar el filtrado de los períodos precrisis de manera efectiva.

Para la aplicación de este modelo, se han definido varias funciones en el código:

1. 'market_portfolio'. Calcula los pesos del portfolio de mercado en base a las capitalizaciones de mercado totales.
2. 'calculate_cov_matrix'. Calcula la matriz de covarianza de los retornos logarítmicos de los precios de las acciones.
3. 'black_litterman_model'. Aplica el modelo Black-Litterman para ajustar los

retornos esperados en base a las capitalizaciones de mercado, a las expectativas que tiene el inversor, que, en este caso, es que prevé que el mercado va a caer un 20% y la matriz de covarianza ajustada por un factor 'tau' que modula la incertidumbre en las expectativas del mercado.

4. 'portfolio_return' y 'portfolio_volatility'. Estas funciones calculan el retorno esperado y la volatilidad de la cartera, respectivamente, basándose en los pesos asignados a cada activo y la matriz de covarianza.
5. 'optimize_portfolio'. Esta función busca minimizar la volatilidad de la cartera para un retorno dado, utilizando un algoritmo de optimización de programación cuadrática (SLSQP). La función ajusta los pesos de los activos en la cartera para alcanzar el máximo retorno.

Finalmente, el código aplica estas funciones para optimizar las carteras de los diferentes periodos de crisis utilizando las capitalizaciones de mercado correspondientes y los retornos ajustados según el modelo de Black-Litterman. Calcula los pesos óptimos, selecciona los diez activos con mayor peso, y calcula el retorno esperado para estas carteras optimizadas. Este proceso no solo permite integrar las expectativas del mercado en la optimización de carteras, sino que también ofrece un enfoque más personalizado y ajustado a la realidad del mercado que el modelo de Markowitz tradicional.

Por último, se ha implementado un algoritmo genético para optimizar las carteras, maximizando el ratio de Sharpe. Se comienza definiendo la función 'fitness' que evalúa como de bueno es un porfolio. Esta función calcula el retorno esperado del porfolio y su desviación estándar anual, para calcular el ratio de Sharpe. Dado que se busca maximizarlo, la función devuelve el negativo de este valor para convertir el problema en uno de minimización.

Luego se define la función 'create_population' que inicializa una población de porfolios, donde cada porfolio se representa por un vector de pesos asignados a cada activo. Estos pesos se generan aleatoriamente siguiendo una distribución Dirichlet, que garantiza que la suma de todos los pesos sea igual a uno, igual que se ha definido para el resto de los modelos.

Las funciones 'select_population' y 'crossover' y 'mutate' que se definen a continuación

son operadores genéticos clásicos:

- ‘select_population’. Utiliza el método del torneo para seleccionar portfolios de la población actual en función de su fitness, favoreciendo a aquellos con un mejor ratio de Sharpe.
- ‘crossover’. Combina los pesos de dos portfolios para crear uno nuevo, esperando que herede las características de alto rendimiento de ambos “padres”.
- ‘mutate’. Modifica aleatoriamente los pesos de un portfolio para explorar nuevas soluciones potenciales. Primero la función decide si una solución particular debe mutar, luego solo los activos con pesos positivos son candidatos para la mutación, si se decide mutar, la función modifica aleatoriamente los pesos de los activos seleccionados.

El ciclo general de los algoritmos genéticos se maneja en la función ‘run_genetic_algorithms’, que ejecuta el proceso de selección, cruce y mutación durante número determinado de generaciones, en este caso, 50 veces. Con cada generación, la población debería evolucionar hacia soluciones con mejores ratios de Sharpe hasta obtener la mejor, en la generación 50.

Por último, se procede a optimizar el modelo generado. Para cada período se dispone de un conjunto de retornos de los activos. Para cada conjunto de retornos se ejecuta el algoritmo genético que se había elaborado previamente la cual devuelve los mejores pesos obtenidos, el retorno anual de la cartera y un historial del fitness de las soluciones. Una vez obtenidos los mejores pesos, se seleccionan los 10 principales pesos y se identifican los activos correspondientes. Estos pesos y activos representan la configuración óptima de la cartera para ese período específico. A continuación, se crea un vector de pesos completo para todos los activos en el conjunto de datos, inicialmente establecido en cero. Luego, se asignan los pesos de los 10 principales activos a sus respectivos índices en este vector. Por último, se imprime una visualización gráfica que muestra la evolución del fitness, medida a través del Sharpe Ratio, a lo largo de las generaciones, lo que permite la mejora de la solución a lo largo del tiempo.

El último paso es la validación de cada uno de los modelos desarrollados. Esto se realiza utilizando el conjunto de prueba que esta formado por los periodos postcrisis de cada una

de las crisis. Para la crisis financiera de 2008 este está formado desde el 1 de enero de 2008 al 31 de diciembre de 2010. Para la crisis griega de 2010 desde el 1 de enero de 2012 hasta el 31 de diciembre de 2013. Y para la crisis del COVID-19 desde el 1 de enero de 2021 hasta el 31 de diciembre de 2022. Esta fase es importante para verificar si el modelo puede prever correctamente bajo un nuevo contexto del mercado tras cada una de las crisis, proporcionando una medida robusta de su capacidad de generalización.

4.3 Evaluación actualizada del desempeño ESG en el S&P500

En este análisis se pretende analizar aquellas empresas que forman parte del S&P500 son las que mejor puntuación ESG tienen en términos de las variables seleccionadas que se explicaran a lo largo del análisis.

Para ello, se ha extraído de FacSet cada una de las empresas que forman parte del índice con las métricas ESG explicadas previamente.

De entre todas esas variables se ha seleccionado 4 de ellas, teniendo en cuenta que tenían que cubrir todos los planos del ESG, es decir, una métrica que sea capaz de medir la sostenibilidad, para ello se han seleccionado 2 variables ya que se ha considerado que dicho plano es el más complejo de medir “GHG Emissions” y “Water and Waste Water Management”; una métrica social, en este caso “Employee Health and Safety” y una métrica que pueda medir la buena gobernanza de cada una de las empresas “Business Ethics”.

Una vez, seleccionadas las variables se ha procedido a elaborar el código. Este comienza importando las bibliotecas necesarias y se carga el archivo que contiene cada una de las empresas que forman el S&P500.

El análisis se centra en la información más actualizada, por lo que el código identifica la fecha más reciente disponible en los datos y filtra para trabajar solo con esa instantánea temporal. Este enfoque se ha elegido porque utilizar la última fecha disponible asegura que el análisis refleje el estado más reciente de las empresas en términos ESG. Asimismo,

al concentrarse en una sola fecha, se garantiza que todas las mediciones son contemporáneas entre sí, eliminando las inconsistencias que podrían surgir al comparar datos de diferentes periodos en un ámbito tan novedoso como es el ESG. Esto es particularmente importante en análisis comparativos como en el que nos encontramos donde se determinan las mejores y peores empresas.

A continuación, se indica la selección de las variables que han sido definidas previamente: emisiones de gases de efecto invernadero, gestión del agua y aguas residuales, salud y seguridad de los empleados y ética empresarial. Con el objetivo de garantizar la integridad del análisis, el código excluye cualquier registro que no contenga todos los datos necesarios, eliminando filas donde alguna de las métricas clave es nula. Esto prepara el terreno para calcular una puntuación media de ESG, el cual da una visión integrada del desempeño de cada empresa.

El siguiente paso, es ordenar las empresas por su puntuación ESG, de mayor a menor, lo que permite identificar a las 10 empresas con el mejor y el peor desempeño. Este ranking se imprime en la consola, ofreciendo una lista clara de cuáles empresas son líderes en ESG y cuales se quedan atrás.

Para finalizar, se crean gráficas de barras horizontales para visualizar mejor estos rankings. Las mejores empresas se presentan en un gráfico con barras verdes, destacando su sobresaliente desempeño ESG, mientras que las peores se muestran con barras rojas. Las gráficas de barras se disponen lado a lado, facilitando una comparación visual directa entre los grupos de mejor y peor desempeño.

Por último, se ha tenido en cuenta que en nuestro set de datos contábamos con una variable llamada 'Materiality' que releja una puntuación donde agrega solo las categorías ESG relevantes para cada empresa, utilizando un promedio móvil ponderado exponencialmente con un periodo de seis meses (FactSet Research Systems Inc, 2021). Dado que esta variable es más objetiva y recoge más información que la que se ha desarrollado, es la que utilizaremos en la sección de resultados. Para estas empresas con calificación más y menos alta en términos de esta variable, se ha calculado su rendimiento y riesgo para los periodos de antes y después de la crisis del COVID-19 que se utilizarán para comparar estas carteras con las creadas con los modelos y así poder ver la correlación del objeto de estudio. Como para dicha cartera no se han tenido en cuenta factores como el sharpe ratio sino que ha sido construida simplemente en términos ESG, se ha procedido

a dar el mismo peso a cada uno de los activos, es decir un 20%.

5. Análisis y explicación de los resultados

Después de haber llevado a cabo diferentes aplicaciones de modelos para la optimización de carteras en contextos de crisis financieras, y realizar un análisis de las prácticas de gobernanza ambiental, social y corporativa (ESG) de las empresas que conforman el índice S&P500, ahora se procede a presentar los resultados obtenidos. La exposición de los resultados no solo valida las técnicas de optimización utilizadas, sino que también proporciona insights sobre el comportamiento de las carteras bajo condiciones de mercados adversas y la posible correlación entre la sostenibilidad corporativa y la resiliencia financiera.

5.1 Descripción de las carteras construidas

Tras la aplicación del modelo de Markowitz, se han obtenido las siguientes carteras para cada una de las crisis.

La primera tabla (Tabla 2) representa la cartera compuesta por diez empresas, todas con una asignación diferente donde destacan Lockheed Martin y Baxter International como las empresas con mayores pesos durante el periodo de antes de la crisis financiera de 2008. En esta cartera nos encontramos empresas como el gigante del sector de reservas de viajes Booking, uno de los mayores productores de fosfato y potasio como Mosaic, o CSX. Los activos incluyen empresas de diferentes sectores, reflejando una estrategia de diversificación para minimizar el riesgo sistemáticos y específico del mercado durante un período de alta volatilidad financiera.

“Tabla 2. Cartera aplicando el modelo de Markowitz para la Crisis Financiera de 2008 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
FMC Corporation	FMC-US	6,66%
The Mosaic Company	MOS- US	15,63%

Baxter International	BAX-US	23,50%
Booking Holdings Inc	BKNG-US	10,67%
CSX	CSX-US	19.07%
Lockheed Martin	LMT-US	24,48%

La siguiente tabla vuelve a una mostrar una cartera totalmente diversificada donde el activo con mayor peso se lo lleva de manera considerable Hormel Foods Corporation (Tabla 3). Llama la atención, la inclusión de empresas como Netflix, conocida por su fuerte crecimiento y estabilidad financiera, ya que apunta a una estrategia de incluir activos que potencialmente podrían ofrecer un buen rendimiento en tipos de incertidumbre económica. Aunque también hay que tener en cuenta la proximidad que tienen ambas crisis y que la crisis del euro no afecto de la misma manera en Estados Unidos que la crisis financiera de 2008.

