



Facultad de Ciencias Económicas y Empresariales
ICADE

**DISEÑO E IMPLEMENTACIÓN DE
UNA ESTRATEGIA DE INVERSIÓN
MEDIANTE LA APLICACIÓN DE
FILTRADO CUANTITATIVO Y EL
USO DE HERRAMIENTAS DE
MARKET TIMING**

Autor: Julián Velasco Blanco
Director: Ramón Bermejo Climent

MADRID | Junio 2024

Resumen

El presente trabajo tiene por objetivo diseñar una estrategia de inversión capaz de superar al mercado mediante el uso de herramientas de filtrado, modelos de factores y la optimización de estrategias a través de reglas heurísticas y algoritmos de market timing.

En primer lugar, se lleva a cabo una exhaustiva revisión de la literatura existente para identificar las estrategias de inversión más efectivas y con mayor potencial para superar el rendimiento del mercado. Esta revisión incluye análisis detallados de métodos de filtrado cuantitativo, modelos de factores como el Piotroski F-Score, el Altman Z-Score, y criterios ESG, así como técnicas avanzadas de market timing.

A partir de esta base teórica, se desarrolla una estrategia de inversión que combina estos elementos, diseñando una cartera diversificada y optimizada para maximizar el ratio de Sharpe y el retorno total. La estrategia se somete a un riguroso proceso de *backtesting* utilizando datos históricos del índice S&P 500, abarcando el período de 2007 a 2024. Este análisis retrospectivo permite evaluar la efectividad de la estrategia en diferentes condiciones de mercado y ciclos económicos.

Los resultados obtenidos demuestran que la estrategia propuesta no solo es capaz de superar considerablemente al índice de referencia en términos de rendimiento total, sino que también mejora la gestión del riesgo mediante un rebalanceo eficiente y adaptativo. La combinación de herramientas de filtrado, modelos de factores y market timing proporciona una aproximación innovadora y robusta para la gestión de carteras de inversión.

Palabras clave: Estrategia de inversión, filtrado cuantitativo, modelos de factores, market timing, Piotroski F-Score, Altman Z-Score, ESG, rebalanceo de cartera.

Abstract

The present work aims to design an investment strategy capable of outperforming the market through the use of screening tools, factor models, and the optimization of strategies via heuristic rules and market timing algorithms.

First, a comprehensive literature review is conducted to identify the most effective investment strategies with the highest potential to outperform the market. This review includes detailed analyses of quantitative screening methods, factor models such as the Piotroski F-Score, the Altman Z-Score, and ESG criteria, as well as advanced market timing techniques.

Based on this theoretical foundation, an investment strategy is developed that combines these elements, designing a diversified and optimized portfolio to maximize the Sharpe ratio and total return. The strategy undergoes a rigorous backtesting process using historical data from the S&P 500 index, covering the period from 2007 to 2024. This retrospective analysis allows for evaluating the effectiveness of the strategy under different market conditions and economic cycles.

The results obtained demonstrate that the proposed strategy is not only capable of significantly outperforming the reference index in terms of total return but also improves risk management through efficient and adaptive rebalancing. The combination of screening tools, factor models, and market timing provides an innovative and robust approach to investment portfolio management.

Keywords: Investment strategy, quantitative screening, factor models, market timing, Piotroski F-Score, Altman Z-Score, ESG, portfolio rebalancing.

Índice

Resumen.....	2
Abstract	3
Índice.....	4
1. Revisión de literatura.....	8
1.1 Historia de la inversión	8
1.2 Gestión Activa.....	10
1.3 Gestión Pasiva	12
1.4 Inversión en valor	13
1.4.1 Inversión en valor: estrategias e inversiones relevantes	15
1.5 Inversión n en crecimiento.....	18
1.5.1 Inversión en crecimiento: estrategias e inversores relevantes	19
1.6 <i>Factor Investing</i>	22
1.7 Trading algorítmico.....	24
1.7.1 Trading algorítmico: estrategias e inversiones relevantes.....	25
2. Estrategia de inversión	26
2.1 Análisis <i>Top-Down</i>	26
2.2 Análisis Macroeconómico	26
2.2.1 Ciclos económicos	27
2.2.2 Política monetaria de la FED.....	28
2.3 Predicción de Recesiones en Estados Unidos.....	31
2.3.1 Mercado Laboral	31
2.3.2 Curva invertida de tipos	34
2.3.3 Mercado Inmobiliario.....	35
2.3.4 <i>Leading Economic Index (LEI)</i>	36
2.3.5 Índice de confianza del consumidor.....	36
3. Proceso de definición de la estrategia de inversión.....	38
3.1 Objetivo y proceso de definición de la estrategia	38
3.2 Selección y extracción de los datos.....	38
3.2.1 Regímenes de Mercado.....	39
3.2.2 Ciclo económico	40
3.2.3 Medidas extraordinarias de política monetaria	40
3.3 Selección del índice de referencia.....	41
3.4 Periodo de rebalanceo de la estrategia.....	43

3.5 Diversificación del riesgo de la cartera	45
3.6 Análisis de ratios.....	46
4. Estrategia base	49
4.1 Variables de la estrategia	49
4.1.1 Piotroski F-Score.....	49
4.1.2 Altman Z Score	50
4.1.3 Criterio de ESG.....	51
4.2 Definición de la estrategia.....	51
5. Estrategia de Factor Investing	54
5.1 Factores de la estrategia.....	54
5.1.1 Factor de Valor	54
5.1.2 Factor de Rentabilidad.....	55
5.1.3 Factor de <i>Momentum</i>	56
5.1.4 Variables incluidas en la estrategia	56
5.2 Definición de la estrategia.....	57
6. Estrategia optimizada mediante Market Timing	59
6.1 Diseño y racional de la estrategia.....	59
6.2 Estrategias de inversión para ponerse en largo.....	60
6.2.1 Estrategia óptima obtenida en el Modelo Base	60
6.2.1 Estrategia óptima obtenida en el modelo de Factor Investing.....	60
6.3 Estrategias de inversión para ponerse en corto	60
6.3.1 Ponerse en corto	60
6.3.2 Inversiones en Activos Refugio.....	60
6.3.3 Inversión en el tipo de interés libre de riesgo	61
6.3.4 Inversión en las empresas con peor ranking del modelo de Factor Investing.....	61
6.3.5 Empresas peor clasificadas en el Modelo Base.....	61
6.4 Estrategias de Market timing	62
Para el desarrollo de las estrategias de Market timing, se han optimizado los parámetros asociados a cada estrategia. En la estrategia de media móvil, se ajustó el rango de la media móvil, mientras que en la estrategia de bandas de Bollinger se optimizaron el tamaño y la posición para inversiones en largo y corto. Además, se iteraron las posibles estrategias para invertir en corto y largo, buscando combinar las mejores opciones para cada una. El objetivo es maximizar el retorno y la ratio de Sharpe mediante una cartera diversificada capaz de superar al índice.....	62
6.4.1 Estrategia de Medias Móviles.....	62
6.4.2 Estrategia de Bandas de Bollinger	63
6.4.3 Estrategia basada en la regla de Sahn.....	64

7. Posibles futuras líneas de investigación	66
Declaración de Uso de Herramientas de Inteligencia Artificial Generativa en Trabajos Fin de Grado.....	68
Bibliografía	69
ANEXO 1 – CÓDIGO PARA LA PREPARACIÓN DE LAS VARIABLES.....	82
ANEXO 2 – Código para el cálculo y optimización de la estrategia base	88
ANEXO 3 – Código para calcular la estrategia de Factor Investing.....	100
ANEXO 4 – Cálculo y optimización de las estrategias con herramientas de <i>market timing</i> ...	105

Figura 1. Performance de los fondos de inversión de Estados Unidos. Vanguard Research. 2015	11
Figura 2. Estrategia de inversión siguiendo los principios de Benjamin Graham. Bloomberg. Elaboración propia. 2024	15
Figura 3. Estrategia de inversión utilizando el Piotroski F-Score. Bloomberg. Elaboración propia. 2024.....	17
Figura 4. Estrategia aplicando la Fórmula Mágica de Greenblatt. Bloomberg. Elaboración propia. 2024.....	18
Figura 5. Estrategia de inversión basada en los principios de Phillip Fisher. Bloomberg. Elaboración propia. 2024	21
Figura 6: Evolución del ciclo económico de Estados Unidos desde 1948. NBER. 2024.....	27
Figure 7. Evolución del porcentaje del PIB de Estados Unidos representado por el sector privado. CEIC DAta. 2024.....	28
Figura 8. Impacto del endurecimiento de la política monetaria en la generación de recesiones en Estados Unidos. Bloomberg. 2024	30
Figure 9. Evolución de la contratación neta mensual del sector privado en Estados Unidos. Bloomberg. 2024.....	33
Figure 10. Relación entre el balance de la Fed y los tipos de interés. Bloomberg. 2024	41
Figura 11. Listado de empresas incluidas en el S&P 500 por fecha. Bloomberg. Elaboración propia. 2024.....	43
Figura 12. Riesgo diversificable y no diversificable en función del número de acciones en cartera. McGraw Hill. 2016.....	46
Figura 13. Número de empresas en cartera para la estrategia con rebalanceo mensual. Elaboración propia. 2024	53
Figure 14. Resultados de la estrategia de inversión base. Elaboración propia. 2024	54
Figura 15. Estrategia óptima bajo el modelo de Factor Investing que maximiza la rentabilidad. Elaboración propia. 2024	58
Figura 16. Ejemplo de estrategias calculadas al optimizar la estrategia de Value Investing. elaboración propia. 2024	58
Figure 17. Estrategia optimizada con la Media Móvil. Elaboración Propia. 2024	63
Figura 18. Estrategia optimizada con las Bandas de Bollinger. Elaboración Propia. 2024	64
Figure 19. Estrategia optimizada en base a la regla de Sahm. Elaboración propia. 2024	65

1. Revisión de literatura

1.1 Historia de la inversión

El origen de la inversión se remonta a los primeros inicios de civilización organizada, donde los seres humanos comenzaron a desarrollar formas de ahorrar y gestionar sus recursos para asegurar su supervivencia y prosperidad futura. Los estudios históricos sugieren que las primeras inversiones estaban vinculadas a la agricultura y el almacenamiento de granos. En las antiguas civilizaciones de Mesopotamia y Egipto, la acumulación de excedentes agrícolas y su intercambio a través del comercio constituyeron las primeras formas de inversión (Goetzmann, 2016). Estos intercambios no solo aseguraban el sustento durante períodos de escasez, sino que también fomentaban el desarrollo de sistemas económicos más complejos.

Con el tiempo, estas prácticas rudimentarias de inversión evolucionaron hacia formas más sofisticadas con el desarrollo de las primeras ciudades estado y el comercio internacional. En la antigua Grecia y Roma, la inversión comenzó a tomar formas más estructuradas, incluyendo la compra de tierras, esclavos, y bienes inmuebles, así como la financiación de empresas comerciales a través de asociaciones y sociedades (Wilson, 2013). La aparición de mercados y monedas facilitó estas transacciones, permitiendo una mayor fluidez y diversidad en las oportunidades de inversión.

El Renacimiento marcó un punto de inflexión en la historia de la inversión, impulsado por el auge del comercio internacional y la expansión colonial europea. La creación de las primeras bolsas de valores en ciudades como Ámsterdam y Londres, y la formación de compañías mercantiles como la Compañía Holandesa de las Indias Orientales, introdujeron mecanismos para la inversión en acciones y bonos, diversificando aún más las opciones disponibles para los inversores (Neal, 1990). Este periodo también vio el surgimiento de las primeras teorías económicas que intentaban explicar y sistematizar la conducta de inversión.

A principios del siglo XX, las teorías de inversión comenzaron a formalizarse con la contribución de académicos como Irving Fisher y John Maynard Keynes. Fisher introdujo conceptos fundamentales como el valor presente y el interés compuesto, que sentaron las bases para la teoría moderna de la inversión (Fisher, 1930). Keynes, por su parte, abordó la incertidumbre y el comportamiento de los inversores en su obra seminal "La teoría general del empleo, el interés y el dinero" (Keynes, 1936), proporcionando un marco para entender cómo las expectativas y la psicología de los inversores influyen en los mercados financieros.

El desarrollo de la teoría de la cartera de Harry Markowitz en 1952 representó otro avance crucial, proporcionando un marco matemático para la diversificación y la gestión del riesgo (Markowitz, 1952). Esta teoría fue posteriormente ampliada por William Sharpe con el modelo de valoración de activos financieros (CAPM), que ofrecía una relación sistemática entre el riesgo y el rendimiento esperado de los activos (Sharpe, 1964). Estas teorías no solo transformaron la práctica de la inversión, sino que también establecieron los fundamentos de la finanzas modernas como disciplina académica.

El estudio de De Bondt y Thaler en 1985 fue pionero en demostrar cómo los inversores tienden a sobre reaccionar a las noticias. En su investigación, encontraron que las acciones que habían tenido rendimientos extremos en un periodo de tres a cinco años tienden a revertir en los años subsiguientes, es decir, las ganadoras del pasado reciente tendían a tener rendimientos inferiores en el futuro, mientras que las perdedoras tendían a superar al mercado. Este fenómeno sugiere que los precios iniciales habían sido inflados o deprimidos por una reacción excesiva a las noticias, y que los inversores eventualmente corregían sus expectativas (De Bondt y Thaler, 1985).

El modelo de tres factores de Fama-French, introducido en 1992, amplió el CAPM al incluir dos factores adicionales: el tamaño de la empresa (SMB) y el valor (HML). Este modelo mostró que las acciones de pequeñas empresas y las acciones de valor tienden a tener rendimientos superiores, tras ajustar el riesgo de mercado (Fama y French, 1993). Posteriormente, el modelo de cuatro factores de Carhart añadió el factor *momentum* (UMD), capturando la tendencia de las acciones con buenos rendimientos recientes a continuar subiendo (Carhart, 1997). Estas anomalías de tamaño, valor y *momentum*, documentadas en estudios previos (Banz, 1981; Jegadeesh y Titman, 1993), han sido fundamentales para el desarrollo de estrategias de inversión y gestión de carteras, proporcionando una comprensión más completa de los aspectos clave del rendimiento de las acciones. La evidencia empírica respalda la eficacia de estas estrategias, llevando a una adopción generalizada en la industria de la inversión y mejorando la capacidad de los gestores de fondos para diseñar carteras más robustas y diversificadas (Lakonishok, Shleifer, y Vishny, 1994).

El uso de matemáticas avanzadas para la gestión de activos y el análisis cuantitativo se intensificó en los años 2000-2010, con el auge de los fondos cuantitativos y el trading algorítmico. Las grandes gestoras de activos comenzaron a adoptar modelos cuantitativos para analizar grandes volúmenes de datos financieros, identificar patrones y ejecutar estrategias de inversión con precisión. La incorporación de algoritmos de aprendizaje automático y técnicas de

big data permitió a los inversores cuantitativos crear modelos más sofisticados y adaptativos, mejorando la capacidad de predecir movimientos del mercado y gestionar el riesgo de manera efectiva (Lopez de Prado, 2018). Este enfoque ha transformado la industria de la inversión, proporcionando herramientas poderosas para optimizar el rendimiento ajustado por riesgo.

El impacto de estas estrategias avanzadas ha sido significativo en el desarrollo de nuevas teorías y prácticas de inversión. Las finanzas conductuales, por ejemplo, han surgido como una respuesta a las limitaciones de los modelos tradicionales, incorporando elementos de psicología para explicar las anomalías del mercado y el comportamiento de los inversores (Thaler, 2015). Además, el auge de la inversión pasiva y los fondos indexados, promovidos por figuras como John Bogle, fundador de Vanguard Group, ha cambiado el entorno de la inversión, ofreciendo alternativas de bajo coste a los inversores (Bogle, 2016).

Estos avances no solo han democratizado el acceso a las inversiones sofisticadas, sino que también han incrementado la eficiencia de los mercados financieros. La tecnología y el análisis de datos han permitido a los inversores obtener información más precisa y oportuna, mejorando la toma de decisiones. Además, la globalización de los mercados ha abierto nuevas oportunidades para la diversificación geográfica y sectorial, proporcionando a los inversores una gama más amplia de opciones para construir sus carteras (Dimson, Marsh y Staunton, 2002).

1.2 Gestión Activa

La gestión activa se refiere a una estrategia de inversión en la que los gestores de fondos toman decisiones específicas sobre qué activos incluir en una cartera con el objetivo de superar el rendimiento de un índice de referencia o del mercado en general. Este enfoque requiere un análisis constante del mercado, una comprensión profunda de los fundamentos económicos y financieros, y la capacidad de anticipar movimientos futuros del mercado. A pesar de sus costes más elevados en comisiones debido a la investigación y la frecuencia de las transacciones, la gestión activa puede ofrecer potenciales rendimientos superiores si se ejecuta con éxito (Fama & French, 2010).

A diferencia de la gestión pasiva, que simplemente sigue un índice de referencia, la gestión activa permite a los gestores reaccionar ante cambios en las condiciones del mercado, ajustar sus estrategias de inversión en respuesta a eventos económicos y políticos, y tomar decisiones que podrían generar rendimientos superiores. Esta flexibilidad puede ser especialmente valiosa en mercados volátiles o en situaciones donde las oportunidades de inversión no están plenamente reflejadas en los precios del mercado (Wermers, 2000).

Uno de los principales beneficios de la gestión activa es la posibilidad de obtener rendimientos superiores al mercado. Los gestores activos pueden identificar y capitalizar oportunidades de inversión, utilizando una combinación de análisis fundamental, técnico y cuantitativo. Estudios han demostrado que ciertos gestores activos han sido capaces de superar consistentemente sus índices de referencia, aunque esto tiende a ser más la excepción que la regla (Grinblatt & Titman, 1989). Además, la gestión activa permite una mayor personalización de las carteras para satisfacer los objetivos y las tolerancias al riesgo de los inversores.

Sin embargo, uno de los desafíos más significativos de la gestión activa es la dificultad para superar consistentemente al índice de referencia. Estudios académicos han demostrado que, en promedio, los fondos gestionados activamente tienden a tener un rendimiento inferior al índice, una vez descontadas las comisiones. Fama y French (2010) concluyeron que, después de considerar los gastos de gestión y las comisiones de transacción, los fondos activos en general no logran superar a los fondos pasivos, salvo escasas excepciones.

En los últimos 20 años, solo el 26% de los fondos de inversión de renta variable gestionados activamente en Estados Unidos superaron sus índices de referencia (Wallick, Wimmer y Balsamo, 2015). La investigación ha demostrado que el rendimiento inferior de los fondos gestionados activamente es relativamente constante en diferentes países, segmentos de mercado y periodos de tiempo. Los fondos gestionados activamente tienden a tener ratios de gastos más altos, lo que contribuye a su menor rendimiento en comparación con los fondos indexados (Wallick, Wimmer y Balsamo, 2015).

Por lo tanto, la gestión activa ofrece la posibilidad de rendimientos superiores y una mayor flexibilidad en la toma de decisiones de inversión, pero también conlleva riesgos significativos, incluyendo costes más altos y la dificultad de superar consistentemente al índice de referencia y por lo tanto de generar alfa (Sharpe, 1991).




Figura 1. Performance de los fondos de inversión de Estados Unidos. Vanguard Research. 2015

Ejemplos de estrategias de gestión activa

Dentro de la gestión activa existen varias estrategias que los gestores pueden emplear para alcanzar sus objetivos de rentabilidad. Una estrategia común es la inversión en valor, que implica buscar y adquirir acciones que se cotizan por debajo de su valor intrínseco. Los gestores de valor examinan empresas con sólidos fundamentos pero que el mercado ha infravalorado temporalmente, con la expectativa de que su valor real se reconocerá con el tiempo (Graham, 1949). Otra estrategia es la inversión en crecimiento (*growth*), que se centra en empresas que se espera que experimenten un crecimiento superior al promedio en ingresos, beneficios o flujo de caja. Los gestores de crecimiento tienden a invertir en empresas emergentes o en sectores innovadores que tienen un gran potencial de expansión (Damodaran, 2012).

Además de estas estrategias, existen otras como la inversión basada en el análisis técnico, que utiliza patrones históricos de precios y volúmenes para predecir movimientos futuros del mercado. Los analistas técnicos centran su análisis en gráficos y tendencias del mercado (Murphy, 1999). Otra estrategia activa es el trading de alta frecuencia (HFT), que emplea algoritmos complejos y tecnología avanzada para ejecutar un gran número de órdenes en fracciones de segundo aprovechando arbitrajes, pequeñas ineficiencias del mercado (Aldridge, 2013).

1.3 Gestión Pasiva

La gestión pasiva es una estrategia de inversión que busca replicar el rendimiento de un índice de referencia específico o del mercado en general. Este enfoque implica la creación de una cartera que contiene los mismos activos en las mismas proporciones que el índice objetivo, minimizando así el número de transacciones y los costes asociados. La gestión pasiva se basa en la premisa de que los mercados son eficientes y que es difícil superar consistentemente al mercado (Easley et. al, 2003).

Al seguir un índice de referencia, los inversores pueden obtener una diversificación amplia y automática, lo que ayuda a reducir el riesgo específico de los activos individuales. La gestión pasiva también ofrece una mayor previsibilidad y transparencia en términos de rendimiento puesto que la cartera reflejará el rendimiento del índice. Esto es particularmente atractivo para los inversores que prefieren evitar la incertidumbre asociada con la selección activa de acciones y las posibles fluctuaciones en el rendimiento (Malkiel, 2003).

A pesar de sus ventajas, la gestión pasiva también tiene sus limitaciones. Uno de los desafíos más significativos es que esta estrategia está intrínsecamente diseñada para igualar el

rendimiento del mercado. Los inversores que buscan generar alfa, rendimientos superiores al mercado, pueden encontrar que la gestión pasiva no satisface sus objetivos de inversión (Garleanu y Pedersen, 2022).

Otro aspecto a considerar es la falta de flexibilidad en la gestión pasiva. Dado que esta estrategia implica seguir estrictamente un índice, los gestores de fondos pasivos no pueden ajustar las posiciones de la cartera en respuesta a cambios en las condiciones del mercado o a eventos económicos imprevistos. Esto puede ser una desventaja en periodos de alta volatilidad o crisis financieras, donde una gestión activa podría mitigar los riesgos (Garleanu y Pedersen, 2022).

1.4 Inversión en valor

La inversión en valor es una estrategia de inversión que implica la compra de acciones que parecen estar infravaloradas por el mercado. Este enfoque se basa en la premisa de que el mercado puede ser ineficiente a corto plazo, pero que los precios de las acciones eventualmente reflejarán su valor intrínseco (CFA Level III, Vol. 1-6, 2024). Los inversores en valor buscan acciones que cotizan a un precio inferior a su valor fundamental, calculado a través de diversos métodos de análisis financiero y económico (Graham, 1949). Esta estrategia fue popularizada por Benjamin Graham y David Dodd (1934) en su influyente obra "Security Analysis", y ha sido adoptada por inversores como Warren Buffett.

Uno de los principios fundamentales de la inversión en valor es la evaluación del valor intrínseco de una empresa, que se estima mediante el análisis de sus estados financieros, flujos de caja futuros y otros indicadores económicos. Los inversores en valor suelen utilizar métricas como la relación precio/ganancias (P/E) y la relación precio/valor contable (P/B) para identificar acciones infravaloradas (Damodaran, 2012). Al comparar estas ratios con la media histórica o las ratios de empresas comparables, los inversores pueden detectar oportunidades donde el mercado ha subestimado el valor de una empresa.

La filosofía de inversión en valor también enfatiza la importancia del margen de seguridad. El margen de seguridad se refiere a la diferencia entre el valor intrínseco de una acción y su precio de mercado. Al comprar acciones con un margen de seguridad significativo, los inversores en valor buscan minimizar el riesgo de pérdida en caso de que su análisis sea incorrecto o de que el mercado tarde en reconocer el valor de la empresa (Graham, 1949).

A lo largo del tiempo, la inversión en valor ha demostrado ser una estrategia rentable. Fama y French (1992) demostraron en su estudio seminal que las acciones con bajos ratios precio/valor

contable tienden a generar mayores rendimientos ajustados por riesgo en comparación con el mercado en general.

Sin embargo, la inversión en valor no está exenta de desafíos y críticas. En períodos de crecimiento del mercado, las acciones de valor pueden quedarse rezagadas en comparación con las acciones *growth*, que suelen ser más atractivas para los inversores durante los mercados alcistas (Lakonishok, Shleifer, y Vishny, 1994). Además, identificar correctamente el valor intrínseco de una empresa requiere un análisis profundo y un conocimiento sólido de finanzas, lo que puede ser una barrera para los inversores menos experimentados.

Quantitative value

El concepto de *quantitative value* se refiere a una estrategia de inversión que combina los principios de la inversión en valor con técnicas cuantitativas para identificar y seleccionar acciones infravaloradas. Este enfoque se basa en el uso de modelos matemáticos y estadísticos para evaluar y comparar una gran cantidad de datos financieros, permitiendo a los inversores aplicar los fundamentos de la inversión en valor de manera sistemática y objetiva (Gray y Carlisle, 2013).

A diferencia de la inversión en valor tradicional, que puede depender en gran medida del juicio subjetivo del inversor, el *quantitative value* utiliza algoritmos para analizar datos históricos y actuales, identificando patrones y relaciones que puedan indicar el descuento de una acción. Este enfoque cuantitativo puede incorporar filtros adicionales para evaluar la calidad de los beneficios, la estabilidad de los flujos de caja y otros indicadores de la salud financiera de la empresa (Gray y Carlisle, 2013).

El *quantitative value* ha demostrado ser eficaz en diversos estudios empíricos. Por ejemplo, investigaciones han mostrado que las estrategias basadas en modelos cuantitativos de valor pueden generar rendimientos superiores a largo plazo en comparación con estrategias de mercado más generales. Esto se debe a que los modelos cuantitativos pueden identificar de manera más precisa y rápida las acciones que están infravaloradas por el mercado, aprovechando las ineficiencias del mercado antes de que sean corregidas (Piotroski, 2000; Greenblatt, 2006).

1.4.1 Inversión en valor: estrategias e inversiones relevantes

Benjamin Graham

La estrategia de inversión de Benjamin Graham es una de las metodologías más influyentes en el campo de la inversión. Graham, considerado el padre de la inversión en valor, desarrolló un enfoque basado en la evaluación de los fundamentos financieros de las empresas para identificar acciones infravaloradas. Su filosofía se centra en la compra de valores que cotizan a un precio inferior a su valor intrínseco, proporcionando un margen de seguridad para protegerse contra errores de valoración y fluctuaciones del mercado (Graham, 1949).

Otro pilar de la estrategia de Graham es la diversificación. Para Graham, la diversificación es esencial para reducir el riesgo específico de cada inversión. Sugería mantener una cartera diversificada de al menos 20 a 30 acciones diferentes, seleccionadas según los criterios de valor aplicados (Graham, 1949). La diversificación ayuda a amortiguar el impacto de la caída en el precio de una acción individual en el rendimiento total de la cartera, proporcionando una mayor estabilidad y previsibilidad en los rendimientos (Ross, et al., 2016).

La estrategia de inversión de la figura 2 utiliza los criterios teóricos establecidos por Benjamin Graham. Siguiendo esta metodología tradicional de inversión se puede determinar mediante un *backtest* a 15 años realizado con Bloomberg como su estrategia es capaz de batir al mercado, superando al S&P 500 en un 3,13% anual de media. Este es el motivo por el que es considerado el padre de las finanzas modernas y ha sido el precursor de la teoría empleada por otros grandes inversores, como es el caso destacable de Warren Buffet.




Figura 2. Estrategia de inversión siguiendo los principios de Benjamin Graham. Bloomberg. Elaboración propia. 2024

Warren Buffet

La estrategia de inversión de Warren Buffett, uno de los inversores más exitosos y respetados de todos los tiempos, se basa en principios fundamentales de la inversión en valor, pero con adaptaciones y enfoques específicos que reflejan su experiencia y perspectiva única (Buffett, 1984). Buffett, influenciado por su mentor Benjamin Graham, ha desarrollado una metodología que combina el análisis de los fundamentos de las empresas con una visión a largo plazo y un enfoque en la calidad y el crecimiento sostenible (Hagstrom, 2005).

