

2024 - Vol. 2 - n.º 5 - Artículo 1

Creación de una cartera de inversión que venza la inflación atendiendo a criterios ESG gestionada mediante machine learning

Julen Iglesias Tejedor^a

Seleccionado en la segunda convocatoria de trabajos de fin de máster de la Revista de Economía y Finanzas

Tutores: Raúl Gómez Martínez^b y María Luisa Medrano García^c

^a Graduado en Ingeniería Informática y Máster en Asesoramiento y Planificación Financiera - Universidad Rey Juan Carlos.

^{b c} Universidad Rey Juan Carlos.

JEL CODES:

G11; G15; G17; C45;
C53; M14; Q56; E31

KEYWORDS:

Investment portfolio;
Inflation; ESG; Machine
learning

Abstract: This paper explores the creation and management of an investment portfolio aimed at outperforming inflation, integrating environmental, social and governance (ESG) criteria, and using machine learning tools to manage the portfolio by improving investment. The main objective of the study is to design an investment strategy that is not only financially profitable, but also in line with sustainable practices. For the construction of the portfolio, various investment philosophies, markets, and assets in different sectors and geographies were analysed, prioritising those that meet the best performance and high ESG standards. The XGBoost machine learning model was then used for asset management, proving to be an effective tool in predicting future movements. The resulting portfolio was compared to the MSCI ACWI ESG Universal index as a benchmark, showing superior performance in terms of risk-adjusted returns and compliance with ESG criteria. In addition, various statistics and risk metrics were evaluated to ensure that the portfolio was not only cost-effective, but also consistent. The results of the study highlight the feasibility of combining responsible investments with advanced technologies to improve the profitability and efficiency of investment portfolios, offering a replicable and scalable model for investors seeking to contribute to sustainability without sacrificing profitability.

CÓDIGOS JEL:

G11; G15; G17; C45;
C53; M14; Q56; E31

PALABRAS CLAVE:

Cartera de inversión;
Inflación; ASG; Aprendi-
zaje automático

Resumen: Este trabajo explora la creación y gestión de una cartera de inversión orientada a superar la inflación, integrando criterios ambientales, sociales y de gobierno (ASG), y utilizando herramientas de machine learning para gestionar la cartera mejorando la inversión. El objetivo principal del estudio es diseñar una estrategia de inversión que no solo sea financieramente rentable, sino que también este acorde con prácticas sostenibles. Para la construcción de la cartera, se analizaron diversas filosofías de inversión, mercados, y se estudiaron activos en diferentes sectores y geografías, priorizando aquellos que cumplen con mejor desempeño y altos estándares ESG. Después, se empleó el modelo de machine learning XGBoost para la gestión de activos, demostrando ser una herramienta eficaz en la predicción de movimientos futuros. La cartera resultante se comparó con el índice MSCI ACWI ESG Universal como benchmark, mostrando un desempeño superior en términos de retornos ajustados al riesgo y conforme con los criterios ESG. Además, se evaluaron varias estadísticas y métricas de riesgo, para asegurar que la cartera no solo era rentable, sino también consistente. Los resultados del estudio destacan la viabilidad de combinar inversiones responsables con tecnologías avanzadas para mejorar la rentabilidad y eficiencia de las carteras de inversión, ofreciendo un modelo replicable y escalable para inversores que buscan contribuir a la sostenibilidad sin renunciar a la rentabilidad.

1. Introducción

El presente trabajo tiene como objetivo principal la creación y evaluación de una cartera de inversión que no solo supere la inflación, sino que también atienda a criterios ambientales, sociales y de gobernanza (ASG) o por sus siglas en inglés (ESG). En un contexto económico global donde la inflación ha emergido como un factor crítico que erosiona el poder adquisitivo, siendo esencial diseñar estrategias de inversión que aseguren un crecimiento del capital a largo plazo y promuevan la sostenibilidad.

La relevancia de integrar criterios ESG en las decisiones de inversión ha ganado considerable importancia, no solo por la presión social y regulatoria, sino también por el reconocimiento de que estas prácticas pueden conducir a un rendimiento financiero superior a largo plazo. Las empresas que operan de manera sostenible tienden a gestionar mejor sus riesgos, atraer y retener talento, y por lo tanto, asegurar operaciones eficientes, lo que eventualmente se refleja en su rendimiento financiero.

Adicionalmente, este trabajo se enfoca en el uso de técnicas avanzadas de machine learning, específicamente el algoritmo XGBoost, para la gestión de la cartera. La inteligencia artificial recientemente, ha demostrado ofrecer herramientas poderosas para analizar grandes volúmenes de datos y extraer patrones que pueden predecir tendencias futuras del mercado, permitiendo así una gestión más dinámica y fundamentada de los activos de inversión.

Este estudio pretende demostrar que una cartera gestionada a través de métodos cuantitativos y cualitativos avanzados no solo puede superar la inflación y generar retornos ajustados al riesgo atractivos, sino también contribuir positivamente a los desafíos ambientales, sociales y de gobierno. Al hacerlo, se aborda un doble desafío al realizar inversiones: la rentabilidad y la sostenibilidad.