“Tabla 2. Cartera aplicando el modelo de Markowitz para la Crisis del Euro (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
Cognizant Technology Solutions Corporation	CTSH- US	12,18%
Hormel Foods Corporation	HRL-US	50,98%
Edwards Lifesciences	EW-US	13,21%
Cooper Companies	COO-US	1,55%
Netflix	NFLX-US	18,05%
Tractor Supply Company	TSCO-US	1,60%
Pioner Natural Resources	PXD-US	2,43%

Similar a las tablas anteriores, esta cartera distribuye los pesos de manera muy diversificada en 5 empresas (Tabla 4). Esta cartera destaca por incluir empresas que están

a la vanguardia de la tecnología y la innovación, desde semiconductores y diseño electrónico hasta moda y tecnologías de seguridad pública. La diversificación en diferentes sectores tecnológicos y de consumo puede ser una estrategia para aprovechar el crecimiento en áreas tecnológicas avanzadas mientras se mantiene una base en bienes y servicios más estables y tangibles como la moda.

“Tabla 4. Cartera aplicando el modelo de Markowitz para la Crisis del Covid19 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
NextEra Energy	NEE-US	46,24%
Steris PLC	STE-US	29,26%
Brown & Brown	BRO-US	7,55%
Adobe	ADBE-US	8,29%
Ball Corporation	BALL-US	8,66%

A continuación, se muestran las carteras obtenidas a través de la aplicación del modelo de Black-Litterman para diferentes crisis financieras.

Esta primera cartera (Tabla 5) muestra una distribución de pesos donde empresas como Applied Materials y TJX Companies tienen asignaciones de peso mayores, lo que podría indicar una visión de que estas empresas poseen un riesgo relativamente bajo y un potencial de rendimiento estable antes de la crisis financiera de 2008 y asumiendo que el mercado experimentará una bajada del 20%. Empresas como Walmart y Southwest Airlines también presentan asignaciones más altas, sugiriendo una preferencia por sectores que tienen a mantener una demanda estable, incluso en recesiones, como bienes de consumo y servicios básicos.

“Tabla 5. Cartera aplicando el modelo de Black-Litterman para la Crisis Financiera de 2008 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
Duke Energy Corp	DUK- US	4,73%
Mosaic Co	MOS- US	4,80%
ResMed	RMD- US	4,85%
Cencora	COR- US	4,87%
Old Dominion Freight Line Inc	ODFL- US	5,07%
Walmart	WMT- US	6,88%
Southwest Airlines	LUV- US	7,07%
Estee Lauder Companies Inc	EL- US	7,60%
TJX Companies	TJX- US	10,01%
Applied Materials Inc	AMAT- US	14,69%

En esta cartera (Tabla 6) enfocada en la crisis del Euro, General Mills, pero sobre todo, Campbell Soup, aparecen con un alto porcentaje de peso, reafirmando la preferencia por bienes de consumos básicos en momentos previos a una crisis. Empresas como Netflix y Copart Inc pertenecientes a sectores de servicios básicos y de entretenimiento demostrando que estos sectores son menos susceptibles a las fluctuaciones económicas debido a su naturaleza. Además, McCormik & Co y FirstEnergy Corp representan sectores de alimentación y energía, respectivamente, que tienden a ser resilientes en tiempos de crisis económica.

“Tabla 6. Cartera aplicando el modelo de Black-Litterman para la Crisis del Euro (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
----------	---------	-------

M&T Bank Corporation	MTB-US	3,39%
Charles River Laboratories	CRL-US	3,95%
McCormick & Co	MKC-US	4,78%
FirstEnergy Corp	FE-US	5,51%
Netflix	NFLX-US	5,74%
General Mills Inc	GIS-US	5,88%
Akamai Technologies	AKAM-US	6,56%
Copart Inc	CPRT-US	7,87%
Campbell Soup Co	CPB-US	11,11%
Homel Foods Corp	HRL-US	30,13%

En la última cartera (Tabla 7) que proporciona el modelo, se observan pesos significativos en empresas como ResMed, The J.M. Smucker Company y Regeneron Pharmaceuticals Inc. Estas empresas representan los sectores de salud, alimentación y farmacéutico, respectivamente, que son vistos como esenciales o defensivos durante períodos económicos difíciles. La diversificación en esta cartera también incluye tecnología y servicios con empresas como Axon Enterprise Inc. y CME Group, sugiriendo una apuesta por sectores que pueden ofrecer crecimiento innovador o esencial tras una crisis.

“Tabla 7. Cartera aplicando el modelo de Black-Litterman para la Crisis del Covid19 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
SBA Communications Corporation	SBAC-US	4,38%
Axon Enterprise Inc	AXON-US	4,53%
F5 Inc	FFIV-US	5,06%
International Flavors & Fragrances	IFF-US	5,32%
Regeneron Pharmaceuticals Inc	REGN-US	6,03%

Dollar Tree Inc	DLTR-US	8,15%
ResMed Inc	RMD-US	10,13%
The J.M. Smucker Company	SJM- US	10,48%
Newmont Corp	NEM- US	10,92%
CME Group	CME- US	26,56%

Por último, estas tres siguientes tablas muestran los resultados de aplicar un algoritmo genético para la optimización de carteras.

La primera cartera (Tabla 8) que se obtiene como resultado del algoritmo genético para la crisis financiera de 2008 incluye una diversidad de sectores, reflejando una estrategia de diversificación para mitigar riesgos específicos de la industria durante un periodo de alta incertidumbre económica. La distribución de los pesos varía significativamente, con la mayor asignación a Cadence Design Systems, una empresa líder en software y servicios de diseño electrónico, lo que refleja una posible percepción de estabilidad o demanda creciente en el sector tecnológico durante crisis económicas. Otras empresas como Constellation Brands que se especializa en la producción y comercialización de bebidas alcohólicas, y Public Service Enterprise Group, un proveedor de energía y gas, también tienen asignaciones considerables, posiblemente debido a su papel crítico en infraestructura y consumo básico respectivamente.

“Tabla 8. Cartera aplicando un algoritmo genético para la Crisis Financiera de 2008 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
Cadence Design Systems, Inc	CDNS-US	21,07%
Constellation Brands, Inc	STZ-US	16,55%
Public Service Enterprise Group	PEG-US	15,00%
Nasdaq, Inc	NDAQ-US	13,65%
Comerica Inc	CMA-US	13,51%

General Dynamics Corp	GD-US	8,77%
LKQ Corporation	LKQ-US	6,07%
Seagate Technology Holdings	STX-US	3,29%
Welltower Inc	WELL-US	1,03%
Thermo Fisher Scientific Inc	TMO-US	0,01%

La siguiente cartera (Tabla 9) está compuesta por empresas nuevamente de diversas industrias, indicando un enfoque en la resiliencia y el potencial de crecimiento a través de diferentes sectores. Pulte Homes, una empresa prominente en la construcción de viviendas recibe el mayor peso, lo que podría sugerir una apuesta por el sector inmobiliario que podría comportarse bien en una recuperación económica post-crisis. Empresas como DaVita Inc y Dominion Energy Inc, que operan en los sectores de servicios de salud y energía, respectivamente, también forman parte de la cartera. Destacando la tendencia hacia sectores esenciales que ofrecen servicios críticos durante períodos de incertidumbre económica.

“Tabla 9. Cartera aplicando un algoritmo genético para la Crisis del Euro (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
Pulte Homes	PHM-US	41,73%
DaVita Inc	DVA-US	14,40%
Dominion Energy Inc	D-US	13,59%
Thermo Fisher Scientific Inc	TMO-US	9,79%
Caterpillar Inc	CAT-US	8,13%
Edison International	EIX-US	3,16%
Federal Realty Investment Trust	FRT-US	26,03%
Pfizer Inc	PFE-US	2,41%
Jabil Circuit	JBL-US	2,24%

F5, Inc	FFIV-US	1,91%
---------	----------------	-------

En respuesta a la pandemia global y sus impactos económicos, la siguiente cartera (Tabla 10) incluye una fuerte representación de empresas en sectores críticos y esenciales. Expeditors International of Washington, que lidera la lista con el mayor peso, refleja la importancia del sector logístico en tiempos de crisis sanitaria, destacando cómo el transporte y la distribución son cruciales durante interrupciones globales. Además, DuPont de Nemours, conocida por sus innovaciones en materiales industriales y Huntington Bancshares en el sector financiero, subrayan el enfoque en industrias que soportan infraestructuras críticas y servicios financieros esenciales. Empresas como Pulte Homes y Southern Co, que operan en la construcción de viviendas y servicios públicos respectivamente, también demuestran la inclusión de segmentos considerados resilientes y menos susceptibles a las fluctuaciones económicas causadas por la pandemia.

“Tabla 10. Cartera aplicando un algoritmo genético para la Crisis del Covid19 (Fuente: Tabla de elaboración propia)”

Empresas	Índices	Pesos
Expeditors International of Washington	EXPD-US	22,42%
DuPont de Nemours Inc	DD-US	21,65%
Huntington Bancshares Inc	HBAN-US	14,34%
Pulte Homes	PHM-US	11,09%
Southern Co	SO-US	7,58%
Biogen Inc	BIIB-US	6,62%
Global Payment Inc	GPN-US	5,46%
Wells Fargo & Co	WFC-US	4,55%
Baker Hughes Co	BKR-US	3,88%
Abott Laboratories	ABT-US	2,36%

Cada tabla refleja un enfoque cuidadoso en seleccionar empresas no solo basadas en su desempeño histórico sino también en su potencial para manejar o beneficiarse de las condiciones específicas de cada crisis.

5.2 Análisis de rentabilidad en cada crisis y comparación entre las carteras

Una vez examinadas las carteras generadas por distintos modelos durante varios periodos antes de que cada crisis explotara, el paso siguiente es evaluar cuál de estas proporciona un mejor retorno tras las crisis. Para esto, se ha elaborado una tabla que muestra la rentabilidad anual de cada cartera por euro invertido durante cada periodo antes y después de cada crisis.