Uno de los pilares de la estrategia de Buffett es la inversión en empresas con ventajas competitivas duraderas, o fosos económicos. Buffett busca compañías que tengan una posición de mercado sólida, lo que les permite mantener precios y márgenes de beneficio elevados y resistir la competencia. Estos fosos pueden surgir de varios factores, como marcas fuertes, economías de escala, derechos exclusivos, y efectos de red. La capacidad de identificar y valorar correctamente estas ventajas competitivas es esencial para la metodología de Buffett (Cunningham, 2001).

Buffett también pone un fuerte énfasis en la calidad del equipo directivo de las empresas en las que invierte. Busca empresas lideradas por equipos competentes y éticos que actúen en el mejor interés de los accionistas. Buffett valora la honestidad, la integridad y la capacidad de los directivos para gestionar el crecimiento de la empresa de manera eficiente y rentable. Esta confianza en la gestión se refleja en su tendencia a mantener inversiones a largo plazo, permitiendo que las empresas crezcan y generen valor con el tiempo (Buffett y Clark, 2011).

Bajo su estrategia de inversión, Warren Buffett ha obtenido resultados excepcionales a lo largo de su carrera. Desde 1965 hasta la actualidad, Berkshire Hathaway, la firma de inversión de Buffett, ha logrado un rendimiento anualizado de aproximadamente 19,8%, comparado con el 9,9% del índice S&P 500 durante el mismo periodo. Esto demuestra la capacidad de Buffett para superar consistentemente al mercado a lo largo de varias décadas, consolidándose como uno de los inversores más exitosos de todos los tiempos (Investing.com, 2023).

Joseph Piotroski: F-Score

El Piotroski F-score es una herramienta cuantitativa de análisis financiero desarrollada por el profesor Joseph D. Piotroski en el año 2000, diseñada para evaluar la solidez financiera de las empresas y mejorar las estrategias de inversión en valor. El F-score se compone de nueve criterios basados en datos contables, agrupados en tres categorías: rentabilidad, apalancamiento y liquidez, y eficiencia operativa (Piotroski, 2000).

Piotroski (2000) encontró que los inversores que seleccionan acciones con un F-score alto pueden obtener rendimientos significativamente superiores en comparación con aquellos que no utilizan esta herramienta. Además, investigaciones posteriores han validado estos hallazgos en diferentes mercados y periodos, subrayando la robustez y utilidad del F-score como una herramienta de selección de acciones (Fama & French, 2008).

La figura 4 muestra un análisis de esta estrategia de inversión en Bloomberg basada en el F-score de Piotroski. El análisis indica que las empresas que cuentan con un F-score de 8 o más tienden a batir al mercado. Estas empresas en los últimos 15 años han sido capaces de obtener rendimientos superiores a los del índice S&P 500. Durante este periodo generan una rentabilidad anual media de 0,74% por encima del índice.




Figura 3. Estrategia de inversión utilizando el Piotroski F-Score. Bloomberg. Elaboración propia. 2024

Joel Greenblatt: Fórmula Mágica

La Fórmula Mágica de Joel Greenblatt es una estrategia de inversión que se ha ganado la atención por su simplicidad y eficacia en la selección de acciones. La fórmula combina dos métricas financieras fundamentales: el rendimiento sobre el capital (*ROC*) y el rendimiento de ganancias (*Earnings Yield*). Esta metodología se basa en la premisa de que las empresas con altos rendimientos de ganancias y altos retornos sobre el capital están infravaloradas y, por lo tanto, tienen un mayor potencial de generar rendimientos superiores a largo plazo (Greenblatt, 2006).

Greenblatt y otros investigadores han encontrado que, históricamente, las acciones seleccionadas utilizando esta metodología han superado consistentemente al mercado. Greenblatt mostró que durante el periodo de 1988 a 2004, su fórmula produjo un rendimiento

anual compuesto del 30,8%, significativamente superior al rendimiento del S&P 500 (Greenblatt, 2006).

Se ha llevado un análisis de la estrategia en los últimos 15 años mediante un *backtest* en Bloomberg. Al comparar la estrategia de Greenblatt con el S&P 500 como índice de referencia, los resultados muestran que la estrategia es capaz de batir consistentemente al mercado obteniendo un retorno de media del 1,19% superior al S&P 500.




Figura 4. Estrategia aplicando la Fórmula Mágica de Greenblatt. Bloomberg. Elaboración propia. 2024

1.5 Inversión en crecimiento

La inversión en crecimiento, o *Growth investing*, es una estrategia que se centra en adquirir acciones de empresas que se espera que experimenten un crecimiento superior al promedio en términos de ingresos, beneficios o flujo de caja. A diferencia de la inversión en valor, la inversión en crecimiento se basa en la perspectiva futura de la empresa. Los inversores en crecimiento buscan empresas que están en etapas expansivas de su ciclo de vida y que tienen el potencial de aumentar significativamente su valor con el tiempo (Damodaran, 2012).

Uno de los principales atractivos de la inversión en crecimiento es el potencial de obtener altos rendimientos. Las empresas de crecimiento a menudo operan en sectores dinámicos y en desarrollo, como la tecnología, la biotecnología y el comercio electrónico. Estas empresas suelen reinvertir la mayor parte de sus beneficios en la expansión de sus operaciones, innovación y desarrollo de nuevos productos, lo que puede conducir a un crecimiento exponencial en sus ingresos y beneficios (Chen et al., 2002).

Sin embargo, la inversión en crecimiento también conlleva riesgos considerables. Dado que estas empresas tienden a reinvertir sus beneficios en lugar de pagar dividendos, los inversores dependen en gran medida de la apreciación del precio de las acciones para obtener retornos. Además, las expectativas de crecimiento futuro están incorporadas en los precios actuales de las acciones, lo que puede hacer que su precio de mercado sea caro en términos fundamentales comparado con otras empresas consolidadas en el sector (Rouwenhorst, 1999).

La selección de acciones de crecimiento requiere un análisis y comprensión detallada de la industria y la posición competitiva de la empresa. Los inversores deben evaluar factores como la tasa de crecimiento histórico de los ingresos, las perspectivas de mercado, la capacidad de la empresa para innovar y la calidad de su gestión. También es crucial considerar la sostenibilidad del modelo de negocio y la ventaja competitiva de la empresa (Fama & French, 1995).

Algunos estudios sugieren que las acciones de crecimiento pueden ofrecer rendimientos superiores durante ciertos periodos de mercado, especialmente en entornos de tasas de interés bajas y expansión económica. Sin embargo, a largo plazo, las acciones de crecimiento pueden ser más volátiles y susceptibles a las fluctuaciones del mercado, lo que requiere una mayor tolerancia al riesgo por parte de los inversores (Chan, Karceski, y Lakonishok, 2000).

1.5.1 Inversión en crecimiento: estrategias e inversores relevantes

Rowe Price

Thomas Rowe Price Jr., conocido como el padre de la inversión en crecimiento, desarrolló una estrategia de inversión que se centró en identificar empresas con un potencial de crecimiento sostenible y a largo plazo. Price adoptó un enfoque basado en la creencia de que el mercado ofrece oportunidades para aquellos que pueden identificar tendencias de crecimiento a largo plazo y las empresas que están bien posicionadas para capitalizar sobre ellas (Price, 1973).

Price creía que el crecimiento económico y la innovación tecnológica generaban oportunidades para empresas específicas que podían beneficiarse de estas tendencias. Para identificar estas oportunidades, Price analizaba el entorno macroeconómico y los cambios estructurales en la economía, buscando sectores y empresas que pudieran experimentar un crecimiento significativo durante décadas. Este enfoque le permitió anticipar el crecimiento en industrias emergentes como la tecnología y la salud (Price, 1973).

Price también ponía un fuerte énfasis en la calidad de la gestión de las empresas. Creía que las empresas exitosas estaban lideradas por equipos directivos competentes, con visión a largo plazo y capacidad para ejecutar estrategias de crecimiento efectivas. Price valoraba la estabilidad

en la gestión y prefería empresas donde los directivos tenían un historial probado de tomar decisiones acertadas y manejar eficazmente los recursos de la empresa. Este enfoque en la calidad de la gestión ayudó a Price a seleccionar empresas que no solo tenían potencial de crecimiento, sino también la capacidad de realizar ese potencial (Price, 1973).

Peter Lynch

La estrategia de inversión en crecimiento de Peter Lynch, desarrollada durante su gestión del fondo Magellan en Fidelity, es ampliamente reconocida por su enfoque pragmático y su éxito en la identificación de oportunidades de inversión. Lynch, conocido por su filosofía de invertir en lo que conoces, enfatizaba la importancia de comprender profundamente las empresas y sus industrias antes de realizar inversiones. Este enfoque le permitió obtener rendimientos superiores al promedio del mercado, transformando el fondo Magellan en uno de los más exitosos de su tiempo (Lynch & Rothchild, 2000).

Lynch considera que los inversores pueden obtener una ventaja significativa al invertir en empresas e industrias con las que están familiarizados. Esto no solo permite una mejor comprensión de los fundamentos del negocio, sino que también facilita la identificación de tendencias emergentes y oportunidades de crecimiento antes de que sean ampliamente reconocidas por el mercado. Lynch alienta a los inversores a utilizar sus observaciones cotidianas y su conocimiento personal como punto de partida para el análisis de inversión (Lynch, 2015).

La diversificación también jugaba un papel crucial en la estrategia de Lynch. Aunque favorecía la concentración en industrias y empresas que comprendía bien, mantenía una cartera diversificada para mitigar riesgos específicos de la empresa y del sector. Esta diversificación le permitió capitalizar oportunidades en diferentes áreas del mercado y reducir el impacto de posibles fracasos en inversiones individuales. Lynch era conocido por su habilidad para encontrar *tenbaggers*, o acciones que multiplicaban su valor por diez, lo que compensaba con creces las pérdidas en otras inversiones (Lynch, 1993).

Durante la vida del fondo Fidelity Magellan gestionado por Peter Lynch siguiendo el enfoque de inversión en *growth* y la identificación de *tenbaggers*, el fondo consiguió batir al índice S&P 500 en ese periodo generando un retorno anual medio de un 28,88%, muy por encima del 15,13% de rentabilidad media generado por el S&P 500 (Morningstars, 2022). Por estos motivos, Peter Lynch es reconocido como uno de los inversores más relevantes de la historia y su estrategia de inversión ha sido adoptada en el mercado debido a su rentabilidad sostenida en el tiempo.

Phillip Fisher

La estrategia de inversión de Philip Fisher es una de las metodologías más respetadas y adoptadas en el ámbito de la inversión en crecimiento. Fisher es conocido por su enfoque en la inversión a largo plazo en empresas de alta calidad con potencial de crecimiento sostenido. Su filosofía se centra en un análisis exhaustivo tanto cualitativo como cuantitativo de las empresas, buscando identificar aquellas con fuertes perspectivas de crecimiento y ventajas competitivas duraderas (Fisher, 1996).

Uno de los pilares fundamentales de la estrategia de Fisher es la evaluación exhaustiva de la calidad de la gestión. Fisher considera firmemente que el éxito de una empresa a largo plazo depende en gran medida de la competencia, la integridad y la visión de su equipo directivo. Por lo tanto, dedicaba una cantidad considerable de tiempo a analizar las capacidades de los directivos, su historial de desempeño y su capacidad para tomar decisiones estratégicas. Fisher recomienda a los inversores realizar entrevistas y recopilar información directa sobre la gestión para evaluar adecuadamente su calidad (Fisher, 1996).

La figura 5 muestra el *backtest* realizado con Bloomberg utilizando la estrategia de inversión en crecimiento de Fisher. El análisis demuestra que la estrategia obtiene retornos significativamente superiores a los del S&P 500 durante el periodo de 15 años analizado. En promedio, la estrategia supera la rentabilidad del S&P 500 en un 4,72%, y logra un ratio de Sharpe cercano a 1, que indica una relación rentabilidad riesgo muy atractiva para el inversor.

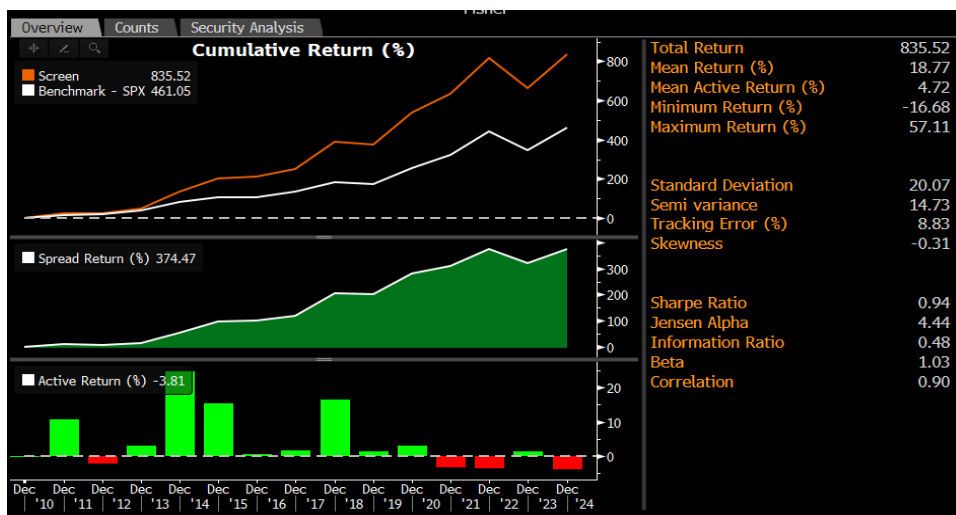


Figura 5. Estrategia de inversión basada en los principios de Phillip Fisher. Bloomberg. Elaboración propia. 2024

Mohanram: G-Score

El Mohanram G-Score es una herramienta de análisis financiero desarrollada por Partha Mohanram en 2005 para evaluar la solidez financiera y el potencial de crecimiento de las empresas bajo una estrategia de inversión *growth*. Este enfoque se centra en identificar acciones de empresas con perspectivas de crecimiento utilizando una serie de métricas financieras que proporcionan una visión más completa de la salud y las perspectivas futuras de una empresa. El G-Score de Mohanram utiliza ocho indicadores financieros agrupados en tres categorías: rentabilidad, estabilidad financiera y eficiencia operativa (Mohanram, 2005).

El G-Score es calculado asignando puntos a cada uno de los ocho indicadores financieros. Una puntuación más alta indica una empresa con mejores fundamentos financieros y mayor potencial de crecimiento (Mohanram, 2005).

1.6 Factor Investing

El factor investing es una estrategia de inversión que se centra en identificar y aprovechar ciertos factores que, históricamente, han demostrado ser predictivos de los rendimientos de los activos. Esta estrategia implica seleccionar activos en función de características específicas que están asociadas con un rendimiento superior a lo largo del tiempo (CFA Level II, Vol. 1-8, 2024). Los factores más comunes utilizados en el *factor investing* incluyen valor, tamaño, *momentum*, calidad, volatilidad y dividendos. Cada uno de estos factores se basa en diferentes características financieras y de mercado, y ha sido validado por investigaciones académicas que demuestran su efectividad a largo plazo.

El origen del modelo de *factor investing* se remonta a los modelos desarrollados por Eugene Fama y Kenneth French, así como por Mark Carhart. El modelo de Fama-French y el modelo de Carhart son enfoques fundamentales en la teoría de finanzas que buscan explicar los rendimientos de las carteras de inversión más allá de lo que puede predecir el Modelo de Valoración de Activos de Capital (CAPM). Ambos modelos introducen factores adicionales para capturar anomalías del mercado y mejorar la explicación de los rendimientos de los activos (Fama y French, 1992; Carhart, 1997) .

El modelo de tres factores de Fama-French (1992), amplía la fórmula del modelo CAPM al incluir además de la beta dos factores adicionales: el tamaño de la empresa (SMB) y el valor (HML). El CAPM solo considera el riesgo de mercado, medido por el beta, pero Fama y French encontraron que el tamaño de la empresa y el valor relativo en libros también son importantes para explicar los rendimientos. Este modelo ha demostrado ser más efectivo que el CAPM en la explicación de

los rendimientos de las carteras, proporcionando una mejor comprensión de los riesgos que afectan los precios de los activos (Fama & French, 1993).

El modelo de cuatro factores de Carhart, desarrollado por Mark Carhart en 1997, extiende aún más el modelo de Fama-French al incluir un cuarto factor: el *momentum*. Este factor captura la tendencia de las acciones que han tenido un buen rendimiento en el pasado reciente a continuar creciendo en el futuro cercano. Carhart incorporó este factor basado en la evidencia de que el *momentum* es una característica persistente y significativa en los rendimientos de las acciones (Carhart, 1997).

Estos modelos han sido ampliamente adoptados en la industria para el desarrollo de estrategias para fondos de inversión y para la construcción de carteras diversificadas que buscan captar primas de riesgo asociadas con tamaño, valor y *momentum* (Bodie, Kane y Marcus, 2014).

Principales factores utilizados en modelos de factor investing

Valor: El factor de valor se centra en la adquisición de acciones que están infravaloradas en comparación con sus fundamentales siguiendo el marco teórico proporcionado por Benjamin Graham (1949).

Tamaño: El factor tamaño se basa en la premisa de que las acciones de empresas pequeñas tienden a superar a las de empresas grandes a largo plazo. Banz (1981) fue uno de los primeros en documentar este efecto, mostrando que las empresas con menor capitalización bursátil ofrecían mayores comparaciones con las grandes empresas, que se atribuye a la mayor capacidad de crecimiento de las pequeñas empresas y a la menor atención que reciben de los grandes inversores institucionales.

Momentum: El factor momentum se refiere a la tendencia de las acciones que han tenido un buen desempeño en el pasado reciente a continuar teniendo un buen desempeño en el futuro cercano. Jegadeesh y Titman (1993) demostraron que las estrategias de inversión basadas en *momentum* pueden generar rendimientos superiores al mercado al seguir comprando acciones que habían mostrado fuertes rendimientos en los últimos 3 a 12 meses.

Calidad: El factor de calidad se enfoca en la selección de acciones de empresas con sólidos fundamentos financieros, como alta rentabilidad, bajos niveles de endeudamiento y estabilidad en los beneficios. Asness, Frazzini y Pedersen (2014) demostraron que las empresas de alta calidad tienden a generar mayores rendimientos.

Baja volatilidad: El factor de baja volatilidad se basa en la observación de que las acciones con menor volatilidad tienden a superar a las de alta volatilidad en términos de rendimientos ajustados por riesgo. Este fenómeno, conocido como la anomalía de baja volatilidad, fue popularizado por estudios como el de Ang, Hodrick, Xing y Zhang (2006), quienes encontraron que las carteras de baja volatilidad producían rendimientos superiores y menores riesgos en comparación con carteras de alta volatilidad.

Sostenibilidad: El factor de sostenibilidad, o criterios ambientales, sociales y de gobernanza (ESG), se está volviendo cada vez más importante en el mundo del *factor investing*. Empresas con altas puntuaciones en ESG son aquellas que gestionan bien sus riesgos ambientales y sociales y que tienen una buena gobernanza corporativa. Estudios han mostrado que las empresas con fuertes prácticas ESG tienden a tener un mejor rendimiento financiero a largo plazo (Friede, Busch, y Bassen, 2015).

1.7 Trading algorítmico

El trading algorítmico se refiere al uso de algoritmos y modelos matemáticos para tomar decisiones de inversión en los mercados financieros. Estos algoritmos están diseñados para ejecutar órdenes de compra y venta de manera automática, aprovechando patrones y oportunidades de mercado. El objetivo principal del trading algorítmico es mejorar la eficiencia de las operaciones, minimizar el impacto del mercado y maximizar las ganancias mediante la ejecución rápida y precisa de estrategias de trading predefinidas (Treleaven, Galas, y Lalchand, 2013).

Uno de los principales beneficios del trading algorítmico es su capacidad para procesar grandes volúmenes de datos a una velocidad mucho mayor que los seres humanos. Los algoritmos pueden analizar múltiples variables y ejecutar órdenes en milisegundos, lo que es crucial en mercados donde los precios pueden cambiar en fracciones de segundo. Además, el trading algorítmico elimina el sesgo emocional que puede afectar las decisiones de los *traders* humanos, permitiendo una toma de decisiones más objetiva y basada en datos (Hendershott, Jones, y Menkveld, 2011).

El trading algorítmico se utiliza en una variedad de estrategias, incluyendo el arbitraje y el trading de alta frecuencia (HFT). El arbitraje aprovecha las diferencias de precio entre diferentes mercados o instrumentos financieros para obtener ganancias sin riesgo. El HFT, una forma avanzada de trading algorítmico se centra en ejecutar un gran número de operaciones en

fracciones de segundo, capturando pequeñas diferencias de precio que pueden sumar ganancias significativas debido al alto volumen de operaciones (Aldridge, 2013).

1.7.1 Trading algorítmico: estrategias e inversiones relevantes

Jim Simons

Jim Simons, el fundador de Renaissance Technologies, es uno de los pioneros y más exitosos practicantes del trading algorítmico. Simons, un matemático y ex profesor de la Universidad de Stony Brook, aplicó sus conocimientos de matemáticas y estadística para desarrollar modelos de trading que han generado rendimientos extraordinarios. El fondo más famoso de Renaissance, el Medallion Fund, ha logrado rendimientos anuales promedio de alrededor del 39% desde su creación en 1988, después de deducir las comisiones, lo que lo convierte en uno de los fondos más exitosos de la historia (Zuckerman, 2019).

La estrategia ganadora de Simons y su equipo en Renaissance Technologies se basa en el uso intensivo de datos y el análisis cuantitativo. Utilizan técnicas avanzadas de análisis de datos, aprendizaje automático y modelado estadístico para identificar patrones y anomalías en los datos de mercado que pueden ser explotados para obtener beneficios. Estos modelos no solo analizan datos históricos de precios, sino que también incorporan una amplia variedad de variables, incluyendo datos económicos, información de transacciones y otros indicadores relevantes (Zuckerman, 2019).

El éxito de Jim Simons y Renaissance Technologies ha tenido un impacto significativo en la industria financiera, inspirando a otros gestores de fondos y traders a adoptar enfoques similares basados en datos y algoritmos.

2. Estrategia de inversión

2.1 Análisis *Top-Down*

El análisis top-down es un enfoque integral utilizado en el diseño de estrategias de inversión que considera todos los aspectos macroeconómicos, sectoriales y específicos de las empresas que pueden influir en la rentabilidad de una inversión. Este enfoque comienza con la evaluación de las condiciones macroeconómicas generales, como el crecimiento del PIB, las tasas de interés, el desempleo y la inflación, para luego identificar los sectores mejor posicionados y, finalmente, seleccionar las empresas más prometedoras dentro de esos sectores. Este método asegura una evaluación exhaustiva y sistemática, minimizando la arbitrariedad en la toma de decisiones de inversión (CFA Level III, Vol. 1-6, 2024; Fabozzi, Focardi y Kolm, 2006). Al aplicar este enfoque para la predicción de recesiones en los Estados Unidos, se puede obtener una visión más completa y precisa de los factores que podrían anticipar una recesión, permitiendo a los inversores y responsables de políticas económicas tomar decisiones informadas y oportunas.

2.2 Análisis Macroeconómico

El análisis macroeconómico se centra en el estudio de variables y tendencias económicas agregadas, tales como el producto interno bruto (PIB), la inflación, el desempleo, las tasas de interés y las políticas fiscales y monetarias. Estas variables son indicadores clave de la salud económica de una nación y pueden influir significativamente en el desempeño de los mercados de renta variable (CFA Level I, Vol. I, 2024).

El análisis macroeconómico desempeña un papel crucial para la formulación de estrategias de inversión en renta variable. En el contexto actual de incertidumbre económica global, es fundamental que los inversores comprendan y anticipen los cambios en el panorama macroeconómico.

El panorama económico de Estados Unidos tiene una influencia significativa en el rendimiento de las economías mundiales. Como la mayor economía del mundo, Estados Unidos establece tendencias globales que afectan a otros países a través del comercio, la inversión y la política monetaria. Los cambios en los tipos de interés de la Reserva Federal tienen repercusiones globales, afectando los flujos de capital y los tipos de cambio en todo el mundo. Además, las políticas fiscales y económicas adoptadas por el gobierno estadounidense, como estímulos fiscales o regulaciones comerciales, pueden influir en la estabilidad y el crecimiento económico global (Obstfeld y Rogoff, 2009).

2.2.1 Ciclos económicos

Los ciclos económicos son fluctuaciones recurrentes en la actividad económica que impactan de manera significativa a diversos sectores de la economía. Estas fluctuaciones comprenden períodos alternantes de expansión y contracción en la producción, el empleo, las ventas y otros indicadores económicos fundamentales (NBER, 2024). Según el CFA Institute, los ciclos económicos son una característica inherente de las economías de mercado, aunque la magnitud y la duración de estos ciclos pueden variar considerablemente.

En términos generales, los ciclos económicos se subdividen en dos fases principales: expansión y recesión. La fase de expansión se caracteriza por un crecimiento sostenido en la actividad económica, lo que se traduce en un aumento en la producción, el empleo, las ventas y los ingresos. Durante esta fase, la confianza empresarial y del consumidor tienden a elevarse, estimulando la inversión y el consumo. Por el contrario, la fase de recesión se define por una disminución en la actividad económica, acompañada de una caída en la producción, el empleo y las ventas. Esta fase suele estar marcada por una reducción en la demanda agregada, la inversión y la confianza económica (CFA Level I, Vol. I, 2024).

El Comité del Ciclo Económico del NBER (National Bureau of Economic Research) es responsable de mantener una cronología de los ciclos económicos en Estados Unidos, identificando de manera retrospectiva las fechas de picos y valles que definen las recesiones y expansiones experimentadas por la economía estadounidense. La definición de recesión del NBER enfatiza una disminución significativa de la actividad económica que se extiende por toda la economía y dura más de unos pocos meses. Para determinar estas fechas, el comité utiliza varias medidas de actividad económica, incluyendo el ingreso personal real menos transferencias y el empleo no agrícola, entre otras (NBER, 2024).




Figura 6: Evolución del ciclo económico de Estados Unidos desde 1948. NBER. 2024

2.2.2 Política monetaria de la FED

La política monetaria en Estados Unidos juega un papel crucial en la gestión de los ciclos económicos, influenciando directamente la estabilidad económica y financiera del país. La política monetaria, implementada por la Reserva Federal (FED), busca controlar la oferta de dinero y los tipos de interés para alcanzar el mandato dual, que tiene como objetivo el pleno empleo y la estabilidad de precios mediante una tasa de inflación de en torno al 2% (Federal Reserve, 2012).

El concepto de pleno empleo se refiere a la situación en la cual todas las personas que están dispuestas y son capaces de trabajar pueden encontrar empleo. No significa una tasa de desempleo del 0%, ya que siempre habrá un nivel de desempleo friccional y estructural. En términos prácticos, el pleno empleo se asocia con la tasa de desempleo natural, que en Estados Unidos se estima generalmente entre el 4% y el 5% (Blanchard y Johnson, 2013).

El pleno empleo es una prioridad para la economía de los Estados Unidos debido a la alta dependencia del Producto Interno Bruto (PIB) en el sector privado. El sector privado representa aproximadamente el 68% de la economía estadounidense, constituyendo la mayor parte del PIB y del empleo total del país, lo que explica el motivo de la existencia del mandato dual por la dependencia de la economía estadounidense en el consumo privado (CEIC Data, 2024).




Figure 7. Evolución del porcentaje del PIB de Estados Unidos representado por el sector privado. CEIC DATA. 2024

El mandato dual de la Reserva Federal fue formalmente adoptado el 27 de octubre de 1978 con la promulgación de la Ley de Pleno Empleo y Producción Balanceada, también conocida como la Ley Humphrey-Hawkins. Esta legislación estableció explícitamente que la política monetaria de la Fed debía dirigirse hacia el logro de dos objetivos principales: la estabilidad de precios y el

pleno empleo. La adopción del mandato dual fue impulsada por la necesidad de abordar simultáneamente el alto desempleo y la alta inflación que afectaban a la economía estadounidense en la década de 1970 (Steelman, 1978). Antes de esta modificación, la política monetaria de la Reserva Federal estaba más enfocada en la estabilidad de precios y la moderación de los ciclos económicos sin una obligación explícita de promover el pleno empleo, tal como fue establecido originalmente por la Ley de la Reserva Federal de 1913. El cambio reflejó un compromiso más amplio del gobierno para equilibrar estos dos objetivos a veces conflictivos, reconociendo que la estabilidad económica y el crecimiento sostenido requieren una atención equilibrada tanto a la inflación como al desempleo (Heztel, 2008).

