RICCA
Revista de Investigación en Ciencias Contables y Administrativas

Optimización de portafolios financieros utilizando simulaciones de Monte Carlo y Python

Optimization of financial portfolios using Monte Carlo simulations and Python

José Gerardo De La Vega Meneses

Universidad Popular Autónoma del Estado de Puebla, México · ORCID 0000-0001-6748-5901

Aceptado: 20 de noviembre de 2026

Correo de contacto: josegerardo.delavega@upaep.mx

© Universidad Michoacana de San Nicolás de Hidalgo
Licencia Creative Commons CC BY-NC 4.0

Vol. 14, Núm. 2, Julio-Diciembre de 2026, pp. 106-135 · ISSN electrónico 2448-606X

Facultad de Contaduría y Ciencias Administrativas
Ave. Gral. Francisco J. Múgica S/N, Edificio AII
Col. Felícitas del Río, C.P. 58030, Morelia, Michoacán
ricca.publicaciones@umich.mx · ricca.umich.mx

Resumen:

Este estudio simula la construcción de portafolios utilizando 10 acciones tanto del índice Dow Jones, como de las bolsas de valores de México, Japón y Colombia, aplicando simulaciones de Monte Carlo para generar diversas combinaciones de ponderaciones. El análisis calcula tres métricas clave: rendimiento esperado, volatilidad y índice de Sharpe. Se utilizan precios históricos de cierre de las acciones seleccionadas desde 2014 hasta 2024, los cuales se someten a un reescalamiento a base 1 para facilitar la comparación. Después de realizar 1,000 simulaciones, se identifican los portafolios con el mayor índice de Sharpe para cada mercado. Los resultados destacan al índice Dow Jones como el más eficiente con un índice de Sharpe de 1.28, superando a los mercados de Japón (0.77), Colombia (0.45) y México (0.41). Los hallazgos se visualizan en un gráfico de frontera eficiente, destacando el portafolio óptimo, lo que permite a los inversores seleccionar la mejor combinación de riesgo y retorno.

Palabras clave: Monte Carlo, portafolios, índice de Sharpe, frontera eficiente, Markowitz, Python.

Códigos JEL: C63; G11; G15.

Optimization of financial portfolios using Monte Carlo simulations and Python

Abstract:

This study simulates portfolio construction using 10 stocks from each of the following markets: the Dow Jones Index and the stock exchanges of Mexico, Japan, and Colombia. Monte Carlo simulations are applied to generate various combinations of portfolio weights. The analysis calculates three key metrics: expected return, volatility, and the Sharpe ratio. Historical closing prices for the selected stocks from 2014 to 2024 are used and normalized to a base value of 1 to facilitate comparison. After conducting 1,000 simulations, the portfolios with the highest Sharpe ratio are identified for each market. The results highlight the Dow Jones Index as the most efficient market, with a Sharpe ratio of 1.28, outperforming Japan (0.77), Colombia (0.45), and Mexico (0.41). The findings are illustrated using an efficient frontier graph, highlighting the optimal portfolio and enabling investors to select the best risk-return combination.

Keywords: Monte Carlo, portfolios, Sharpe ratio, efficient frontier, Markowitz, Python.

JEL Codes: C63; G11; G15.

1. Introducción

La optimización de portafolios es un pilar fundamental en la toma de decisiones financieras, ya que permite a los inversores maximizar el retorno esperado mientras gestionan los riesgos inherentes a las inversiones (Mendonça et al., 2020). En este contexto, la simulación de Monte Carlo se ha consolidado como una herramienta poderosa para evaluar diferentes combinaciones de activos, proporcionando una aproximación robusta para la optimización de portafolios en mercados de capitales diversos (Gunjan y Bhattacharyya, 2023). Este estudio tiene como objetivo simular la construcción de portafolios de inversión utilizando 10 acciones representativas del índice Dow Jones, así como de las bolsas de valores de México, Japón y Colombia. A través de simulaciones de Monte Carlo, se generan distintas combinaciones de pesos en el portafolio, y se calculan tres métricas clave: rendimiento esperado, volatilidad y índice de Sharpe. El propósito es identificar el portafolio más eficiente, es decir, aquel que maximiza el rendimiento ajustado al riesgo (Pankunni y Kumar, 2020).