Durante la crisis financiero de 2008, observamos comportamientos variados entre los modelos (Tabla 11). El modelo de Markowitz muestra un aumento en el riesgo postcrisis, lo cual es común durante periodos de alta volatilidad financiera, aunque su rentabilidad se mantuvo de forma moderada. Por otro lado, el modelo de Black-Litterman, muestra una rentabilidad excepcionalmente alta antes de la crisis y logra mantener un riesgo relativamente bajo después. Cabe mencionar que, aunque en el modelo se puso como expectativa del inversor que la rentabilidad iba a bajar en el periodo postcrisis, no ha ayudado a mantener una rentabilidad elevada. El algoritmo genético, aunque toma un enfoque más innovador, no logra rendimientos positivos antes de la crisis. Este resultado sugiere que el algoritmo genético este sufriendo de un problema de underfitting, ya explicado previamente, durante la fase de training. Curiosamente, mejora en la fase del test, lo cual es inusual en problemas de underfitting pero esto puede darse a razones como el cambio en las condiciones del mercado como diferencia en la volatilidad del mercado. De todas formas, el algoritmo genético sigue por debajo del resto de las rentabilidades de los modelos postcrisis. Comparativamente, el índice S&P500 refleja un incremento considerable en la rentabilidad postcrisis, pero a un coste de riesgo significativamente

más alto. De todas formas, vemos que aunque el modelo de Markowitz toma una posición más conservadora, con ninguno de los modelos se obtienen rentabilidades excesivas manteniendo un riesgo bajo.

“Tabla 11. Resultados aplicados a la Crisis Financiera de 2008 (Fuente: Tabla de elaboración propia)”

CRISIS FINANCIERA 2008				
Carteras	Antes		Después	
	rentabilidad	riesgo	rentabilidad	riesgo
Markowitz	2,75%	3,01%	1,86%	6,61%
Black-Litterman	41,01%	0,11%	1,80%	3,77%
Algoritmo Genético	-4,61%	16,21%	1,31%	3,28%
SP500	2,77%	25,67%	39,23%	32,67%

En la crisis del euro de 2010, la performance del modelo de Black-Litterman destaca nuevamente con una rentabilidad antes de la crisis desproporcionadamente alta, lo cual en este caso sugiere que este sufriendo de un problema de overfitting durante la fase de training (Tabla 12). A esto se le suma que en el periodo de postcrisis que equivale a la fase de test, la rentabilidad se reduce drásticamente unido a un aumento en el riesgo lo que indica que el modelo puede no estar generalizando bien más allá de las condiciones específicas. Este cambio en el rendimiento sugiere que el modelo, aunque ha sido capaz de capturar con gran precisión las tendencias de precios previos a la crisis, no ha podido adaptarse a las condiciones del mercado postcrisis. El modelo de Markowitz y el Algoritmo Genético tuvieron una reducción similar en cuanto a la rentabilidad y un aumento en el riesgo, mientras que el S&P500, aunque mantuvo rentabilidades más altas, logro reducir el riesgo asociado, mostrando una resiliencia notable.

“Tabla 12. Resultados aplicados a la Crisis del Euro de 2010 (Fuente: Tabla de elaboración propia)”

CRISIS DEL EURO DE 2010				
Carteras	Antes		Después	
	rentabilidad	riesgo	rentabilidad	riesgo
Markowitz	4,64%	2,25%	2,07%	5,51%
Black-Litterman	1473,26%	0,25%	1,47%	3,10%
Algoritmo Genético	17,61%	25,00%	1,31%	3,27%

SP500	46,21%	33,90%	46,97%	16,85%
-------	--------	--------	--------	--------

Durante la crisis del COVID-19, todas las carteras, experimentan reducciones en sus rentabilidades, lo que es típico en periodos de incertidumbre económica y de mercado como los inducidos por la pandemia (Tabla 13). El modelo de Black-Litterman, al igual que en la crisis del euro de 2010, muestra una rentabilidad muy alta antes de la crisis con un riesgo increíblemente bajo. Sin embargo, después de la crisis, la rentabilidad cae drásticamente mientras que el riesgo aumenta. El modelo parece estar excesivamente optimizado nuevamente para las condiciones del mercado antes de la crisis, capturando detalles específicos y posiblemente ruido de los datos, haciendo que no generalice bien al adaptarse a las nuevas condiciones del mercado postcrisis, indicando así, que sufre de overfitting. Por otro lado, el algoritmo genético exhibe una rentabilidad negativa con un riesgo relativamente alto antes de la crisis. Esto mejora después de la crisis con una rentabilidad positiva y un riesgo moderado. Este comportamiento puede interpretarse como underfitting, donde el modelo es demasiado simple. Como resultado, no logra rendir bien, aunque muestra una ligera mejora en el entorno postcrisis que podría deberse a cambios en el mercado que casualmente se alinean mejor con las capacidades limitadas del modelo. El modelo de Markowitz, en cambio, refleja un comportamiento bastante estable antes y después de la crisis del COVID-19. Por último, el S&P500 en su conjunto, muestra una mejora en su rentabilidad y una variación significativa en su riesgo. Esto podría reflejar una recuperación del mercado más general o la eficacia de las respuesta políticas y económicas que se implementaron para manejar la crisis.

“Tabla 13. Resultados aplicados a la Crisis del COVID-19 (Fuente: Tabla de elaboración propia)”

CRISIS DEL COVID-19				
Carteras	Antes		Después	
	rentabilidad	riesgo	rentabilidad	riesgo
Markowitz	1,94%	3,15%	1,76%	3,03%
Black-Litterman	87,46%	0,24%	1,24%	2,87%
Algoritmo Genético	-12,62%	17,27%	1,88%	3,59%
SP500	46,21%	33,90%	46,97%	16,85%

5.3 Identificación de Líderes ESG

A continuación, se procede a analizar los resultados al intentar identificar las empresas líderes de ESG en el S&P500. Como resultado, se obtienen las 10 empresas con mejor rating ESG y paralelamente las 10 empresas con peor rating ESG (Figura 4) a partir de la variable que se ha creado tomando como base las 4 variables mencionadas antes.

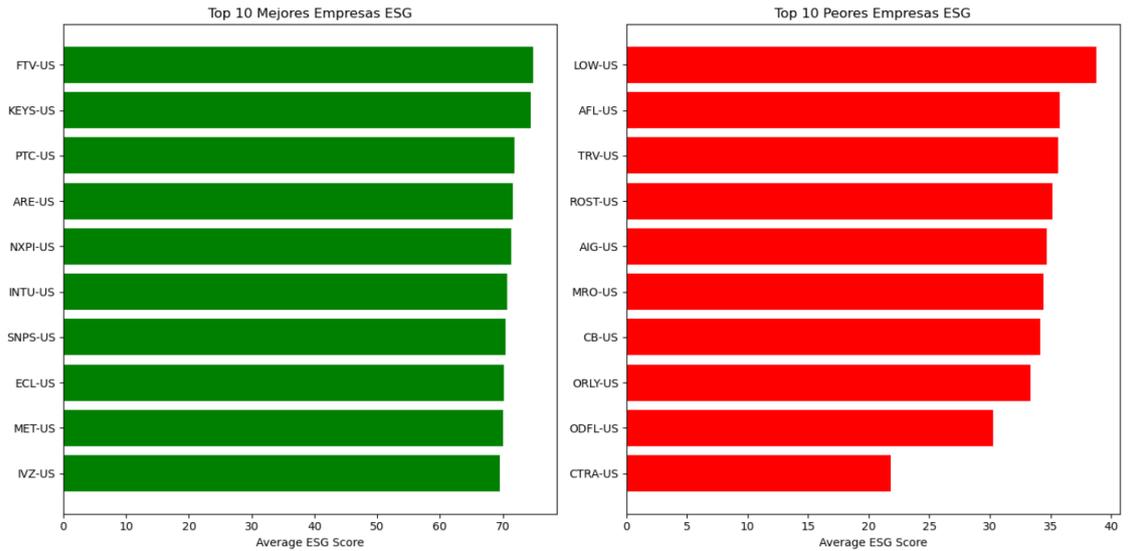


Figura 4. Ranking empresas ESG según variable creada (Fuente: Gráfico de elaboración propia)

En el diagrama de la izquierda, las barras verdes representan las 10 empresas del S&P500 con la puntuación más alta en términos de ESG, lo que implica una mejor performance en términos de sostenibilidad, social y gobernanza. Este ranking (Tabla 14) está formado por empresas de diferentes sectores donde se observa una tendencia hacia la superioridad del sector tecnológico en la actualidad.

“Tabla 14. Top 10 empresas ESG (Fuente: Tabla de elaboración propia)”

Ranking	Símbolo	Empresa	Sector
1	FTV- US	Fortive Corp.	Industrial
2	KEYS-US	Keysight Technologies Inc	Tecnológico

3	PTC- US	PTC Inc.	Industrial
4	ARE- US	Alexandria Real Estate Equities, Inc	Financiero
5	NXPI- US	NXP Semiconductors NV	Tecnológico
6	INTU- US	Intuit Inc.	Tecnológico
7	SNPS- US	Synopsys, Inc.	Tecnológico
8	ECL- US	Ecolab Inc.	Materiales no energéticos
9	MET- US	MetLife, Inc.	Financiero
10	IVZ- US	Invesco Ltd.	Financiero

Este dominio puede atribuirse a que las empresas tecnológicas tienen una huella de carbono inferior ya que estas no necesitan recurrir a recursos naturales. Las operaciones tecnológicas se realizan en infraestructuras digitales como los centros de datos que tienen el potencial de ser más eficientes y estar más alineadas con fuentes de energía renovables (KPMG, 2020). Por otro lado, la gestión del agua en este tipo de empresas es ínfimo por lo que no presenta tantos desafíos como en otro tipo de sectores. Adicionalmente, cada vez más empresas se preocupan por el ámbito de la salud y la seguridad laboral de sus empleados, así como de la implementación de una correcta ética empresarial (Cockburn, 2005).

Por otro lado, en el diagrama de la derecha, se encuentran las 10 empresas del S&P500 con peor rating ESG (Tabla 15). Esta vez, el sector de empresas que se obtienen, es aún más variado, aunque nuevamente, encontramos un sector predominante, que en este caso es el financiero.

“Tabla 15. Worst 10 empresas ESG (Fuente: Tabla de elaboración propia)”

Ranking	Símbolo	Empresa	Sector
1	LOW- US	Lowe’s Companies, Inc.	Hotelero
2	AFL- US	Aflac Incorporated	Financiero
3	TRV-US	Travelers Companies, Inc.	Financiero

4	ROST- US	Ross Stores, Inc.	Grán Almacen
5	AIG- US	American International Group, Inc.	Financiero
6	MRO- US	Marathon Oil Corporation	Energético
7	CB- US	Chubb Limited	Financiero
8	ORLY- US	O'Reilly Automotiv, Inc.	Automovilístico
9	ODFL- US	Old Dominion Freight Line, Inc.	Industrial
10	CTRA- US	Coterra Energy, Inc.	Energético

Aunque dicho resultado resulta extraño, las firmas financieras pueden tener puntuaciones ESG más bajas debido a la influencia indirecta que tienen en sectores con intensas emisiones de carbono a través de sus inversiones, así como a los desafíos éticos específicos del sector, como el manejo de riesgos asociados a la conducta empresarial. Estos factores pueden eclipsar las áreas en las que normalmente podrían desempeñarse bien, como la seguridad laboral, y destacar la necesidad de prácticas más sostenibles y éticas (Antuña et al., 2020).