Las políticas de la Reserva Federal se dividen en dos categorías: endurecimiento (*tightening*) y relajación (*easing*) de la política monetaria. El endurecimiento de la política monetaria ocurre cuando la Fed aumenta los tipos de interés para frenar el crecimiento económico y controlar la inflación. Esta estrategia reduce la oferta de dinero en la economía, encareciendo el crédito y disminuyendo el consumo y la inversión (Bernanke y Blinder, 1992). Por el contrario, la relajación de la política monetaria implica la reducción de los tipos de interés para estimular el crecimiento económico. Al abaratar el crédito, se incentivan el consumo y la inversión, aumentando la demanda agregada y apoyando el empleo (Taylor, 1993).

Consecuencias de un endurecimiento de la política monetaria

La relación entre las políticas monetarias y las recesiones es compleja y significativa. El endurecimiento excesivo de la política monetaria puede llevar a una recesión al restringir demasiado el acceso al crédito, lo que reduce la inversión y el consumo. Estudios muestran que históricamente varios ciclos de endurecimiento de la FED han sido seguidos por periodos de recesión, como ocurrió en las recesiones de 1980-1982 y la crisis financiera de 2007-2009 (Romer y Romer, 2004; Reinhart y Rogoff, 2009). Por otro lado, una política de relajación prolongada puede generar burbujas de activos y excesos de deuda, que eventualmente conducen a recesiones cuando las burbujas estallan y las deudas se vuelven insostenibles, como se observó en la crisis de las hipotecas *subprime* (Gorton y Metrick, 2012).

El endurecimiento de la política monetaria tiene importantes consecuencias sociales, ya que puede exacerbar las desigualdades económicas y afectar negativamente a los sectores más vulnerables. A medida que las tasas de interés aumentan, el coste de los préstamos se incrementa, dificultando el acceso a bienes esenciales como viviendas y educación para las familias de ingresos bajos y medios. Además, la contracción económica resultante puede llevar

a un aumento del desempleo, lo que incrementa la inseguridad económica y la pobreza. Los periodos de recesión desencadenados por estas políticas son por lo tanto considerados como peligrosos por la Fed debido al aumento de los suicidios, ya que las crisis económicas y el desempleo están correlacionados con un mayor impacto emocional y psicológico en los individuos (Stuckler, et. al, 2009).

La figura 8 analiza el efecto que ha tenido desde el año 1950 el endurecimiento de la política monetaria en la generación de recesiones. Al analizar la figura, se puede determinar que existe una correlación significativa entre los periodos de endurecimiento de la política monetaria y las épocas de recesión. Desde el año 1954, todas las recesiones que han tenido lugar en Estados Unidos, a excepción de la causada por la pandemia de COVID-19, han sido precedidas por un endurecimiento de la política monetaria mediante subidas de los tipos de interés. Por lo tanto, es esencial analizar la política monetaria para anticipar periodos de recesión y así protegerse ante caídas de mercado asociadas a este hecho.

Todas las épocas de recesión en Estados Unidos han venido acompañadas de una caída en la renta variable, mostrada a través del índice S&P 500. Existe un nexo causal entre el endurecimiento de la política monetaria y las recesiones. Por lo tanto, se puede inferir que la Reserva Federal es responsable de todas las recesiones generadas desde 1954, a excepción de la del Covid. Además de producir una caída en la renta variable, este endurecimiento también supone un drama para la sociedad, ya que provoca una destrucción de empleo, dando lugar a periodos considerados por la propia Reserva Federal como peligrosos.




Figura 8. Impacto del endurecimiento de la política monetaria en la generación de recesiones en Estados Unidos. Bloomberg. 2024

2.3 Predicción de Recesiones en Estados Unidos

Una de las aplicaciones más relevantes del análisis macroeconómico en el ámbito de la inversión en renta variable es la predicción de recesiones económicas. Las recesiones, caracterizadas por una contracción del PIB durante al menos dos trimestres consecutivos, suelen tener un impacto negativo en los mercados bursátiles. Como se aprecia en la figura 7, los periodos de recesión están asociados con una caída significativa en la renta variable. Desde 1954, en todas las recesiones producidas, el índice de referencia de Estados Unidos, el S&P 500, ha experimentado caídas pronunciadas como respuesta a estas condiciones económicas adversas. Este patrón subraya la importancia de un análisis riguroso de los indicadores económicos y de la política monetaria para anticipar recesiones y proteger las inversiones en renta variable. La relación entre el endurecimiento de la política monetaria y las recesiones, claramente ilustrada por las subidas de los tipos de interés que preceden a estos periodos, destaca la necesidad de una vigilancia constante de las decisiones de la Reserva Federal y su impacto en el mercado financiero (Bernanke y Blinder, 1992; Mankiw, 2019).

Por lo tanto, el uso de criterios fiables para anticipar recesiones es una herramienta necesaria para la gestión del riesgo y la optimización del rendimiento de las carteras de inversión.

Existen varios indicadores que se utilizan como herramienta predictora de recesiones en Estados Unidos. Algunos de los más relevantes son el nivel de desempleo, la curva invertida de tipos de interés, el mercado inmobiliario, el índice de indicadores líderes (LEI) y el índice del consumidor.

Un complemento eficaz a estos indicadores es la regla de Sahm. Esta regla se activa cuando la tasa de desempleo promedio de los últimos tres meses aumenta 0.5 puntos porcentuales o más por encima de su mínimo de los 12 meses anteriores. Este aumento en el desempleo ha demostrado ser un indicador temprano de recesiones (Sahm, 2019).

2.3.1 Mercado Laboral

El mercado laboral es una herramienta esencial para predecir recesiones en Estados Unidos ya que refleja de manera directa la salud económica del país. Varios indicadores del mercado laboral, como la tasa de desempleo, las nóminas no agrícolas, la tasa de participación laboral y las solicitudes de beneficios por desempleo, proporcionan información valiosa sobre la dirección futura de la economía (Blanchard y Johnson, 2013).

Los datos de desempleo obtenidos del reporte mensual de empleo de Estados Unidos, conocido como el *Employment Situation Report*, publicado por el Bureau of Labor Statistics (BLS) proporcionan datos detallados sobre el mercado laboral del país. Este informe incluye datos

sobre la tasa de desempleo, el empleo no agrícola, las horas trabajadas y los ingresos medios por hora. Se publica el primer viernes de cada mes y se basa en dos encuestas principales: la *Household Survey* y la *Establishment Survey* (BLS, 2023).

La implementación de este reporte se remonta a la Ley de Estadísticas de Empleo de 1946 (*Employment Act of 1946*), que subrayó la importancia de recopilar y analizar datos económicos para apoyar las políticas públicas y fomentar el pleno empleo y la producción. Esta ley estableció la responsabilidad del gobierno federal de promover el bienestar económico del país, y el reporte mensual de empleo se convirtió en una herramienta clave para monitorear el progreso hacia esos objetivos (U.S. Government Publishing Office, 1946).

Nóminas no agrícolas

Las nóminas no agrícolas son el principal indicador para prever recesiones. Este dato, que mide el número de empleos creados o destruidos en la economía excluyendo el sector agrícola, proporciona una visión clara de la tendencia del empleo en sectores clave como manufactura, construcción y servicios. Una caída en las nóminas no agrícolas indica una disminución en la contratación y, por ende, una posible desaceleración económica. Durante la crisis financiera de 2008, por ejemplo, las nóminas no agrícolas mostraron caídas sustanciales antes de que la recesión fuera oficialmente reconocida, subrayando su valor predictivo (Elsby, et. al, 2010).

Estudios han demostrado que existe una fuerte correlación entre el aumento del desempleo y las recesiones económicas. Por ejemplo, la investigación de Juhn, Murphy y Topel (2002) muestra que las recesiones en Estados Unidos están precedidas por aumentos en la tasa de desempleo.

Solicitudes de beneficios por desempleo

Otra herramienta que puede utilizarse son las solicitudes de beneficios por desempleo. Se trata de un indicador semanal que puede ofrecer señales tempranas de cambios en el mercado laboral. Un aumento en las solicitudes de beneficios por desempleo sugiere que más personas están perdiendo sus trabajos y recurriendo al apoyo del gobierno, lo cual es un signo negativo para la economía. Este indicador es particularmente útil porque se publica con mayor frecuencia que otros datos laborales, proporcionando información más inmediata sobre las tendencias del empleo (Owyang y Sekhposyan, 2012).

Análisis actual del nivel de empleo en Estados Unidos

La figura 9 relaciona los tipos de interés controlados por la Reserva Federal (Fed) con la creación neta de empleo no agrícola (*US Employees on Nonfarm Payrolls change in Private Companies*),

medida por la publicación del Informe Mensual de Empleo (*Monthly Employment Report*) el primer viernes de cada mes. En este gráfico se puede observar que existe una correlación significativa entre los periodos de destrucción de empleo y las recesiones que han tenido lugar en Estados Unidos en las últimas décadas. Este fenómeno es evidente en la crisis de las puntocom del año 2000, la crisis financiera del 2008 y la crisis del Covid-19 en 2020. Además, estas caídas en la creación neta de empleo no agrícola están ligadas a situaciones de endurecimiento de la política monetaria, como también se aprecia en la figura.

En la actualidad, se ha producido un fuerte endurecimiento de la política monetaria en Estados Unidos para combatir la inflación generada por la crisis energética y la guerra en Ucrania (Federal Reserve, 2023). Este endurecimiento podría desencadenar nuevamente una creación neta de empleo negativa, aumentando el riesgo de entrar en un periodo de recesión, según lo observado en eventos pasados donde la destrucción de empleo precedió recesiones. El endurecimiento de la política monetaria provoca que las empresas reduzcan su inversión en capital (*CapEx*), ya que los altos tipos de interés crean condiciones restrictivas de financiación. Esto, a su vez, lleva a una disminución en la capacidad productiva y una menor contratación de trabajadores, impactando negativamente en la creación neta de empleo (Bernanke & Blinder, 1992).

Este endurecimiento de la política monetaria se ha producido en un momento de inestabilidad política en Estados Unidos. Los futuros reportes de empleo mensual, si muestran una tendencia de destrucción de empleo, podrían condicionar significativamente el resultado de las elecciones estadounidenses de finales de año, impactando de manera considerable en el futuro económico y social tanto de Estados Unidos como de Europa.




Figure 9. Evolución de la contratación neta mensual del sector privado en Estados Unidos. Bloomberg, 2024

Regla de Sahm

La regla de Sahm, desarrollada por la economista Claudia Sahm, es una herramienta utilizada para señalar el inicio de una recesión económica en los Estados Unidos basándose en cambios en la tasa de desempleo. Esta regla heurística se activa cuando la media móvil simple de las últimas tres observaciones de la tasa de desempleo mensual supere un 0,5% el mínimo de los 12 meses anteriores alcanzado por esa tasa de desempleo (Sahm, 2019).

La motivación principal detrás de la creación de la regla de Sahm radica en la necesidad de contar con un indicador que permita a los responsables de la política económica tomar medidas oportunas para mitigar los efectos negativos de las recesiones en la economía y en el bienestar de la población. La regla de Sahm es un indicador en tiempo real, cuyo objetivo en el momento de su creación por su autora, Claudia Sahm, no era aplicarlo directamente a la renta variable, sino servir como un estabilizador automático para proporcionar subsidios de desempleo a los ciudadanos de Estados Unidos. Este mecanismo se activa tan pronto como se detectan síntomas e indicios suficientemente racionales de recesión, permitiendo una respuesta rápida y efectiva para apoyar a los trabajadores desempleados y estabilizar la economía (Sahm, 2019).

2.3.2 Curva invertida de tipos

La curva invertida de tipos de interés es uno de los indicadores más utilizados para predecir recesiones en Estados Unidos. Esta curva se forma cuando los tipos de los bonos a corto plazo superan los tipos de los bonos a largo plazo, una situación que contrasta con la estructura de típica de la curva, donde los bonos a largo plazo ofrecen rendimientos más altos debido al mayor riesgo asociado con el tiempo. La inversión de la curva de tipos ha precedido a muchas recesiones estadounidenses en el último siglo, convirtiéndose en una herramienta esencial para predecir recesiones (Estrella y Mishkin, 1996).

La teoría detrás de la curva invertida de tipos sugiere que los inversores anticipan una desaceleración económica futura. Cuando la curva se invierte, los inversores están dispuestos a aceptar rendimientos más bajos en bonos a largo plazo debido a la expectativa de que los tipos de interés disminuirán en el futuro. Esto refleja una falta de confianza en el crecimiento económico futuro y una preferencia por la seguridad de los bonos a largo plazo (Estrella y Hardouvelis, 1991).

Históricamente, una curva de tipos invertida ha sido un predictor preciso de recesiones en Estados Unidos. Por ejemplo, antes de la recesión de 2008, la curva de tipos se invirtió en 2006, señalando una desaceleración económica que eventualmente llevó a la crisis financiera global (Rudebusch y Williams, 2009).

2.3.3 Mercado Inmobiliario

El mercado inmobiliario es un componente vital de la economía estadounidense y sus indicadores pueden ser herramientas valiosas para predecir recesiones. Entre estos indicadores, el Housing Market Index (HMI) y los permisos de construcción son especialmente útiles para anticipar cambios en la actividad económica.

Housing Market Index (HMI)

El Housing Market Index (HMI) es un indicador elaborado por la Asociación Nacional de Constructores de Viviendas (NAHB) y Wells Fargo. Este índice mide la confianza de los constructores de viviendas unifamiliares en el mercado de viviendas nuevas. El HMI se basa en una encuesta mensual que pregunta a los constructores sobre sus percepciones de las condiciones actuales de ventas de viviendas unifamiliares, sus expectativas de ventas para los próximos seis meses y el tráfico de posibles compradores. Un HMI superior a 50 indica que más constructores ven las condiciones como buenas que como pobres, mientras que un HMI inferior a 50 sugiere lo contrario (NAHB, 2023).

Un HMI decreciente puede señalar una disminución en la confianza de los constructores, lo que a menudo precede a una desaceleración en la actividad de construcción y, en última instancia, a una recesión económica.

Permisos de Construcción

Los permisos de construcción son otro indicador del mercado inmobiliario que puede proporcionar señales tempranas de recesión. Este indicador mide el número de autorizaciones emitidas para la construcción de nuevas viviendas. Los permisos de construcción son un reflejo de las expectativas de los constructores sobre la demanda futura de viviendas y la salud general del mercado inmobiliario. Un aumento en los permisos de construcción sugiere una perspectiva positiva y un crecimiento económico, mientras que una disminución puede indicar una próxima desaceleración (Glaeser y Gyourko, 2005).

La importancia de los permisos de construcción como predictor de recesiones radica en su relación directa con la actividad económica. La construcción de viviendas no solo afecta a la industria de la construcción, sino que también tiene un impacto en otros sectores económicos, como el financiero, el de materiales de construcción y el de bienes de consumo duradero. Una disminución en los permisos de construcción puede llevar a una menor actividad económica en estos sectores, contribuyendo a una recesión. (Leamer, 2007).

2.3.4 *Leading Economic Index (LEI)*

El *Leading Economic Index (LEI)* es un indicador compuesto desarrollado por *The Conference Board* que mide la actividad económica futura en los Estados Unidos. Este índice agrega diez componentes económicos que tienden a cambiar antes de que la economía en su conjunto se mueva en una nueva dirección, lo que permite anticipar los cambios en la actividad económica. Al combinar estos indicadores, el LEI proporciona una medida robusta y anticipada de la dirección futura de la economía (The Conference Board, 2021).

La correlación entre el LEI y las recesiones ha sido documentada en numerosos estudios, lo que lo convierte en una herramienta valiosa para anticipar recesiones (Stock y Watson, 1989; Zarnowitz y Moore, 1983). Históricamente, una caída significativa en el LEI ha precedido a recesiones económicas. Los inversores pueden utilizar cambios en el LEI para ajustar sus carteras, reduciendo la exposición a activos de alto riesgo y aumentando la asignación a inversiones más seguras.

2.3.5 Índice de confianza del consumidor

El Índice de Confianza del Consumidor es un criterio fundamental para medir y predecir recesiones debido a su capacidad para reflejar las expectativas y el comportamiento futuro de los consumidores. Publicado por *The Conference Board*, este índice mide el grado de optimismo que los consumidores sienten respecto a la situación económica actual y futura. Las expectativas de los consumidores sobre su situación financiera personal, el entorno económico y el empleo influyen directamente en sus decisiones de gasto y ahorro, que a su vez afectan la demanda agregada y el crecimiento económico (Ludvigson, 2004).

La relevancia del Índice de Confianza del Consumidor como predictor de recesiones se basa en la teoría económica keynesiana, que enfatiza el papel del gasto del consumidor en la determinación del producto interior bruto (PIB). El gasto de los consumidores representa aproximadamente el 70% del PIB de Estados Unidos, lo que significa que cualquier cambio significativo en la confianza del consumidor puede tener un impacto directo y sustancial en la economía (CEIC Data, 2024). Cuando los consumidores se sienten confiados, tienden a gastar más en bienes y servicios, impulsando la producción, el empleo y el crecimiento económico. Por el contrario, una disminución en la confianza del consumidor puede llevar a una reducción en el gasto, provocando una contracción económica (Carroll, Fuhrer, y Wilcox, 1994).

Ludvigson (2004) encontró que los cambios en la confianza del consumidor preceden a las variaciones en el gasto de los hogares y la actividad económica general. Un descenso en la

confianza del consumidor suele anticipar una disminución en el consumo y la inversión de los hogares, lo que puede desencadenar una recesión. Además, la investigación de Matsusaka y Sbordone (1995) sugiere que las expectativas de los consumidores sobre el futuro económico pueden ser un predictor más fuerte de recesiones que los indicadores económicos actuales.

3. Proceso de definición de la estrategia de inversión

3.1 Objetivo y proceso de definición de la estrategia

El objetivo de esta estrategia es a partir de un universo ingente de empresas y mediante la aplicación de un método de *screening* (filtrado), convertir ese universo en una cartera perfectamente diversificada y capaz de batir al índice de referencia. La estrategia se diseñará siguiendo una metodología robusta, sin dejar ningún elemento arbitrario. Se utilizarán criterios de screening que han demostrado ser efectivos en el pasado, con la expectativa de que continúen siendo eficaces en el futuro.

El proceso de definición de esta estrategia se ha llevado a cabo en base a una exhaustiva revisión de la literatura académica en el campo de la inversión y la gestión de carteras. Esta revisión ha incluido estudios sobre diversos métodos de screening, técnicas de diversificación, y análisis de rendimiento de diferentes estrategias de inversión. A partir de esta base teórica, se van a seleccionar aquellos criterios de screening que presentan una mayor solidez y consistencia en diferentes contextos de mercado y se optimizarán para maximizar la rentabilidad ponderada por riesgo.

3.2 Selección y extracción de los datos

Para asegurar que la estrategia de inversión sea sólida y aplicable a diferentes condiciones de mercado, se han seleccionado datos que abarcan todos los regímenes de mercado, incluyendo tendencias alcistas, bajistas, laterales, así como periodos de alta y baja volatilidad. Además, se ha considerado que la ventana temporal incluya periodos de endurecimiento y relajación de la política monetaria implementados por la Reserva Federal (NBER), así como las medidas ordinarias y extraordinarias adoptadas durante el periodo de análisis.

La estrategia debe funcionar de manera correcta en todas las diferentes condiciones de mercado. Para ello, es imprescindible que el *backtest* realizado demuestre su efectividad en diversos regímenes de mercado. Además, debe ser capaz de adaptarse a las variaciones en la volatilidad y el volumen del mercado, ciclos económicos, cambios en la política monetaria y medidas extraordinarias.

La ventana temporal seleccionada para la estrategia que cumple con todos estos requisitos es del año 2007 al año 2024. Este período es suficientemente amplio para abarcar diferentes regímenes de mercado, ciclos económicos y medidas implantadas por la Fed. Al incluir todos estos factores en el *backtesting*, se asegura una evaluación más completa y robusta de la

estrategia de inversión, permitiendo predecir mejor su comportamiento futuro y mejorar su capacidad para superar al índice de referencia.

3.2.1 Regímenes de Mercado

Los regímenes de mercado se refieren a diferentes estados o fases del mercado financiero, caracterizados por comportamientos y dinámicas distintas. Comprender estos regímenes es fundamental para el desarrollo y prueba de estrategias de inversión, ya que cada régimen puede afectar de manera diferente el rendimiento y el riesgo de las inversiones. Los cuatro regímenes de mercado más comunes son: mercado alcista, mercado bajista, mercado lateral y mercado de alta volatilidad.

Mercado Alcista (*Bull Market*): un mercado alcista se caracteriza por un aumento sostenido en los precios de los activos. Este régimen se asocia con un alto nivel de confianza del inversor, crecimiento económico y expectativas positivas sobre el futuro. Los mercados alcistas pueden durar varios años y suelen ser impulsados por factores como bajos tipos de interés, políticas fiscales expansivas y mejoras en las ganancias corporativas (Blanchard, 2011).

Mercado Bajista (*Bear Market*): un mercado bajista se define por una caída prolongada en los precios de los activos. Este régimen suele estar asociado con la recesión económica, alta inflación o crisis financieras. La confianza del inversor disminuye y la aversión al riesgo aumenta, lo que puede llevar a ventas masivas de activos y precios en declive. Durante un mercado bajista, las estrategias de inversión se centran en la preservación del capital, y los inversores pueden buscar refugio en activos seguros o utilizar estrategias de cobertura como ponerse en corto (Bodie, Kane, y Marcus, 2014).

Mercado Lateral (*Sideways Market*): un mercado lateral se caracteriza por una falta de tendencia clara en los precios de los activos, que se mueven dentro de un rango estrecho durante un periodo prolongado. Los mercados laterales pueden ser desafiantes para los inversores, ya que las oportunidades de ganancia son limitadas. (Murphy, 1999).

Mercado de Alta Volatilidad: un mercado de alta volatilidad se caracteriza por fluctuaciones significativas en los precios de los activos en cortos periodos de tiempo. La alta volatilidad incrementa el riesgo de inversión, pero también puede ofrecer oportunidades para obtener beneficios significativos a través de estrategias de gestión activa y una correcta diversificación (Engle, 1982).

Mercado de Baja Volatilidad: un mercado de baja volatilidad se caracteriza por movimientos de precios más estables y predecibles. Estos períodos suelen estar asociados con un entorno

económico estable, sin eventos externos significativos que alteren las expectativas del mercado.

3.2.2 Ciclo económico

El análisis debe incluir períodos en los que la Reserva Federal ha endurecido o relajado la política monetaria. Estos cambios en la política monetaria tienen un impacto significativo en los mercados financieros y la economía en general, afectando las tasas de interés, la disponibilidad de crédito y la confianza de los inversores.

Como se puede observar en la figura 1, que muestra el ciclo económico de Estados Unidos, el en rango temporal seleccionado para la estrategia iniciado en el 2007, se han detectado periodos de expansión económica y dos periodos de recesión, la crisis financiera del 2008 y la crisis del Covid en 2020. Por lo tanto, desde el punto de vista de los ciclos económicos, se puede garantizar que la ventana temporal de datos seleccionada recoge los ciclos de expansión y recesión de acuerdo con la NBER, encargada de determinar los ciclos económicos en Estados Unidos

3.2.3 Medidas extraordinarias de política monetaria

Un aspecto crucial en la selección de la ventana temporal es incluir un período en el que se hayan implementado tanto medidas de política monetaria convencional como no convencional por parte de la Reserva Federal (Fed).

Las medidas convencionales de política monetaria son las herramientas tradicionales que los bancos centrales utilizan para controlar la economía. Estas incluyen principalmente la manipulación de la tasa de interés de referencia y las operaciones de mercado abierto.

Las medidas convencionales de política monetaria afectan el balance de los bancos centrales a través de operaciones de mercado abierto y ajustes en la tasa de interés de referencia. Estas medidas pretenden incentivar el consumo y la inversión al reducir el costo del crédito, además de combatir la inflación al ajustar la oferta monetaria.

Por otro lado, las medidas no convencionales se implementan cuando las herramientas tradicionales no son suficientes, especialmente en tiempos de crisis. Estas incluyen Quantitative Easing (QE), donde la Fed realiza compras masivas de activos financieros para aumentar la liquidez en el mercado; Forward Guidance, que consiste en la comunicación sobre futuras políticas monetarias para influir en las expectativas del mercado; tasas de interés negativas, que

desincentivan el ahorro para fomentar el gasto y la inversión; y Credit Easing, que mejora las condiciones de crédito mediante la compra de activos más arriesgados.

Por ejemplo, durante la crisis financiera de 2008 y la crisis del coronavirus en 2020, la Fed redujo las tasas de interés y empleó medidas no convencionales como el Quantitative Easing, comprando bonos en el mercado secundario para aumentar la liquidez y reducir las tasas de interés a largo plazo (CFA Institute, 2024).

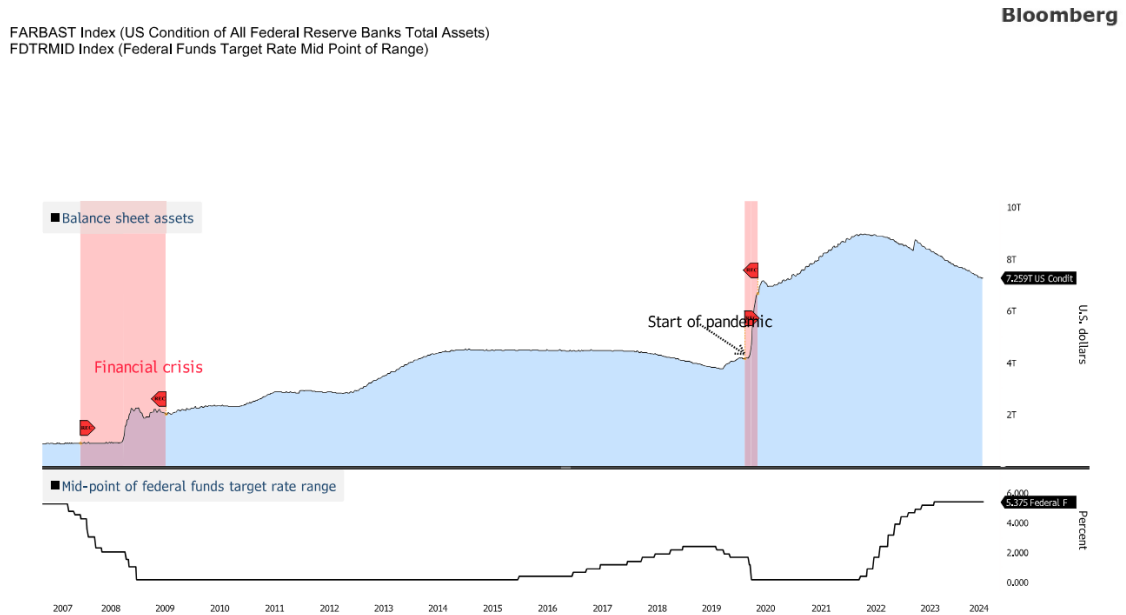


Figure 10. Relación entre el balance de la Fed y los tipos de interés. Bloomberg. 2024

3.3 Selección del índice de referencia

El índice seleccionado como referencia para la estrategia de inversión es el S&P 500 debido a que el universo de inversión está localizado en Estados Unidos y este índice representa una de las principales referencias del mercado estadounidense. El S&P 500 incluye 500 de las empresas más grandes por capitalización bursátil que cotizan en las bolsas de valores de Estados Unidos, ofreciendo una amplia visión de la economía del país (S&P Global, 2024). Además, debido a que se ha realizado un análisis Top-Down en el que se ha considerado la situación macroeconómica de Estados Unidos, el S&P 500 es el índice adecuado para medir el funcionamiento de herramientas predictoras de recesión como la regla de Sahm.

El S&P 500 fue introducido por primera vez en 1957 por Standard & Poor's y desde entonces ha sido una referencia fundamental para los inversores institucionales y minoristas. El índice abarca una amplia gama de sectores económicos, proporcionando una representación diversificada del

mercado estadounidense. Cada una de las 500 empresas incluidas en el índice debe cumplir con ciertos criterios de elegibilidad, incluyendo la capitalización de mercado, la liquidez y la representatividad sectorial (S&P Global, 2024).