La estructura del trabajo se desarrollará a lo largo de varias secciones que incluyen el análisis de la inflación y su impacto histórico, la selección y análisis de activos a través de criterios ESG, la aplicación de técnicas de machine learning para la gestión de la cartera, la evaluación de su rendimiento a través de backtesting y la comparación con su benchmark y otras opciones relevantes. Con estos elementos, se espera no solo ofrecer un enfoque innovador y


efectivo para la creación de carteras de inversión, sino también contribuir al desarrollo de mejores prácticas en la gestión de portafolios que alinean rendimiento financiero con sostenibilidad.

2. Marco conceptual

Para evaluar la inflación desde la adopción del euro, se ha utilizado el Índice de Precios al Consumidor (IPC), que mide la variación en los precios de una canasta de bienes y servicios típicos consumidos por los hogares. Este índice es fundamental para entender cómo los precios al consumidor han aumentado con el tiempo, afectando a la capacidad adquisitiva del euro.


El gráfico del IPC de la Unión Europea muestra una tendencia ascendente desde 2002 hasta 2024. Esta evolución refleja cómo, a lo largo de los años, la inflación ha ido incrementando gradualmente, con una aceleración notable en los últimos años, indicativa de un aumento significativo en la inflación recientemente (Trading economics, 2024a).

Ilustración 1: Índice de precios al consumidor (IPC) de la Unión Europea (Trading economics, 2024a)



Además, el gráfico del Índice de Precios al Consumidor Armonizado (IPCA) o por sus siglas en inglés (HICP) muestra los cambios porcentuales año tras año, destacando el reciente pico inflacionario. Este índice armonizado es esencial para comparar la inflación de manera uniforme entre los países de la zona euro, eliminando las diferencias en el cálculo del IPC entre naciones (Banco Central Europeo, 2024a).

Ilustración 2: Índice de precios al consumidor armonizado (IPCA) anualizado de la zona euro (Banco central europeo, 2024a)



En paralelo, el IPC en España también ha mostrado un crecimiento constante, con un incremento acelerado reciente que refleja las tendencias inflacionarias observadas al nivel de la Unión Europea. Este fenómeno subraya la interconexión de las economías dentro de la zona euro y la influencia compartida de políticas económicas y factores externos (Trading economics, 2024b).

Ilustración 3: Índice de precios al consumidor (IPC) de España (Trading economics, 2024b)





Ilustración 4: Variación interanual del IPC en España (Instituto Nacional de Estadística, 2024a)




Finalmente, la inflación acumulada desde la introducción del euro hasta marzo de 2024 ha sido del 64.9%, según datos del Instituto Nacional de Estadística (INE), lo que representa un 2.95% anual. Este número subraya cómo la inflación ha mermado el poder adquisitivo del euro, destacando la importancia de estrategias de inversión que consideren la pérdida de poder adquisitivo a lo largo del tiempo (Instituto Nacional de Estadística, 2024b).

Según el Banco Central Europeo (BCE), la inflación en la zona euro se espera que disminuya gradualmente tras el pico reciente impulsado por factores excepcionales como la crisis energética, los desafíos logísticos postpandemia y las recientes tensiones geopolíticas o conflictos armados. El BCE proyecta que la inflación se moderará desde un nivel elevado en 2023 hacia un ritmo más estable y cercano al objetivo del 2% hacia 2026. Este ajuste se anticipa como resultado de políticas monetarias ajustadas y una estabilización en los precios de la energía y los alimentos (Banco Central Europeo, 2023b).

En el caso de España, las proyecciones indican un escenario similar. El Banco de España y Funcas destacan que, aunque la inflación se mantuvo elevada durante 2023, se espera que disminuya progresivamente en los próximos años. Esta disminución se atribuye a la normalización de los precios en sectores clave y a una política monetaria que busca estabilizar la economía y controlar el crecimiento de los precios al consumo.

Ilustración 5: Perspectivas del índice de precios de consumo para España en % (Funcas, 2024)



El gráfico anterior, proporcionado por Funcas, ilustra las perspectivas de inflación para España, mostrando tres escenarios posibles hasta 2025: un escenario bajo, un escenario central y un escenario alto. Estas proyecciones sugieren que, aunque el futuro cercano aún se pueden presentar desafíos inflacionarios, la tendencia general es hacia una estabilización y, eventualmente, una inflación más baja que los picos recientes, como se recoge en las previsiones del IPC de la siguiente tabla:

Ilustración 6: Previsiones del IPC de España (Funcas, 2024)

Año	Mes	IPC Mensual	IPC Anual
2022	Diciembre	0.2	5.7
	Media anual	-	8.4
2023	Diciembre	0.0	3.1
	Media anual	-	3.5
2024	Enero	0.1	3.4
	Febrero	0.4	2.8
	Marzo	0.8	3.2
	Abril	0.6	3.2
	Mayo	0.4	3.4
	Junio	0.4	3.4
	Julio	0.1	3.2
	Agosto	0.4	3.2
	Septiembre	-0.2	2.8
	Octubre	0.3	2.8
	Noviembre	0.1	3.3
	Diciembre	0.2	3.5
	Media anual	-	3.2
2025	Enero	-0.2	3.2
	Febrero	0.2	3.0
	Marzo	0.3	3.0
	Abril	0.5	2.5
	Mayo	0.2	2.4
	Junio	-0.3	2.3
	Julio	0.1	2.0
	Agosto	-0.3	2.0
	Septiembre	-0.2	2.0
	Octubre	0.3	2.0
	Noviembre	0.1	2.0
	Diciembre	0.1	2.0
	Media anual	-	2.3