Pero, a la hora de comparar las mejores y las peores empresas en la composición de carteras, se han tenido en cuenta la variable 'Materiality' como ya se ha mencionado antes. La cual aporta unos resultados totalmente diferentes a los obtenidos (Figura 5), lo cual sugiere que a la hora de valorar empresas por sus términos ESG no se puede simplificar dicho análisis eligiendo cuatro variables por mucho que cada una pertenezca a cada uno de los niveles de ESG.

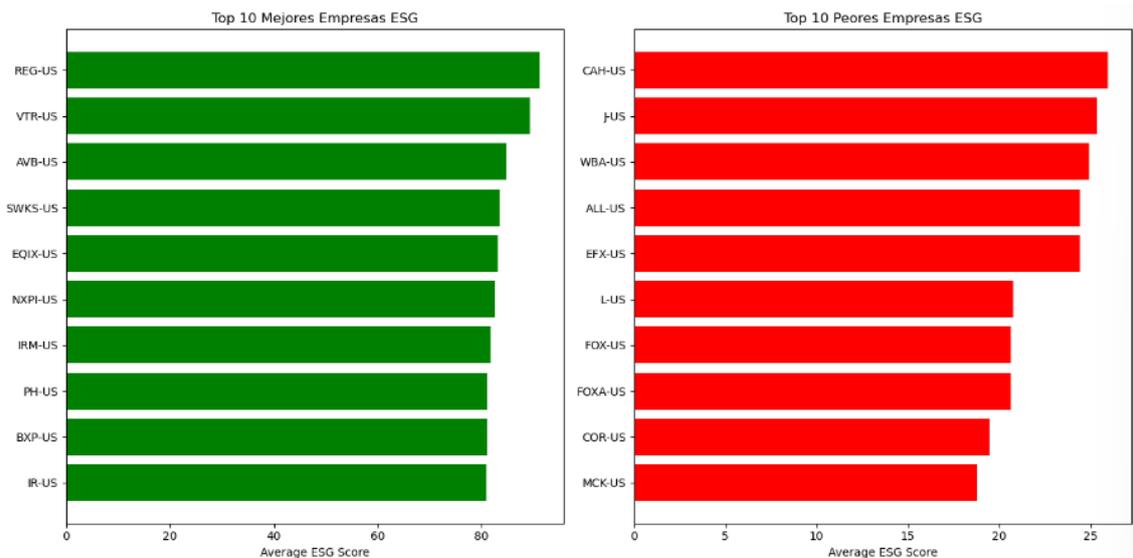


Figura 5: Ranking empresas ESG según variable “Materiality” (Fuente: Gráfico de elaboración propia)

Tras haber obtenido el listado de dichas empresas, se procede a comparar la cartera con las 10 mejores empresas de ESG denominada ‘best ESG’ y las 10 peores empresas del ESG denominada ‘worst ESG’ con el resto de los modelos programados (Tabla 16).

“Tabla 16. Resultados ampliados aplicados a la Crisis del COVID-19 (Fuente: Tabla de elaboración propia)”

CRISIS DEL COVID-19				
Modelos	Antes		Después	
	rentabilidad	riesgo	rentabilidad	riesgo
Markowitz	1,94%	3,15%	1,76%	3,03%
Black-Litterman	87,46%	0,24%	1,24%	2,87%
Algoritmo Genético	-12,62%	17,27%	1,88%	3,59%
SP500	46,21%	33,90%	46,97%	16,85%
top ESG	0,45%	2,73%	0,45%	2,73%
worst ESG	1,76%	2,62%	1,76%	2,62%

En este caso, se han obtenido las mismas rentabilidades y riesgo para ambos periodos antes y después de la crisis. Vemos que la cartera formada por las peores empresas ESG, es la que mejores rendimientos obtiene en comparación con la otra cartera ESG. Esto nos sugiere que para el caso de la crisis del COVID-19, invertir en empresas cuya puntuación es la mejor en términos ESG no protege a los inversores en momentos de incertidumbre económica.

6. Conclusión

A lo largo de este trabajo se ha investigado y desarrollado la eficacia de tres modelos de inversión distintos- el modelo de Markowitz, el modelo de Black-Litterman y un algoritmo genético- para determinar cuál de ellos ofrece las mejores predicciones en la formación de una cartera de inversión compuesta por diez activos que forman parte del S&P500 durante tres diferentes crisis económicas que han causado un impacto significativo en el ámbito financiero mundial. Este análisis se centra en observar la capacidad predictiva de cada modelo bajo condiciones de mercado extremadamente volátiles.

Adicionalmente, se ha explorado la influencia de los factores ambientales, sociales y de gobernanza (ESG) en el rendimiento de las carteras de inversión durante el periodo de inestabilidad económica ocasionado por la pandemia de COVID-19. Para ello, se han comparado las carteras formadas por empresas del S&P500 con puntuaciones ESG altas y bajas para identificar si existe una correlación entre una alta clasificación ESG y un mejor desempeño financiero en tiempos de crisis.

Este enfoque dual no solo ayuda a entender que modelo es el que puede predecir mejor la composición óptima de una cartera de activos, sino que también proporciona insight sobre si integrar criterios ESG podría considerarse como un indicador de resiliencia financiera frente a situaciones económicas adversas.

Tras haber aplicado técnicas de aprendizaje supervisado para desarrollar y evaluar los tres modelos de inversión distintos, con cada período de crisis económica tratada como un conjunto de datos independiente, subdividiendo en conjuntos de training y test, los hallazgos sugieren que el modelo de Markowitz muestra la mayor capacidad de predecir de manera efectiva la composición de una cartera de inversión que logra estabilizar rendimiento y mantener el riesgo a niveles moderados, incluso bajo las condiciones extremadamente adversas de los mercados durante los períodos de crisis analizados. Esta consistencia sugiere que el modelo de Markowitz podría ser preferible para inversores que buscan una estrategia que mitigue los riesgos sin sacrificar considerablemente los rendimientos durante periodos de volatilidad económica.

En contraste, los otros modelos investigados, el modelo de Black-Litterman y el algoritmo genético, enfrentaron problemas específicos de overfitting y underfitting,

respectivamente. Durante los periodos de antes de la crisis del Euro de 2010 y la crisis del COVID-19, el modelo de Black-Litterman mostró un desempeño sustancialmente alto debido al overfitting, donde el modelo era demasiado específico para los datos de training. Por otro lado, el algoritmo genético sufrió de underfitting, indicando que era demasiado simple para capturar la complejidad de los datos, lo que resultaba en predicciones ineficaces. Estos problemas subrayan la necesidad de ajustar estos modelos para mejorar su adaptabilidad y precisión en futuras líneas de investigación.

Por consiguiente, la hipótesis de que una mejora calificación ESG es una cartera de inversión podría traducirse en un mejor rendimiento durante periodos de incertidumbres económica, contrario a las expectativas, los resultados demostraron que, para la crisis del COVID-19, las carteras compuestas por empresas del S&P500 con peores calificaciones ESG superaron a aquellas con mejores calificaciones ESG en términos de rendimiento. Este hallazgo es intrigante ya que sugiere que, en ciertos contextos, los factores ESG no necesariamente predicen un mejor rendimiento económico. Este resultado abre caminos para futuras investigaciones sobre la relevancia y el impacto de los factores ESG en diferentes condiciones de mercado y estructuras determinadas de crisis.

Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado

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

Por la presente, yo, Cristina Bautista Dixon, estudiante de E-2+ Business Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado "Evaluación de Modelos de Inversión y el Impacto de los Factores ESG en Periodos de Crisis Económica", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación [el alumno debe mantener solo aquellas en las que se ha usado ChatGPT o similares y borrar el resto. Si no se ha usado ninguna, borrar todas y escribir "no he usado ninguna"]:

1. **Interpretador de código:** Para realizar análisis de datos preliminares.
2. **Constructor de plantillas:** Para diseñar formatos específicos para secciones del trabajo.
3. **Corrector de estilo literario y de lenguaje:** Para mejorar la calidad lingüística y estilística del texto.
4. **Generador previo de diagramas de flujo y contenido:** Para esbozar diagramas iniciales.
5. **Sintetizador y divulgador de libros complicados:** Para resumir y comprender literatura compleja.
6. **Generador de problemas de ejemplo:** Para ilustrar conceptos y técnicas.
7. **Revisor:** Para recibir sugerencias sobre cómo mejorar y perfeccionar el trabajo con diferentes niveles de exigencia.
8. **Traductor:** Para traducir textos de un lenguaje a otro.

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

Fecha: 15 de junio de 2024

Firma: 

7. Bibliografía

Adrian, T., Natalucci, F. M., & Qureshi, M. S. (2022). *Macro-Financial Stability in the COVID-19 Crisis: Some Reflections*. International Monetary Fund.

Anaconda/Packages/Matplotlib. Anaconda.org. <https://anaconda.org/conda-forge/matplotlib>

Anaconda/Packages/Pandas. Anaconda.org. <https://anaconda.org/anaconda/pandas>

Antuña, C., Aumente, P., Anglés, D., Ruiz de las peñas, J., Álvarez, M., & Benítez, B. (2020). *SOSTENIBILIDAD Y GESTIÓN DE ACTIVOS*. Analistas Financieros Internacionales.

Baldwin, R., & Giavazzi, F. (2015). *The Eurozone Crisis*. Center for Economic Policy Research.

Becker, B., & Ivashina, V. (2018). Financial Repression in the European Sovereign Debt Crisis*. *Review of Finance*, 22(1), 83-115. <https://doi.org/10.1093/rof/rfx041>

Black, F., & Litterman, R. (1992). Global Portfolio Optimization. *Financial Analysts Journal*, 48(5), 28-43. <https://doi.org/10.2469/faj.v48.n5.28>

Blanco, R., Mayordomo, S., Menéndez, Á., & Mulino, M. (2021). *Impact of the COVID-19 crisis on Spanish firms' financial vulnerability*. *Documentos Ocasionales N.º 2119*. Banco de España.

Boffo, R., & Patalano, R. (2020). *ESG Investing: Practices, Progress and Challenges*. OECD Paris, www.oecd.org/finance/ESG-Investing-Practices-Progress-and-Challenges.pdf

Bomfim, A. N. (2022). Credit Default Swaps. *Finance and Economics Discussion Series*, 2022 (023), 1-27. <https://doi.org/10.17016/FEDS.2022.023>

Brownlees, C., Llorens, J., & Senar, N. (2021). *Modelos de selección de carteras con muchos activos*.

Cockburn, W. (2005). *La responsabilidad social de las empresas y la seguridad y la salud en el trabajo* (p. 148). Agencia Europea para la Seguridad y la Salud en el Trabajo.