Un aspecto clave a considerar al diseñar una estrategia de inversión es evaluar en cada momento del tiempo las empresas que formaban parte del índice. Para este análisis, se ha procedido a descargar a través de Bloomberg los datos mensuales de las empresas que incluidas en el índice S&P 500 al final de cada mes de la ventana temporal seleccionada (Bloomberg Terminal, 2023). Durante el periodo de inversión ha habido un total de 864 empresas que han formado parte del índice S&P 500. Esta metodología evita el sesgo de supervivencia, el cual ocurre cuando el análisis se realiza únicamente sobre las empresas que están actualmente en el índice, ignorando aquellas que han dejado de formar parte del mismo.

El sesgo de supervivencia puede llevar a conclusiones erróneas, ya que típicamente omite las empresas que han tenido un desempeño inferior y han sido eliminadas del índice, dando una visión sesgada y optimista del rendimiento histórico del índice. Por ejemplo, Brown, Goetzmann y Ibbotson (1992) señalaron que el sesgo de supervivencia puede causar una sobreestimación del rendimiento promedio de los fondos mutuos debido a la exclusión de aquellos que fracasan. Al incluir todas las empresas que han formado parte del S&P 500 en el período analizado, se obtiene una visión más precisa y representativa de las dinámicas del mercado y la efectividad de las estrategias de inversión a lo largo del tiempo

Esta metodología asegura que se considera el rendimiento completo del índice, incluyendo tanto los éxitos como los fracasos empresariales, proporcionando una base más sólida para evaluar la viabilidad de las estrategias de inversión. Este enfoque es esencial para hacer un análisis adecuado y predecir, basándose en el comportamiento pasado, si una estrategia de inversión será capaz de superar el rendimiento del índice en el futuro.

Durante la ventana temporal analizada, el S&P 500 obtuvo un *total return* del 254%, un retorno anual del 7,7%, una volatilidad del 20% y una ratio de sharpe de 0,38. Estas variables financieras se utilizarán para medir el desempeño de las estrategias de inversión para determinar si la estrategia diseñada es capaz de batir al índice.

Date	Alliant Energy Corp	Allied Waste Industries Inc.	Allstate Corporation	Alltel Corp.	Alpha Natural Resources, Inc.	Alphabet Inc. Class A
31/01/2011	0	0	1	0	0	1
28/02/2011	0	0	1	0	0	1
31/03/2011	0	0	1	0	0	1
30/04/2011	0	0	1	0	0	1
31/05/2011	0	0	1	0	0	1
30/06/2011	0	0	1	0	1	1
31/07/2011	0	0	1	0	1	1
31/08/2011	0	0	1	0	1	1
30/09/2011	0	0	1	0	1	1

Figura 11. Listado de empresas incluidas en el S&P 500 por fecha. Bloomberg. Elaboración propia. 2024

3.4 Periodo de rebalanceo de la estrategia

El rebalanceo de una cartera de inversión es una práctica esencial que puede tener un impacto significativo en el retorno total de la inversión a lo largo del tiempo. Aunque se podría suponer que el rebalanceo frecuente facilita la obtención de mejores resultados de rentabilidad al adaptarse a las condiciones cambiantes del mercado, es crucial considerar el *trade-off* que se genera con los costes de transacción asociados a esta actividad (El Bernoussi y Rockinger, 2023).

Un rebalanceo frecuente permite una adaptación rápida a los cambios del mercado, capturando oportunidades de crecimiento y reduciendo el riesgo de desviaciones significativas. Sin embargo, este enfoque conlleva un incremento en las comisiones y mayores implicaciones fiscales. Por el contrario, un rebalanceo menos frecuente puede ser más eficiente desde el punto de vista fiscal y reducir los costes de comisiones, pero presenta el riesgo de sufrir desviaciones considerables en los retornos debido a *shocks* del mercado que no se ajustan en periodos largos de rebalanceo (Tokat y Wicas, 2007).

Una de las estrategias más comunes para determinar el momento óptimo de rebalanceo es el enfoque basado en intervalos de tiempo. Este método implica realizar el rebalanceo en intervalos regulares, como trimestral o anualmente. La ventaja de este enfoque radica en su simplicidad, ya que no depende de las condiciones del mercado (Daryanani, 2008).

Para optimizar tanto la estrategia base como la estrategia de *factor investment*, se adoptará un enfoque que optimizará la frecuencia de rebalanceo considerando mensual, trimestral, semestral y anual, con el fin de maximizar los retornos y la ratio de Sharpe. Esta es una ventaja de la que dispone el hacer el análisis de la estrategia de inversión con un algoritmo de Python frente a la herramienta EQS de Bloomberg, ya que no permite optimizar parámetros.

Los datos utilizados para este análisis provienen de informes reportados por las empresas constituyentes del S&P 500. En Estados Unidos, las empresas están obligadas por la Ley de Bolsa de Valores de 1934 a presentar informes trimestrales (Formulario 10-Q) y anuales (Formulario 10-K) ante la Comisión de Bolsa y Valores (Perossa, Waldman, Díaz Ubermán, 2015). Estas presentaciones incluyen información financiera detallada que es crucial para los inversores a la hora de tomar decisiones informadas. El Formulario 10-Q proporciona una visión trimestral de la situación financiera de la empresa, mientras que el Formulario 10-K ofrece un resumen anual más completo.

Es crucial considerar el momento en que se reportan estos datos financieros. El informe 10-K se presenta 40 días después de la fecha de referencia, y el informe 10-Q se entrega con 60 días de retraso (Perossa, Waldman, Díaz Ubermán, 2015). Por lo tanto, la estrategia de inversión debe tener en cuenta esta consideración para evitar el error de *forward-looking*, definido como el uso de información futura que no estaba disponible en el momento del *backtesting* (Di Persio, et. Al, 2021). Para mitigar este riesgo, se ha aplicado una corrección al código de Python que prolonga en dos meses los reportes financieros, asegurando que la estrategia de inversión considere solo los datos disponibles en la fecha del rebalanceo.

Una estrategia más sofisticada es el rebalanceo basado en umbrales, que se ejecuta cuando la asignación de activos se desvía más allá de ciertos límites predefinidos. Este método es más dinámico y responde mejor a las fluctuaciones del mercado. Según estudios, el rebalanceo basado en umbrales puede ofrecer una mejor relación riesgo-rentabilidad en comparación con el rebalanceo temporal (Tokat & Wicas, 2007). Por ello, la estrategia final basada en elementos de Market timing de la cartera llevará a cabo el rebalanceo en base a que se supere un umbral fijado por la estrategia. Esto es otra ventaja de Python con respecto a Bloomberg, ya que permite aplicar reglas heurísticas y de Market timing al modelo mediante códigos de *momentum* y predictores de recesiones para anticiparse a caídas del mercado.

Además, se aplicará un enfoque *short-long*, que permite no solo invertir en largo, sino también tomar posiciones en corto. Aunque algunos estudios sugieren que estas estrategias tienden a obtener peores resultados que las estrategias de invertir exclusivamente en largo una vez considerados los costes de transacción, la estrategia podrá considerar este modelo (Wang, Yan, y Zheng, L. 2024). . Esto dará la oportunidad de tomar tanto posiciones largas como cortas, según las oportunidades del mercado identificadas mediante la estrategia de market timing.

3.5 Diversificación del riesgo de la cartera

La diversificación es una estrategia esencial en la gestión de carteras de inversión que busca mitigar el riesgo al repartir las inversiones entre diferentes activos, sectores o mercados. La premisa es que al no concentrar el capital en un solo activo, se puede reducir el impacto negativo que una caída en el valor de ese activo podría tener en la cartera total (Ross, et. al, 2016).

Uno de los conceptos clave en la diversificación es el riesgo diversificable, también conocido como riesgo no sistemático. Este tipo de riesgo está asociado a factores específicos de una empresa o industria y puede ser mitigado mediante la diversificación. Al invertir en una variedad de activos que no están perfectamente correlacionados, los eventos negativos que afectan a un activo específico no tendrán un impacto proporcionalmente grande en el portafolio completo (Ross, et. al, 2016).

No existe un consenso absoluto sobre el número exacto de acciones necesario para alcanzar una diversificación adecuada. Sin embargo, investigaciones sugieren que tener entre 10 y 30 acciones puede ser suficiente para reducir significativamente el riesgo diversificable. Según el Ross et al., a partir de 10 acciones, la reducción del riesgo diversificable se vuelve menos pronunciada, sugiriendo que ya se ha logrado una diversificación efectiva.

Otros estudios clásicos como el de Elton y Gruber (1977) argumentaron que el número de acciones necesario para reducir significativamente el riesgo diversificable podría ser menor de lo que muchos inversores piensan. Según su análisis, un portafolio compuesto por alrededor de 10 a 20 acciones puede ofrecer una reducción considerable del riesgo diversificable, sugiriendo que más allá de este número, los beneficios adicionales en términos de reducción de riesgo son marginales. Por otro lado, Statman (1987) sostiene que un portafolio debe contener al menos 30 acciones para ser considerado adecuadamente diversificado.

A pesar de estas diferencias, ambos estudios coinciden en que existe un punto de rendimientos decrecientes en la diversificación. Es decir, a partir de un cierto número de acciones, los beneficios adicionales en términos de reducción del riesgo se vuelven cada vez menos significativos. Esto sugiere que, aunque no hay un consenso exacto, un rango entre 10 y 30 acciones es generalmente aceptado como adecuado para una diversificación efectiva, siendo 10 acciones un punto de partida razonable para reducir el riesgo diversificable considerablemente, y 30 acciones una meta para una diversificación más completa.

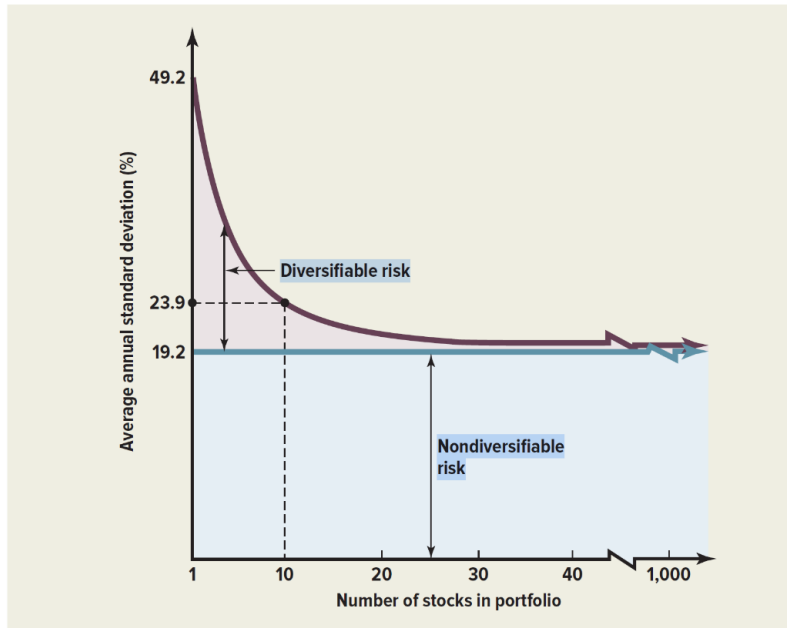


Figura 12. Riesgo diversificable y no diversificable en función del número de acciones en cartera. McGraw Hill. 2016

3.6 Análisis de ratios

Para comprobar la calidad de una estrategia de inversión, es fundamental realizar un análisis comparativo con el índice de referencia S&P 500, utilizando métricas financieras y ratios clave. Estas métricas permiten evaluar la rentabilidad y el riesgo de las estrategias de inversión. Para hacer el análisis y la optimización de los parámetros se van a utilizar las siguientes variables:

Retorno Total (Total Return): mide la ganancia o pérdida obtenida de una inversión durante un periodo específico, considerando tanto la apreciación del capital como los ingresos recibidos (dividendos, intereses, etc.). Un retorno total más alto es mejor, ya que indica que la inversión ha generado mayores ganancias durante el periodo de análisis (Bodie, Kane, y Marcus, 2014).

$$\text{Retorno Total} = (V_f - V_i + D) / V_i$$

Donde:

- V_f es el valor final de la inversión.
- V_i es el valor inicial de la inversión.
- D son los dividendos o ingresos recibidos durante el periodo.

Retorno Anual (Annual Return): es el retorno total promedio que una inversión genera en un año. Se utiliza para medir promedio de los retornos anuales obtenidos durante el periodo de análisis, permitiendo una comparación uniforme del rendimiento de diferentes inversiones. Un

retorno anual más alto es mejor, ya que indica que la inversión ha generado consistentemente altos rendimientos promedio cada año (Elton, et. al, 2014).

$$\text{Retorno Anual} = (Vf / Vi)^{(1/n)} - 1$$

Donde:

- *Vf es el valor final de la inversión.*
- *Vi es el valor inicial de la inversión.*
- *n es el número de años.*

Volatilidad (Volatility): mide la variabilidad o dispersión de los retornos de una inversión, indicando el riesgo inherente de la misma. Una volatilidad más baja es mejor, ya que indica que los retornos de la inversión son más estables y predecibles, sugiriendo menor riesgo (Brealey, Myers y Allen, 2017).

$$\text{Volatilidad } (\sigma) = \text{sqrt}[(1 / (n - 1)) * \Sigma(Ri - \bar{R})^2]$$

Donde:

- *σ es la volatilidad.*
- *n es el número de periodos.*
- *Ri es el retorno en el periodo i.*
- *\bar{R} es el retorno medio.*

Ratio de Sharpe (Sharpe Ratio): mide el rendimiento ajustado por riesgo, indicando cuánto exceso de retorno se obtiene por unidad de riesgo asumido. Se calcula como la diferencia entre el retorno de la inversión y la tasa libre de riesgo, dividido por la volatilidad. Un ratio de Sharpe más alto es mejor, ya que indica que la inversión está generando más retorno por unidad de riesgo asumido (Sharpe, 1966).

$$\text{Ratio de Sharpe} = (Rp - Rf) / \sigma p$$

Donde:

- *Rp es el retorno de la inversión.*
- *Rf es la tasa libre de riesgo.*
- *σp es la desviación estándar de los retornos de la inversión.*

Máxima Pérdida (Maximum Drawdown): mide la mayor caída desde un pico hasta un valle en el valor de una inversión durante un periodo determinado. Representa el peor escenario de pérdida que un inversor podría haber experimentado. Un máximo drawdown más bajo es

mejor, ya que indica que la inversión ha tenido menores pérdidas máximas, sugiriendo mayor estabilidad del portafolio (Maginn, Tuttle, McLeavey, y Pinto, 2007).

$$\text{Máxima Pérdida} = (\text{Valor Máximo} - \text{Valor Mínimo}) / \text{Valor Máximo}$$

Donde:

- *Valor Máximo es el valor pico de la inversión antes de la mayor caída.*
- *Valor Mínimo es el valor más bajo alcanzado durante la caída.*

Ratio de Calmar (*Calmar Ratio*): compara el retorno anualizado de una inversión con su máximo drawdown, evaluando la capacidad de una estrategia para generar retornos ajustados por el riesgo de grandes pérdidas. Una ratio de Calmar más alto es mejor, ya que indica que la inversión está generando buenos rendimientos en relación con el riesgo de grandes pérdidas (Young, 1991).

$$\text{Ratio de Calmar} = Ra / \text{Máxima Pérdida}$$

Donde:

- *Ra es el retorno anualizado.*
- *Máxima Pérdida es el mayor drawdown durante el periodo.*

El análisis de estas métricas permite una evaluación integral de la calidad de una estrategia de inversión en comparación con el índice de referencia S&P 500. Estas interpretaciones permiten comparar efectivamente la rentabilidad y el riesgo de las estrategias de inversión, facilitando la identificación de aquellas que ofrecen un mejor desempeño en relación con el índice de referencia.

4. Estrategia base

4.1 Variables de la estrategia

4.1.1 Piotroski F-Score

El Piotroski F-Score, desarrollada por Joseph Piotroski, es una herramienta para evaluar el valor de las empresas. Este score utiliza nueve criterios financieros basados en la rentabilidad, la eficiencia operativa y la liquidez para identificar empresas con sólidos fundamentales financieros.

La metodología del Piotroski F-Score se centra en asignar un valor de 1 si una empresa cumple con un criterio específico y 0 si no lo hace. La puntuación total es la suma de estos nueve criterios, con un rango de 0 a 9. Para cada uno de estos nueve requisitos, se asigna el valor 1 si cumple con el requisito y cero si no lo hace. El Piotroski F-Score será la suma de estas nueve métricas.

Variabes incluidas en el Piotroski F-Score:

1. Ingreso Neto Positivo
2. Flujo de Caja Operativo Positivo
3. Mejora en el Retorno sobre Activos (ROA) en comparación con el año anterior
4. Flujo de Caja de Operaciones Mayor que el Ingreso Neto
5. Disminución de la Deuda a Largo Plazo en Relación con los Activos en comparación con el año anterior
6. Aumento en el Ratio de Liquidez Corriente en comparación con el año anterior
7. No Emisión de Nuevas Acciones en el año
8. Mejora en el Margen Bruto en comparación con el año anterior
9. Aumento en el Ratio de Rotación de Activos en comparación con el año anterior

$$F\ Score = NI_{pos} + OCF_{pos} + \Delta ROA_{pos} + (OCF > NI) + \Delta DEBT_{neg} + \Delta CR_{pos} + NE_{neg} + \Delta GM_{pos} + \Delta ATO_{pos}$$

- ***NI_{pos}** es 1 si el Ingreso Neto es positivo, 0 en caso contrario.*
- ***OCF_{pos}** es 1 si el Flujo de Caja Operativo es positivo, 0 en caso contrario.*
- ***ΔROA_{pos}** es 1 si el ROA ha mejorado en comparación con el año anterior, 0 en caso contrario.*
- ***OCF > NI** es 1 si el Flujo de Caja Operativo excede el Ingreso Neto, 0 en caso contrario.*

- **$\Delta DEBT_{neg}$** es 1 si la Deuda a Largo Plazo en relación con los Activos ha disminuido en comparación con el año anterior, 0 en caso contrario.
- **ΔCR_{pos}** es 1 si el Ratio de Liquidez Corriente ha aumentado en comparación con el año anterior, 0 en caso contrario.
- **NE_{neg}** es 1 si no se han emitido nuevas acciones en el año, 0 en caso contrario.
- **ΔGM_{pos}** es 1 si el Margen Bruto ha mejorado en comparación con el año anterior, 0 en caso contrario.
- **$\Delta ATOP_{pos}$** es 1 si el Ratio de Rotación de Activos ha aumentado en comparación con el año anterior, 0 en caso contrario.

Numerosos estudios han analizado la efectividad del Piotroski F-Score en estrategias de inversión, demostrando su capacidad para superar al mercado de forma sostenida.

Fama y French (2008) encontraron que las estrategias basadas en el Piotroski F-Score son efectivas para identificar empresas infravaloradas con sólidos fundamentales financieros, proporcionando rendimientos ajustados por riesgo superiores a los de una estrategia pasiva de mercado.

Ammann, Oesch, y Schmid (2013) evaluaron las estrategias basadas en el Piotroski F-Score en mercados globales, encontrando que las empresas con altos F-Scores generaban rendimientos anuales significativamente mayores que aquellas con bajos F-Scores. El análisis mostró que la estrategia del Piotroski F-Score podía superar al mercado en diversas regiones y periodos, evidenciando su robustez y eficacia.

4.1.2 Altman Z Score

Para controlar el riesgo y la probabilidad de default de las empresas, se empleará el Altman Z-Score. Este modelo, desarrollado por Edward Altman, evalúa la solvencia financiera de las empresas utilizando cinco ratios financieras que miden la liquidez, la rentabilidad, el apalancamiento, la capitalización bursátil y la eficiencia operativa. El Z-Score es particularmente útil para predecir la probabilidad de quiebra, proporcionando una medida preventiva que ayuda a evitar inversiones en empresas con alto riesgo de insolvencia. (Altman, 1968).

El Altman Z-Score se utiliza para seleccionar empresas con bajo riesgo de insolvencia. Los gestores de fondos pueden integrar el Z-Score en sus modelos de selección de acciones para identificar empresas con sólidos fundamentos financieros, evitando aquellas con alto riesgo de quiebra. Esto no solo ayuda a mitigar el riesgo de la cartera, sino que también puede mejorar los rendimientos ajustados por riesgo al centrarse en empresas más estables.

El Z-Score se calcula mediante la combinación de variables del balance y la cuenta de pérdidas y ganancias de la empresa ponderadas por un peso:

$$Z - score = 1.2 \times A1 + 1.4 \times A2 + 3.3 \times A3 + 0.6 \times A4 + 1.0 \times A5$$

- A₁: Capital Circulante entre Activos Totales
- A₂: Beneficios no Distribuidos entre Activos Totales
- A₃: EBITDA entre Activos Totales
- A₄: Capitalización Bursátil entre Deuda Total
- A₅: Ventas Netas entre Activos Totales

4.1.3 Criterio de ESG

La sostenibilidad y las prácticas ESG son elementos esenciales del modelo. Se priorizarán empresas que mantengan altos estándares de sostenibilidad y prácticas de gobernanza, sociales y ambientales robustas (Friede, Busch, y Bassen, 2015). Esto no solo alinea el modelo con las demandas crecientes de los inversores por inversiones responsables, sino que también aprovecha la evidencia de que las empresas con fuertes prácticas ESG tienden a tener un mejor desempeño financiero y menores riesgos a largo plazo.

La selección de estas empresas se basará en índice Truvalue ESG > 0.5, garantizando una cartera ética y resiliente. El Truvalue ESG Insight Score es una herramienta esencial para la evaluación sostenible a largo plazo de una empresa mediante el análisis de sus prácticas ESG. Esta herramienta, que toma valores entre 0 y 100, utiliza un promedio ponderado exponencialmente de los datos recolectados, lo que proporciona una visión más estable y representativa del rendimiento ESG de una empresa a lo largo del tiempo. Este enfoque permite a los inversores identificar empresas que mantienen altos estándares ESG de manera consistente, mitigando el impacto de eventos transitorios y proporcionando una evaluación más equilibrada y justa.

4.2 Definición de la estrategia

Tras un análisis teórico exhaustivo de literatura, se ha decidido desarrollar una estrategia de *equity screening* en base a los criterios contables publicados por las empresas mediante el Formulario 10-Q, aprobado en el año 1934 (Perossa, Waldman, Díaz Ubermán, 2015). Estos datos han sido extraídos mediante una descarga masiva a través del terminal de FactSet.

El objetivo de la estrategia es la optimización del periodo de rebalanceo de la cartera de modo que se logre maximizar al *Sharpe Ratio* y el *total return*. El rebalanceo de la cartera puede producirse en cuatro frecuencias temporales: mensual, trimestral, semestral y anual.

Para este *screening* se han utilizado las variables de Piotroski F-Score, Altman Z-Score y el criterio de ESG. Se van a incluir en la cartera de la estrategia de inversión las empresas que cumplan con las siguientes condiciones para un cada horizonte temporal:

- **Piotroski F-Score ≥ 8 ,**
- **Altman Z-Score ≥ 1.8**
- **ESG > 50**

El resultado de la estrategia es una cartera completamente diversificada que supera al índice de referencia S&P 500.

4.3 Funcionamiento y resultados de la estrategia

La estrategia de inversión realiza un *backtest* comenzando en el año 2007. Para el análisis tan solo considera los reportes financieros de las empresas que formaban parte del índice S&P 500 en ese momento temporal para evitar el sesgo del superviviente. Además, también se evita el *forward-looking*, ajustando el código para que no se utilice información desconocida en el periodo de análisis.

Las empresas que cumplen con las condiciones de la estrategia en cada periodo reciben un valor de 1, conformando así un nuevo conjunto de datos que contiene las empresas incluidas en la cartera de la estrategia.

La Figura 13 ilustra el número de empresas en el portafolio para cada periodo. En este caso se trata de una cartera con rebalanceo mensual que sirve para ilustrar que se ha producido una diversificación óptima, manteniéndose siempre dentro del rango de 10 a 30 empresas, tal como se recomienda en la revisión literaria para eliminar el riesgo diversificable. El código impide tomar posición cuando el número de empresas que cumplen con los criterios es menor a 10. Esto hecho sucede entre los años 2008 a 2010, en el que hay menos de 10 empresas que cumplen con criterios de screening de la estrategia. Como consecuencia, el modelo no incluye ninguna empresa en la cartera durante estos años, ya que no alcanzaba el rango óptimo de diversificación necesario para eliminar el riesgo diversificable.




Figura 13. Número de empresas en cartera para la estrategia con rebalanceo mensual. Elaboración propia. 2024

La figura 14 muestra el resultado de la optimización de la estrategia en la que se observa que la estrategia con periodo de rebalanceo anual es la que obtiene el mejor resultado en cuanto a *total return*. Sin embargo, desde el punto de vista de Sharpe ratio, la estrategia ganadora es la que lleva a cabo un rebalanceo cada 6 meses.

En cuanto a la máxima caída sufrida por la cartera durante el periodo de inversión, la estrategia de rebalanceo anual dispone del menor *drawdown*, es decir, la menor pérdida máxima sufrida por la cartera.

Comparando las estrategias con el índice S&P 500, todas ellas superan el rendimiento del mercado, que fue del 254% en el periodo de análisis. Además, las estrategias mejoran en términos de rentabilidad ajustada por el riesgo, dado que el Sharpe ratio del mercado (0.38) es inferior al de todas las estrategias analizadas (Figura 14).

Estas conclusiones indican que la estrategia implementada no solo logra una diversificación efectiva y una gestión del riesgo adecuada, sino que también supera consistentemente el rendimiento del mercado tanto en términos absolutos como en términos de retornos ajustados por el riesgo.

	Total Return	Annual Return	Annual Volatility	Sharpe Ratio	Maximum Drawdown	Calmar Ratio
M	393.06 %	9.84 %	18.86 %	0.52	-48.05 %	0.20
3M	391.36 %	9.82 %	15.13 %	0.65	-37.42 %	0.26
6M	342.44 %	9.14 %	13.3 %	0.69	-32.84 %	0.28
12M	410.69 %	10.07 %	15.28 %	0.66	-24.34 %	0.41

Figure 14. Resultados de la estrategia de inversión base. Elaboración propia. 2024

5. Estrategia de Factor Investing

5.1 Factores de la estrategia

Para optimizar la estrategia base, la cual tan solo considera tres variables, el F-Score, el Z-Score y el criterio de ESG, se ha aplicado una estrategia de Factor Investing a la que se le han incluido los criterios de valor, rentabilidad y *momentum*.

5.1.1 Factor de Valor

El factor de valor se refiere a la práctica de seleccionar acciones que se consideran infravaloradas en el mercado. Esto significa que su precio actual es bajo en comparación con su valor intrínseco o fundamental (Graham, 1949). Los inversores de valor buscan comprar estas acciones con la expectativa de que el mercado eventualmente reconocerá su verdadero valor.

El criterio de valor para esta estrategia de factor investing se basa en los principios de inversión desarrollados por Benjamin Graham y seguidos por Warren Buffett. Esta estrategia se centra en identificar y adquirir acciones que se cotizan por debajo de su valor intrínseco, utilizando un análisis fundamental riguroso (Graham, 1949).

Para determinar si una empresa está infravalorada en comparación con el resto del mercado, se utilizan varios criterios fundamentales. Entre los más importantes se encuentran el P/E Ratio, el Price to Book Ratio y el EV/EBITDA:

P/E Ratio (*Price to Earnings Ratio*): es una relación entre el precio de las acciones de una empresa y sus ganancias por acción (EPS). Se calcula dividiendo el precio de mercado de una acción por las ganancias por acción. Esta ratio se utiliza para evaluar si una acción está sobrevalorada o infravalorada en relación con sus ganancias actuales. Un P/E ratio bajo indica que una empresa puede estar infravalorada, mientras que un P/E ratio alto puede sugerir que está sobrevalorada (CFA, Level III, Vol. 1-6, 2024).

Price to Book Ratio (*P/B Ratio*): compara el precio de mercado de una acción con su valor contable, que es el valor de los activos de la empresa menos sus pasivos. Se calcula dividiendo

el precio de mercado por acción entre el valor contable por acción. Esta ratio ayuda a los inversores a entender cuánto están pagando por los activos netos de una empresa. Un P/B ratio bajo puede indicar que una acción está infravalorada en términos de sus activos netos. Generalmente, un P/B ratio por debajo de 1 se considera una señal de que la empresa está infravalorada (Damodaran, 2012).