El proceso comienza con la recopilación de precios históricos de cierre de las acciones seleccionadas desde 2014 hasta 2024. Estos datos se limpian y estandarizan para permitir una comparación precisa entre las distintas acciones. Posteriormente, se realizan 1,000 simulaciones para generar combinaciones aleatorias de pesos, asegurando que la suma de los mismos sea 1. Los resultados se presentan en forma tabular y gráfica, destacando la frontera eficiente, lo que facilita la identificación del portafolio óptimo. Este análisis resalta la efectividad de las simulaciones de Monte Carlo en la optimización de portafolios y en la evaluación de oportunidades de inversión en función de su rendimiento y riesgo.

1.1. Objetivo general

Aplicar simulaciones de Monte Carlo para la construcción de portafolios de inversión utilizando 10 acciones representativas del índice Dow Jones y las bolsas de valores de México, Japón y Colombia, calculando métricas de rendimiento ajustado al riesgo, con el fin de identificar el portafolio más eficiente.

1.2. Objetivos específicos

El primero es obtener los precios históricos de cierre de las 10 acciones seleccionadas del índice Dow Jones y las bolsas de valores de México, Japón y Colombia, para el periodo comprendido entre 2014 y 2024. El segundo es realizar la limpieza de los datos eliminando valores nulos o incorrectos, reemplazándolos por el precio más reciente disponible para asegurar la consistencia del análisis. El tercero es escalar los precios de cierre para estandarizar las acciones, de modo que todas comiencen con un valor de 1, permitiendo comparaciones precisas entre las variaciones porcentuales de cada acción. El cuarto es generar 1,000 simulaciones de Monte Carlo para calcular el rendimiento esperado, la volatilidad y el índice de Sharpe de cada portafolio, y seleccionar el más eficiente basado en el mayor índice de Sharpe.

2. Marco teórico

La optimización de portafolios es una de las disciplinas más relevantes dentro del campo de las finanzas, especialmente en lo que respecta a la gestión de inversiones en mercados de capitales. Este proceso no solo constituye la base para una asignación eficiente de recursos, sino que también tiene

como propósito fundamental identificar las combinaciones más rentables y balanceadas de activos, a fin de maximizar los rendimientos esperados mientras se gestionan adecuadamente los riesgos inherentes al contexto de inversión (Vo et al., 2019). En términos sencillos, la optimización de portafolios busca permitir a los inversores lograr un balance adecuado entre rentabilidad y riesgo. Este proceso requiere de un análisis meticuloso, sustentado en una serie de variables clave como el retorno esperado, la volatilidad y el rendimiento ajustado al riesgo (Ma et al., 2021).

En el desarrollo de la optimización de portafolios, la medición, evaluación y ajuste de las características de los activos que lo componen resulta esencial (Saunders et al., 2021). Para realizar este tipo de optimización, los analistas y gestores financieros emplean una variedad de metodologías y herramientas especializadas que les permiten modelar y evaluar el comportamiento de los portafolios bajo una diversidad de escenarios de mercado. Estas herramientas, lejos de ser meros instrumentos técnicos, son cruciales para llevar a cabo una correcta toma de decisiones en el ámbito de las inversiones, pues facilitan la identificación de las mejores combinaciones de activos que no solo maximizan el rendimiento, sino que también permiten gestionar con prudencia los riesgos involucrados (Xiang y Borjigin, 2024). En este marco, es necesario profundizar en los conceptos fundamentales que sustentan la optimización de portafolios, destacando herramientas como la simulación de Monte Carlo y el uso del lenguaje de programación Python, que brindan una ventaja significativa en la eficiencia del análisis y la visualización de los resultados.