Comisión Europea. (2020). *Plan de recuperación Para Europa*. https://commission.europa.eu/strategy-and-policy/recovery-plan-europe_es

Conférence des Nations Unies sur le commerce et le développement (Ed.). (2010). *The financial and economic crisis of 2008-2009 and developing countries*. United Nations.

Crespo Espert, J. L., & Mir Fernandez, C. (2009). *Descubriendo el mercado (II): La rentabilidad*.

CVXOPT. *Cvxop.org*. <https://cvxopt.org/>

Dabush, U. (2010). *Paradigm Lost. The Euro in Crisis*. Carnegie Endowment for International Peace.

Das, A. K., Dutt, S., & Chandramouli, S. (2019). *Machine Learning*.

Dolan, L. R., & Nguyen, Q. (2021). Mutual gain or resource drain? Attitudes toward international financial assistance during the early COVID-19 pandemic. *International Interactions*, 47(6), 1131-1150. <https://doi.org/10.1080/03050629.2021.1962858>

El imperativo de las ESG para las empresas tecnológicas (p. 7). (2020). KPMG.

FactSet Research Systems Inc. (2021). *Content methodology: Truvalue SASB Scores & Spotlights*. <https://www.factset.com>

FactSet Research Systems Inc. (2021). *Standard datafeed user guide: FactSet ESG SASB Codified Edition V2*. <https://www.factset.com>

Fahria, I., & Kustiawan, E. (2021). *Genetic Algorithm Approach in Forming the Optimal Portfolio of Issuer Companies with Dividend Distribution Criteria: 1st International Conference on Mathematics and Mathematics Education (ICMMEd 2020)*, Ambon, Indonesia. <https://doi.org/10.2991/assehr.k.210508.107>

Fernández Cerezo, A., Montero, J. M., & Prades, E. (2021). *Informe trimestral de la economía española* (El impacto potencial de los cuellos de botella en las cadenas globales de suministro sobre la economía española en los próximos trimestres). Banco de España.

Griffin, J. M., Harris, J. H., Shu, T., & Topaloglu, S. (2011). Who Drove and Burst the Tech Bubble? *The Journal of Finance*, 66(4), 1251-1290. <https://doi.org/10.1111/j.1540-6261.2011.01663.x>

Gunzberg, J., & Edwards, T. (2018). *¿Por qué el S&P 500® es importante a nivel global?*. S&P Dow Jones Indices

Haider, D. S. A. (2023). *SUPERVISED LEARNING ALGORITHMS - CLASSIFICATION AND REGRESSION ALGORITHMS*.

He, G., & Litterman, R. (2002). The Intuition Behind Black-Litterman Model Portfolios. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.334304>

Herrera, F. (2009). Introducción a los Algoritmos Metaheurísticos. *Swarm Intelligence*.

Holland, J. H. (1992). *Genetic Algorithms*. Scientific American.

How UNESCO's mandate in earth sciences contributes to the implementation of the United Nations 2030 agenda. (2015). UNESCO.

Impact of COVID-19 on the Global Financial System. (2020). World Economic Forum.

Índice S&P 500 ESG INDEX. (2022). S&P Dow Jones Indices.

Índice S&P 500® ESG. (2024). S&P Dow Jones Indices.

Informe anual 2011 (p. 254). (2011). Bolsas y Mercados Españoles (BME).

James, H. (2024). *The IMF and the European Debt Crisis*. International Monetary Fund.
<https://doi.org/10.5089/9798400231902.071>

Kräussl, R., Lehnert, T., & Stefanova, D. (2016). The European sovereign debt crisis: What have we learned? *Journal of Empirical Finance*, 38, 363-373.
<https://doi.org/10.1016/j.jempfin.2016.04.005>

La brújula del mercado de alta capitalización de EE. UU. (2023). S&P Dow Jones Indices.

Laffaye, S. (2008). *La crisis financiera: origen y perspectivas* (nº 13). Revista del CEI.

Markowitz, H. (1952). *The journal of finance* (Vol. 7). American Finance Association.

McKibbin, W. J., & Stoeckel, A. (2010). The Global Financial Crisis: Causes and Consequences. *Asian Economic Papers*, 9(1), 54-86.
<https://doi.org/10.1162/asep.2010.9.1.54>

Moreno, A., Armengol, E., Béjar Alonso, J., Belanche Muñoz, L. A., Cortés García, C. U., Gavaldà Mestre, R., Gimeno, J. M., Martín Muñoz, M., & Sánchez-Marrè, M. (1994). *Aprendizaje automático*. Edicions UPC. <https://doi.org/10.5821/ebook-9788483019962>

Morrison, R. (2021). Environmental, Social, and Governance Theory: Defusing a Major Threat to Shareholder Rights. *SSRN Electronic Journal*.
<https://doi.org/10.2139/ssrn.3845709>

Official Government Edition. (2011). *THE FINANCIAL CRISIS INQUIRY REPORT*.

Pollman, E. (2022). *The Making and Meaning of ESG*. European Corporate Governance Institute (ECGI).

Reserve Bank of Australia (RBA). (2020). *The Global Financial Crisis*.

S&P U.S. Indices. Metodología. (2024). S&P Dow Jones Indices.

Sefiane, S., & Benbouziane, M. (2012). *Portfolio Selection Using Genetic Algorithm* (nº 4). Journal of Applied Finance & Banking.

Sharpe, W., F. (1994). The Sharpe Ratio. *The Journal of Portfolio Management*. Stanford University.

Spivey, A., Zilberman, I., & Orzano, M. (2024). *El creciente ecosistema de liquidez del S&P 500 ESG*.

Sustainability Risk Management. Powering performance for responsible growth (p. 18). (2019). Deloitte.

Szczepanski, M. (2019). *A decade on from the crisis*. European Parliament.

The 2030 agenda for sustainable development. (2015). United Nations.

The COVID-19 Crisis: An unprecedented shock. (2020). CaixaBank Research.

Van Duuren, E., Plantinga, A., & Scholtens, B. (2016). ESG Integration and the Investment Management Process: Fundamental Investing Reinvented. *Journal of Business Ethics*, 138(3), 525-533. <https://doi.org/10.1007/s10551-015-2610-8>

World Development Report 2022 (Emerging risks to the recovery). (2022). The World Bank.

Wrobel, J. (2017). *The cost of crisis: Why stock fees rise when markets slip* (n° 3). U.S. Bureau of Labor Statistics.

Zurita González, J. & Martínez Pérez, J. F. (2009). *La crisis financiera y económica del 2008. Origen y consecuencias en los Estados Unidos y México* (n° 1579). Universidad Autónoma Metropolitana Unidad Azcapotzalco.

8. Anexo

TFG ANALYTICS

```
pip install pandas numpy cvxopt  
pip install deap  
pip install numpy deap  
from math import sqrt  
import numpy as np  
import pandas as pd  
import matplotlib.pyplot as plt  
from cvxopt import matrix, solvers  
from scipy.optimize import minimize  
from numpy.linalg import inv  
import random  
from deap import base, creator, tools, algorithms  
from numpy.linalg import inv  
from datetime import datetime  
from scipy import stats  
from pandas.tseries.offsets import BDay
```

SP500 HISTORIAL

```
historial_sp500= pd.read_excel('sp500_historical.xlsx', skiprows=2)  
print(historial_sp500.head())  
In [ ]:  
historial_sp500.columns=['Date', 'Price', 'PE_LTM', 'PE_NTM']  
historial_sp500['Date']=pd.to_datetime(historial_sp500['Date'])  
historial_sp500['Price']=pd.to_numeric(historial_sp500['Price'], errors='coerce')  
historial_sp500=historial_sp500.sort_values('Date').reset_index(drop=True)  
print(historial_sp500.head())
```

In []:

```
periodos = [('2006-01-01', '2008-09-01'), ('2009-01-01', '2010-12-31'), ('2009-01-01', '2011-06-30'), ('2012-01-01', '2013-12-31'), ('2018-01-01', '2020-03-01'), ('2021-01-01', '2022-12-31')]
```

In []:

```
historial_sp500['Log Returns'] = np.log(historial_sp500['Price'] / historial_sp500['Price'].shift(1))
```

In []:

```
def calcular_retorno_volatilidad(df, start_date, end_date):
```

```
    filtered_data = df[(df['Date'] >= start_date) & (df['Date'] <= end_date)]
```

```
    mean_log_return = filtered_data['Log Returns'].mean()
```

```
    volatility = filtered_data['Log Returns'].std()
```

```
    annual_return = np.exp(mean_log_return * filtered_data['Log Returns'].count()) - 1 # Total  
    retorno para el período
```

```
    annual_volatility = volatility * np.sqrt(filtered_data['Log Returns'].count()) # Volatilidad  
    ajustada al número de días
```

```
    return (annual_return, annual_volatility)
```

In []:

```
results = {}
```

```
for i, (start, end) in enumerate(periodos):
```

```
    results[f'Period {i+1}'] = calcular_retorno_volatilidad(historial_sp500, start, end)
```

```
# Mostrar resultados
```

```
for period, values in results.items():
```

```
    print(f"{period} - Return: {values[0]:.4f}, Volatility: {values[1]:.4f}")
```

```
Subida y limpieza de datos
```

In []:

```
# Subimos los ficheros con los que vamos a trabajar
```

```
listado_sp500 = pd.read_excel('Listado.xlsx', index_col='p_symbol')
```

```
listado_sp500
```

In []:

```

precios= pd.read_excel('SP500 def.xlsx', index_col=0)

precios

In [ ]:

#limpiamos los datos

precios.dropna(axis=1, inplace=True)

precios.replace([np.inf, -np.inf], np.nan, inplace=True)

precios.dropna(axis=1, inplace=True)

In [ ]:

precios=precios.loc[:, (precios!=0).all(axis=0)]

In [ ]:

# función para filtrar las empresas con datos completos en un rango de fechas

def precios_completo(precios, fecha_inicio, fecha_fin):

    periodo= precios.loc[fecha_inicio:fecha_fin]

    return periodo.dropna(axis=1, how='any')

In [ ]:

#seleccionamos los periodos para las fechas que necesitamos

periodos=[('2006-01-01', '2008-09-01'),('2009-01-01', '2011-06-30'), ('2018-01-01', '2020-03-01')]

In [ ]:

#Aplicamos filtro para cada periodo

precios_crisis= [precios_completo(precios,*periodo) for periodo in periodos]

precios_crisis

In [ ]:

for i, df in enumerate(precios_crisis):

    print(f"Revisión del DataFrame {i+1}")

    print("Información general:")