EV/EBITDA (*Enterprise Value to EBITDA*): es una medida del valor de una empresa (Enterprise Value) en relación con sus ganancias antes de intereses, impuestos, depreciación y amortización (EBITDA). El valor empresarial se calcula como la capitalización de mercado más la deuda total menos el efectivo. Esta ratio proporciona una visión más completa de la valoración de una empresa, considerando tanto la estructura de capital como la capacidad de generar ganancias operativas. Un EV/EBITDA bajo sugiere que una empresa puede estar infravalorada en términos de sus ganancias operativas (CFA, Level III, Vol. 1-6, 2024).

5.1.2 Factor de Rentabilidad

El factor de rentabilidad se refiere a la capacidad de una empresa para generar ganancias en relación con sus ingresos, activos o capital invertido. Este concepto es crucial para los inversores, ya que indica la eficiencia y efectividad con la que una empresa utiliza sus recursos para producir beneficios (Greenblatt, 2006).

Para evaluar la rentabilidad en una estrategia de factor investing, se van a utilizar las dos variables principales de la Fórmula Mágica de Joel Greenblatt extraídas de la revisión de la literatura, el *Return on Capital* (ROC) y el *Earnings Yield* (EY). Estas métricas son fundamentales para identificar empresas que no solo son rentables, sino que también están infravaloradas en el mercado.

Return on Capital (ROC): mide la eficiencia con la que una empresa utiliza su capital para generar beneficios. Se calcula dividiendo el beneficio operativo (EBIT) entre el capital empleado (activos netos operativos). Esta ratio ayuda a los inversores a evaluar cuánto beneficio operativo se genera por cada unidad monetaria de capital invertido en el negocio. Un ROC alto indica que una empresa está utilizando su capital de manera eficiente para generar altos retornos. Generalmente, cuanto mayor sea el ROC, mejor, ya que refleja una mayor rentabilidad del capital invertido (Greenblatt, 2006).

Earnings Yield (EY): es la relación entre las ganancias antes de intereses e impuestos (EBIT) y el valor empresarial (*Enterprise Value*). Se calcula dividiendo el EBIT por el EV. Esta ratio permite a los inversores comparar las ganancias generadas por la empresa con su valor de mercado,

proporcionando una medida del nivel de atractivo de la inversión en términos de rentabilidad. Un EY alto sugiere que una empresa está generando ganancias significativas en relación con su valor de mercado, lo que puede indicar una buena oportunidad de inversión (Greenblatt, 2006).

5.1.3 Factor de *Momentum*

El concepto de *momentum* se refiere a la tendencia de los precios de los activos a continuar moviéndose en la misma dirección. Este fenómeno se basa en la observación de que las acciones que han tenido un buen desempeño en el pasado reciente tienden a seguir generando un buen rendimiento en el futuro cercano. El *momentum* es una de las anomalías más estudiadas en los mercados financieros y es utilizado por los inversores para aprovechar las tendencias del mercado (Banz, 1981).

Para evaluar el criterio de *momentum* se va a utilizar la variable del *Total Return* de los últimos 3 meses. Este indicador mide la rentabilidad total de una acción en los últimos tres meses, incluyendo tanto las apreciaciones de capital como los dividendos pagados.

Total Return 3M: es la suma de la apreciación del precio de la acción y los dividendos recibidos, expresada como un porcentaje del precio de la acción al inicio del periodo de tres meses. Este indicador es útil para identificar acciones que han tenido un buen desempeño reciente. Los inversores que utilizan el criterio de *momentum* buscan beneficiarse de la inercia en el movimiento de los precios de las acciones, comprando aquellas que han mostrado un rendimiento positivo y vendiendo las que han tenido un rendimiento negativo (Banz, 1981).

5.1.4 Variables incluidas en la estrategia

A los factores de valor, rentabilidad y *momentum* se le añaden las variables que habían sido utilizadas en la estrategia base para desarrollar la estrategia de inversión inicial. Por lo tanto, tras aplicar todos estos factores, el resultado de la estrategia de factor investing va a estar formada por los siguientes criterios:

- Piotroski F-Score
- Altman Z-Score
- Criterio de ESG
- Variables de valor: ["P/E ratio", ["Price to Book ratio", "EV/EBITDA"]]
- Variables de rentabilidad: ["Return on Capital", "Earnings Yield"]
- Variables de *momentum*: ["Total Return 3M"]

5.2 Definición de la estrategia

Para mejorar la estrategia de *equity screening* denominada estrategia base, se va a combinar factores de *momentum*, rentabilidad y valor de modo que para cada periodo de inversión se clasifiquen las empresas que cuentan con presencia en ese instante en el índice SP 500 ordenadas de mayor a menor en función de los valores contables de cada compañía.

El objetivo de la estrategia es maximizar la rentabilidad y la ratio de Sharpe. Para ello se va a llevar a cabo una optimización de los periodos de rebalanceo, el peso asociado a cada factor y el número de empresas seleccionadas para la cartera de inversión.

Los periodos de rebalanceo pueden producirse en cuatro frecuencias temporales: mensual, trimestral, semestral y anual; los pesos asociados a cada factor se van a optimizar con la restricción de que la suma total de los pesos sea 1 y que el peso asignado a cada factor esté comprendido entre 0 y 0.5; y para el número de empresas se va a optimizar entre 10, 20 y 30 compañías asignadas a la cartera de inversión de la estrategia.

El resultado de la estrategia es una cartera completamente diversificada que supera al índice de referencia S&P 500.

5.3 Funcionamiento y resultados de la estrategia

La estrategia al igual que en el caso anterior va a evitar el problema de Forward looking y va a considerar tan solo las empresas que forman parte del índice para ese momento determinado del tiempo. Esta estrategia estandarizará los criterios de cada 1 de los factores para que tengan el mismo peso en el modelo y en base a ellos calculará el ranking de las empresas para la selección de la estrategia óptima de inversión.

La estrategia será perfectamente diversificada ya que tendrá entre 10 y 30 empresas acordes a lo que considera el análisis de la literatura como óptimo para eliminar el riesgo diversificable.

En total el modelo analiza 480 combinaciones para optimizar 4 posibles periodos de rebalanceo, 3 tamaño distintos de la cartera y 40 combinaciones aleatorias de pesos asociados a los factores. (3 x 4 x 40 = 480 estrategias distintas analizadas)

El resultado de la optimización muestra un resultado que maximiza tanto el retorno total en la ratio de Sharpe. La combinación óptima alcanza un retorno total de un 570% y una ratio de Sharpe de 0,65.

El modelo de Factor Investing ha superado la mejor estrategia alcanzada en la estrategia base, lo que indica que añadir los factores de valor, rentabilidad y *momentum* han tenido un impacto

positivo en el modelo. Además, comparándolo con el Índice S&P 500, en el periodo en el que se analiza la estrategia de inversión, el modelo es capaz de duplicar el rendimiento del benchmark, pasando de un 254% de retorno total del mercado a un 570%.

La combinación óptima, mostrada en la figura 15 es la siguiente: Rebalanceo mensual con una cartera de 10 compañías y unos pesos de 0.3 para Piotroski F-Score, 0.5 para momentum y 0.2 para value. Esta variable también destaca en cuanto a su maximum drawdown, puesto que solo tiene una caída máxima del 26%, muy por debajo del resto de estrategias analizadas.

Rebalance Period	Number of Companies	Total Return	Sharpe Ratio	Maximum Drawdown	Calmar Ratio	Annualized Return	Annualized Volatility	Weight
240	M	10	5.700271	0.651134	-0.269585	0.439160	0.118391	0.181823 (0.3, 0, 0, 0.5, 0.2, 0)

Figura 15. Estrategia óptima bajo el modelo de Factor Investing que maximiza la rentabilidad. Elaboración propia. 2024

Rebalance Period	Number of Companies	Total Return	Sharpe Ratio	Maximum Drawdown	Calmar Ratio	Annualized Return	Annualized Volatility	Weights
238 12M	20	0.8423834	0.8995637	-0.9761421	0.0321076	0.00244474	0.0303454	(0.4, 0, 0, 0.3, 0, 0.3)
239 12M	30	-0.289853	-0.378877	-0.317725	-0.0627367	-0.019933	0.0526108	(0.4, 0, 0, 0.3, 0, 0.3)
240 M	10	5.70027	0.651134	-0.269585	0.43916	0.118391	0.181823	(0.3, 0, 0, 0.5, 0.2, 0)
241 M	20	4.32596	0.574932	-0.419582	0.246414	0.103391	0.179831	(0.3, 0, 0, 0.5, 0.2, 0)
242 M	30	4.54454	0.611621	-0.422706	0.250775	0.106004	0.173317	(0.3, 0, 0, 0.5, 0.2, 0)
243 3M	10	0.915576	0.424561	-0.162146	0.240381	0.0389768	0.0918048	(0.3, 0, 0, 0.5, 0.2, 0)
244 3M	20	0.681116	0.281907	-0.332267	0.0933828	0.031828	0.110065	(0.3, 0, 0, 0.5, 0.2, 0)

Figura 16. Ejemplo de estrategias calculadas al optimizar la estrategia de Value Investing. elaboración propia. 2024

6. Estrategia optimizada mediante Market Timing

6.1 Diseño y racional de la estrategia

Finalmente, para optimizar la estrategia obtenida tanto en el modelo base como en el modelo de factor investing, se ha diseñado un modelo que utiliza herramientas de Market timing y variables heurísticas como la regla de Sam para optimizar el rebalanceo del portfolio.

En lugar de mantener una asignación estática a ciertos factores, los inversores pueden aumentar la exposición a factores que se espera que rindan bien en el entorno actual y reducir la exposición a aquellos que pueden enfrentar desafíos. Este enfoque dinámico permite a los inversores responder rápidamente a las señales de mercado y aprovechar las oportunidades a corto plazo sin perder de vista los objetivos de inversión a largo plazo (Jegadeesh y Titman, 1993).

Estas estrategias van a contar con una serie de criterios para cambiar de una estrategia long a una estrategia short. Para esta estrategia no se va a considerar un modelo basado en la media móvil simple sino otro basado en las bandas de Bollinger y, finalmente, un último modelo que considera la regla de Sahm como predictor del entorno macroeconómico para detectar posibles recesiones en el mercado de Estados Unidos.

Además, para cada una de estas estrategias se han definido varias alternativas en cuanto a estrategias de invertir en largo y estrategias de invertir en corto. Las estrategias de invertir en largo son las dos estrategias optimizadas de los modelos de screening y de factor investing calculados anteriormente. En cuanto a las estrategias de invertir en corto se han diseñado dos estrategias que son las que peores funcionan en los modelos anteriores y otras tres alternativas que invierten en el oro como activo refugio, invierten Optimizar una estrategia de factor investing utilizando herramientas de Market timing implica integrar la selección de factores con la capacidad de ajustar las posiciones en función de las condiciones actuales del mercado. El Market timing busca identificar los momentos óptimos para entrar y salir del mercado, maximizando los rendimientos y minimizando los riesgos asociados a las fluctuaciones del mercado.

La diversificación temporal es otra estrategia para optimizar el factor investing con Market timing. Esto implica la revaluación periódica en el tipo de interés libre de riesgo o se ponen en corto sobre el índice de referencia S&P 500.

6.2 Estrategias de inversión para ponerse en largo

6.2.1 Estrategia óptima obtenida en el Modelo Base

Esta estrategia utilizará la cartera de inversión optimizada en el modelo base.

Los criterios asociados a esta estrategia son:

- Piotroski F-Score ≥ 8
- Altman Z-Score ≥ 1.8
- Criterio de ESG > 50

6.2.1 Estrategia óptima obtenida en el modelo de Factor Investing

Esta estrategia utilizará la cartera de inversión optimizada en base al modelo de Factor Investing que maximiza el retorno y la ratio de Sharpe.

Los criterios asociados a esta estrategia son:

- Número de empresas en cartera = 10
- Periodo de rebalanceo mensual
- Pesos de los factores: $0.3 * \text{Piotroski F-Score} + 0.5 * \text{Momentum} + 0.2 * \text{Value}$

6.3 Estrategias de inversión para ponerse en corto

6.3.1 Ponerse en corto

Ponerse en corto es una estrategia que permite a los inversores beneficiarse de la caída de los precios de las acciones. Este enfoque implica tomar prestadas acciones de un corredor y venderlas en el mercado abierto con la expectativa de que los precios caerán. Si los precios efectivamente disminuyen, el inversor puede recomprar las acciones a un precio más bajo, devolverlas al corredor y obtener una ganancia con la diferencia de precios. Esta estrategia es arriesgada ya que las pérdidas potenciales son teóricamente ilimitadas si el precio de las acciones sube en lugar de bajar (Bodie, Kane, & Marcus, 2014).

Esta estrategia consistirá en ponerse en corto sobre el índice S&P 500 cuando lo indique el criterio de Market timing de cada una de las diferentes estrategias.

6.3.2 Inversiones en Activos Refugio

Durante las recesiones, los inversores a menudo buscan refugio en activos considerados seguros, como el oro, los bonos del Tesoro de Estados Unidos y las monedas fuertes (por ejemplo, el dólar estadounidense y el franco suizo). Los bonos del Tesoro son atractivos debido a su bajo riesgo de

incumplimiento y su capacidad para ofrecer ingresos fijos en forma de pagos de intereses regulares (Baur & Lucey, 2010).

Esta estrategia consistirá en invertir en largo en el oro cuando lo indique el criterio de market timing de cada una de las diferentes estrategias.

6.3.3 Inversión en el tipo de interés libre de riesgo

La estrategia de inversión en el tipo de interés libre de riesgo consiste en invertir en instrumentos financieros que ofrecen un retorno garantizado y seguro, típicamente representados por bonos del gobierno de alta calidad crediticia, como los bonos del Tesoro de Estados Unidos. Estos instrumentos se consideran libres de riesgo porque el riesgo de incumplimiento es extremadamente bajo, proporcionando así un rendimiento predecible y estable. La estrategia es ideal para inversores que buscan preservar su capital y obtener ingresos constantes sin asumir la volatilidad y los riesgos asociados con los mercados de acciones y otros activos más volátiles.

La estrategia consistirá en invertir en el largo en el tipo de interés del bono a 10 años de Estados Unidos cuando lo indique el criterio de Market timing de cada una de las diferentes estrategias

6.3.4 Inversión en las empresas con peor ranking del modelo de Factor Investing

Para esta estrategia la posición en corto a tomar va a ser la combinación de la cartera que cuenta con las empresas peor clasificadas por los factores del modelo de factor *investing*. En base a ello, se va a invertir en corto cuando se dé la situación establecida por la herramienta de Market timing que determine esta situación.

6.3.5 Empresas peor clasificadas en el Modelo Base

Para esta estrategia se va a invertir en aquellas empresas que cuenten con criterios de Piotroski, Altman y ESG muy por debajo de los líderes del mercado. Se tomará una estrategia de ponerse en corto sobre esas empresas las cuales ya de por sí generan rendimientos inferiores a los de aquellas con unos fundamentos financieros de mayor calidad.

Criterios utilizados para la inversión:

- Piotroski F-Score > 4
- Altman Z-Score > 1.0
- ESG > 40

6.4 Estrategias de Market timing

Para el desarrollo de las estrategias de Market timing, se han optimizado los parámetros asociados a cada estrategia. En la estrategia de media móvil, se ajustó el rango de la media móvil, mientras que en la estrategia de bandas de Bollinger se optimizaron el tamaño y la posición para inversiones en largo y corto. Además, se iteraron las posibles estrategias para invertir en corto y largo, buscando combinar las mejores opciones para cada una. El objetivo es maximizar el retorno y la ratio de Sharpe mediante una cartera diversificada capaz de superar al índice.

6.4.1 Estrategia de Medias Móviles

Una media móvil es un indicador técnico utilizado en análisis financiero para suavizar los datos de precios y destacar la dirección de una tendencia. Calcula el promedio de los precios de un activo durante un periodo específico. A medida que cada nuevo precio se añade, el precio más antiguo se elimina del cálculo, lo que permite a la media móvil adaptarse a los cambios en la acción del precio.

Para el desarrollo de una estrategia de media móvil, se han optimizado los parámetros relevantes para maximizar su efectividad. En esta estrategia, se ajustaron los periodos de las medias móviles, como la media móvil simple (SMA) para identificar señales de compra y venta. También se optimizaron el tamaño y la posición de las inversiones tanto en largo como en corto.

Las medias móviles son indicadores técnicos que suavizan los datos de precios para identificar la dirección de una tendencia. En estrategias de momentum, se busca aprovechar las fluctuaciones de precios dentro de una tendencia general.

La decisión de ponerse en largo viene dada por el siguiente criterio:

Señal de Compra (Largo): Cuando el precio del índice de referencia S&P 500 se sitúa por encima de la media móvil.

Señal de Venta (Corto): Cuando el precio del índice de referencia S&P 500 se sitúa por encima de la media móvil.

Parámetros a optimizar:

- Size_short: Tamaño de la posición en corto
- Size_long: Tamaño de la posición en largo
- Moving_Aaverage_Period: Periodo de la media móvil

Resultados de la estrategia de Media Móvil

La estrategia optimizada utilizando la media móvil consigue un retorno total de 590%, superando a las estrategias base diseñadas anteriormente y además logra optimizar la ratio de Sharpe alcanzando una cifra superior a 1.

Esta estrategia muestra como al utilizar las medias móviles optimizando la ventana temporal del y los pesos de ponerse en corto y en largo, se obtienen retornos que mejoran a aquellos de nlas estrategias que no utilizan herramientas de market timing.

Resultados de la estrategia optimizada:

- Estrategia de inversión en largo: Modelo base
- Estrategia de inversión en corto: Tipo de interés libre de riesgo (Bono a 10 años de Estados Unidos)

	Moving Avg	Period	Size Long	Size Short	Total Return	Annual Return	Annual Volatility	Sharpe Ratio	Max DD	Calmar Ratio	Long Strategy	Short Strategy
4992	6	1.0	1.0	590.997022	0.119799	0.113009	1.060083	-0.157540	0.760434	base_strategy_returns_long	bond_10yr	
4997	6	1.0	1.0	559.667496	0.116762	0.127803	0.913608	-0.150193	0.777408	factor_strategy_returns_long	bond_10yr	
4982	6	1.0	0.9	549.702375	0.115767	0.112468	1.029334	-0.158024	0.732593	base_strategy_returns_long	bond_10yr	
4987	6	1.0	0.9	520.245132	0.112741	0.127322	0.885479	-0.159312	0.707671	factor_strategy_returns_long	bond_10yr	
4892	6	0.5	1.0	511.835510	0.111852	0.102334	1.093004	-0.141982	0.787789	base_strategy_returns_long	bond_10yr	
...
2094	4	0.1	1.0	-67.513670	-0.063697	0.181643	-0.350669	-0.761396	-0.083658	base_strategy_returns_long	factor_strategy_returns_short	
6094	8	0.1	1.0	-68.060590	-0.064627	0.158770	-0.412239	-0.786577	-0.082162	base_strategy_returns_long	factor_strategy_returns_short	
6099	8	0.1	1.0	-68.074283	-0.064650	0.156885	-0.412085	-0.787318	-0.082114	factor_strategy_returns_long	factor_strategy_returns_short	
3099	5	0.1	1.0	-69.372575	-0.066920	0.179083	-0.373684	-0.777057	-0.086120	factor_strategy_returns_long	factor_strategy_returns_short	
3094	5	0.1	1.0	-69.561633	-0.067259	0.178980	-0.375787	-0.776438	-0.086625	base_strategy_returns_long	factor_strategy_returns_short	

Figure 17. Estrategia optimizada con la Media Móvil. Elaboración Propia. 2024

6.4.2 Estrategia de Bandas de Bollinger

Las Bandas de Bollinger, desarrolladas por John Bollinger, son un indicador técnico que utiliza una media móvil y dos desviaciones estándar para crear bandas superior e inferior alrededor del precio de una acción. Estas bandas se expanden y contraen en función de la volatilidad del mercado. Cuando el precio de una acción toca o se acerca a la banda superior, puede indicar condiciones de sobrecompra, mientras que tocar la banda inferior puede sugerir sobreventa (Bollinger, 2001).

En estrategias de Momentum, las Bandas de Bollinger se utilizan para identificar puntos de entrada y salida basados en la volatilidad y las tendencias de precios. Los inversores buscan oportunidades de compra cuando los precios se acercan a la banda inferior en un mercado alcista y oportunidades de venta cuando los precios se acercan a la banda superior en un mercado

bajista. Esta estrategia ayuda a los inversores a aprovechar las fluctuaciones de precios dentro de una tendencia general, gestionando el riesgo al mismo tiempo.

Estrategia:

- Posición en largo: cuando el S&P500 está por encima de la banda superior
- Posición en corto: cuando la banda inferior está por encima del S&P500
- Posición medio: Cuando el S&P 500 se encuentra entre las bandas.

Esta estrategia optimiza el valor para la posición en medio además de los pesos asociados a cada una de las estrategias y el tamaño de la ventana temporal utilizada por la media móvil necesaria para calcular las bandas de Bollinger.

Resultado de la estrategia

Esta estrategia es capaz de batir a la media móvil ya que consigue retornos superiores al 400% pero Sharp ratios superiores a 2.2 utilizando una combinación de invertir en la estrategia en largo con el tipo de interés libre de riesgo.

	Moving Avg Period	Size Long	Size Short	Size Med	Total Return	Annual Return	Annual Volatility	Sharpe Ratio	Max DD	Calmar Ratio	Long Strategy	Short Strategy
0	12	0.1	-1.0	-1.0	120.719818	0.324555	0.018865	17.204121	-0.056605	5.733676	base_strategy_returns_long	returns
1	12	0.1	-1.0	-1.0	120.719818	0.324555	0.018865	17.204121	-0.056605	5.733676	base_strategy_returns_long	returns_gold
2	12	0.1	-1.0	-1.0	120.719818	0.324555	0.018865	17.204121	-0.056605	5.733676	base_strategy_returns_long	bond_10yr
3	12	0.1	-1.0	-1.0	120.719818	0.324555	0.018865	17.204121	-0.056605	5.733676	base_strategy_returns_long	base_strategy_returns_short
4	12	0.1	-1.0	-1.0	120.719818	0.324555	0.018865	17.204121	-0.056605	5.733676	base_strategy_returns_long	factor_strategy_returns_short
...
23095	12	1.0	1.0	1.0	437.445757	0.427739	0.195493	2.187995	-0.483812	0.884100	factor_strategy_returns_long	returns
23096	12	1.0	1.0	1.0	437.445757	0.427739	0.195493	2.187995	-0.483812	0.884100	factor_strategy_returns_long	returns_gold
23097	12	1.0	1.0	1.0	437.445757	0.427739	0.195493	2.187995	-0.483812	0.884100	factor_strategy_returns_long	bond_10yr
23098	12	1.0	1.0	1.0	437.445757	0.427739	0.195493	2.187995	-0.483812	0.884100	factor_strategy_returns_long	base_strategy_returns_short
23099	12	1.0	1.0	1.0	437.445757	0.427739	0.195493	2.187995	-0.483812	0.884100	factor_strategy_returns_long	factor_strategy_returns_short

23100 rows x 12 columns

Figura 18. Estrategia optimizada con las Bandas de Bollinger. Elaboración Propia. 2024

6.4.3 Estrategia basada en la regla de Sahm

Para el desarrollo de una estrategia basada en la regla de Sahm, se han optimizado los parámetros clave para maximizar su efectividad. La regla de Sahm utiliza cambios en la tasa de desempleo para identificar el inicio de una recesión. Según esta regla, se toma una posición en corto si la tasa de desempleo aumenta en 0.5 puntos porcentuales o más en comparación con su valor mínimo en los últimos 12 meses, indicando una posible recesión. Por otro lado, se toma una posición en largo cuando la tasa de desempleo se mantiene estable o disminuye, indicando un crecimiento económico.

Se han optimizado el tamaño y la posición de las inversiones tanto en largo como en corto, buscando maximizar el retorno y la ratio de Sharpe mediante una cartera diversificada que pueda

superar al índice. Esta estrategia permite a los inversores gestionar el riesgo de manera efectiva al ajustar sus posiciones en función de las condiciones económicas actuales, basándose en indicadores confiables del mercado laboral.

Resultado de la estrategia

La optimización del modelo utilizando la regla de Sahn como detector de las recesiones en Estados Unidos no mejora las estrategias base de los modelos anteriores a pesar de que obtienen retornos cercanos al 400% y al 0.6 de Sharpe. Esta estrategia es muy interesante desde el punto de vista teórico por sus implicaciones en la detección de recesiones pero, al aplicarla a una cartera de inversión no mejora a las estrategias típicas de market timing

	Moving Avg Period	Size Long	Size Short	Total Return	Annual Return	Annual Volatility	Sharpe Ratio	Max DD	Calmar Ratio	Long Strategy	Short Strategy
0	12	0.1	0.1	20.719818	0.011084	0.018865	0.587520	-0.056605	0.195805	base_strategy_returns_long	return
1	12	0.1	0.1	20.719818	0.011084	0.018865	0.587520	-0.056605	0.195805	base_strategy_returns_long	returns_gok
2	12	0.1	0.1	20.719818	0.011084	0.018865	0.587520	-0.056605	0.195805	base_strategy_returns_long	bond_10y
3	12	0.1	0.1	20.719818	0.011084	0.018865	0.587520	-0.056605	0.195805	base_strategy_returns_long	base_strategy_returns_shor
4	12	0.1	0.1	20.719818	0.011084	0.018865	0.587520	-0.056605	0.195805	base_strategy_returns_long	factor_strategy_returns_shor
...
995	12	1.0	1.0	337.445757	0.090228	0.195493	0.461542	-0.483812	0.186495	factor_strategy_returns_long	return
996	12	1.0	1.0	337.445757	0.090228	0.195493	0.461542	-0.483812	0.186495	factor_strategy_returns_long	returns_gok
997	12	1.0	1.0	337.445757	0.090228	0.195493	0.461542	-0.483812	0.186495	factor_strategy_returns_long	bond_10y
998	12	1.0	1.0	337.445757	0.090228	0.195493	0.461542	-0.483812	0.186495	factor_strategy_returns_long	base_strategy_returns_shor
999	12	1.0	1.0	337.445757	0.090228	0.195493	0.461542	-0.483812	0.186495	factor_strategy_returns_long	factor_strategy_returns_shor

Figure 19. Estrategia optimizada en base a la regla de Sahn. Elaboración propia. 2024

7. Posibles futuras líneas de investigación

Una de las direcciones más prometedoras para futuras investigaciones en el ámbito de la optimización de estrategias de inversión es el empleo de algoritmos genéticos, una técnica de inteligencia artificial diseñada para encontrar parámetros óptimos en áreas específicas.

Los algoritmos genéticos (AG) son métodos de búsqueda y optimización basados en los principios de la selección natural y la genética inspirados en los mecanismos de la evolución biológica. Estos algoritmos reiteradamente modifican un conjunto de soluciones candidatas mediante operadores genéticos tales como la mutación, el cruce y la selección. La aplicación de AG en la optimización de estrategias de inversión presenta una oportunidad significativa para mejorar el rendimiento y la robustez de dichas estrategias.

Entre las principales ventajas de los AG se encuentra su capacidad para la optimización multivariable, donde múltiples parámetros interactúan de maneras complejas. En el contexto de las estrategias de inversión, los AG pueden ajustar simultáneamente diversos parámetros como los umbrales de compra/venta, periodos de inversión y pesos de activos, optimizando así el rendimiento global de la cartera. Además, su adaptabilidad y flexibilidad permiten que los AG sean eficaces incluso en entornos no lineales y de alta incertidumbre, características comunes en los mercados financieros. Los AG pueden adaptarse dinámicamente a cambios en las condiciones del mercado, proporcionando buenas soluciones en entornos volátiles.

Otra ventaja crucial de los AG es su capacidad para explorar vastos espacios de solución de manera eficiente. Esto es especialmente relevante en la inversión cuantitativa, donde el espacio de parámetros es enorme y las soluciones óptimas pueden no ser obvias a priori. La implementación de AG en la optimización de estrategias de inversión puede seguir varios pasos clave: definir el espacio de parámetros relevante, codificar las soluciones de forma adecuada para la manipulación genética, diseñar operadores de cruce y mutación efectivos, establecer una función de aptitud que evalúe las soluciones basadas en criterios de rendimiento como la ratio de Sharpe y el retorno total, y realizar iteraciones hasta alcanzar una solución óptima.