En conclusión, la inflación esperada para Europa y España hacia el final del periodo proyectado, 2026, se espera que ronde cerca del 1.9% para Europa, según las últimas proyecciones del Banco Central Europeo. Para España, las expectativas son ligeramente más diferentes, dada la sensibilidad de la economía a los factores internos y externos, pero en general, se alinea con las tendencias europeas hacia una inflación controlada y más predecible (Gavilán, 2023; Funcas, 2024).

3. Metodología

Para realizar la creación de la cartera de inversión, se empleó una metodología exhaustiva que combina análisis cuantitativo y cualitativo para evaluar y construir una cartera de inversión atendiendo a criterios ESG y estando optimizada para superar la inflación, cumpliendo con las ideas establecidas.

3.1. Comparación de activos

En cuanto al análisis cuantitativo, se utilizaron datos históricos para analizar el rendimiento de diferentes clases de activos, mercados y sectores. Incluyéndose el uso de distintas comparaciones para evaluar la rentabilidad, rendimiento y optimizar la selección de activos y su consiguiente asignación de pesos en la cartera.

En cuanto al estilo de inversión, se han analizado los índices de MSCI, el ACWI IMI growth y el ACWI IMI value, que representan estilos de crecimiento y valor, respectivamente, observándose como las acciones de crecimiento han superado a las de valor recientemente.

Ilustración 7: Comparación entre ACWI IMI growth y ACWI IMI value (MSCI, 2024)



Respecto a la capitalización, este gráfico ilustra cómo recientemente, en los últimos 10 años, las acciones de gran capitalización han tenido mayor desempeño que las de pequeña capitalización y mediana capitalización, demostrando que las small-caps no siempre han superado a las large-caps, como se tiende a pensar.

Ilustración 8: Comparación entre índices Large-Cap, Mid-Cap y Small-cap (MSCI, 2024)



En el caso de los tipos de mercados y activos, se pueden clasificar en renta variable y renta fija, aunque, además de estos activos tradicionales, también existen las inversiones alternativas, entre las que sé que se incluyen, bienes raíces materias primas y criptomonedas.

Ilustración 9: Crecimiento real de 1000 \$ desde 1920 a 2019 (Loo, 2024)





Ilustración 10: S&P 500 vs Real State. (Longtermrends, 2024a)



Ilustración 11: Comparación de rendimiento entre la renta variable y las materias primas (Longterm trends, 2024b, c)

Activo	Rendimiento (%)
S&P 500	279.02%
Oro	51.13%
Plata	-21.61%
Aluminio	10.23%
Cobre	10.67%
Combustible para calefacción	-27.40%
Gas natural	-44.93%
Petróleo Brent	-35.17%
Petróleo crudo	-32.42%
Arroz con cáscara	19.35%
Haba de soja	-13.48%
Avena	13.14%
Aceite de soja	-21.69%
Maíz	-40.82%
Trigo SRW de Chicago	-11.80%
Cacao	175.25%
Azúcar	-21.73%
Algodón	-57.41%
Café	-25.72%
Zumo de naranja	165.13%
Manteca	49.01%
Queso	15.03%
Suero de leche	-15.81%
Leche Clase 3	13.35%
Leche en polvo sin grasa	-28.50%
Ganado vivo	55.10%
Carne magra de cerdo	-0.97%
Rentabilidad media materias primas	6.84%

Ilustración 12: Comparación entre renta variable (S&P500) y criptomonedas (CMC200) (Yahoo Finance, 2024)




Como se ha observado, las acciones de renta variable han demostrado ser más rentables en comparación con la renta fija y las inversiones alternativas a lo largo del tiempo, a excepción de las criptomonedas, aunque estas últimas se descartarán por no cumplir con los criterios ambientales, sociales y de gobierno (ESG) debido a su considerable impacto ambiental según es ampliamente conocido

(Organización para la Cooperación y el Desarrollo Económico, 2022; Universidad de las Naciones Unidas, 2023).

En lo que corresponde a las distintas geografías, se ha llevado a cabo un estudio de las principales zonas geográficas mundiales más significativas como son: América, Europa y Asia. Predominando la zona americana, seguida de la zona europea y asiática.


Ilustración 13: Comparación entre la zona americana, europea y asiática (MSCI, 2024)




En referencia a los distintos sectores comparados, se dividen en varias categorías representando cada uno una parte específica de la economía con características únicas que pueden influir en su rendimiento en diferentes condiciones

económicas. Estos sectores son: tecnología, salud, finanzas, consumo discrecional, consumo básico, industrial, energía, materiales, servicios de comunicación, utilidades y bienes raíces.