```

```

print(df.info()) # Muestra información general, incluyendo el tipo de dato de cada columna.

print("Primeras filas del DataFrame:")

print(df.head()) # Muestra las primeras filas para ver ejemplos de los datos.

print("Verificación de valores NaN en el DataFrame:")

print(df.isna().sum().sum(), "valores NaN") # Cuenta todos los valores NaN en el DataFrame.

print("Verificación de valores infinitos en el DataFrame:")

print(np.isinf(df).values.sum(), "valores infinitos") # Cuenta valores infinitos en el
DataFrame.

print("Número de columnas (activos) con datos completos:")

print(len(df.dropna(axis=1).columns)) # Muestra el número de columnas sin valores NaN.

print("Descripción estadística del DataFrame:")

print(df.describe()) # Estadísticas descriptivas para ver rangos de valores y detectar
anomalías.

print("\n")

```

Markowitz

#Función para calcular retornos logarítmicos

```
def calcular_retornos(precios):
```

```
    return np.log(precios/precios.shift(1))
```

In []:

#Función para seleccionar los 10 mejores activos basados en el sharpe ratio indiv

```
def seleccionar_mejores_activos(retornos):
```

```
    sharpe_ratios = retornos.mean() / retornos.std()
```

```
    mejores_activos = sharpe_ratios.nlargest(10).index
```

```
    return retornos[mejores_activos], list(mejores_activos)
```

In []:

Función para calcular el retorno y la volatilidad de la cartera

```
def calcular_metricas_cartera(pesos, retornos, cov_matrix):
```

```
retorno_cartera = np.sum(retornos.mean() * pesos)
volatilidad_cartera = np.sqrt(np.dot(pesos.T, np.dot(cov_matrix, pesos)))
return retorno_cartera, volatilidad_cartera
```

In []:

```
#Función para aplicar el modelo de Markowitz
```

```
def optimizar_markowitz(precios):
```

```
    retornos, activos_seleccionados= seleccionar_mejores_activos(calcular_retornos(precios))
    expected_returns=retornos.mean()
    cov_matrix=retornos.cov()
    num_assets=len(expected_returns)
    initial_guess= np.array([1./num_assets]*num_assets)
    bounds=tuple((0.0, 1.0) for asset in range(num_assets))
```

```
#Ponemos como restricción que la suma de pesos sea igual a 1
```

```
constraints=[{'type': 'eq', 'fun': lambda x:np.sum(x)-1}
            ]
```

```
def neg_sharpe_ratio(weights, returns, cov_matrix, risk_free_rate):
```

```
    pf_ret=np.sum(returns*weights)
    pf_vol=np.sqrt(np.dot(weights.T, np.dot(cov_matrix, weights)))
    pf_sharpe= (pf_ret- risk_free_rate)/ pf_vol
    return -pf_sharpe
```

```
result= minimize(neg_sharpe_ratio, initial_guess, args=(expected_returns, cov_matrix, 0.01),
method='SLSQP', bounds=bounds, constraints=constraints)
```

```
if not np.isclose(np.sum(result.x), 1, atol=1e-10):
```

```
    raise ValueError("La optimización no resulto en una suma de pesos de 1.")
```

```
return result.x, expected_returns, cov_matrix, activos_seleccionados
```

In []:

```
#Aplicamos la optimización para cada periodo
```

```

resultados = {}

for fecha_inicio, fecha_fin in periodos:

    precios_periodo = precios_completo(precios, fecha_inicio, fecha_fin)

    pesos, retornos, cov_matrix, activos_seleccionados= optimizar_markowitz(precios_periodo)

    retorno_cartera, volatilidad_cartera = calcular_metricas_cartera(pesos, retornos,
cov_matrix)

    resultados[(fecha_inicio, fecha_fin)] = (pesos, retorno_cartera, volatilidad_cartera,
activos_seleccionados)

```

In []:

```

print("Resultados de la Optimización de la Cartera:")

for (fecha_inicio, fecha_fin), (pesos, retorno_cartera, volatilidad_cartera,
activos_seleccionados) in resultados.items():

    print(f"\nPeriodo {fecha_inicio} hasta {fecha_fin}:")

    print(f" Retorno de la cartera: {retorno_cartera:.4f}")

    print(f" Volatilidad de la cartera: {volatilidad_cartera:.4f}")

    print(" Composición de la cartera:")

    for activo, peso in zip(activos_seleccionados, pesos):

        print(f" {activo}: {peso:.4f}")

```

In []:

```

precios_post2008= precios['2009-01-01':'2010-12-31']

pre2008_mk= ['FMC-US', 'MOS-US', 'BAX-US', 'BKNG-US', 'LIN-US', 'MCD-US', 'CSX-US', 'TMO-
US', 'GD-US', 'LMT-US']

cartera1_mk= precios_post2008[pre2008_mk]

retornos = np.log(cartera1_mk / cartera1_mk.shift(1))

pesos=np.array([0.0666, 0.1563, 0.2350, 0.1067, 0.0000, 0.0000, 0.1907, 0.0000, 0.0000,
0.2448])

rendimiento_cartera1= np.sum(pesos*retornos.mean())

varianza_cartera1= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

```

```

riesgo_cartera1= np.sqrt(varianza_cartera1)

print(f"Rendimiento anualizado de la cartera1: {rendimiento_cartera1}")
print(f"Riesgo (desviación estándar anualizada) de la cartera1: {riesgo_cartera1}")

In [ ]:

precios_post2011= precios['2012-01-01':'2013-12-31']

pre2011_mk= ['CTSH-US', 'AAPL-US', 'HRL-US', 'EW-US', 'COO-US', 'NFLX-US', 'TSCO-US', 'PXD-
US', 'EL-US', 'TJX-US']

cartera2_mk= precios_post2011[pre2011_mk]

retornos = np.log(cartera2_mk / cartera2_mk.shift(1))

pesos=np.array([0.1218, 0.0000, 0.5098, 0.1321, 0.0155, 0.1805, 0.0160, 0.0243, 0.0000,
0.0000])

rendimiento_cartera2= np.sum(pesos*retornos.mean())

varianza_cartera2= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera2= np.sqrt(varianza_cartera2)

print(f"Rendimiento anualizado de la cartera2: {rendimiento_cartera2}")
print(f"Riesgo (desviación estándar anualizada) de la cartera2: {riesgo_cartera2}")

In [ ]:

precios_post2019= precios['2021-01-01':'2022-12-31']

pre2019_mk= ['NEE-US', 'STE-US', 'MSFT-US', 'BRO-US', 'AEE-US', 'TDY-US', 'AJG-US', 'ETR-US',
'ADBE-US', 'BALL-US']

cartera3_mk= precios_post2011[pre2019_mk]

retornos = np.log(cartera3_mk / cartera3_mk.shift(1))

pesos=np.array([0.4624, 0.2926, 0.0000, 0.0755, 0.0000, 0.0000, 0.0000, 0.0000, 0.0829,
0.0866])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

```

```
varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))
```

```
riesgo_cartera3= np.sqrt(varianza_cartera3)
```

```
print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")
```

```
print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")
```

Blacklitterman

```
In [ ]:
```

```
#cargamos las capitalizaciones del índice S&P500 para aplicarlo al modelo de blacklitterman
```

```
market_cap= pd.read_excel('market cap.xlsx', index_col=0)
```

```
In [ ]:
```

```
market_cap.dropna(axis=1, inplace=True)
```

```
market_cap.replace([np.inf, -np.inf], np.nan, inplace=True)
```

```
market_cap.dropna(axis=1, inplace=True)
```

```
In [ ]:
```

```
market_cap=market_cap.loc[:, (market_cap!=0).all(axis=0)]
```

```
In [ ]:
```

```
#periodos de pre crisis
```

```
periodos = {
```

```
    '2006-2008': ('2006-01-01', '2008-08-31'),
```

```
    '2009-2011': ('2009-01-01', '2011-06-30'),
```

```
    '2018-2020': ('2018-01-01', '2020-02-29'),
```

```
}
```

```
In [ ]:
```

```
precios_periodos={}
```

```
for name, (start, end) in periodos.items():
```

```

period_precios= precios[start:end]

period_precios=period_precios.loc[:, (period_precios !=0).any(axis=0)]

precios_periodos[name]=period_precios

print(precios_periodos)

In [ ]:

def get_closest_date(df, target_date):

    # Usamos searchsorted para encontrar la posición de inserción para mantener el orden

    pos = df.index.searchsorted(target_date)

    # Si la posición es igual a la longitud del índice, entonces buscamos la última posición
    disponible

    if pos == len(df.index):

        closest_date = df.index[-1]

    else:

        # Comparamos con la fecha anterior para ver cuál está más cerca del target

        after = df.index[pos]

        if pos > 0 and (target_date - df.index[pos-1] < after - target_date):

            closest_date = df.index[pos-1]

        else:

            closest_date = after

    return closest_date

In [ ]:

market_caps = {}

for name, (start, end) in periodos.items():

    # Convertimos la fecha 'end' a datetime para asegurarnos que sea compatible con las
    operaciones de fechas

    closest_end_date = get_closest_date(market_cap, pd.to_datetime(end))

    period_cap = market_cap.loc[closest_end_date]

    period_cap = period_cap[period_cap != 0]

```

```
market_caps[name] = period_cap
```

```
print(market_caps)
```

```
In [ ]:
```

```
def market_portfolio(returns, market_caps):
```

```
    #Calcular la capitalización del mercado total
```

```
    total_market_cap=market_caps.sum().sum()
```

```
    #Calcular los pesos del portafolio de mercado
```

```
    market_weights=np.array([market_caps[ticker]/ total_market_cap for ticker in  
returns.columns])
```

```
    return market_weights
```

```
In [ ]:
```

```
def calculate_cov_matrix(returns):
```

```
    #calcular los retornos logaritmicos
```

```
    log_returns=np.log(returns/ returns.shift(1)).dropna()
```

```
    #calcular la matriz de cov
```

```
    covariance_matrix=log_returns.cov()
```

```
    return covariance_matrix
```

```
In [ ]:
```

```
def black_litterman_model(returns, market_caps, period, tau=0.05):
```

```
    # Número de activos
```

```
    n_assets = len(returns.columns)
```

```
    # Calcular el portafolio de mercado
```

```
    pi = market_portfolio(returns, market_caps)
```

```
    # Calcular la matriz de covarianza
```

```
    sigma = calculate_cov_matrix(returns)
```

```
    # Ajustar la matriz de covarianza con tau
```

```
    sigma_adjusted = sigma * tau
```

```

#Asumimos que después de cada crisis el mercado cae un 20%
if period in ['2009-2010', '2012-2013', '2021-2022']:
    view_return=pi*0.80
else:
    view_return=pi #sin ajuste para el resto de periodos

#Matriz de identidad para P si todas las acciones son ajustadas
P=np.eye(n_assets)

#Asumiendo una confianza bastante alta en nuestra vista, reducimos la incertidumbre
Omega= np.diag(np.full(n_assets, 0.1))

#Aplicar la fórmula de Black-Litterman
inverse_term= np.linalg.inv(np.linalg.inv(sigma_adjusted)+ P.T @ np.linalg.inv(Omega) @ P)
mu_bl = inverse_term @ ((np.linalg.inv(sigma_adjusted) @ pi) + (P.T @ np.linalg.inv(Omega)
@ view_return))
mu_bl_annual= (np.exp(mu_bl) -1)*12 #retornos anuales

return mu_bl_annual
In [ ]:
#Función para calcular el retorno esperado de la cartera
def portfolio_return(weights, returns):
    return np.dot(weights, returns)
In [ ]:
#Función para calcular la volatilidad de la cartera
def portfolio_volatility (weights, cov_matrix):
    return np.sqrt(np.dot(weights.T, np.dot(cov_matrix, weights)))