El desempeño de los algoritmos genéticos debe ser evaluado y comparado con otras técnicas de optimización, como la optimización por enjambre de partículas, las redes neuronales y los métodos tradicionales de búsqueda local. Esta comparación permitirá determinar la eficacia relativa de los AG en la optimización de estrategias de inversión y su potencial para mejorar el rendimiento ajustado por riesgo.

La integración de algoritmos genéticos en la investigación y desarrollo de estrategias de inversión representa una frontera emocionante y de alto impacto en la inteligencia artificial aplicada a las finanzas. Su capacidad para optimizar múltiples parámetros de manera eficiente y adaptativa ofrece un potencial considerable para avanzar en la gestión de carteras y maximizar el rendimiento en mercados financieros complejos y dinámicos.

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, Julián Velasco Blanco, estudiante de E2-Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado " Diseño e Implementación de una Estrategia de Inversión mediante la aplicación de filtrado cuantitativo y el uso de herramientas de *Market Timing*", declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

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

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: 21 Junio 2024

Firma: Julián Velasco Blanco

Bibliografía

- Aldridge, I. (2013). *High-Frequency Trading: A Practical Guide to Algorithmic Strategies and Trading Systems*. Wiley.
- Ang, A., Hodrick, R. J., Xing, Y., y Zhang, X. (2006). The Cross-Section of Volatility and Expected Returns. *Journal of Finance*, 61(1), 259-299. Recuperado el 8 de mayo de 2024 de <https://www0.gsb.columbia.edu/faculty/rhodrick/crosssection.pdf>
- Ammann, M., Oesch, D., & Schmid, M. M. (2013). Value and Size Anomalies: Evidence from Global Stock Markets. *Journal of Empirical Finance*, 20, 294-311.**
- Ang, A., Hodrick, R. J., Xing, Y., y Zhang, X. (2006). The Cross-Section of Volatility and Expected Returns. *Journal of Finance*, 61(1), 259-299. Recuperado el 8 de mayo de 2024 de <https://www0.gsb.columbia.edu/faculty/rhodrick/crosssection.pdf>
- Asness, C. S., Frazzini, A., y Pedersen, L. H. (2014). Quality Minus Junk. *Review of Accounting Studies*, 19(2), 389-429. Recuperado el 8 de mayo de 2024 de https://www.researchgate.net/publication/328746688_Quality_minus_junk
- Banz, R. W. (1981). The Relationship Between Return and Market Value of Common Stocks. *Journal of Financial Economics*, 9(1), 3-18. Recuperado el 8 de mayo de 2024 de https://search.dailystocks.com/Banz_sizeeffect_1980.pdf
- Bernanke, B. S., y Blinder, A. S. (1992). The Federal Funds Rate and the Channels of Monetary Transmission. *American Economic Review*, 82(4), 901-921. Recuperado el 14 de mayo de 2024 de <http://drphilipshaw.com/Protected/The%20Federal%20Funds%20Rate%20and%20the%20Channels%20of%20Monetary%20Transmission.pdf>
- Blanchard, O., y Johnson, D. R. (2013). *Macroeconomics*. Pearson. Recuperado el 14 de mayo de 2024 de <https://home.ufam.edu.br/andersonlfc/Macro/Livro%20Macro.pdf>
- Bodie, Z., Kane, A., y Marcus, A. J. (2014). *Investments*. McGraw-Hill Education.
- Bogle, J. C. (2016). *The Little Book of Common Sense Investing: The Only Way to Guarantee Your Fair Share of Stock Market Returns*. Wiley.
- Bloomberg (2024) S&P 500 Constituents. Bloomberg Terminal (Recuperado: 25 de enero de 2024).

- Brown, S. J., Goetzmann, W., Ibbotson, R. G., y Ross, S. A. (1992). Survivorship bias in performance studies. *The Review of Financial Studies*, 5(4), 553–580. Recuperado el 9 de febrero de 2024 de <https://doi.org/10.1093/rfs/5.4.553>
- Buffett, W. (1984). *The Superinvestors of Graham-and-Doddsville*. Columbia Business School. Recuperado el 2 de marzo de 2024 de https://www.chawtoninvestors.co.uk/files/Insights/Essay_The-superinvestors-of-Graham-and-Doddsville-by-warren-buffett.pdf
- Buffett, M., & Clark, D. (1999). *Buffettología: Las técnicas jamás contadas que han hecho de Warren Buffett el inversor más famoso del mundo*. Grupo Planeta.
- Bureau of Economic Analysis. (2021). *Gross Domestic Product by Industry*. Recuperado el 14 de mayo de 2024 de <https://www.bea.gov/data/gdp/gdp-industry>
- Bureau of Labor Statistics. (2023). *Employment Situation Summary*. BLS. Recuperado el 18 de mayo de 2024 de <https://www.bls.gov/news.release/pdf/empsit.pdf>
- Casarella, F. (5 de julio de 2023). *Warren Buffett gana 19.8% en rendimientos anuales: ¿Cómo lo hace?* Investing.com. Recuperado el 2 de marzo de 2024 de <https://mx.investing.com/analysis/warren-buffett-gana-198-en-rendimientos-anuales-como-lo-hace-200466984>
- Carhart, M. M. (1997). On Persistence in Mutual Fund Performance. *The Journal of Finance*, 52(1), 57-82. Recuperado el 12 de febrero de 2024 de <https://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1997.tb03808.x>
- Carroll, C. D., Fuhrer, J. C., & Wilcox, D. W. (1994). Does Consumer Sentiment Forecast Household Spending? If So, Why? *American Economic Review*, 84(5), 1397-1408. Recuperado el 26 de mayo de 2024 de https://www.researchgate.net/publication/4901272_Does_Consumer_Sentiment_Forecast_Household_Spending_If_So_Why
- CEIC Data. (2024). *United States Private Consumption: % of Nominal GDP*. Recuperado de <https://www.ceicdata.com/en/indicator/united-states/private-consumption--of-nominal-gdp#:~>
- Carroll, C. D., Fuhrer, J. C., & Wilcox, D. W. (1994). Does Consumer Sentiment Forecast Household Spending? If So, Why? *American Economic Review*, 84(5), 1397-1408. Recuperado el 26 de

mayo de 2024 de

https://www.researchgate.net/publication/4901272_Does_Consumer_Sentiment_Forecast_Household_Spending_If_So_Why

CFA Program Curriculum 2024: Level I, Volume 1. (2024). Reading 11: Understanding Business Cycles. CFA Institute.

CFA Program Curriculum 2024: Level I, Volume 1. (2024). Reading 28: The Term Structure and Interest Rate Dynamics. CFA Institute.

CFA Program Curriculum 2024: Level I, Volume 1. (2024). Reading 50: Portfolio Risk and Return: Part II. CFA Institute.

CFA Program Curriculum 2024: Level III, Volumes 1-6. (2024). Reading 18: Active Equity Investing: Portfolio Construction Learning Outcomes. CFA Institute.

CFA Program Curriculum 2024: Level III, Volumes 1-6. (2024). Reading 41: Backtesting and Simulation. CFA Institute.

CFA Program Curriculum 2024: Level II, Volumes 1-8. (2024). Reading 21. Using Multifactor Models. CFA Institute.

Chan, L. K. C., Karceski, J., y Lakonishok, J. (2000). New Paradigm or Same Old Hype in Equity Investing? *Financial Analysts Journal*, 56(1), 23-36. Recuperado el 24 de marzo de 2024 de https://www.researchgate.net/publication/254911501_New_Paradigm_or_Same_Old_Hype_in_Equity_Investing

Chen, N.-F., Roll, R., y Ross, S. A. (2002). Economic Forces and the Stock Market. *Journal of Business*, 59(3), 383-403. Recuperado el 24 de marzo de 2024 de https://www.researchgate.net/publication/24102948_Economic_Forces_and_the_Stock_Market

Clark, E (2022). *Lessons from Peter Lynch: Invest in what you know*. Morningstars. Recuperado el 24 de marzo de 2024 de <https://www.accuvest.com/alpha-brands-insights/2022/10/31lessonsfrompeterlynch>

- Cunningham, L. A. (Ed.). (2001). *The Essays of Warren Buffett: Lessons for Corporate America*. Cunningham Group.
- Damodaran, A. (2012). *Investment Valuation: Tools and Techniques for Determining the Value of Any Asset*. Wiley. Recuperado el 25 de febrero de 2024 de <https://suhiconsulting.com/wp-content/uploads/2018/09/investment-valuation-3rd-edition.pdf>
- Daryanani, G. (2008). Opportunistic Rebalancing: A New Paradigm for Wealth Managers. *Journal of Financial Planning*, 21(1), 48-61. Recuperado el 22 de febrero de 2024 de <https://www.financialplanningassociation.org/sites/default/files/2020-05/9%20Opportunistic%20Rebalancing%20A%20New%20Paradigm%20for%20Wealth%20Managers.pdf>
- De Bondt, W. F. M. y Thaler, R. (1985). Does the Stock Market Overreact? *The Journal of Finance*, 40(3), 793-805. Recuperado el 12 de febrero de 2024 de <https://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1985.tb05004.x>
- Di Persio, L., Garbelli, M., y Wallbaum, K. (2021). Forward-Looking Volatility Estimation for Risk-Managed Investment Strategies during the COVID-19 Crisis. *Risks*, 9(2), 33. Recuperado el 14 de mayo de 2024 de <https://doi.org/10.3390/risks9020033>
- Dimson, E., Marsh, P., & Staunton, M. (2002). *Triumph of the Optimists: 101 Years of Global Investment Returns*. Princeton University Press.
- Easley, D., Michayluk, D., O'Hara, M., y Putniņš, T. J. (2021). The active world of passive investing. *Review of Finance*, 25(5), 1433-1471. Recuperado el 24 de febrero de 2024 de <https://academic.oup.com/rof/article-abstract/25/5/1433/6342430>
- El Bernoussi, R., & Rockinger, M. (2023). Rebalancing with transaction costs: theory, simulations, and actual data. *Financial Markets and Portfolio Management*, 37(1), 121–160. Recuperado el 22 de febrero de 2024 de <https://doi.org/10.1007/s11408-022-00419-6>
- Elton, E. J., & Gruber, M. J. (1977). Risk reduction and portfolio size: An analytical solution. *The Journal of Business*, 50(4), 415-437. Recuperado el 14 de mayo de 2024 de https://www.researchgate.net/publication/24102674_Risk_Reduction_and_Portfolio_Size_An_Analytical_Solution

- Elsby, M. W., Hobijn, B., y Sahin, A. (2010). The Labor Market in the Great Recession. *Brookings Papers on Economic Activity*, 2010(1), 1-48. Recuperado el 18 de mayo de 2024 de https://www.brookings.edu/wp-content/uploads/2010/03/2010a_bpea_elsby.pdf
- Estrella, A., y Hardouvelis, G. A. (1991). The Term Structure as a Predictor of Real Economic Activity. *Journal of Finance*, 46(2), 555-576. Recuperado el 18 de mayo de 2024 de https://www.researchgate.net/publication/257896013_The_Term_Structure_as_a_Predictor_of_Real_Economic_Growth_A_General_Equilibrium_Approach
- Estrella, A., y Mishkin, F. S. (1996). The Yield Curve as a Predictor of US Recessions. *Current Issues in Economics and Finance*, 2(7), 1-6. Recuperado el 18 de mayo de 2024 de https://www.newyorkfed.org/medialibrary/media/research/current_issues/ci2-7.pdf
- Fabozzi, F. J., Focardi, S. M., y Kolm, P. N. (2006). *Quantitative Equity Investing: Techniques and Strategies*. Wiley. Recuperado el 14 de mayo de 2024 de <https://download.e-bookshelf.de/download/0000/5762/98/L-G-0000576298-0002383206.pdf>
- Fama, E. F. y French, K. R. (1992). The Cross-Section of Expected Stock Returns. *The Journal of Finance*, 47(2), 427-465. Recuperado el 12 de febrero de 2024 de <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1540-6261.1992.tb04398.x>
- Fama, E. F. y French, K. R. (1993). Common Risk Factors in the Returns on Stocks and Bonds. *Journal of Financial Economics*, 33(1), 3-56. Recuperado el 12 de febrero de 2024 de <https://www.sciencedirect.com/science/article/abs/pii/0304405X93900235>
- Fama, E. F., y French, K. R. (1995). Size and Book-to-Market Factors in Earnings and Returns. *Journal of Finance*, 50(1), 131-155. Recuperado el 24 de marzo de 2024 de <https://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1995.tb05169.x>
- Fama, E. F., y French, K. R. (2008). Dissecting Anomalies. *The Journal of Finance*, 63(4), 1653-1678. Recuperado el 25 de febrero de 2024 de https://www.researchgate.net/publication/4769783_Dissecting_Anomalies
- Fama, E. F., y French, K. R. (2010). Luck versus Skill in the Cross-Section of Mutual Fund Returns. *The Journal of Finance*, 65(5), 1915-1947. Recuperado el 12 de febrero de 2024 de https://www.researchgate.net/publication/227505955_Luck_Versus_Skill_in_the_Cross_Section_of_Mutual_Fund_Returns
- Federal Reserve. (2012). *Federal Reserve's Mandate and Goals*. FED
- Federal Reserve Economic Data (FRED). (2023). *Employment Situation Summary*. FRED.

- Fisher, I. (1930). *The Theory of Interest*. Macmillan. Recuperado el 12 de febrero de 2024 de http://files.libertyfund.org/files/1416/0219_Bk.pdf
- Fisher, P. (1996). *Common Stocks and Uncommon Profits and Other Writings*. Wiley.
- Friede, G., Busch, T., y Bassen, A. (2015). ESG and Financial Performance: Aggregated Evidence from More than 2000 Empirical Studies. *Journal of Sustainable Finance & Investment*, 5(4), 210-233. Recuperado el 14 de mayo de 2024 de https://www.researchgate.net/publication/287126190_ESG_and_financial_performance_Aggregated_evidence_from_more_than_2000_empirical_studies
- Garleanu, N. y Pedersen, L. H. (2022). Active and Passive Investing: Understanding Samuelson's Dictum. *The Review of Asset Pricing Studies*, 12(2) 389–446. Recuperado el 24 de febrero de 2024 de <https://academic.oup.com/raps/article/12/2/389/6350496>
- Glaeser, E. L., y Gyourko, J. (2005). The Impact of Zoning on Housing Affordability. *Harvard Institute of Economic Research Discussion Paper No. 2017*. Recuperado el 26 de mayo de 2024 de https://www.researchgate.net/publication/5196807_The_Impact_of_Zoning_on_Housing_Affordability
- Goetzmann, W. N. (2016). *Money Changes Everything: How Finance Made Civilization Possible*. Princeton University Press.
- Gorton, G., y Metrick, A. (2012). Getting Up to Speed on the Financial Crisis: A One-Weekend-Reader's Guide. *Journal of Economic Literature*, 50(1), 128-150. Recuperado el 18 de mayo de 2024 de https://www.researchgate.net/publication/227363171_Getting_Up_to_Speed_on_the_Financial_Crisis_A_One-Weekend-Reader's_Guide
- Graham, B., y Dodd, D. (1934). *Security Analysis*. McGraw-Hill.
- Graham, B. (1949). *The intelligent investor* (32ª ed.). Deusto.
- Gray, W. R., y Carlisle, T. E. (2013). *Quantitative Value: A Practitioner's Guide to Automating Intelligent Investment and Eliminating Behavioral Errors*. Wiley.
- Greenblatt, J. (2006). *The Little Book That Beats the Market*. Wiley.
- Grinblatt, M., & Titman, S. (1989). Mutual Fund Performance: An Analysis of Quarterly Portfolio Holdings. *Journal of Business*, 62(3), 394-415. Recuperado el 24 de febrero de 2024 <https://www.jstor.org/stable/2353353>
- Hagstrom, R. G. (2005). *The Warren Buffett Way*. Wiley.

- Hetzl, R. L. (2008). *The Monetary Policy of the Federal Reserve: A History*. Cambridge University Press.
- Jegadeesh, N., & Titman, S. (1993). Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency. *The Journal of Finance*, 48(1), 65-91. Recuperado el 12 de febrero de 2024 de <https://www.bauer.uh.edu/rsusmel/phd/jegadeesh-titman93.pdf>
- Juhn, C., Murphy, K. M., y Topel, R. H. (2002). Current Unemployment, Historically Contemplated. *Brookings Papers on Economic Activity*, 2002(1), 79-116. Recuperado el 18 de mayo de 2024 de <https://uh.edu/~cjuhn/Papers/docs/1209174.pdf>
- Kenan Institute of Private Enterprise. (2022). *Does ESG Investing Generate Higher Returns?*. Recuperado el 12 de abril de 2024 de <https://kenaninstitute.unc.edu/kenan-insight/does-esg-investing-generate-higher-returns/>
- Juhn, C., Murphy, K. M., y Topel, R. H. (2002). Current Unemployment, Historically Contemplated. *Brookings Papers on Economic Activity*, 2002(1), 79-116. Recuperado el 18 de mayo de 2024 de <https://uh.edu/~cjuhn/Papers/docs/1209174.pdf>
- Keynes, J. M. (1936). *The General Theory of Employment, Interest, and Money*. Macmillan. Recuperado el 12 de febrero de 2024 de https://www.files.ethz.ch/isn/125515/1366_keynestheoryofemployment.pdf
- Lakonishok, J., Shleifer, A., & Vishny, R. W. (1994). Contrarian Investment, Extrapolation, and Risk. *The Journal of Finance*, 49(5), 1541-1578. Recuperado el 12 de febrero de 2024 de <https://www.jstor.org/stable/2329262>
- Leamer, E. E. (2007). Housing IS the Business Cycle. *National Bureau of Economic Research Working Paper No. 13428*. Recuperado el 26 de mayo de 2024 de https://www.nber.org/system/files/working_papers/w13428/w13428.pdf
- Lynch, P. (1993). *Beating the Street*. Simon & Schuster.
- Lynch, P., y Rothchild, J. (2000). *One Up On Wall Street: How To Use What You Already Know To Make Money In The Market*. Simon & Schuster.
- Lynch, P. (2015). *Un paso por delante de Wall Street*. Deusto
- Lopez de Prado, M. (2018). *Advances in Financial Machine Learning*. Wiley
- Ludvigson, S. C. (2004). Consumer Confidence and Consumer Spending. *Journal of Economic Perspectives*, 18(2), 29-50. Recuperado el 26 de mayo de 2024 de

https://www.researchgate.net/publication/4724429_Consumer_Confidence_and_Consumer_Spending

Malkiel, B. G. (2003). Passive Investment Strategies and Efficient Markets. *European Financial Management*, 9(1), 1-10. Recuperado el 24 de febrero de 2024 de <https://onlinelibrary.wiley.com/doi/10.1111/1468-036X.00205>

Mankiw, N. G. (2019). *Principles of Economics*. Cengage Learning.

Markowitz, H. (1952). Portfolio Selection. *The Journal of Finance*, 7(1), 77-91. Recuperado el 12 de febrero de 2024 de https://www.researchgate.net/publication/228051028_Portfolio_Selection

Matusaka, J. G., y Sbordone, A. M. (1995). Consumer Confidence and Economic Fluctuations. *Economic Inquiry*, 33(2), 296-318. Recuperado el 26 de mayo de 2024 de <https://www.proquest.com/docview/200868771?sourcetype=Scholarly%20Journals>

Mohanram, P. S. (2005). Separating Winners from Losers among Low Book-to-Market Stocks using Financial Statement Analysis. *Review of Accounting Studies*, 10(2-3), 133-170. Recuperado el 2 de marzo de 2024 de https://www.researchgate.net/publication/226481123_Separating_Winners_from_Losers_Among_Low_Book-to-Market_Stocks_Using_Financial_Statement_Analysis

Murphy, J. J. (1999). *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*. New York Institute of Finance. Recuperado el 24 de febrero de 2024 de <https://cdn.preterhuman.net/texts/unsorted2/Stock%20books%20029/John%20J%20Murphy%20-%20Technical%20Analysis%20Of%20The%20Financial%20Markets.pdf>

National Bureau of Economic Research. (2024.). *Business Cycle Dating*. Recuperado el 24 de marzo de 2024 de <https://www.nber.org/research/business-cycle-dating>

NAHB. (2023). Housing Market Index. National Association of Home Builders. Recuperado el 26 de mayo de 2024 de <https://www.nahb.org>

Neal, L. (1990). *The Rise of Financial Capitalism: International Capital Markets in the Age of Reason*. Cambridge University Press. Recuperado el 12 de febrero de 2024 de https://www.researchgate.net/publication/227407914_Larry_Neal_The_Rise_of_Financial_Cap

[italism International Capital Markets in the Age of Reason Cambridge Cambridge University Press 1993 278 pags](#)

Obstfeld, M., y Rogoff, K. (2009). Global Imbalances and the Financial Crisis: Products of Common Causes. *Proceedings - Economic Policy Symposium - Jackson Hole*, Federal Reserve Bank of Kansas City. Recuperado el 14 de mayo de 2024 de https://www.researchgate.net/publication/227437591_Global_Imbalances_and_the_Financial_Crisis_Products_of_Common_Causes

Owyang, M. T., y Sekhposyan, T. (2012). Okun's Law over the Business Cycle: Was the Great Recession All That Different? *Federal Reserve Bank of St. Louis Review*, 94(5), 399-418. Recuperado el 18 de mayo de 2024 de https://files.stlouisfed.org/files/htdocs/publications/review/12/09/399-418Owyang_rev.pdf

Pabrai, M. (2007). *The Dhandho Investor: The Low-Risk Value Method to High Returns*. Wiley.

Perossa, M.L, Waldman, P. y Díaz Übermán, D.S. (2015). Reglamentación y uso de información privilegiada en el mercado norteamericano de valores. *Revista Academia y Virtualidad*, 8, (1), 111-120.

Piotroski, J. D. (2000). Value Investing: The Use of Historical Financial Statement Information to Separate Winners from Losers. *Journal of Accounting Research*, 38, 1-41. Recuperado el 4 de enero de 2024 de https://www.ivey.uwo.ca/media/3775523/value_investing_the_use_of_historical_financial_statement_information.pdf

Price, T. R. (1973). *A Successful Investor's Philosophy*. T. Rowe Price Associates.

Reinhart, C. M., y Rogoff, K. S. (2009). *This Time Is Different: Eight Centuries of Financial Folly*. Princeton University Press. Recuperado el 14 de mayo de 2024 de https://www.researchgate.net/publication/227486731_This_Time_Is_Different_Eight_Centuries_of_Financial_Folly

Romer, C. D., & Romer, D. H. (2004). A New Measure of Monetary Shocks: Derivation and Implications. *American Economic Review*, 94(4), 1055-1084. Recuperado el 14 de mayo de 2024 de https://eml.berkeley.edu/~dromer/papers/AER_September04.pdf

- Ross, S. A., Westerfield, R. W., Jaffe, J., & Jordan, B. D. (2016). *Corporate finance: Core principles & applications* (5th ed.). McGraw-Hill Education.
- Rouwenhorst, K. G. (1999). Local Return Factors and Turnover in Emerging Stock Markets. *Journal of Finance*, 54(4), 1439-1464. Recuperado el 24 de marzo de 2024 de https://papers.ssrn.com/sol3/papers.cfm?abstract_id=115788
- Rudebusch, G. D., & Williams, J. C. (2009). Forecasting Recessions: The Puzzle of the Enduring Power of the Yield Curve. *Journal of Business & Economic Statistics*, 27(4), 492-503. Recuperado el 18 de mayo de 2024 de https://www.researchgate.net/publication/5034307_Forecasting_Recessions_The_Puzzle_of_the_Enduring_Power_of_the_Yield_Curve
- Sahm, C. (2019). *Direct Stimulus Payments to Individuals*. Hutchins Center on Fiscal and Monetary Policy at Brookings. Recuperado el 18 de mayo de 2024 de https://www.brookings.edu/wp-content/uploads/2019/05/ES_THP_Sahm_web_20190506.pdf
- Sharpe, W. F. (1964). Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, 19(3), 425-442. Recuperado el 12 de febrero de 2024 de <https://onlinelibrary.wiley.com/doi/10.1111/j.1540-6261.1964.tb02865.x>
- Sharpe, W. F. (1991). The arithmetic of active management. *Financial Analysts Journal*, 47(1), 7-9. Taylor & Francis, Ltd. Recuperado el 24 de febrero de 2024 de <https://www.jstor.org/stable/4479386>
- Statman, M. (1987). How many stocks make a diversified portfolio? *The Journal of Financial and Quantitative Analysis*, 22(3), 353-363. Recuperado el 14 de mayo de 2024 de https://www.researchgate.net/publication/227406059_How_Many_Stocks_Make_a_Diversified_Portfolio
- Steelman, A. (1978). *Full Employment and Balanced Growth Act of 1978 (Humphrey-Hawkins)*. Federal Reserve History. Recuperado el 17 de abril de 2024 de <https://www.federalreservehistory.org/essays/humphrey-hawkins-act>

- Stock, J. H., y Watson, M. W. (1989). New Indexes of Coincident and Leading Economic Indicators. *NBER Macroeconomics Annual*, 4, 351-394. Recuperado el 26 de mayo de 2024 de <https://www.nber.org/system/files/chapters/c10968/c10968.pdf>
- Stuckler, D., Basu, S., Suhrcke, M., Coutts, A., & McKee, M. (2009). The public health effect of economic crises and alternative policy responses in Europe: an empirical analysis. *The Lancet*, 374(9686), 315-323. Recuperado el 12 de abril de 2024 de <https://pubmed.ncbi.nlm.nih.gov/19589588/>
- S&P Global. (2024). *S&P 500 Index*. S&P Dow Jones Indices. Recuperado el 18 de marzo de 2024 de <https://www.spglobal.com/spdji/es/indices/equity/sp-500/#overview>
- Stock, J. H., y Watson, M. W. (1989). New Indexes of Coincident and Leading Economic Indicators. *NBER Macroeconomics Annual*, 4, 351-394. Recuperado el 26 de mayo de 2024 de <https://www.nber.org/system/files/chapters/c10968/c10968.pdf>
- Thaler, R. H. (2015). *Misbehaving: The Making of Behavioral Economics*. W. W. Norton & Company.
- The Conference Board. (2021). *The Conference Board Leading Economic Index (LEI) for the United States*. Recuperado el 26 de mayo de 2024 de [The Conference Board](https://www.conferenceboard.com/)
- Tokat, Y., & Wicas, N. W. (2007). Portfolio Rebalancing in Theory and Practice. *Vanguard Investment Counseling & Research*, 2007. Recuperado el 22 de febrero de 2024 de <https://indexacapital.com/bundles/unaiadvisor/docs/papers/2007-Vanguard-Portfolio-Rebalancing-in-Theory-and-Practice.pdf?v=236>
- U.S. Government Publishing Office. (1946). *Employment Act of 1946*. GovInfo. Recuperado el 18 de mayo de 2024 de <https://www.govinfo.gov/app/details/COMPS-1530>
- Wallick, D. W., Wimmer, B. R., y Balsamo, J. (2015). *Keys to improving the odds of active management success*. Vanguard Research. Recuperado el 18 de mayo de 2024
- Wang, F., Yan, X. S., & Zheng, L. (2024). Do sophisticated investors follow fundamental analysis strategies? Evidence from hedge funds and mutual funds. *Review of Accounting Studies*, 29(4), 1097–1146. Recuperado el 14 de mayo de 2024 de <https://doi.org/10.3390/risks9020033>
- Wermers, R. (2000). Mutual Fund Performance: An Empirical Decomposition into Stock-Picking Talent, Style, Transactions Costs, and Expenses. *The Journal of Finance*, 55(4), 1655-1695. Recuperado el 24 de febrero de 2024 https://www.researchgate.net/publication/4768982_Mutual_Fund_Performance_An_Empirical_Decomposition_into_Stock-Picking_Talent_Style_Transactions_Costs_and_Expenses