La optimización de portafolios constituye un proceso técnico complejo que, en su esencia, busca identificar la asignación de activos que mejor logre equilibrar el retorno esperado con el riesgo asociado (Gutiérrez et al., 2019). Este equilibrio es crucial para que los inversores puedan tomar decisiones que sean financieramente viables a lo largo del tiempo. En particular, la optimización de portafolios se encuentra estrechamente relacionada con la teoría moderna de portafolios desarrollada

por Harry Markowitz a mediados del siglo XX (Oyedeko et al., 2023). En su enfoque, Markowitz introdujo el concepto de diversificación como un medio para mitigar el riesgo de un portafolio, proponiendo que un inversor puede reducir la volatilidad total de su portafolio mediante la combinación de activos cuya correlación entre los rendimientos sea baja o incluso negativa (Hunjra et al., 2021).

La diversificación se basa en la premisa de que los rendimientos de los activos no siempre se mueven en la misma dirección. Por ejemplo, si un activo experimenta un rendimiento negativo en un determinado período, es posible que otros activos del portafolio no se vean afectados de la misma manera o incluso ofrezcan rendimientos positivos, lo que mitiga el riesgo general del portafolio. De este modo, el enfoque de Markowitz establece que la clave para construir un portafolio eficiente radica en seleccionar y combinar activos de manera tal que se maximicen los retornos esperados para un nivel de riesgo dado, optimizando así la relación entre ambos (Wu et al., 2020).

En términos prácticos, la optimización de portafolios implica determinar la mezcla de activos que maximiza el rendimiento esperado para un nivel específico de riesgo. Este proceso de selección requiere una asignación adecuada de ponderaciones a cada activo dentro del portafolio, teniendo en cuenta las características individuales de los mismos y sus interrelaciones dentro del portafolio. Así, la combinación correcta de activos dentro de un portafolio no solo se basa en el rendimiento histórico de estos, sino también en la correlación entre los activos y su comportamiento en diferentes escenarios de mercado (Abensur y de Carvalho, 2022).

El rendimiento esperado del portafolio se define mediante la ecuación (1):

$$E(R_p) = \sum_{i-1}^{n} w_i E(R_i)$$

El retorno esperado es, sin lugar a dudas, una de las métricas más importantes en la toma de decisiones de inversión, ya que proporciona una estimación del rendimiento promedio anticipado de un activo o portafolio durante un período determinado. En el contexto de la teoría de portafolios, el retorno esperado se calcula tomando en cuenta los rendimientos históricos de los activos en el portafolio, ponderados según su peso en el portafolio total. Este cálculo permite a los inversores anticipar las ganancias que podrían obtener por cada unidad de inversión, bajo el supuesto de que las condiciones del mercado se mantendrán de forma similar a las observadas en el pasado (Rahman y Gan, 2020).

En un modelo simplificado, el retorno esperado de un portafolio compuesto por varios activos se calcula sumando los rendimientos ponderados de cada activo que lo compone. Por ejemplo, si un portafolio está compuesto por dos activos, se estima el retorno esperado del portafolio como una combinación ponderada de los retornos individuales de cada activo, multiplicados por sus respectivas ponderaciones dentro del portafolio. Este cálculo es clave para determinar el rendimiento global del portafolio y, en última instancia, para tomar decisiones informadas sobre la asignación de activos (Plyakha et al., 2021).

El riesgo, entendido como la incertidumbre sobre los rendimientos futuros, es otro concepto esencial en la gestión de portafolios. En las finanzas, se asocia comúnmente el riesgo con la volatilidad, que mide la dispersión de los rendimientos alrededor de su media. La volatilidad indica el grado de variabilidad que los rendimientos de un activo o portafolio pueden experimentar a lo largo del tiempo. Cuanto mayor sea la volatilidad, mayor será el riesgo, ya que los rendimientos futuros se vuelven más

inciertos. En este sentido, los inversores deben considerar tanto el retorno esperado como el riesgo asociado a un portafolio al momento de tomar decisiones sobre la asignación de activos (Huang et al., 2019).

La volatilidad del portafolio se calcula con la ecuación (2):

$$\sigma_p = \sqrt{\sum_{i-1}^{n}\sum_{j-1}^{n} w_i w_j \sigma_{ij}}$$

En la optimización de portafolios, la gestión del riesgo es un componente fundamental, ya que los inversores buscan alcanzar un equilibrio entre el retorno esperado y el nivel de riesgo que están dispuestos a asumir. Para reducir el riesgo, los inversores emplean diversas estrategias, siendo la diversificación una de las más efectivas. La diversificación consiste en combinar activos con perfiles de riesgo diferentes para mitigar el riesgo total del portafolio. Al incluir activos cuya correlación entre sus rendimientos sea baja o negativa, es posible reducir la volatilidad del portafolio y, por ende, el riesgo global. Así, la gestión activa de las correlaciones entre los activos dentro del portafolio es un aspecto crucial en la optimización (Koumou, 2020).