```

In []:

```
def optimize_portfolio (returns, cov_matrix, target_return=None):  
    n_assets= len(returns)  
    args= (cov_matrix, )  
    constraints= [{'type': 'eq', 'fun': lambda weights: np.sum(weights)-1}]  
    if target_return is not None:  
        constraints.append (({'type': 'eq', 'fun': lambda weights: portfolio_return (weights,  
returns)- target_return})  
    bounds= [(0,1) for _ in range(n_assets)]  
    initial_guess=[1. / n_assets]*n_assets  
    result= minimize (portfolio_volatility, initial_guess, args=args, method='SLSQP',  
bounds=bounds, constraints=constraints)  
    return result.x
```

In []:

```
optimized_portfolios_bl = {}  
for period, returns in precios_periodos.items():  
    market_caps_period = market_caps[period] # Asumiendo que tienes las capitalizaciones por  
periodo  
    mu_bl_annual = black_litterman_model(returns, market_caps_period, period)  
    sigma_bl= calculate_cov_matrix(returns)*0.05  
    optimal_weights=optimize_portfolio(mu_bl_annual, sigma_bl)  
  
    top_indices=np.argsort(optimal_weights)[-10:]  
    top_weights=optimal_weights[top_indices]  
    top_assets= returns.columns[top_indices]  
    top_returns=mu_bl_annual[top_indices]  
  
    expected_return=portfolio_return(top_weights, top_returns)  
    portfolio_vol=portfolio_volatility(optimal_weights, sigma_bl)
```

```

optimized_portfolios_bl[period] = {
    'Assets': top_assets,
    'Weights': top_weights,
    'Expected Return': expected_return,
    'Portfolio Volatility': portfolio_vol # Añade la volatilidad
}

# Se imprime también la volatilidad junto con los otros resultados
print(f'Optimized portfolio for {period}: {optimized_portfolios_bl[period]}')

```

In []:

```

precios_post2008= precios['2009-01-01':'2010-12-31']
pre2008_bl= ['DUK-US', 'MOS-US', 'RMD-US', 'COR-US', 'ODFL-US', 'WMT-US', 'LUV-US',
             'EL-US', 'TJX-US', 'AMAT-US']
cartera1_bl= precios_post2008[pre2008_bl]
retornos = np.log(cartera1_bl / cartera1_bl.shift(1))
pesos=np.array([0.04729561, 0.04797971, 0.04855889, 0.04868692, 0.05071844,
               0.06880142, 0.07068311, 0.07596573, 0.10001793, 0.14686003])

rendimiento_cartera1= np.sum(pesos*retornos.mean())
varianza_cartera1= np.dot(pesos.T, np.dot(retornos.cov(), pesos))
riesgo_cartera1= np.sqrt(varianza_cartera1)

print(f"Rendimiento anualizado de la cartera1: {rendimiento_cartera1}")
print(f"Riesgo (desviación estándar anualizada) de la cartera1: {riesgo_cartera1}")

In [ ]:
precios_post2011= precios['2012-01-01':'2013-12-31']

```

```

pre2011_bl= ['MTB-US', 'CRL-US', 'MKC-US', 'FE-US', 'NFLX-US', 'GIS-US', 'AKAM-US',
             'CPRT-US', 'CPB-US', 'HRL-US']

cartera2_bl= precios_post2011[pre2011_bl]

retornos = np.log(cartera2_bl / cartera2_bl.shift(1))

pesos=np.array([0.03399023, 0.03952454, 0.04781979, 0.05505312, 0.05742198,
               0.05877132, 0.06560911, 0.07872319, 0.1111622 , 0.3013457])

rendimiento_cartera2= np.sum(pesos*retornos.mean())

varianza_cartera2= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera2= np.sqrt(varianza_cartera2)

print(f"Rendimiento anualizado de la cartera2: {rendimiento_cartera2}")

print(f"Riesgo (desviación estándar anualizada) de la cartera2: {riesgo_cartera2}")

In [ ]:

precios_post2019= precios['2021-01-01':'2022-12-31']

pre2019_bl= ['SBAC-US', 'AXON-US', 'FFIV-US', 'IFF-US', 'REGN-US', 'DLTR-US',
            'RMD-US', 'SJM-US', 'NEM-US', 'CME-US']

cartera3_bl= precios_post2011[pre2019_bl]

retornos = np.log(cartera3_bl / cartera3_bl.shift(1))

pesos=np.array([0.04384052, 0.04531884, 0.05058566, 0.05315955, 0.0602954 ,
               0.08154447, 0.10125459, 0.10477999, 0.10917939, 0.26575951])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera3= np.sqrt(varianza_cartera3)

print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")

```

```
print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")
```

Algoritmo genético

```
In [ ]:
```

```
#periodos de pre crisis
```

```
periodos = {  
    '2006-2008': ('2006-01-01', '2008-08-31'),  
    '2009-2011': ('2009-01-01', '2011-06-30'),  
    '2018-2020': ('2018-01-01', '2020-02-29'),  
}
```

```
In [ ]:
```

```
#Filtramos los datos por los periodos y eliminamos las columnas donde la cotización sea 0 en  
cada periodo
```

```
precios_periodos={}  
  
for name, (start, end) in periodos.items():  
    period_precios= precios[start:end]  
    period_precios=period_precios.loc[:, (period_precios !=0).any(axis=0)]  
    precios_periodos[name]=period_precios  
  
print(precios_periodos)
```

```
In [ ]:
```

```
for key in precios_periodos:  
    precios_periodos[key]= precios_periodos[key].pct_change().dropna()
```

```
In [ ]:
```

```
#Definimos la función fitness para evaluar como de bueno es el portfolio
```

```
def fitness(weights, returns):  
    portfolio_return=np.sum(returns.mean()*weights)*12 #como los datos que tenemos son  
mensuales, lo ajustamos para el retorno anual  
  
    portfolio_std=np.sqrt(np.dot(weights.T, np.dot(returns.cov()*12, weights)))
```

```
sharpe_ratio=portfolio_return/ portfolio_std  
return sharpe_ratio #queremos max el sharpe ratio
```

In []:

```
#Definimos la población
```

```
def create_population(num_portfolios, num_assets, num_selected=10):  
    population= []  
    for _ in range(num_portfolios):  
        selected_indices=np.random.choice(num_assets, size=num_selected, replace=False)  
        weights= np.random.dirichlet(np.ones(num_selected))  
        portfolio=np.zeros(num_assets)  
        portfolio[selected_indices]=weights  
        population.append(portfolio)  
    return np.array(population)
```

In []:

```
#Proceso de selección donde elige los mejores activos
```

```
def select_population(population, returns, tournament_size=5):  
    selected=[]  
    population_size= len(population)  
  
    for _ in range(population_size):  
        contenders= np.random.choice(np.arange(population_size), size=tournament_size,  
replace= False)  
        conteder_fitness= [fitness(population[i], returns) for i in contenders]  
        winner= contenders[np.argmin(conteder_fitness)]  
        selected.append(population[winner])  
  
    return np.array(selected)
```

In []:

```

#cruce

def crossover(parent1, parent2):

    p= np.random.randint(1, len(parent1)-1) #para evitar el extremo del rango

    child1= np.concatenate([parent1[:p], parent2[:p]])

    child2= np.concatenate([parent2[:p], parent1[p:]])

    #aseguramos que los dos hijos tengan sumas de pesos mayores que cero

    if np.any(child1<=0) or np.any(child2<=0):

        return parent1, parent2

    child1 /= child1.sum()

    child2 /= child2.sum()

    return child1, child2

```

In []:

```

#definimos la variabilidad en la población

```

```

def mutate(solution, mutation_rate=0.02, num_assets=10):

    if np.random.rand()<mutation_rate:

        active_indices=np.where(solution>0)[0]

        if len(active_indices)==0:

            return solution

        perturbation=np.random.normal(loc=0, scale=0.1, size=len(active_indices))

        mutated= solution.copy()

        mutated[active_indices]+= perturbation

        mutated=np.maximum(mutated,0) #nos aseguramos qu eno hay valores negativos

        if mutated.sum()==0:

            return solution

        mutated /= mutated.sum()

    return solution

```

In []:

```
def run_genetic_algorithms(returns, num_generations=50, population_size=100):  
    num_assets= returns.shape[1]  
    population= create_population(population_size, num_assets)  
    best_fitness_history=[] #almacenamos el mejor fitness de cada generaci3n  
  
    for _ in range(num_generations):  
        fitness_scores= [fitness(individual, returns) for individual in population]  
        best_fitness_history.append(max(fitness_scores)) #para registrar el mejor fitness  
        population= select_population(population, returns)  
        new_population=[]  
  
        for i in range(0, population_size, 2):  
            parent1, parent2= population[i], population[(i+1) % population_size]  
            child1, child2= crossover(parent1, parent2)  
            child1, child2= mutate(child1), mutate(child2)  
            new_population.extend([child1, child2])  
  
        population= np.array(new_population, dtype=float)  
  
    best_index= np.argmax([fitness(individual, returns) for individual in population])  
    best_portfolio= population[best_index]  
    best_return= np.sum(returns.mean()*best_portfolio)*12 #calculamos el retorno anual  
  
    return best_portfolio, best_return, best_fitness_history
```

In []:

```
def calculate_volatility(weights, returns):
```

```

annualized_covariance= returns.cov()*12

portfolio_variance=np.dot(weights.T, np.dot(annualized_covariance, weights))

portfolio_volatility= np.sqrt(portfolio_variance)

return portfolio_volatility

In [ ]:

#ejecución del algoritmo genético

optimized_portfolios={}

for period, returns in precios_periodos.items():

    best_weights, annual_return, fitness_history = run_genetic_algorithms(returns,
num_generations=50, population_size=100)

    indices_sorted = np.argsort(-best_weights)[:10]

    best_indices = returns.columns[indices_sorted]

    best_weights_sorted = best_weights[indices_sorted]

    # Creamos un vector completo de pesos para todos los activos

    complete_weights = np.zeros(len(returns.columns))

    complete_weights[indices_sorted] = best_weights_sorted # Asigna los pesos a los índices
correspondientes

# Calculamos la volatilidad usando el vector completo de pesos

portfolio_volatility = calculate_volatility(complete_weights, returns)

optimized_portfolios[period] = {

    'weights': dict(zip(best_indices, best_weights_sorted)),

    'annual_return': annual_return,

    'volatility': portfolio_volatility

}

print(f"Optimal portfolio for {period}: Weights: {optimized_portfolios[period]['weights']},
Annual Return: {optimized_portfolios[period]['annual_return']}, Volatility:
{optimized_portfolios[period]['volatility']:.4f}")

plt.figure(figsize=(10, 6)) # Crea una figura nueva