Ilustración 14: Rendimiento por sector en los últimos 10 años (YCharts, 2024)



Finalmente, el análisis del rendimiento de los activos ESG realizado, muestra que las empresas líderes en ESG superan consistentemente al índice MSCI ACWI general, lo que subraya la importancia de integrar consideraciones ESG en la toma de decisiones de inversión.

Ilustración 15: Comparación del rendimiento de activos ESG (MSCI, 2024)

3.2. Criterios ESG

Los activos fueron evaluados en base a su desempeño en criterios ambientales, sociales y de gobernanza conocidos por sus siglas ASG o ESG. Se examinaron estos factores ESG de cada activo utilizando métricas establecidas y puntuaciones proporcionadas por plataformas reconocidas como el London Stock Exchange Group (LSEG) evaluando así, a través de estas puntuaciones cómo las empresas se comportan y cumplen con estos factores, seleccionando aquellas con un valor mayor a 75. Esta evaluación que se centra en proporcionar una evaluación objetiva y transparente del desempeño relativo de una empresa en estos criterios, utilizando datos reportados públicamente, abarca diez temas principales que incluyen emisiones, innovación de productos ambientales, derechos humanos, gestión y estrategia de responsabilidad social corporativa, entre otros (London Stock Exchange Group, 2023).

Ilustración 16: Acciones seleccionadas

Nombre	Sector	Zona	ESG score
Microsoft Corp (MSFT)	Tecnologías de la información	América	88
Intuit Inc (INTU)			83
Broadcom Inc (AVGO)			77
Autodesk Inc (ADSK)			81
Intuit Inc (INTU)			83
SAP SE (SAP)		Europa	89
Infineon Technologies AG (IFNNF)			79
NXP Semiconductors NV (NXPI)			78
Taiwan Semiconductor Manufacturing Co Ltd (TSM)		Asia	81
Intuitive Surgical Inc (ISRG)	Cuidado de la salud	América	79
Boston Scientific Corp (BSX)			95
Novo Nordisk A/S (NVO)		Europa	79
Lonza Group Ltd (LZAGY)			81
UCB SA (UCBJY)			89
Genmab A/S (GMAB)			77
Terumo Corp (TRUMF)		Asia	78
Daiichi Sankyo Co Ltd (DSNKY)			84
Amazon.com Inc (AMZN)	Consumo discrecional	América	80
Marriott International Inc (MAR)			77
Lvmh Moet Hennessy Louis Vuitton SE (LVMUY)		Europa	79
Industria De Diseno Textil SA (IDEXY)			79
adidas AG (ADDYY)			89
Amadeus IT Group SA (AMADY)			88
InterContinental Hotels Group PLC (IHG)			77
Fast Retailing Co Ltd (FRCOY)		Asia	80
Mahindra & Mahindra Ltd (MAHMF)			90
GE Aerospace (GE)	Industrial	América	78
Canadian Pacific Kansas City Ltd (CP.TO)			77
Canadian National Railway Co (CNR.TO)			84
WSP Global Inc (WSP.TO)			76
Schneider Electric SE (SBGSY)		Europa	77
Airbus SE (EADSY)			84
ABB Ltd (ABBNY)			91
Atlas Copco AB (ATLKY)			76
RELX PLC (RELX)			81
Vinci SA (VCISF)			83
Rolls-Royce Holdings PLC (RYCEY)			79
Rheinmetall AG (RNMBY)			84
Alfa Laval AB (ALFVY)			78
Teleperformance SE (TLPFF)			79

3.3. Composición

Utilizando los resultados del análisis cuantitativo y cualitativo, se seleccionaron los activos y se asignaron los pesos dentro de la cartera. Construyéndose así, la cartera

utilizando la teoría moderna de portafolios, específicamente mediante la aplicación de la frontera eficiente para encontrar la combinación que maximice el retorno ajustado por riesgo, seleccionando el máximo ratio de sharpe.

Ilustración 17: Frontera eficiente (YCharts, 2024)




Ilustración 18: Extracto del cálculo de la frontera eficiente (YCharts, 2024)

N.º	BSX	MSFT	NVO	RELX	TSM	AVGO	DSNKY	RNMBY	CNR.TO	CP.TO	WSP.TO	VCISF	FRCOY	UCBJY	TRUMF	MAHMF	Retorno esperado	Desviación estándar	Ratio de Sharpe
50	7,5	27,6	14,49	0	0	24	7,84	1,78	0	0	15,77	0	0	0	0	1,07	28,61	15,71	1,820
51	6,7	27,9	14,40	0	0	25	7,72	1,82	0	0	15,58	0	0	0	0	0,88	28,88	15,86	1,822
52	5,9	28,2	14,31	0	0	26,1	7,59	1,86	0	0	15,39	0	0	0	0	0,69	29,16	16	1,822
53	5,2	28,5	14,22	0	0	27,1	7,47	1,89	0	0	15,20	0	0	0	0	0,49	29,43	16,15	1,822
54	4,4	28,8	14,13	0	0	28,1	7,34	1,93	0	0	15,01	0	0	0	0	0,30	29,71	16,31	1,822
55	3,6	29,2	14,04	0	0	29,1	7,21	1,97	0	0	14,82	0	0	0	0	0,11	29,98	16,47	1,821
56	2,8	29,5	13,94	0	0	30,1	7,09	2,01	0	0	14,57	0	0	0	0	0	30,26	16,64	1,819
57	1,9	29,9	13,81	0	0	31,2	6,96	2,05	0	0	14,25	0	0	0	0	0	30,53	16,81	1,817
58	1	30,3	13,68	0	0	32,2	6,83	2,10	0	0	13,93	0	0	0	0	0	30,81	16,98	1,814
59	0,1	30,7	13,55	0	0	33,2	6,69	2,14	0	0	13,61	0	0	0	0	0	31,09	17,17	1,811
60	0	30,9	13,10	0	0	34,5	6,39	2,17	0	0	12,93	0	0	0	0	0	31,36	17,35	1,807