La simulación de Monte Carlo es una de las herramientas más utilizadas para modelar situaciones de incertidumbre en el ámbito de la optimización de portafolios. Esta técnica matemática permite generar una gran cantidad de escenarios posibles a partir de variables aleatorias, lo que ayuda a simular el comportamiento de un portafolio bajo diversas condiciones del mercado (Zhang, 2021). Mediante la simulación de Monte Carlo, es posible realizar miles de simulaciones de los rendimientos futuros de un portafolio, teniendo en cuenta las distribuciones de probabilidad de los activos involucrados.

Esta técnica resulta particularmente útil cuando los datos históricos no son suficientes para predecir el comportamiento futuro de los activos, ya que permite evaluar una amplia gama de resultados posibles y proporcionar una imagen más robusta de los riesgos y rendimientos asociados con el portafolio (Zheng et al., 2019). A través de la simulación de Monte Carlo, los analistas pueden identificar el portafolio más eficiente para diferentes niveles de riesgo, lo que facilita la toma de decisiones informadas.

La selección de las combinaciones de activos dentro de un portafolio es un aspecto central en la optimización (Sarwar et al., 2019). Diversificar el portafolio a través de diferentes tipos de activos, como acciones, bonos y otros instrumentos financieros, es una estrategia clave para reducir el riesgo total. Sin embargo, la elección de activos no se basa solo en sus rendimientos esperados, sino también en la correlación entre ellos. Los activos cuya correlación entre sus rendimientos sea baja o negativa son especialmente valiosos para la optimización de portafolios, ya que ayudan a reducir la volatilidad y el riesgo general.

El rendimiento ajustado al riesgo es otro criterio fundamental que permite evaluar si un portafolio está generando un rendimiento adecuado en relación con el riesgo asumido. Una de las métricas más utilizadas para medir el rendimiento ajustado al riesgo es el índice de Sharpe, que compara el exceso de retorno de un portafolio con su volatilidad (Raza y Ye, 2025). Este índice permite identificar qué tan bien un portafolio está compensando el riesgo que se asume. Un valor alto del índice de Sharpe indica que el portafolio está generando un buen retorno por cada unidad de riesgo, lo que lo convierte en una opción eficiente para los inversores. El índice de Sharpe (Sharpe, 1966), que compara el exceso de retorno por cada unidad de riesgo dado, se define en la ecuación (3):

$$S_p = \frac{E(R_p) - R_f}{\sigma_p}$$

La volatilidad es la medida principal del riesgo en la optimización de portafolios. Representa la dispersión de los rendimientos alrededor de la media, y los inversores buscan minimizarla para reducir la incertidumbre sobre el comportamiento futuro del portafolio (Li y Webster, 2023).

El uso de herramientas como Python ha revolucionado la optimización de portafolios, proporcionando una plataforma accesible y poderosa para implementar modelos matemáticos complejos. Python ofrece bibliotecas especializadas, como NumPy, Pandas, Matplotlib y SciPy, que permiten a los analistas e inversores realizar simulaciones de Monte Carlo, calcular métricas como el índice de Sharpe y la frontera eficiente, y llevar a cabo análisis estadísticos de manera eficiente. Esta capacidad para automatizar y simplificar el proceso de optimización permite a los analistas experimentar con diferentes combinaciones de activos, evaluar su rendimiento y riesgo asociados, y tomar decisiones más informadas y precisas (Nystrup et al., 2020; Perrin y Roncalli, 2020).

En consecuencia, la optimización de portafolios es un componente esencial en la gestión de inversiones. Las técnicas como la simulación de Monte Carlo y el análisis del rendimiento ajustado al riesgo proporcionan a los inversores herramientas eficaces para maximizar el retorno mientras gestionan los riesgos asociados. Con el respaldo de Python, los analistas pueden ejecutar estos modelos de forma más eficiente y precisa, lo que les permite tomar decisiones informadas y optimizar su rendimiento en los mercados financieros.