- Wilson, A. (2013). *The Roman Economy*. Cambridge University Press. Recuperado el 12 de febrero de 2024 de https://assets.cambridge.org/97805218/98225/frontmatter/9780521898225_frontmatter.pdf
- Zarnowitz, V., y Moore, G. H. (1983). Sequential Signals of Recession and Recovery. *Journal of Business*, 56(1), 57-85. Recuperado el 26 de mayo de 2024 de <https://www.nber.org/system/files/chapters/c0690/c0690.pdf>
- Steelman, A. (1978). *Full Employment and Balanced Growth Act of 1978 (Humphrey-Hawkins)*. Federal Reserve History. Recuperado el 17 de abril de 2024 de <https://www.federalreservehistory.org/essays/humphrey-hawkins-act>
- Stuckler, D., Basu, S., Suhrcke, M., Coutts, A., & McKee, M. (2009). The public health effect of economic crises and alternative policy responses in Europe: an empirical analysis. *The Lancet*, 374(9686), 315-323. Recuperado el 12 de abril de 2024 de <https://pubmed.ncbi.nlm.nih.gov/19589588/>
- S&P Global. (2024). *S&P 500 Index*. S&P Dow Jones Indices. Recuperado el 18 de marzo de 2024 de <https://www.spglobal.com/spdji/es/indices/equity/sp-500/#overview>
- Brown, S. J., Goetzmann, W., Ibbotson, R. G., y Ross, S. A. (1992). Survivorship bias in performance studies. *The Review of Financial Studies*, 5(4), 553–580. Recuperado el 9 de febrero de 2024 de <https://doi.org/10.1093/rfs/5.4.553>
- Daryanani, G. (2008). Opportunistic Rebalancing: A New Paradigm for Wealth Managers. *Journal of Financial Planning*, 21(1), 48-61. Recuperado el 22 de febrero de 2024 de <https://www.financialplanningassociation.org/sites/default/files/2020-05/9%20Opportunistic%20Rebalancing%20A%20New%20Paradigm%20for%20Wealth%20Managers.pdf>
- Tokat, Y., & Wicas, N. W. (2007). Portfolio Rebalancing in Theory and Practice. *Vanguard Investment Counseling & Research*, 2007. Recuperado el 22 de febrero de 2024 de <https://indexacapital.com/bundles/unaiadvisor/docs/papers/2007-Vanguard-Portfolio-Rebalancing-in-Theory-and-Practice.pdf?v=236>
- El Bernoussi, R., & Rockinger, M. (2023). Rebalancing with transaction costs: theory, simulations, and actual data. *Financial Markets and Portfolio Management*, 37(1), 121–160. Recuperado el 22 de febrero de 2024 de <https://doi.org/10.1007/s11408-022-00419-6>

- Di Persio, L., Garbelli, M., y Wallbaum, K. (2021). Forward-Looking Volatility Estimation for Risk-Managed Investment Strategies during the COVID-19 Crisis. *Risks*, 9(2), 33. Recuperado el 14 de mayo de 2024 de <https://doi.org/10.3390/risks9020033>
- Wang, F., Yan, X. S., & Zheng, L. (2024). Do sophisticated investors follow fundamental analysis strategies? Evidence from hedge funds and mutual funds. *Review of Accounting Studies*, 29(4), 1097–1146. Recuperado el 14 de mayo de 2024 de <https://doi.org/10.3390/risks9020033>
- Statman, M. (1987). How many stocks make a diversified portfolio? *The Journal of Financial and Quantitative Analysis*, 22(3), 353-363. Recuperado el 14 de mayo de 2024 de <https://www.researchgate.net/publication/227406059> How Many Stocks Make a Diversified Portfolio
- Elton, E. J., & Gruber, M. J. (1977). Risk reduction and portfolio size: An analytical solution. *The Journal of Business*, 50(4), 415-437. Recuperado el 14 de mayo de 2024 de <https://www.researchgate.net/publication/24102674> Risk Reduction and Portfolio Size An Analytical Solution
- Kenan Institute of Private Enterprise. (2022). *Does ESG Investing Generate Higher Returns?*. Recuperado el 12 de abril de 2024 de <https://kenaninstitute.unc.edu/kenan-insight/does-esg-investing-generate-higher-returns/>

ANEXO 1 – CÓDIGO PARA LA PREPARACIÓN DE LAS VARIABLES

Preparación de los datos

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import warnings
```

Cálculo de las variables

```
ROA = pd.read_excel('ROA (yearly).xlsx')
ROA.set_index('Unnamed: 0', inplace=True)

OCF = pd.read_excel('OCF (YEARLY).xlsx')
OCF.set_index('Symbol', inplace=True)

NetIncome = pd.read_excel('Net Income Evolution (Yearly).xlsx')
NetIncome.set_index('Symbol', inplace=True)

LTD = pd.read_excel('LTD (YEARLY).xlsx')
LTD.set_index('Symbol', inplace=True)

CurrentRatio = pd.read_excel('Current Ratio (Yearly).xlsx')
CurrentRatio.set_index('Symbol', inplace=True)

NoShares = pd.read_excel('NoShares Outstanding (yearly).xlsx')
NoShares.set_index('Symbol', inplace=True)

GrossMargin = pd.read_excel('Gross Margin (yearly).xlsx')
GrossMargin.set_index('Symbol', inplace=True)
```

```

AssetTurnover = pd.read_excel('Asset Turnover Ratio (Yearly).xlsx')
AssetTurnover.set_index('Symbol', inplace=True)

A = pd.read_excel('A working capital_total assets (Yearly).xlsx')
A.set_index('Symbol', inplace=True)

B = pd.read_excel('B retained earnings _ total assets (Yearly).xlsx')
B.set_index('Symbol', inplace=True)

C = pd.read_excel('C EBIT _ total assets (Yearly).xlsx')
C.set_index('Symbol', inplace=True)

D = pd.read_excel('D market value of equity _ total liabilities (Y).xlsx')
D.set_index('Symbol', inplace=True)

E = pd.read_excel('E sales _ total assets (Yearly).xlsx')
E.set_index('Symbol', inplace=True)

f_score_ROA = pd.DataFrame(index=ROA.index, columns=ROA.columns)

for i in range(len(ROA.index)):
    for j in range(len(ROA.columns)):
        op_cf = pd.to_numeric(ROA.iloc[i, j], errors='coerce')
        if not np.isnan(op_cf):
            f_score_3 = 1 if op_cf > 0 else 0
            f_score_ROA.iloc[i, j] = f_score_3

f_score_ROA_crec = pd.DataFrame(index=ROA.index, columns=ROA.columns)

for i in range(len(ROA.index)):
    for j in range(len(ROA.columns)):

```

```

    roa = pd.to_numeric(ROA.iloc[i, j], errors='coerce')

    if not np.isnan(roa) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

        f_score_2 = 1 if roa > ROA.iloc[i, j - 12] else 0

        f_score_ROA_crec.iloc[i, j] = f_score_2

f_score_ROA_crec = f_score_ROA_crec.drop(f_score_ROA_crec.columns[0], axis=1)

f_score_OCF = pd.DataFrame(index=OCF.index, columns=OCF.columns)

for i in range(len(OCF.index)):

    for j in range(len(OCF.columns)):

        op_cf = pd.to_numeric(OCF.iloc[i, j], errors='coerce')

        if not np.isnan(op_cf):

            f_score_3 = 1 if op_cf > 0 else 0

            f_score_OCF.iloc[i, j] = f_score_3

f_score_OCF_NI = pd.DataFrame(index=OCF.index, columns=OCF.columns)

for i in range(len(OCF.index)):

    for j in range(len(OCF.columns)):

        op_cf = pd.to_numeric(OCF.iloc[i, j], errors='coerce')

        net_income = pd.to_numeric(NetIncome.iloc[i, j], errors='coerce')

        if not np.isnan(op_cf) and not np.isnan(net_income):

            f_score_4 = 1 if op_cf > net_income else 0

            f_score_OCF_NI.iloc[i, j] = f_score_4

f_score_LTD = pd.DataFrame(index=LTD.index, columns=LTD.columns)

for i in range(len(LTD.index)):

    for j in range(len(LTD.columns)):

        ltd = pd.to_numeric(LTD.iloc[i, j], errors='coerce')

```

```

        if not np.isnan(ltd) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

            f_score_5 = 1 if ltd > LTD.iloc[i, j - 12] else 0

            f_score_LTD.iloc[i, j] = f_score_5

f_score_LTD = f_score_LTD.drop(f_score_LTD.columns[0], axis=1)

f_score_CR = pd.DataFrame(index=CurrentRatio.index,
columns=CurrentRatio.columns)

for i in range(len(CurrentRatio.index)):

    for j in range(len(CurrentRatio.columns)):

        cr = pd.to_numeric(CurrentRatio.iloc[i, j], errors='coerce')

        if not np.isnan(cr) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

            f_score_6 = 1 if cr > CurrentRatio.iloc[i, j - 12] else 0

            f_score_CR.iloc[i, j] = f_score_6

f_score_CR = f_score_CR.drop(f_score_CR.columns[0], axis=1)

f_score_NS = pd.DataFrame(index=NoShares.index, columns=NoShares.columns)

for i in range(len(NoShares.index)):

    for j in range(len(NoShares.columns)):

        nos = pd.to_numeric(NoShares.iloc[i, j], errors='coerce')

        if not np.isnan(nos) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

            f_score_7 = 1 if nos <= NoShares.iloc[i, j - 12] else 0

            f_score_NS.iloc[i, j] = f_score_7

f_score_NS = f_score_NS.drop(f_score_NS.columns[0], axis=1)

f_score_GM = pd.DataFrame(index=GrossMargin.index,
columns=GrossMargin.columns)

for i in range(len(GrossMargin.index)):

```

```

for j in range(len(GrossMargin.columns)):

    gm = pd.to_numeric(GrossMargin.iloc[i, j], errors='coerce')

    if not np.isnan(gm) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

        f_score_5 = 1 if gm > GrossMargin.iloc[i, j - 12] else 0

        f_score_GM.iloc[i, j] = f_score_5

f_score_GM = f_score_GM.drop(f_score_GM.columns[0], axis=1)

f_score_ATR = pd.DataFrame(index=AssetTurnover.index,
columns=AssetTurnover.columns)

for i in range(len(AssetTurnover.index)):

    for j in range(len(AssetTurnover.columns)):

        atr = pd.to_numeric(AssetTurnover.iloc[i, j], errors='coerce')

        if not np.isnan(atr) and j > 0: # Asegurarse de que no sea NaN y no
sea el primer año

            f_score_5 = 1 if atr > AssetTurnover.iloc[i, j - 12] else 0

            f_score_ATR.iloc[i, j] = f_score_5

f_score_ATR = f_score_ATR.drop(f_score_ATR.columns[0], axis=1)

# ALTMAN Z SCORE

Altman_z_score = pd.DataFrame(index=A.index, columns=A.columns)

for i in range(len(A.index)):

    for j in range(len(A.columns)):

        a = A.iloc[i, j]

        b = B.iloc[i, j]

        c = C.iloc[i, j]

        d = D.iloc[i, j]

        e = E.iloc[i, j]

```

```

        # Realiza el producto solo si no todos los valores son NaN

        if not (np.isnan(a) or np.isnan(b) or np.isnan(c) or np.isnan(d) or
np.isnan(e)):

            z_score = (1.2 * a) + (1.4 * b) + (3.3 * c) + (0.6 * d) + (1.0 *
e)

            Altman_z_score.iloc[i, j] = z_score

# PIOTROSKI F SCORE

num_columns = len(f_score_ROA_crec.columns)

piotroski_dataframes = []

for i in range(num_columns):

    year = i

    piotroski_df = pd.concat([f_score_ROA_crec.iloc[:, i], f_score_ROA.iloc[:,
i], f_score_OCF.iloc[:, i], f_score_OCF_NI.iloc[:, i], f_score_LTD.iloc[:, i],
f_score_CR.iloc[:, i], f_score_NS.iloc[:, i], f_score_GM.iloc[:, i],
f_score_ATR.iloc[:, i]], axis=1)

    columns = ['ROA_crec', 'ROA', 'OCF', 'OCF_NI', 'LTD', 'CR', 'NS', 'GM',
'ATR']

    piotroski_df.columns = [f"{col}_{year}" for col in columns]

    piotroski_df['Piotroski_F_Score'] = piotroski_df.sum(axis=1)

    piotroski_dataframes.append(piotroski_df)

for i, df in enumerate(piotroski_dataframes):

    year = i

    globals()[f'Piotroski_{year}'] = df

Piotroski_Completo = pd.DataFrame()

```

```

for year in range(num_columns):

    piotroski_df = globals().get(f'Piotroski_{year}')

    if piotroski_df is not None:

        last_column = piotroski_df.iloc[:, -1]

        Piotroski_Completo[f'Piotroski_{year}'] = last_column

# Instalar openpyxl

!pip install openpyxl

# Exportar el DataFrame a un archivo Excel

Piotroski_Completo.to_excel('Piotroski_Completo.xlsx', index=True)

# Descargar el archivo Excel exportado

from google.colab import files

files.download('Piotroski_Completo.xlsx')

# Exportar el DataFrame a un archivo Excel

Altman_z_score.to_excel('Altman_z_score.xlsx', index=True)

# Descargar el archivo Excel exportado

files.download('Altman_z_score.xlsx')

```

ANEXO 2 – Código para el cálculo y optimización de la estrategia base

```

# Estrategia Base

```



```

#Import libraries
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
import seaborn as sns
from math import sqrt

#Download data

prices_sp = pd.read_excel('SP500_indice.xlsx')
prices_sp['Date'] = pd.to_datetime(prices_sp['Date'])
prices_sp.set_index('Date', inplace=True)
num_days, num_underlying = prices_sp.shape
print(num_days, num_underlying)

Piotroski = pd.read_excel('Piotroski_F-Score.xlsx')
Piotroski.set_index('Date', inplace=True)

Altman = pd.read_excel('Altman_z_score.xlsx')
Altman.set_index('Date', inplace=True)

ESG = pd.read_excel('ESG.xlsx')
ESG.set_index('Date', inplace=True)

Constituents = pd.read_excel('Empresas SP500 por fecha.xlsx')
Constituents.set_index('Date', inplace=True)

precios = pd.read_excel('SP500_constituent_prices.xlsx')
precios.set_index('Date', inplace=True)

# Retornos

returns = pd.DataFrame(index=prices_sp.index)

```

```

returns['ret'] = prices_sp / prices_sp.shift(1) - 1

returns.iloc[0, 0] = 0

all_returns = pd.DataFrame(index=precios.index)

for i in precios.columns:
    all_returns[i] = precios[i] / precios[i].shift(1) - 1
all_returns.iloc[0, :] = 0

# Evitar forward looking

all_returns = all_returns.shift(-1)

all_returns = all_returns.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=all_returns.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

all_returns = pd.concat([new_row, all_returns], axis=0)

# Cálculo Estrategia Base

def calculate_annual_return(nav, periods_per_year):
    total_return = nav.iloc[-1] / nav.iloc[0] - 1
    annualized_return = (1 + total_return) ** (periods_per_year / len(nav)) -
1
    return annualized_return

def calculate_volatility(strategy_returns, periods_per_year):
    annualized_volatility = strategy_returns.std() * sqrt(periods_per_year)
    return annualized_volatility

def calculate_sharpe_ratio(annual_return, annual_volatility):
    return annual_return / annual_volatility if annual_volatility != 0 else
np.nan

```

```

rebalance_frequencies = ['M', '3M', '6M', '12M']

results = {}

for rebalance_frequency in rebalance_frequencies:

    Investment = pd.DataFrame(0, index=Piotroski.index,
columns=Piotroski.columns)

    # Calcular las condiciones en un bucle

    for date in Piotroski.index:

        for company in Piotroski.columns:

            if (Piotroski.loc[date, company] >= 8 and

                Altman.loc[date, company] >= 1.8 and

                ESG.loc[date, company] > 50 and

                Constituents.loc[date, company] == 1):

                Investment.loc[date, company] = 1

    # Evitar forward looking

    Investment = Investment.shift(1)

    No_empresas = pd.DataFrame(0, index=Piotroski.index, columns=['Total'])

    No_empresas['Total'] = Investment.sum(axis=1)

    if rebalance_frequency == 'M':

        # Calcular el retorno mensual compuesto

        monthly_returns = (1 +
all_returns).resample(rebalance_frequency).prod() - 1

        monthly_returns = monthly_returns.iloc[:-1]

        # Crear un nuevo DataFrame para almacenar los resultados

        filtered_returns = pd.DataFrame(index=monthly_returns.index,
columns=monthly_returns.columns)

```

```

# Bucle para multiplicar cada elemento correspondiente
for i in range(monthly_returns.shape[0]): # Recorrer filas
    for j in range(monthly_returns.shape[1]): # Recorrer columnas
        filtered_returns.iloc[i, j] = monthly_returns.iloc[i, j] *
Investment.iloc[i, j]

returns_1 = filtered_returns.sum(axis=1)
returns_1 = returns_1.to_frame(name='Sum')

monthly_strategy_returns = pd.DataFrame(index=returns_1.index,
columns=['Result'])

for i in range(len(returns_1)):
    if No_empresas.iloc[i, 0] == 0:
        monthly_strategy_returns.iloc[i, 0] = 0 # Asignar 0 donde el
divisor es 0 para evitar división por cero
    else:
        monthly_strategy_returns.iloc[i, 0] = returns_1.iloc[i, 0] /
No_empresas.iloc[i, 0]

nav = (1 + monthly_strategy_returns).cumprod()

monthly_SP = (1 + returns).resample('M').prod() - 1
nav_SP = (1 + monthly_SP).cumprod()

strategy_returns = monthly_strategy_returns
periods_per_year = 12

elif rebalance_frequency == '3M':
    Investments2 = Investment.shift(2)
    Investment_trim = Investments2.iloc[3::3].copy()

```

```

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=Investment_trim.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

Investment_trim = pd.concat([new_row, Investment_trim], axis=0)

No_empresas_trim = pd.DataFrame(0, index=Investment_trim.index,
columns=['Total'])

No_empresas_trim['Total'] = Investment_trim.sum(axis=1)

# Calcular el retorno trimestral compuesto
trim_returns = (1 + all_returns).resample('3M').prod() - 1
trim_returns = trim_returns.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=trim_returns.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

trim_returns = pd.concat([new_row, trim_returns], axis=0)

trim_returns = trim_returns.iloc[:-1]

# Crear un nuevo DataFrame para almacenar los resultados

filtered_returns_trim = pd.DataFrame(index=Investment_trim.index,
columns=Investment_trim.columns)

# Bucle para multiplicar cada elemento correspondiente
for i in range(trim_returns.shape[0]): # Recorrer filas
    for j in range(trim_returns.shape[1]): # Recorrer columnas
        filtered_returns_trim.iloc[i, j] = trim_returns.iloc[i, j] *
Investment_trim.iloc[i, j]

returns_2 = filtered_returns_trim.sum(axis=1)

returns_2 = returns_2.to_frame(name='Sum')

```

```

    trim_strategy_returns = pd.DataFrame(index=returns_2.index,
columns=['Result'])

    for i in range(len(returns_2)):

        if No_empresas_trim.iloc[i, 0] == 0:

            trim_strategy_returns.iloc[i, 0] = 0 # Asignar 0 donde el
divisor es 0 para evitar división por cero

        else:

            trim_strategy_returns.iloc[i, 0] = returns_2.iloc[i, 0] /
No_empresas_trim.iloc[i, 0]

    nav = (1 + trim_strategy_returns).cumprod()

    trim_SP = (1 + returns).resample('Q').prod() - 1

    new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=trim_SP.columns)

    new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

    trim_SP = pd.concat([new_row, trim_SP], axis=0)

    nav_SP = (1 + trim_SP).cumprod()

    strategy_returns = trim_strategy_returns

    periods_per_year = 4

elif rebalance_frequency == '6M':

    Investment3 = Investment.shift(5)

    Investment_sem = Investment3.iloc[6::6].copy()

    new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=Investment_sem.columns)

    new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

    Investment_sem = pd.concat([new_row, Investment_sem], axis=0)

```

```

    No_empresas_sem = pd.DataFrame(0, index=Investment_sem.index,
columns=['Total'])

    No_empresas_sem['Total'] = Investment_sem.sum(axis=1)

    # Calcular el retorno semestral compuesto

    sem_returns = (1 + all_returns).resample('6M').prod() - 1

    sem_returns = sem_returns.iloc[1:]

    new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=sem_returns.columns)

    new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

    sem_returns = pd.concat([new_row, sem_returns], axis=0)

    sem_returns = sem_returns.iloc[:-1]

    # Crear un nuevo DataFrame para almacenar los resultados

    filtered_returns_sem = pd.DataFrame(index=Investment_sem.index,
columns=Investment_sem.columns)

    # Bucle para multiplicar cada elemento correspondiente
    for i in range(sem_returns.shape[0]): # Recorrer filas
        for j in range(sem_returns.shape[1]): # Recorrer columnas
            filtered_returns_sem.iloc[i, j] = sem_returns.iloc[i, j] *
Investment_sem.iloc[i, j]

    returns_3 = filtered_returns_sem.sum(axis=1)

    returns_3 = returns_3.to_frame(name='Sum')

    sem_strategy_returns = pd.DataFrame(index=returns_3.index,
columns=['Result'])

    for i in range(len(returns_3)):
        if No_empresas_sem.iloc[i, 0] == 0:

```

```

        sem_strategy_returns.iloc[i, 0] = 0 # Asignar 0 donde el
divisor es 0 para evitar división por cero

    else:

        sem_strategy_returns.iloc[i, 0] = returns_3.iloc[i, 0] /
No_empresas_sem.iloc[i, 0]

nav = (1 + sem_strategy_returns).cumprod()

sem_SP = (1 + returns).resample('6M').prod() - 1
sem_SP = sem_SP.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=sem_SP.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})
sem_SP = pd.concat([new_row, sem_SP], axis=0)

nav_SP = (1 + sem_SP).cumprod()

strategy_returns = sem_strategy_returns
periods_per_year = 2

elif rebalance_frequency == '12M':

    Investment4 = Investment.shift(11)

    Investment_annual = Investment4.iloc[12::12].copy()

    new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=Investment_annual.columns)

    new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

    Investment_annual = pd.concat([new_row, Investment_annual], axis=0)

    No_empresas_annual = pd.DataFrame(0, index=Investment_annual.index,
columns=['Total'])

    No_empresas_annual['Total'] = Investment_annual.sum(axis=1)

```



```

# Calcular el retorno anual compuesto

annual_returns = (1 + all_returns).resample('12M').prod() - 1

annual_returns = annual_returns.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=annual_returns.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})

annual_returns = pd.concat([new_row, annual_returns], axis=0)

annual_returns = annual_returns.iloc[:-1]

# Crear un nuevo DataFrame para almacenar los resultados

filtered_returns_annual = pd.DataFrame(index=Investment_annual.index,
columns=Investment_annual.columns)

# Bucle para multiplicar cada elemento correspondiente

for i in range(annual_returns.shape[0]): # Recorrer filas
    for j in range(annual_returns.shape[1]): # Recorrer columnas
        filtered_returns_annual.iloc[i, j] = annual_returns.iloc[i, j]
* Investment_annual.iloc[i, j]

returns_4 = filtered_returns_annual.sum(axis=1)

returns_4 = returns_4.to_frame(name='Sum')

annual_strategy_returns = pd.DataFrame(index=returns_4.index,
columns=['Result'])

for i in range(len(returns_4)):
    if No_empresas_annual.iloc[i, 0] == 0:
        annual_strategy_returns.iloc[i, 0] = 0 # Asignar 0 donde el
divisor es 0 para evitar división por cero
    else:

```

```

        annual_strategy_returns.iloc[i, 0] = returns_4.iloc[i, 0] /
No_empresas_annual.iloc[i, 0]

nav = (1 + annual_strategy_returns).cumprod()

annual_SP = (1 + returns).resample('12M').prod() - 1
annual_SP = annual_SP.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=annual_SP.columns)

new_row = new_row.assign(**{col: np.nan for col in new_row.columns})
annual_SP = pd.concat([new_row, annual_SP], axis=0)

nav_SP = (1 + annual_SP).cumprod()

strategy_returns = annual_strategy_returns
periods_per_year = 1

# Calcular las métricas
annualized_return = calculate_annual_return(nav, periods_per_year)
annualized_volatility = calculate_volatility(strategy_returns,
periods_per_year)

running_max = nav.cummax()
drawdown = (nav - running_max) / running_max
max_drawdown = drawdown.min().item()
calmar_ratio = annualized_return / abs(max_drawdown)

sharpe_ratio = calculate_sharpe_ratio(annualized_return,
annualized_volatility)

results[rebalance_frequency] = {
    'NAV': nav,

```

```

    'Total Return': nav.iloc[-1] - 1,
    'Annualized Return': annualized_return,
    'Annualized Volatility': annualized_volatility,
    'Max Drawdown': max_drawdown,
    'Calmar Ratio': calmar_ratio,
    'Sharpe Ratio': sharpe_ratio,
    'NAV_SP': nav_SP
}

for key, value in results.items():
    nav, total_return, ann_return, ann_volatility, max_dd, calmar, sharpe,
    nav_SP = (
        value['NAV'], value['Total Return'], value['Annualized Return'],
        value['Annualized Volatility'],
        value['Max Drawdown'], value['Calmar Ratio'], value['Sharpe Ratio'],
        value['NAV_SP']
    )
    print(f"Rebalance Frequency: {key}")
    print(f"Total Return: {total_return}")
    print(f"Annualized Return: {ann_return}")
    print(f"Annualized Volatility: {ann_volatility}")
    print(f"Max Drawdown: {max_dd}")
    print(f"Calmar Ratio: {calmar}")
    print(f"Sharpe Ratio: {sharpe}\n")

plt.figure(figsize=(15,6))
plt.plot(results['12M']['NAV'], label='12M', color='g')
plt.plot(results['6M']['NAV'], label='6M', color='r')
plt.plot(results['3M']['NAV'], label='3M', color='orange')
plt.plot(results['M']['NAV'], label='1M', color='black')
plt.plot(results['M']['NAV_SP'], label='SPX', color='b')
plt.legend(loc='upper left')

```

```
plt.show()
```

ANEXO 3 – Código para calcular la estrategia de Factor Investing

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np
import seaborn as sns
from itertools import product
from tabulate import tabulate

# Cargar datos
prices_sp = pd.read_excel('SP500_indice.xlsx')
prices_sp.set_index('Date', inplace=True)

piotroski = pd.read_excel('Piotroski_F-Score.xlsx')
piotroski.set_index('Date', inplace=True)

altman_z_score = pd.read_excel('Altman_z_score.xlsx')
altman_z_score.set_index('Date', inplace=True)

esg = pd.read_excel('ESG.xlsx')
esg.set_index('Date', inplace=True)

rendimiento_greenblatt = pd.read_excel('EBIT_EV.xlsx')
rendimiento_greenblatt.set_index('Date', inplace=True)
rendimiento_greenblatt = rendimiento_greenblatt.iloc[:-1]

roic_greenblatt = pd.read_excel('EBIT_WC.xlsx')
roic_greenblatt.set_index('Date', inplace=True)
roic_greenblatt = roic_greenblatt.iloc[:-1]
```

```

ev_ebitda = pd.read_excel('EV_EBITDA.xlsx')
ev_ebitda.set_index('Date', inplace=True)
ev_ebitda = ev_ebitda.iloc[: -1]
ev_ebitda = 1 / ev_ebitda

pe_ratio = pd.read_excel('PE.xlsx')
pe_ratio.set_index('Date', inplace=True)
pe_ratio = pe_ratio.iloc[: -1]
pe_ratio = 1 / pe_ratio

price_book = pd.read_excel('P_BV.xlsx')
price_book.set_index('Date', inplace=True)
price_book = price_book.iloc[: -1]
price_book = 1 / price_book

constituents = pd.read_excel('Empresas SP500 por fecha.xlsx')
constituents.set_index('Date', inplace=True)

precios = pd.read_excel('SP500_constituent_prices.xlsx')
precios.set_index('Date', inplace=True)

all_returns = pd.DataFrame(index=precios.index)
for i in precios.columns:
    all_returns[i] = precios[i] / precios[i].shift(1) - 1

tot_ret_3m = pd.read_excel('TR_3M.xlsx')
tot_ret_3m.set_index('Date', inplace=True)
tot_ret_3m = tot_ret_3m.iloc[: -1]

all_returns = all_returns.shift(1)