3.4. Gestión mediante machine learning

Se empleó el uso de un modelo predictivo de machine learning como, XGBoost (eXtreme Gradient Boosting), basado en la creación de varios árboles de decisión y conocido por su eficacia en tareas de clasificación y regresión en grandes conjuntos de datos, para así poder mejorar el desempeño de la cartera de inversión (Chen, Zang, Kumar y Jia, 2021; Nobre y Ferreira, 2019). Además, se llevó a cabo un backtesting riguroso de la estrategia de inversión desarrollada utilizando datos históricos para validar la efectividad de la estrategia propuesta. Este proceso ayudó a comprobar cuál ha sido el comportamiento de la cartera de inversión creada.

Para la aplicación de machine learning a la cartera de inversión propuesta, se utilizaron datos históricos de cada una de las acciones mencionadas anteriormente, obtenidos a través de Yahoo Finance. Con estos datos, se utilizó el lenguaje de programación Python, para calcular distintos indicadores y realizar las predicciones de machine learning. Estos indicadores son: Relative Strength Index (RSI), Stochastic Oscillator, William %R, Moving Average Convergence Divergence (MACD), Price Rate of Change (ROC) y On Balance Volume (OBV).

Ilustración 19: Extracto del conjunto de datos inicial

Date	Close	volume_adl	momen- tum_rsi	momen- tum_stoch_r si_k	momen- tum_stoch_r si_d	momen- tum_stoch	momen- tum_stoch_si gnal	trend_macd	trend_macd_ signal	momen- tum_roc	volume_obv
2015-08-17	29,09761	-84685729366	33,13552132	0,493635144	0,371661549	48,74156574	43,42438923	-0,70595753	-0,635688985	-5,27514	41377868800
2015-08-18	29,11131	-84739822971	33,4359496	0,658758316	0,498544947	52,38453888	47,69307109	-0,67485758	-0,643522705	-4,62038	41516111600
2015-08-19	28,9319	-84713031041	31,44265417	0,780071744	0,644155068	46,86868758	49,3315974	-0,65711221	-0,646240605	-3,77125	41322965600
2015-08-20	28,5472	-84471500521	27,63778276	0,717654873	0,718828311	35,2303702	44,82786555	-0,66640912	-0,650274308	-2,77792	41048959200
2015-08-21	27,4936	-84274567286	20,3681916	0,446538295	0,648088304	30,15623888	37,41843222	-0,75014655	-0,670248756	-5,54117	40535857200
2015-08-24	26,6368	-83799750727	16,55474616	0,177965705	0,447386291	51,97286539	39,11982482	-0,87555285	-0,711309575	-7,97274	39887032000
2015-08-25	26,2859	-84035150906	15,2919928	0	0,208168	46,95820611	43,02910346	-0,99181993	-0,767411646	-9,08382	39472625600
2015-08-26	26,8542	-84043660608	25,23812799	0,182726317	0,120230674	55,07968146	51,33691765	-1,02627509	-0,819184335	-8,72474	39859724000
2015-08-27	27,5421	-84350926743	35,16220335	0,51605965	0,232928656	64,91032977	55,64940578	-0,986699250	-0,852687318	-4,68809	40198188400
2015-08-28	27,9323	-84518121306	40,02542558	0,849392983	0,51605965	75,35981736	65,11660953	-0,91332103	-0,852687318	-0,86481406	40410846000
2015-08-31	28,06115	-84699548339	41,58358956	1	0,788484211	78,92631607	73,06548774	-0,8351441	-0,858880069	-2,63459	40635763200
2015-08-17	29,09761	-84685729366	33,13552132	0,493635144	0,371661549	48,74156574	43,42438923	-0,70595753	-0,635688985	-5,27514	41377868800

Para la implementación de este modelo, el 80% de los datos recopilados se utiliza para el entrenamiento del modelo, mientras que el 20% restante se destina a validar su precisión y efectividad. Para evaluar la precisión del modelo XGBoost en las predicciones financieras, se han utilizado varias métricas clave, que se evalúan de 0 a 1: Área bajo la curva (AUC), Raíz del error cuadrático medio (RMSE), Exactitud (Accuracy), Precisión (Precision) y Sensibilidad (Recall).