3. Metodología

La investigación se desarrolló en las cuatro etapas siguientes:

1. Obtención de datos históricos: Se descargaron los precios históricos de cierre de 10 acciones seleccionadas del índice Dow Jones y las bolsas de valores de México, Japón y Colombia, para el período comprendido entre 2014 y 2024. Para la obtención de los datos históricos, los precios de cierre de las acciones seleccionadas se descargaron desde Yahoo Finance mediante la implementación de la librería yfinance en Python. La extracción de esta información abarcó el período exacto comprendido entre el 2 de enero de 2014 y el 31 de diciembre de 2024, tal como se especifica en los parámetros del código utilizado para el estudio.
2. Limpieza de datos: Se realizó un proceso de limpieza de los datos, eliminando aquellos valores nulos o incorrectos. Los valores erróneos o faltantes fueron reemplazados por el precio más reciente disponible, lo que garantizó la consistencia y calidad de los datos utilizados en el análisis.
3. Escalado de precios: Se procedió a escalar los precios de cierre de cada acción para estandarizarlos. Este proceso permitió que todas las acciones comenzaran con un valor de 1, facilitando comparaciones precisas entre las variaciones porcentuales de cada una de las acciones seleccionadas.
4. Simulaciones de Monte Carlo: Se generaron 1,000 simulaciones de Monte Carlo, con el fin de calcular el rendimiento esperado, la volatilidad y el índice de Sharpe de cada portafolio resultante de diferentes combinaciones de activos, utilizando la tasa libre de riesgo de 4.5% de los bonos del tesoro norteamericano. Posteriormente, se seleccionó el portafolio más eficiente en función del mayor índice de Sharpe, lo que permitió identificar la cartera óptima para la toma de decisiones.

A continuación, se presentan las características con las que se diseñó esta investigación (Tabla 1).

Tabla 1. Diseño de la investigación

Metodología	*Descripción*
Nivel de investigación:	Investigación cuantitativa y descriptiva. El estudio se enfoca en el análisis cuantitativo de los portafolios de inversión mediante simulaciones de Monte Carlo, utilizando datos históricos de acciones para modelar el rendimiento y riesgo.
Propósito de investigación:	Investigación pura o básica. El objetivo principal es contribuir al conocimiento académico mediante el análisis del rendimiento y riesgo de portafolios de inversión utilizando la simulación de Monte Carlo.
Muestreo utilizado:	Deliberado. Se seleccionaron 10 emisoras representativas de los mercados de valores representados por el índice Dow Jones, y las bolsas de valores de México, Japón y Colombia, con el fin de realizar una simulación que cubra una variedad de activos y escenarios. Las 10 emisoras de cada mercado fueron seleccionadas bajo el criterio de mayor capitalización bursátil y liquidez dentro de sus respectivos índices al momento del estudio.
Variables utilizadas:	Investigación no experimental. Se recopilaron datos históricos de precios de cierre de las acciones seleccionadas entre 2014 y 2024, para analizar el rendimiento y riesgo en base a ponderaciones aleatorias generadas en la simulación de Monte Carlo.

Fuente: elaboración propia.

4. Resultados

Para optimizar los portafolios mediante simulaciones de Monte Carlo se desarrolló un código en Python, que se reproduce en el Anexo 1, aplicado a portafolios representativos del índice Dow Jones y

de las bolsas de valores de México, Japón y Colombia. Los resultados mostraron una amplia variedad de portafolios con distintos rendimientos y volatilidades.

El portafolio más eficiente, con el mejor índice de Sharpe correspondió al portafolio representativo del índice Dow Jones, con un rendimiento anualizado de 33.44% y una volatilidad de 22.54%, que en base a una tasa libre de riesgo de 4.5% resultó en un índice de Sharpe de 1.28. Este portafolio optimizó la relación entre riesgo y retorno, destacando la utilidad de las simulaciones de Monte Carlo para explorar distintas combinaciones de activos. El uso de Python facilitó la recolección de datos, la simulación de escenarios y el análisis de métricas clave, proporcionando una herramienta valiosa para la toma de decisiones informadas en la optimización de portafolios. A continuación, se muestran los principales resultados y sus interpretaciones.