```

```

plt.plot(fitness_history, label='Fitness (Sharpe Ratio)', marker='o')

plt.title(f'Evolución del Fitness a lo largo de las Generaciones para el período {period}')

plt.xlabel('Número de Generación')

plt.ylabel('Fitness (Ratio de Sharpe)')

plt.legend()

plt.grid(True)

plt.show()

```

In []:

```

precios_post2008= precios['2009-01-01':'2010-12-31']

pre2008_ag= ['PARA-US', 'C-US', 'CMA-US', 'MAR-US', 'O-US', 'ED-US', 'EQT-US', 'MDT-US',
'ORLY-US', 'EMR-US']

cartera1_ag= precios_post2008[pre2008_ag]

retornos = np.log(cartera1_ag / cartera1_ag.shift(1))

pesos=np.array([0.2281114044869362, 0.20988207456129335, 0.16435382690923125,
0.10839515712915461, 0.10765133860983961, 0.08174849338809859,
0.05708300906297895, 0.02987260401191482, 0.01196002651479398,
0.0009420653257585364])

rendimiento_cartera1= np.sum(pesos*retornos.mean())

varianza_cartera1= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera1= np.sqrt(varianza_cartera1)

```

```

print(f"Rendimiento anualizado de la cartera1: {rendimiento_cartera1}")

```

```

print(f"Riesgo (desviación estándar anualizada) de la cartera1: {riesgo_cartera1}")

```

In []:

```

precios_post2011= precios['2012-01-01':'2013-12-31']

pre2011_bl= ['WM-US', 'VMC-US', 'XEL-US', 'GL-US', 'MAS-US', 'MO-US', 'DE-US', 'WFC-US',
'WRK-US', 'ZBRA-US']

cartera2_bl= precios_post2011[pre2011_bl]

```

```

retornos = np.log(cartera2_bl / cartera2_bl.shift(1))

pesos=np.array([0.32627938180124383, 0.22081676411420767, 0.1480517969325228,
0.13480729847142783, 0.05792847537828735, 0.043767885220949265,
0.025304611558874843, 0.022500668406372274, 0.01641377556458763,
0.004129342551526529])

rendimiento_cartera2= np.sum(pesos*retornos.mean())

varianza_cartera2= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera2= np.sqrt(varianza_cartera2)

print(f"Rendimiento anualizado de la cartera2: {rendimiento_cartera2}")

print(f"Riesgo (desviación estándar anualizada) de la cartera2: {riesgo_cartera2}")

In [ ]:

precios_post2019= precios['2021-01-01':'2022-12-31']

pre2019_ag= ['AIG-US', 'ROL-US', 'FDX-US', 'EXPD-US', 'DVN-US', 'BAC-US', 'IP-US', 'CCL-US', 'O-
US', 'PAYX-US']

cartera3_ag= precios_post2011[pre2019_ag]

retornos = np.log(cartera3_ag / cartera3_ag.shift(1))

pesos=np.array([0.304298845701206, 0.137889410627858, 0.11249748665580467,
0.10917069153479712, 0.09671478381425913, 0.0902299843077822,
0.07395360344326615, 0.05782708595929473, 0.009975796849320769,
0.00744231110641101])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera3= np.sqrt(varianza_cartera3)

print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")

print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")

```

Análisis ESG - tener en cuenta que solo lo aplicamos al covid

In []:

```
#cargamos los datos
```

```
ESG_data= pd.read_excel('ESG.xlsx')
```

```
ESG_data
```

In []:

```
#filtramos por la última fecha disponible para asegurar que el análisis sea lo mas relevante y preciso dado el contexto de evaluación continuamente evolutivo de las prácticas ESG
```

```
# razones principales para explicar: relevancia actual, consistencia de datos, simplicidad analitica
```

```
latest_date= ESG_data['date'].max()
```

```
ESG_data= ESG_data[ESG_data['date']==latest_date]
```

In []:

```
#seleccionamos las variables a analizar
```

```
ESG_data_variables= ['symbol', 'GHG Emissions', 'Water and Waste Water Management', 'Employee Health and Safety', 'Business Ethics', 'Materiality']
```

```
ESG_data_analysis= ESG_data[ESG_data_variables]
```

```
#eliminamos las filas donde alguna de las columnas de interés tenga NaN
```

```
ESG_data_analysis=ESG_data_analysis.dropna()
```

```
print(ESG_data_analysis)
```

In []:

```
# a continuacion calcularemos el promedio de las variables ESG que hemos seleccionado
```

```
ESG_data_analysis['Average ESG Score'] = ESG_data_analysis[
```

```
    ['GHG Emissions', 'Water and Waste Water Management', 'Employee Health and Safety', 'Business Ethics']
```

```
].mean(axis=1, skipna=True)
```

```
print(ESG_data_analysis.head())
```

In []:

```
#Realizamos la prueba t para muestras relacionadas
```

```

t_stat, p_value= stats.ttest_rel(ESG_data_analysis['Average ESG Score'],
ESG_data_analysis['Materiality'])

print(f'T-statistic: {t_stat}, P_value: {p_value}')

In [ ]:

#Interpretación del resultado

alpha= 0.05

if p_value<alpha:

    print("Hay una diferencia significativa entre las medias de 'Average ESG Score' y
'Materiality'.")

else:

    print("No hay una diferencia significativa entre las medias de 'Average ESG Score' y
'Materiality'.")

In [ ]:

#ahora quiero ordenar los datos según el promedio de ESG que se ha obtenido así como los
de Materiality para compararlos

ESG_results= ESG_data_analysis.sort_values(by='Average ESG Score', ascending=False)

ESG_materiality= ESG_data_analysis.sort_values(by='Materiality', ascending=False)

In [ ]:

#A partir de los datos, selecciono las top 10 y las peores 10 empresas

top_companies1= ESG_results.head(10)

worst_companies1= ESG_results.tail(10)

top_companies2= ESG_materiality.head(10)

worst_companies2= ESG_materiality.tail(10)

In [ ]:

#Mostrar los resultados

print("Top 10 Empresas con Mejor Desempeño ESG calculado:")

print(top_companies1)

print("\nTop 10 Empresas con Peor Desempeño ESG calculado:")

print(worst_companies1)

```

```
print("Top 10 Empresas con Mejor materialidad ESG:")
print(top_companies2)
print("\nTop 10 Empresas con Peor materialidad ESG:")
print(worst_companies2)

In [ ]:

#gráfica para visualizar el desempeño ESG calculado

plt.figure(figsize=(14,7))

#ploteamos las mejores empresas

plt.subplot(1,2,1)

plt.barh(top_companies1['symbol'], top_companies1['Average ESG Score'], color='green')

plt.xlabel('Average ESG Score')

plt.title('Top 10 Mejores Empresas ESG')

plt.gca().invert_yaxis()

#ploteamos las peores empresas

plt.subplot(1,2,2)

plt.barh(worst_companies1['symbol'], worst_companies1['Average ESG Score'], color='red')

plt.xlabel('Average ESG Score')

plt.title('Top 10 Peores Empresas ESG')

plt.gca().invert_yaxis()

plt.tight_layout()

plt.show()

In [ ]:

#gráfica para visualizar la materialidad
```

```
plt.figure(figsize=(14,7))
```

```
#ploteamos las mejores empresas
```

```
plt.subplot(1,2,1)
```

```
plt.barh(top_companies2['symbol'], top_companies2['Materiality'], color='green')
```

```
plt.xlabel('Average ESG Score')
```

```
plt.title('Top 10 Mejores Empresas ESG')
```

```
plt.gca().invert_yaxis()
```

```
#ploteamos las peores empresas
```

```
plt.subplot(1,2,2)
```

```
plt.barh(worst_companies2['symbol'], worst_companies2['Materiality'], color='red')
```

```
plt.xlabel('Average ESG Score')
```

```
plt.title('Top 10 Peores Empresas ESG')
```

```
plt.gca().invert_yaxis()
```

```
plt.tight_layout()
```

```
plt.show()
```

```
In [ ]:
```

```
precios_post2019= precios['2018-01-01': '2020-03-01']
```

```
pre2019_best= ['REG-US', 'VTR-US', 'AVB-US', 'SWKS-US', 'EQIX-US', 'IRM-US', 'PH-US', 'BXP-US']
```

```
cartera3_best= precios_post2011[pre2019_best]
```

```
retornos = np.log(cartera3_best / cartera3_best.shift(1))
```

```
pesos=np.array([0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1])
```

```
rendimiento_cartera3= np.sum(pesos*retornos.mean())
```

```
varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))
```

```

riesgo_cartera3= np.sqrt(varianza_cartera3)

print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")
print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")

In [ ]:
precios_post2019= precios['2021-01-01':'2022-12-31']

pre2019_best= ['REG-US', 'VTR-US', 'AVB-US', 'SWKS-US', 'EQIX-US', 'IRM-US', 'PH-US', 'BXP-
US']

cartera3_best= precios_post2011[pre2019_best]

retornos = np.log(cartera3_best / cartera3_best.shift(1))

pesos=np.array([0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera3= np.sqrt(varianza_cartera3)

print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")
print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")

In [ ]:
precios_post2019= precios['2018-01-01': '2020-03-01']

pre2019_worst= ['CAH-US', 'J-US', 'WBA-US', 'ALL-US', 'EFX-US', 'L-US', 'COR-US', 'MCK-US']

cartera3_worst= precios_post2011[pre2019_worst]

retornos = np.log(cartera3_worst / cartera3_worst.shift(1))

pesos=np.array([0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera3= np.sqrt(varianza_cartera3)

```

```
print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")
print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")

In [ ]:

precios_post2019= precios['2021-01-01':'2022-12-31']

pre2019_worst= ['CAH-US', 'J-US', 'WBA-US', 'ALL-US', 'EFX-US', 'L-US', 'COR-US', 'MCK-US']

cartera3_worst= precios_post2011[pre2019_worst]

retornos = np.log(cartera3_worst / cartera3_worst.shift(1))

pesos=np.array([0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1, 0.1])

rendimiento_cartera3= np.sum(pesos*retornos.mean())

varianza_cartera3= np.dot(pesos.T, np.dot(retornos.cov(), pesos))

riesgo_cartera3= np.sqrt(varianza_cartera3)

print(f"Rendimiento anualizado de la cartera3: {rendimiento_cartera3}")

print(f"Riesgo (desviación estándar anualizada) de la cartera3: {riesgo_cartera3}")
```