Ilustración 20: Métricas del modelo de machine learning

Días	AUC	RMSE	Accuracy	Precision	Recall
22	0,9530	0,1870	0,9650	0,9683	0,9825
44	0,9308	0,2313	0,9465	0,9467	0,9756
66	0,9289	0,2443	0,9403	0,9448	0,9655
88	0,9244	0,2566	0,9342	0,9441	0,9560


Las predicciones, se han calculado para varios horizontes temporales de predicción: 1 mes, 2 meses, 3 meses y 4 meses. Sin embargo, como en los datos no se recoge información para los días en los que los mercados están cerrados, se han descontado estos días, quedando predicciones para

22, 44, 66 y 44 días respectivamente. Obteniéndose un datasheet, en el que a los datos de precio e indicadores calculados, se añaden las predicciones del modelo donde:

- Targets: Variables objetivo que indican si el precio de cierre ha subido (1) o bajado (0) después de 22, 44, 66 y 88 días respectivamente.
- Predictions: Predicciones realizadas por el modelo para 22, 44, 66 y 88 días respectivamente.
- True labels: Aciertos para los periodos de 22, 44, 66 y 88 días, utilizadas para evaluar la precisión del modelo.

Posteriormente, se implementó la estrategia del modelo utilizando los activos y pesos seleccionados previamente, con un enfoque de rebalanceo cada 22 días para mantener la distribución proporcional del capital según los pesos asignados. En este escenario, la estrategia de backtesting del modelo produjo un retorno de 20.252,73 dólares a partir de una inversión inicial de 1.000 dólares en los últimos 10 años, lo que representa un retorno del 2025%. En comparación, la estrategia de comprar y mantener o “buy and hold”, generó un retorno de 8.634,96 euros, equivalente a un 863,50% de retorno. Estos valores obtenidos son parecidos a estrategias de inversión dinámicas similares (InvestMood, 2024; TradingMotion, 2024).

Ilustración 21: Backtesting de la cartera




Esta estrategia fue validada comparándola con benchmarks estándar y analizando su rendimiento. Esto aseguró que la cartera no solo sea teóricamente sólida, sino también prácticamente viable y capaz de cumplir con los objetivos de inversión previamente establecidos, sometidos a las condiciones del mercado.

4. Resultados

La cartera de inversión configurada representa una diversificación en términos de activos, sectores y geografías. Los

activos seleccionados reflejan una combinación de acciones de gran capitalización, distribuidos principalmente en los sectores de tecnología de la información y cuidados de la salud, con una menor participación en el sector industrial y consumo discrecional.


Ilustración 22: Pesos de los activos de la cartera de inversión



Geográficamente, la cartera está fuertemente inclinada hacia las Américas, especialmente los Estados Unidos,


seguida por significativas inversiones en Europa y una menor proporción en Asia.

Ilustración 23: Distribución de las zonas geográficas de la cartera de inversión



La siguiente imagen muestra la distribución específica de los activos dentro de la cartera, detallando los símbolos y los pesos asignados a cada inversión. Esta distribución refleja la estrategia de inversión centrada en la diversificación y optimización.

Ilustración 24: Distribución de los pesos de la cartera de inversión (YCharts, 2024)



Para evaluar el rendimiento de la cartera, se utilizó el MSCI ACWI ESG Universal como benchmark, proporcionando una comparación estándar contra un índice que representa una amplia variedad de activos con criterios de sostenibilidad integrados, asegurando que la cartera no solo sea rentable, sino también responsable desde un punto de vista ambiental, social y de gobierno. Además, se utilizaron varias estadísticas clave y métricas de riesgo que se han calculado para proporcionar una visión integral del desempeño y los riesgos asociados de la cartera.

Ilustración 25: Estadísticas de la cartera de inversión (YCharts, 2024)

Estadística		Valor	Fecha
Rango de retornos totales diarios de 1 Mes			
Mínimo		-28,65%	23-mar-20
Máximo		29,04%	23-abr-20
Promedio		3,29%	
Mediana		3,53%	
Rango de retornos totales diarios acumulados en el año			
Mínimo		-23,66%	23-mar-20
Máximo		75,31%	19-dic-23
Promedio		18,49%	
Mediana		14,09%	
Rango de retornos totales anualizados a 3 años			
Mínimo		20,92%	23-mar-20
Máximo		52,93%	23-mar-23
Promedio		37,42%	
Mediana		36,24%	
Rango de retornos totales anualizados a 5 años			
Mínimo		21,48%	23-mar-20
Máximo		45,56%	24-dic-23
Promedio		34,59%	
Mediana		34,25%	
Rango de retornos totales anualizados desde la creación (Mensual)			
Mínimo		14,45%	jun-19
Máximo		35,39%	ene-24
Promedio		23,56%	
Mediana		24,72%	
Rango de desviación estándar anualizada de retornos mensuales			
Mínimo		12,32%	feb-20
Máximo		19,54%	jun-23
Promedio		16,86%	
Mediana		16,88%	


Ilustración 26: Métricas de la cartera de inversión (YCharts, 2024)