```

```

# Normalizar datos

piotroski_std = (piotroski - piotroski.mean()) / piotroski.std().fillna(0)

altman_z_score_std = (altman_z_score - altman_z_score.mean()) /
altman_z_score.std().fillna(0)

profitability_raw = (rendimiento_greenblatt + roic_greenblatt)

value_raw = (1 / pe_ratio + price_book + ev_ebitda)

momentum_std = (tot_ret_3m - tot_ret_3m.mean()) / tot_ret_3m.std().fillna(0)

esg_std = (esg - esg.mean()) / esg.std().fillna(0)

# Estandarizar métricas combinadas

profitability_std = (profitability_raw - profitability_raw.mean()) /
profitability_raw.std().fillna(0)

value_std = (value_raw - value_raw.mean()) / value_raw.std().fillna(0)

# Crear lista de métricas estandarizadas

metrics_list = [piotroski_std, altman_z_score_std, profitability_std,
value_std, momentum_std, esg_std]

# Asegurar que todas las métricas tengan los mismos índices y columnas

common_index = piotroski.index

common_columns = piotroski.columns

metrics_list = [pd.DataFrame(metric).reindex(index=common_index,
columns=common_columns).fillna(0) for metric in metrics_list]

# Generar combinaciones de pesos

def generate_weights(num_metrics, num_combinations):

    possible_weights = [0, 0.1, 0.2, 0.3, 0.4, 0.5]

    all_combinations = [comb for comb in product(possible_weights,
repeat=num_metrics) if sum(comb) == 1]

    selected_combinations = np.random.choice(len(all_combinations),
num_combinations, replace=False)

    return [all_combinations[i] for i in selected_combinations]

```

```

num_combinations = 40

results = []

# Definir frecuencias de rebalanceo y número de compañías a seleccionar
rebalance_frequencies = ['M', '3M', '6M', '12M']
top_n_values = [10, 20, 30]
periods_per_year = {'M': 12, '3M': 4, '6M': 2, '12M': 1}
total_periods = {'M': 204, '3M': 68, '6M': 34, '12M': 17}

# Calcular métricas combinadas y estrategias para cada combinación de pesos
for weights in generate_weights(len(metrics_list), num_combinations):
    combined_metrics = sum(w * metric for w, metric in zip(weights,
metrics_list))

    combined_metrics = (combined_metrics - combined_metrics.mean()) /
combined_metrics.std()

    ranked_metrics = combined_metrics.rank(axis=1, method='min',
ascending=False)

    for rebalance_frequency in rebalance_frequencies:
        for top_n in top_n_values:
            new_df = pd.DataFrame(index=ranked_metrics.index,
columns=ranked_metrics.columns)

            for period in ranked_metrics.index:
                top_companies =
ranked_metrics.loc[period].nsmallest(top_n).index

                count = 0

                selected_companies = []

                for company in top_companies:
                    if constituents.loc[period, company] == 1:

```

```

        selected_companies.append(company)

        count += 1

        if count == top_n:

            break

    for company in ranked_metrics.columns:

        new_df.loc[period, company] = 1 if company in
selected_companies else 0

    new_df.fillna(0, inplace=True)

    top_companies = new_df.shift(1)

    top_companies.iloc[0, :] = 0

    period_returns = (1 +
all_returns).resample(rebalance_frequency).prod() - 1

    period_returns = period_returns.iloc[:-1]

    ret_top_n = pd.DataFrame(index=period_returns.index,
columns=period_returns.columns)

    for i in range(period_returns.shape[0]):

        for j in range(period_returns.shape[1]):

            ret_top_n.iloc[i, j] = period_returns.iloc[i, j] *
top_companies.iloc[i, j]

    ret_top_n = ret_top_n.shift(1)

    returns_top_n = ret_top_n.sum(axis=1).to_frame(name='Sum')

    strategy_returns = returns_top_n / top_n

    nav = (1 + strategy_returns).cumprod()

    total_return = nav.iloc[-1].item() - 1

    periods = periods_per_year[rebalance_frequency]

    tot_periods = total_periods[rebalance_frequency]

```



```

        annualized_return = (1 + total_return) ** (periods / tot_periods)
- 1

        annualized_volatility = strategy_returns.std().item() *
np.sqrt(periods)

        sharpe_ratio = (annualized_return / annualized_volatility).item()

        running_max = nav.cummax()

        drawdown = (nav - running_max) / running_max

        max_drawdown = drawdown.min().item()

        calmar_ratio = annualized_return / abs(max_drawdown)

        results.append([

            rebalance_frequency, top_n, total_return, sharpe_ratio,
max_drawdown,

            calmar_ratio, annualized_return, annualized_volatility,
weights

        ])

results_df = pd.DataFrame(results, columns=[

    'Rebalance Period', 'Number of Companies', 'Total Return', 'Sharpe Ratio',

    'Maximum Drawdown', 'Calmar Ratio', 'Annualized Return', 'Annualized
Volatility',

    'Weights'

])

results = results_df.sort_values(by='Sharpe Ratio', ascending=False)

```

ANEXO 4 – Cálculo y optimización de las estrategias con herramientas de *market timing*

```

# Import libraries
import pandas as pd

```

```

import matplotlib.pyplot as plt

import numpy as np

import seaborn as sns

# Download data

prices_sp = pd.read_excel('SP500_mensual.xlsx')
prices_sp.set_index('Date', inplace=True)
num_days, num_underlying = prices_sp.shape
print(num_days, num_underlying)

precios = pd.read_excel('SP500_constituent_prices.xlsx')
precios.set_index('Date', inplace=True)

moving_avg_period = 12
time_factor = 12
size_long = 1
size_short = -1

estrategia_base_long = pd.read_excel('EstrategiaBase.xlsx')
estrategia_base_long.set_index('Date', inplace=True)
estrategia_base_long = estrategia_base_long.shift(1)

estrategia_factor_long = pd.read_excel('FactorInvesting.xlsx')
estrategia_factor_long.set_index('Date', inplace=True)

estrategia_base_short = pd.read_excel('EstrategiaBase_short.xlsx')
estrategia_base_short.set_index('Date', inplace=True)
estrategia_base_short = estrategia_base_short.shift(1)

estrategia_factor_short = pd.read_excel('FactorInvesting_short.xlsx')
estrategia_factor_short.set_index('Date', inplace=True)

```

```

gold = pd.read_excel('Gold.xlsx')
gold.set_index('Date', inplace=True)

bond_10yr = pd.read_excel('RFR.xlsx')
bond_10yr.set_index('Date', inplace=True)
bond_10yr = (bond_10yr / 120) * -1
bond_10yr.iloc[0, 0] = 0
bond_10yr = bond_10yr.rename(columns={bond_10yr.columns[0]: 'Result'})

# Regla de Sahm

sahm_data = pd.read_excel('Sahm.xlsx')
sahm_data.set_index('Date', inplace=True)

num_days, col = sahм_data.shape
time_factor = 12

sahm_data['3M Moving Average'] =
sahm_data['Unemployment'].rolling(window=3).mean()

# Calcular el mínimo de la tasa de desempleo en los últimos 12 meses
sahm_data['12M Min'] = sahм_data['Unemployment'].rolling(time_factor).min()

# Calcular la diferencia entre el promedio móvil de 3 meses y el mínimo de 12 meses
sahm_data['Difference'] = sahм_data['3M Moving Average'] - sahм_data['12M Min']

# Identificar las señales de la Regla de Sahm
sahm_data['Sahm Trigger'] = (sahм_data['Difference'] >= 0.005).astype(int)

sahm_data = sahм_data.iloc[31:-4]

```

```

sahm_data['Strategy'] = np.where(sahm_data['Value'] >= 0.5, -1, 1)
sahm_data['Threshold'] = 0.5

# Monthly returns
returns = pd.DataFrame(index=prices_sp.index)
returns['Result'] = prices_sp / prices_sp.shift(1) - 1
returns.iloc[0, 0] = 0

returns_gold = pd.DataFrame(index=gold.index)
returns_gold['Result'] = gold / gold.shift(1) - 1
returns_gold.iloc[0, 0] = 0

all_returns = pd.DataFrame(index=precios.index)
for i in precios.columns:
    all_returns[i] = precios[i] / precios[i].shift(1) - 1

all_returns.iloc[0, :] = 0
all_returns = all_returns.shift(-1)
all_returns = all_returns.iloc[1:]

new_row = pd.DataFrame(index=[pd.to_datetime('2007-01-31')],
columns=all_returns.columns)
new_row = new_row.assign(**{col: np.nan for col in new_row.columns})
new_row

all_returns = pd.concat([new_row, all_returns], axis=0)
all_returns.iloc[0, :] = 0

# Calcular el retorno mensual compuesto
monthly_returns = (1 + all_returns).resample('M').prod() - 1
monthly_returns = monthly_returns.iloc[:-1]

```

```

# Crear un DataFrame No_empresas para almacenar el número de empresas

No_empresas = pd.DataFrame(0, index=estrategia_factor_long.index,
columns=['Total'])

No_empresas['Total'] = estrategia_factor_long.sum(axis=1)

# Crear un nuevo DataFrame para almacenar los resultados filtrados

filtered_returns = pd.DataFrame(index=estrategia_factor_long.index,
columns=estrategia_factor_long.columns)

# Bucle para multiplicar cada elemento correspondiente

for i in range(monthly_returns.shape[0]): # Recorrer filas
    for j in range(monthly_returns.shape[1]): # Recorrer columnas
        filtered_returns.iloc[i, j] = monthly_returns.iloc[i, j] *
estrategia_factor_long.iloc[i, j]

# Sumar los resultados filtrados por filas

returns_1 = filtered_returns.sum(axis=1)
returns_1 = returns_1.to_frame(name='Sum')

# Crear un DataFrame para almacenar los resultados finales de la estrategia

factor_strategy_returns_long = pd.DataFrame(index=returns_1.index,
columns=['Result'])

# Calcular los retornos ajustados por el número de empresas

for i in range(len(returns_1)):
    if No_empresas.iloc[i, 0] == 0:
        factor_strategy_returns_long.iloc[i, 0] = 0
    else:
        factor_strategy_returns_long.iloc[i, 0] = returns_1.iloc[i, 0] /
No_empresas.iloc[i, 0]

factor_strategy_returns_long

```

```

# Crear un DataFrame No_empresas para almacenar el número de empresas
No_empresas = pd.DataFrame(0, index=estrategia_base_long.index,
columns=['Total'])

No_empresas['Total'] = estrategia_base_long.sum(axis=1)

# Crear un nuevo DataFrame para almacenar los resultados filtrados
filtered_returns = pd.DataFrame(index=estrategia_base_long.index,
columns=estrategia_base_long.columns)

# Bucle para multiplicar cada elemento correspondiente
for i in range(monthly_returns.shape[0]): # Recorrer filas
    for j in range(monthly_returns.shape[1]): # Recorrer columnas
        filtered_returns.iloc[i, j] = monthly_returns.iloc[i, j] *
estrategia_base_long.iloc[i, j]

# Sumar los resultados filtrados por filas
returns_1 = filtered_returns.sum(axis=1)
returns_1 = returns_1.to_frame(name='Sum')

# Crear un DataFrame para almacenar los resultados finales de la estrategia
base_strategy_returns_long = pd.DataFrame(index=returns_1.index,
columns=['Result'])

# Calcular los retornos ajustados por el número de empresas
for i in range(len(returns_1)):
    if No_empresas.iloc[i, 0] == 0:
        base_strategy_returns_long.iloc[i, 0] = 0
    else:
        base_strategy_returns_long.iloc[i, 0] = returns_1.iloc[i, 0] /
No_empresas.iloc[i, 0]

base_strategy_returns_long

```

```

# Crear un DataFrame No_empresas para almacenar el número de empresas
No_empresas = pd.DataFrame(0, index=estrategia_base_short.index,
columns=['Total'])

No_empresas['Total'] = estrategia_base_short.sum(axis=1)

# Crear un nuevo DataFrame para almacenar los resultados filtrados
filtered_returns = pd.DataFrame(index=estrategia_base_short.index,
columns=estrategia_base_short.columns)

# Bucle para multiplicar cada elemento correspondiente
for i in range(monthly_returns.shape[0]): # Recorrer filas
    for j in range(monthly_returns.shape[1]): # Recorrer columnas
        filtered_returns.iloc[i, j] = monthly_returns.iloc[i, j] *
estrategia_base_short.iloc[i, j]

# Sumar los resultados filtrados por filas
returns_1 = filtered_returns.sum(axis=1)
returns_1 = returns_1.to_frame(name='Sum')

# Crear un DataFrame para almacenar los resultados finales de la estrategia
base_strategy_returns_short = pd.DataFrame(index=returns_1.index,
columns=['Result'])

# Calcular los retornos ajustados por el número de empresas
for i in range(len(returns_1)):
    if No_empresas.iloc[i, 0] == 0:
        base_strategy_returns_short.iloc[i, 0] = 0
    else:
        base_strategy_returns_short.iloc[i, 0] = returns_1.iloc[i, 0] /
No_empresas.iloc[i, 0]

base_strategy_returns_short

```

```

import pandas as pd

# Crear un DataFrame No_empresas para almacenar el número de empresas
No_empresas = pd.DataFrame(0, index=estrategia_factor_short.index,
columns=['Total'])

No_empresas['Total'] = estrategia_factor_short.sum(axis=1)

# Crear un nuevo DataFrame para almacenar los resultados filtrados
filtered_returns = pd.DataFrame(index=estrategia_factor_short.index,
columns=estrategia_factor_short.columns)

# Bucle para multiplicar cada elemento correspondiente
for i in range(monthly_returns.shape[0]): # Recorrer filas
    for j in range(monthly_returns.shape[1]): # Recorrer columnas
        filtered_returns.iloc[i, j] = monthly_returns.iloc[i, j] *
estrategia_factor_short.iloc[i, j]

# Sumar los resultados filtrados por filas
returns_1 = filtered_returns.sum(axis=1)
returns_1 = returns_1.to_frame(name='Sum')

# Crear un DataFrame para almacenar los resultados finales de la estrategia
factor_strategy_returns_short = pd.DataFrame(index=returns_1.index,
columns=['Result'])

# Calcular los retornos ajustados por el número de empresas
for i in range(len(returns_1)):
    if No_empresas.iloc[i, 0] == 0:
        factor_strategy_returns_short.iloc[i, 0] = 0
    else:
        factor_strategy_returns_short.iloc[i, 0] = returns_1.iloc[i, 0] /
No_empresas.iloc[i, 0]

```



```

factor_strategy_returns_short

long_strategies = [base_strategy_returns_long, factor_strategy_returns_long]

short_strategies = [returns, returns_gold, bond_10yr,
base_strategy_returns_short, factor_strategy_returns_short]

# Optimización Moving Average

import warnings

import numpy as np

import pandas as pd

from math import sqrt

warnings.filterwarnings("ignore", category=RuntimeWarning)

# Variables iniciales

best_sharpe_ratio = 0

optimal_moving_avg_period = 0

optimal_size_long = 0

optimal_size_short = 0

optimal_long_strategy = None

optimal_short_strategy = None

strategy_return = 0.0

risk_free_rate = 0.00

long_strategies = {

    "base_strategy_returns_long": base_strategy_returns_long,

    "factor_strategy_returns_long": factor_strategy_returns_long

}

short_strategies = {

    "returns": returns,

    "returns_gold": returns_gold,

```

```

    "bond_10yr": bond_10yr,

    "base_strategy_returns_short": base_strategy_returns_short,

    "factor_strategy_returns_short": factor_strategy_returns_short
}

results_list = []

# Parámetros de tiempo
num_months = len(prices_sp)
time_factor = 12

for moving_avg_period_i in range(2, 13):
    for size_long_i in np.arange(0.1, 1.1, 0.1):
        for size_short_i in np.arange(0.1, 1.1, 0.1):
            for long_strategy in long_strategies:
                for short_strategy in short_strategies:

                    # Calcular la media móvil

                    moving_average =
prices_sp.rolling(moving_avg_period_i).mean()

                    # Inicializar el DataFrame para las señales de la
estrategia

                    strategy_returns = pd.DataFrame(index=prices_sp.index)
                    strategy_returns['SP500'] = 0

                    # Generar señales de compra (long) y venta (short)

                    strategy_returns[prices_sp >= moving_average] =
size_long_i

                    strategy_returns[prices_sp < moving_average] = -
size_short_i

                    # Shift para evitar el look-ahead bias

```

```

strategy_returns = strategy_returns.shift(1)

# Inicializa una serie para los retornos de la estrategia
strategy_returns['Strategy Returns'] = 0

# Calcular los retornos de la estrategia dependiendo de la
posición

long_str = long_strategies[long_strategy]
short_str = short_strategies[short_strategy]
strategy_returns.loc[strategy_returns['SP500'] >= 0,
'Strategy Returns'] = size_long_i * long_str['Result']
strategy_returns.loc[strategy_returns['SP500'] < 0,
'Strategy Returns'] = -size_short_i * short_str['Result']

# Calcular el NAV de la estrategia
nav_strategy = (1 + strategy_returns['Strategy
Returns']).cumprod().mul(100)

tot_return = nav_strategy.iloc[-1] - 100

# Calcular los retornos anuales y la volatilidad
ann_return_strategy = (nav_strategy.iloc[-1] / 100) **
(time_factor / num_months) - 1
ann_volatility = strategy_returns['Strategy
Returns'].std() * sqrt(time_factor)

# Calcular el ratio de Sharpe
sharpe_ratio = (ann_return_strategy - risk_free_rate) /
ann_volatility

# Calcular el Maximum Drawdown
running_max = nav_strategy.cummax()
drawdown = (nav_strategy - running_max) / running_max
max_drawdown = drawdown.min().item()

```

```

        # Calcular el Calmar Ratio

        calmar_ratio = ann_return_strategy / abs(max_drawdown)

        results_list.append([moving_avg_period_i, size_long_i,
size_short_i, tot_return, ann_return_strategy, ann_volatility, sharpe_ratio,
max_drawdown, calmar_ratio, long_strategy, short_strategy])

    # Actualizar los mejores resultados
    if sharpe_ratio > best_sharpe_ratio:
        best_sharpe_ratio = sharpe_ratio
        optimal_moving_avg_period = moving_avg_period_i
        optimal_size_long = size_long_i
        optimal_size_short = size_short_i
        optimal_long_strategy = long_strategy
        optimal_short_strategy = short_strategy
        strategy_return = ann_return_strategy

# Crear un DataFrame con los resultados

results_df = pd.DataFrame(results_list, columns=['Moving Avg Period', 'Size
Long', 'Size Short', 'Total Return', 'Annual Return', 'Annual Volatility',
'Sharpe Ratio', 'Max DD', 'Calmar Ratio', 'Long Strategy', 'Short Strategy'])

# Imprimir los resultados óptimos

print("Optimal Moving Avg Period:", optimal_moving_avg_period)

print("Optimal Size Long:", optimal_size_long)

print("Optimal Size Short:", optimal_size_short)

print("Optimal Long Strategy:", optimal_long_strategy)

print("Optimal Short Strategy:", optimal_short_strategy)

print("Optimal Ann Return:", round(strategy_return, 5))

print("Best Sharpe Ratio:", round(best_sharpe_ratio, 5))

results_df.sort_values(by='Total Return', ascending=False)

```

Optimización Bandas de Bollinger

```
import warnings

import numpy as np

import pandas as pd

from math import sqrt

warnings.filterwarnings("ignore", category=RuntimeWarning)

# Variables iniciales

best_sharpe_ratio = 0

optimal_moving_avg_period = 0

optimal_size_long = 0

optimal_size_short = 0

optimal_long_strategy = None

optimal_short_strategy = None

strategy_return = 0.0

risk_free_rate = 0.00

long_strategies = {

    "base_strategy_returns_long": base_strategy_returns_long,

    "factor_strategy_returns_long": factor_strategy_returns_long

}

short_strategies = {

    "returns": returns,

    "returns_gold": returns_gold,

    "bond_10yr": bond_10yr,

    "base_strategy_returns_short": base_strategy_returns_short,

    "factor_strategy_returns_short": factor_strategy_returns_short

}
```

```

results_list = []

# Parámetros de tiempo
num_months = len(prices_sp)
time_factor = 12

for time_window_length_i in range(2, 13):
    for size_long_i in np.arange(0.1, 1.1, 0.1):
        for size_short_i in np.arange(0.1, 1.1, 0.1):
            for size_med_i in np.arange(-1, 1.1, 0.1):
                for long_strategy in long_strategies:
                    for short_strategy in short_strategies:

                        # Calcular la media móvil
                        df_rolling_volatility =
prices_sp.rolling(time_window_length_i).std()

                        df_prices_mov_average =
prices_sp.rolling(time_window_length_i).mean()

                        df_upper_Bollinger_band = df_prices_mov_average +
df_rolling_volatility

                        df_lower_Bollinger_band = df_prices_mov_average -
df_rolling_volatility

                        strategy_returns = pd.DataFrame(index=prices_sp.index)

                        # Generar señales de compra (long) y venta (short)
                        strategy_returns[prices_sp['SP500'] >=
df_upper_Bollinger_band['SP500']] = size_long_i

                        strategy_returns[prices_sp['SP500'] <=
df_lower_Bollinger_band['SP500']] = - size_short_i

```

```

        strategy_returns[(prices_sp['SP500'] >
df_lower_Bollinger_band['SP500']) & (prices_sp['SP500'] <
df_upper_Bollinger_band['SP500'])] = size_med_i

# Shift para evitar el look-ahead bias
strategy_returns = strategy_returns.shift(1)

# Inicializa una serie para los retornos de la estrategia
strategy_returns['SP500'] = 0

# Calcular los retornos de la estrategia dependiendo de la
posición

long_str = long_strategies[long_strategy]
short_str = short_strategies[short_strategy]
strategy_returns.loc[strategy_returns['SP500'] >= 0,
'Strategy Returns'] = size_long_i * long_str['Result']
strategy_returns.loc[strategy_returns['SP500'] < 0,
'Strategy Returns'] = -size_short_i * short_str['Result']

# Calcular el NAV de la estrategia
nav_strategy = (1 + strategy_returns['Strategy
Returns']).cumprod().mul(100)

tot_return = nav_strategy.iloc[-1]

# Calcular los retornos anuales y la volatilidad
ann_return_strategy = (nav_strategy.iloc[-1] + 100 / 100)
** (time_factor / num_months) - 1
ann_volatility = strategy_returns['Strategy
Returns'].std() * sqrt(time_factor)

# Calcular el ratio de Sharpe
sharpe_ratio = (ann_return_strategy - risk_free_rate) /
ann_volatility

```

```

# Calcular el Maximum Drawdown

running_max = nav_strategy.cummax()

drawdown = (nav_strategy - running_max) / running_max

max_drawdown = drawdown.min().item()

# Calcular el Calmar Ratio

calmar_ratio = ann_return_strategy / abs(max_drawdown)

results_list.append([moving_avg_period_i, size_long_i,
size_short_i, size_med_i, tot_return, ann_return_strategy, ann_volatility,
sharpe_ratio, max_drawdown, calmar_ratio, long_strategy, short_strategy])

# Actualizar los mejores resultados

if sharpe_ratio > best_sharpe_ratio:

    best_sharpe_ratio = sharpe_ratio

    optimal_moving_avg_period = moving_avg_period_i

    optimal_size_long = size_long_i

    optimal_size_short = size_short_i

    optimal_long_strategy = long_strategy

    optimal_short_strategy = short_strategy

    strategy_return = ann_return_strategy

# Crear un DataFrame con los resultados

results_df_2 = pd.DataFrame(results_list, columns=['Moving Avg Period', 'Size
Long', 'Size Short', 'Size Med', 'Total Return', 'Annual Return', 'Annual
Volatility', 'Sharpe Ratio', 'Max DD', 'Calmar Ratio', 'Long Strategy', 'Short
Strategy'])

# Imprimir los resultados óptimos

print("Optimal Moving Avg Period:", optimal_moving_avg_period)

print("Optimal Size Long:", optimal_size_long)

print("Optimal Size Short:", optimal_size_short)

print("Optimal Long Strategy:", optimal_long_strategy)

```



```

print("Optimal Short Strategy:", optimal_short_strategy)
print("Optimal Ann Return:", round(strategy_return, 5))
print("Best Sharpe Ratio:", round(best_sharpe_ratio, 5))

results_df_2

# Optimización Regla de Sahn

import warnings

import numpy as np

import pandas as pd

from math import sqrt

warnings.filterwarnings("ignore", category=RuntimeWarning)

# Variables iniciales

best_sharpe_ratio = 0

optimal_moving_avg_period = 0

optimal_size_long = 0

optimal_size_short = 0

optimal_long_strategy = None

optimal_short_strategy = None

strategy_return = 0.0

risk_free_rate = 0.00

long_strategies = {

    "base_strategy_returns_long": base_strategy_returns_long,

    "factor_strategy_returns_long": factor_strategy_returns_long

}

short_strategies = {

    "returns": returns,

```

```

"returns_gold": returns_gold,

"bond_10yr": bond_10yr,

"base_strategy_returns_short": base_strategy_returns_short,

"factor_strategy_returns_short": factor_strategy_returns_short
}

results_list = []

# Parámetros de tiempo
num_months = len(prices_sp)
time_factor = 12

for size_long_i in np.arange(0.1, 1.1, 0.1):
    for size_short_i in np.arange(0.1, 1.1, 0.1):
        for long_strategy in long_strategies:
            for short_strategy in short_strategies:

                strategy_returns = pd.DataFrame(index=prices_sp.index)

                # Generar señales de compra (long) y venta (short)
                strategy_returns[sahm_data['Strategy'] == 1] = size_long_i
                strategy_returns[sahm_data['Strategy'] == -1] = -size_short_i

                # Shift para evitar el look-ahead bias
                strategy_returns = strategy_returns.shift(1)

                # Inicializa una serie para los retornos de la estrategia
                strategy_returns['SP500'] = 0

                # Calcular los retornos de la estrategia dependiendo de la
posición

                long_str = long_strategies[long_strategy]

```

```

        short_str = short_strategies[short_strategy]

        strategy_returns.loc[strategy_returns['SP500'] >= 0, 'Strategy
Returns'] = size_long_i * long_str['Result']

        strategy_returns.loc[strategy_returns['SP500'] < 0, 'Strategy
Returns'] = -size_short_i * short_str['Result']

        # Calcular el NAV de la estrategia

        nav_strategy = (1 + strategy_returns['Strategy
Returns']).cumprod().mul(100)

        tot_return = nav_strategy.iloc[-1] - 100

        # Calcular los retornos anuales y la volatilidad

        ann_return_strategy = (nav_strategy.iloc[-1] / 100) **
(time_factor / num_months) - 1

        ann_volatility = strategy_returns['Strategy Returns'].std() *
sqrt(time_factor)

        # Calcular el ratio de Sharpe

        sharpe_ratio = (ann_return_strategy - risk_free_rate) /
ann_volatility

        # Calcular el Maximum Drawdown

        running_max = nav_strategy.cummax()

        drawdown = (nav_strategy - running_max) / running_max

        max_drawdown = drawdown.min().item()

        # Calcular el Calmar Ratio

        calmar_ratio = ann_return_strategy / abs(max_drawdown)

        results_list.append([moving_avg_period_i, size_long_i,
size_short_i, tot_return, ann_return_strategy, ann_volatility, sharpe_ratio,
max_drawdown, calmar_ratio, long_strategy, short_strategy])

```

```

# Actualizar los mejores resultados

if sharpe_ratio > best_sharpe_ratio:

    best_sharpe_ratio = sharpe_ratio

    optimal_moving_avg_period = moving_avg_period_i

    optimal_size_long = size_long_i

    optimal_size_short = size_short_i

    optimal_long_strategy = long_strategy

    optimal_short_strategy = short_strategy

    strategy_return = ann_return_strategy

# Crear un DataFrame con los resultados

results_df_3 = pd.DataFrame(results_list, columns=['Moving Avg Period', 'Size
Long', 'Size Short', 'Total Return', 'Annual Return', 'Annual Volatility',
'Sharpe Ratio', 'Max DD', 'Calmar Ratio', 'Long Strategy', 'Short Strategy'])

# Imprimir los resultados óptimos

print("Optimal Moving Avg Period:", optimal_moving_avg_period)

print("Optimal Size Long:", optimal_size_long)

print("Optimal Size Short:", optimal_size_short)

print("Optimal Long Strategy:", optimal_long_strategy)

print("Optimal Short Strategy:", optimal_short_strategy)

print("Optimal Ann Return:", round(strategy_return, 5))

print("Best Sharpe Ratio:", round(best_sharpe_ratio, 5))

results_df_3

```