Métrica		Valor	Fecha
Alpha (5A)			
Mínimo		22,77	oct-20
Máximo		37,27	ene-24
Promedio		27,94	
Mediana		27,63	
Beta (5A)			
Mínimo		0,7909	nov-23
Máximo		0,9123	mar-22
Promedio		0,8669	
Mediana		0,8716	
Ratio de Sharpe histórico (5A)			
Mínimo		1,489	abr-20
Máximo		2,63	ene-20
Promedio		1,992	
Mediana		1,963	
Ratio de Sortino histórico (5A)			
Mínimo		1,486	mar-20
Máximo		4,215	ene-20
Promedio		2,159	
Mediana		1,908	
Máxima pérdida (5A)			
Mínimo		13,24%	jun-19
Máximo		29,86%	mar-20
Promedio		27,19%	
Mediana		29,86%	
Valor en riesgo mensual (VaR) 5% (5A)			
Mínimo		2,58%	sep-21
Máximo		6,37%	oct-22
Promedio		4,56%	
Mediana		4,88%	
Ratio de Calmar (5A)			
Mínimo		0,814	mar-20
Máximo		2,452	ene-20
Promedio		1,291	
Mediana		1,168	
Ratio de Treynor (5A)			
Mínimo		28,05	mar-20
Máximo		53,87	dic-23
Promedio		38,83	
Mediana		38,54	

Estas métricas y estadísticas, son fundamentales para evaluar la efectividad de la cartera de inversión y su capacidad para alcanzar los objetivos de retorno ajustado al riesgo en diferentes condiciones de mercado.

Al evaluar el desempeño de la cartera de inversión configurada, se hace esencial compararla con otras opciones para contextualizar su rendimiento. Primero se comparará con el índice de referencia MSCI ACWI ESG Universal.


Ilustración 27: Comparación de la rentabilidad total periódica de la cartera frente al benchmark (YCharts, 2024)



La cartera de inversión ha mostrado un desempeño sobresaliente en comparación con su benchmark, el MSCI ACWI ESG Universal. A lo largo de diferentes periodos temporales, la cartera ha superado consistentemente al índice,

demonstrando no solo un crecimiento robusto sino también una mayor resiliencia durante las fluctuaciones del mercado.


Ilustración 28: Comparación de la rentabilidad total de la cartera frente al benchmark (YCharts, 2024)



Los rendimientos anuales también reflejan esta tendencia, con la cartera superando al índice en la mayoría de los años, particularmente en periodos de recuperación del mercado y crecimiento económico.

Además del índice de referencia, se realiza una comparación con otro índice que se enfoca en crecimiento de gran capitalización. Aunque ambos han logrado rendimientos significativos, la cartera de inversión ha tenido un rendimiento superior, en un periodo de cinco años, tal como se evidencia en los datos acumulados hasta la fecha.

Ilustración 29: Comparación de la cartera con otras opciones de inversión (YCharts, 2024)



Esta comparativa enfatiza no solo la eficacia de la cartera de inversión, sino también se destaca la importancia de una gestión activa y un enfoque bien definido hacia la sostenibilidad y el crecimiento a largo plazo que asegure buenos resultados.

5. Discusión, conclusión, e implicaciones

El presente trabajo ha explorado en profundidad la creación de una cartera de inversión que no solo busca superar la inflación, sino que también atiende a criterios ESG, utilizando herramientas avanzadas de machine learning para la gestión de la cartera. Los resultados obtenidos a lo largo de este estudio han permitido aclarar y aumentar el conocimiento de múltiples aspectos relevantes de la inversión sostenible y la aplicación de tecnologías avanzadas en el ámbito financiero.

La investigación ha demostrado que las estrategias de inversión que integran criterios ambientales, sociales y de gobernanza no solo contribuyen a un mundo más sostenible, sino que también pueden generar rendimientos superiores. La cartera diseñada superó a otras opciones tradicionales y al índice benchmark MSCI ACWI ESG Universal, reafirmando que el éxito financiero puede ir de la mano con la responsabilidad ambiental, social y de gobierno y la aplicación de tecnologías avanzadas.

La aplicación de modelos de machine learning, específicamente XGBoost, ha mejorado significativamente la precisión en la predicción de tendencias y movimientos del mercado, lo que ha resultado en una gestión más efectiva de la cartera. Este enfoque ha permitido maximizar los retornos ajustados al riesgo, destacando el potencial de estas tecnologías para transformar las prácticas de inversión.

La cartera no solo cumplió con el objetivo de superar la tasa de inflación, sino que también ofreció un colchón significativo contra la pérdida del poder adquisitivo en el tiempo. Esto subraya la importancia de seleccionar activos y estrategias que ofrezcan protección y crecimiento en entornos económicos complejos.

Los análisis realizados confirmaron la importancia de una diversificación adecuada dentro de la cartera. Invertir en diferentes geografías y sectores no solo reduce el riesgo, sino que también permite aprovechar oportunidades de crecimiento en diversas áreas del mercado, destacando en el marco temporal histórico estudiado la prevalencia de activos ESG de renta variable growth de gran capitalización, pertenecientes a los sectores de tecnología, cuidado de la salud, consumo discrecional e industrial de Europa, América y Asia.

Este trabajo abre varias vías para investigaciones futuras, especialmente en el área de integración de tecnologías avanzadas en la gestión de carteras. Además, sugiere una reevaluación periódica y continua constantemente de las estrategias de inversión tradicionales en el contexto de la creciente importancia de los factores ESG y el mantenimiento de estas alineaciones.

En conclusión, este estudio ha proporcionado una evidencia sólida de que es posible alcanzar y superar los objetivos financieros mediante la investigación exhaustiva de activos, la optimización y la adopción de enfoques innovadores y sostenibles. Los hallazgos destacan la viabilidad de las inversiones sostenibles y tecnológicamente avanzadas como medio para lograr retornos financieros robustos, mientras se contribuye positivamente a los criterios de sostenibilidad.

Bibliografía

- Banco central europeo. (2024a). "HICP - Overall index, Euro area (changing composition), Monthly". Recuperado de <https://data.ecb.europa.eu/data/datasets/ICP>
- Banco central europeo. (2023b). "Proyecciones macroeconómicas." Recuperado de <https://www.ecb.europa.eu/press/projections/html/index.es.html>
- Chen, W., Zhang, H., Kumar Mehlaawat, M., y Jia, L. (2021). "Mean-variance portfolio optimization using machine learning-based stock price prediction". Recuperado de <https://www.sciencedirect.com/science/article/abs/pii/S1568494620308814>
- Funcas. (2024). "Coyuntura Económica: Previsiones IPC." Recuperado de <https://www.funcas.es/textointegro/ipc-marzo-2024-previsiones-hasta-diciembre-2025/>
- Gavilán, Á (2023). "Proyecciones macroeconómicas de España 2023-2026". Banco de España. Recuperado de <https://www.bde.es/f/webbe/GAP/Seciones/SalaPrensa/IntervencionesPublicas/Gobernador/Arc/Fic/IIPP-2023-12-19-gavilan-es-or.pdf>
- Instituto nacional de estadística. (2024a). "INEbase. Cónsul". Recuperado de <https://www.ine.es/consul/serie.do?s=IPC251856&c=2&nult=268>
- Instituto nacional de estadística. (2024b). "Cálculo de variaciones del Índice de Precios de Consumo (sistema IPC base 2021)". Recuperado de <https://www.ine.es/varipc/verVariaciones.do?id-mesini=1&anyoini=2002&id-mesfin=3&anyofin=2024&ntipo=1&enviar=Calcular>
- Investmood (2024). "InvestMood Fintech", Recuperado de <https://www.investmood.com/investmood-fintech>
- London Stock Exchange Group. (2023). "Environmental, social and governance scores from LSEG". Recuperado de https://www.lseg.com/content/dam/data-analytics/en_us/documents/methodology/lseg-esg-scores-methodology.pdf
- Longtermtrends. (2024a). "Stocks vs. Bonds". Recuperado de <https://www.longtermtrends.net/stocks-to-real-estate-ratio/>
- Longtermtrends. (2024b). "Stocks vs. Gold and Silver". Recuperado de <https://www.longtermtrends.net/stocks-vs-gold-comparison/>
- Longtermtrends. (2024c). "Commodity Futures". Recuperado de <https://www.longtermtrends.net/commodity-futures-prices/>
- Loo, E (2024). "Stocks vs. bonds over the past 100 years". CIBC Wood Gundy. Recuperado de <https://woodgundyadvisors.cibc.com/documents/525322/667371/V11102-AA.pdf/0f4c9ed7-2e68-4497-9994-1556b6f93eeb>
- MSCI. (2024). Recuperado de <https://www.msci.com/end-of-day-data-search>
- Nobre, J y Ferreira Neves, R. (2019). "Combining Principal Component Analysis, Discrete Wavelet Transform and XGBoost to trade in the financial markets". Recuperado de <https://www.sciencedirect.com/science/article/abs/pii/S0957417419300995>
- Organización para la Cooperación y el Desarrollo Económico. (2022). "Environmental impact of digital assets: Crypto-asset mining and distributed ledger technology consensus mechanisms". Recuperado de https://www.oecd-ilibrary.org/finance-and-investment/environmental-impact-of-digital-assets_8d834684-en
- Trading economics. (2024a). "Unión Europea - Índice de Precios al Consumidor IPC". Recuperado de <https://tradingeconomics.com/european-union/consumer-price-index-cpi>
- Trading economics. (2024b). "España- Índice de Precios al Consumidor IPC". Recuperado de <https://tradingeconomics.com/spain/consumer-price-index-cpi>
- Tradingmotion (2024). Recuperado de <https://www.tradingmotion.com/https://www.investmood.com/investmood-fintech>
- Universidad de las Naciones Unidas. (2023). "UN Study Reveals the Hidden Environmental Impacts of Bitcoin: Carbon is Not the Only Harmful By-product". Recuperado de <https://unu.edu/press-release/un-study-reveals-hidden-environmental-impacts-bitcoin-carbon-not-only-harmful-product>
- Yahoo finance. (2024). "Yahoo Finanzas". Recuperado de <https://yhoo.it/3wDhgEl>
- Ycharts. (2024). Recuperado de <https://ycharts.com/>