4.1. Portafolio óptimo representativo del índice Dow Jones

La Figura 1 ilustra la frontera eficiente del portafolio resultante de las simulaciones de Monte Carlo, aplicadas a un conjunto de 10 acciones representativas del índice Dow Jones: Apple, Nvidia, Microsoft, Amazon, Walmart, JPMorgan, Visa, United Health, Home Depot y P&G. A través de 1,000 simulaciones, se generaron combinaciones aleatorias de pesos para cada acción, calculando el rendimiento esperado, la volatilidad y el índice de Sharpe de cada portafolio. El objetivo fue identificar el portafolio con el mejor rendimiento ajustado al riesgo, determinado por el índice de Sharpe más alto, con una tasa libre de riesgo de 4.5%. La visualización de la frontera eficiente destaca cómo se relacionan la volatilidad y el rendimiento esperado, resaltando el portafolio óptimo con un rendimiento de 33.44%, una volatilidad de 22.54% y un índice de Sharpe de 1.28.

Figura 1. Portafolio óptimo resultante de la simulación de Monte Carlo aplicada al índice Dow Jones

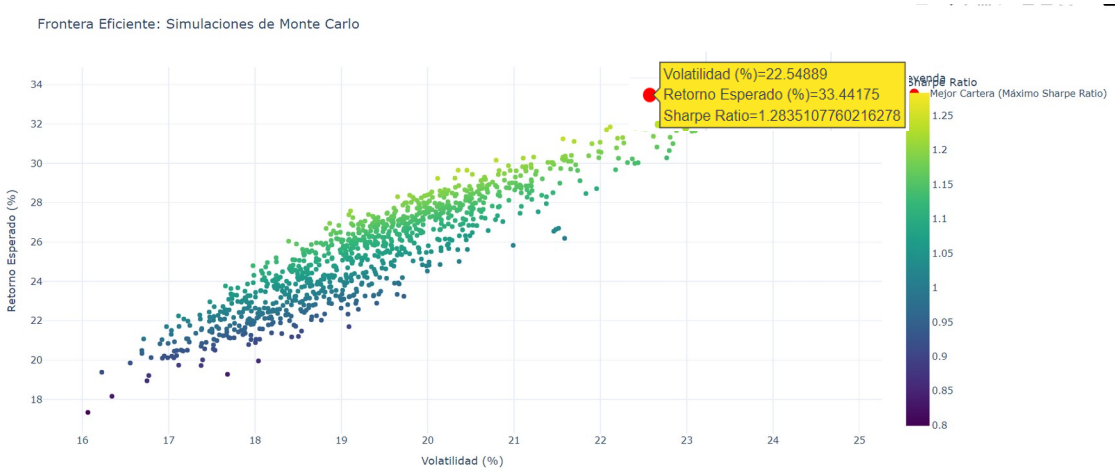

Fuente: elaboración propia con Python.

4.2. Portafolio óptimo representativo del mercado de valores de México

La Figura 2 ilustra la frontera eficiente del portafolio resultante de las simulaciones de Monte Carlo, aplicadas a un conjunto de 10 acciones representativas del mercado de valores de México: Walmart de México, América Móvil, Grupo México, Fomento Económico, Banorte, Cemex, Arca Continental, Inbursa, Grupo Carso, y Bimbo. El objetivo fue identificar nuevamente, pero ahora para este mercado específico, el portafolio con el mejor rendimiento ajustado al riesgo, determinado por el índice de Sharpe más alto, con una tasa libre de riesgo de 4.5%. La visualización de la frontera eficiente resalta el portafolio óptimo con un rendimiento de 11.28%, una volatilidad de 16.49%, y un índice de Sharpe de 0.41, lo que evidencia una combinación eficaz de rentabilidad y riesgo en este mercado.

Figura 2. Portafolio óptimo resultante de la simulación de Monte Carlo aplicada al mercado de valores de México

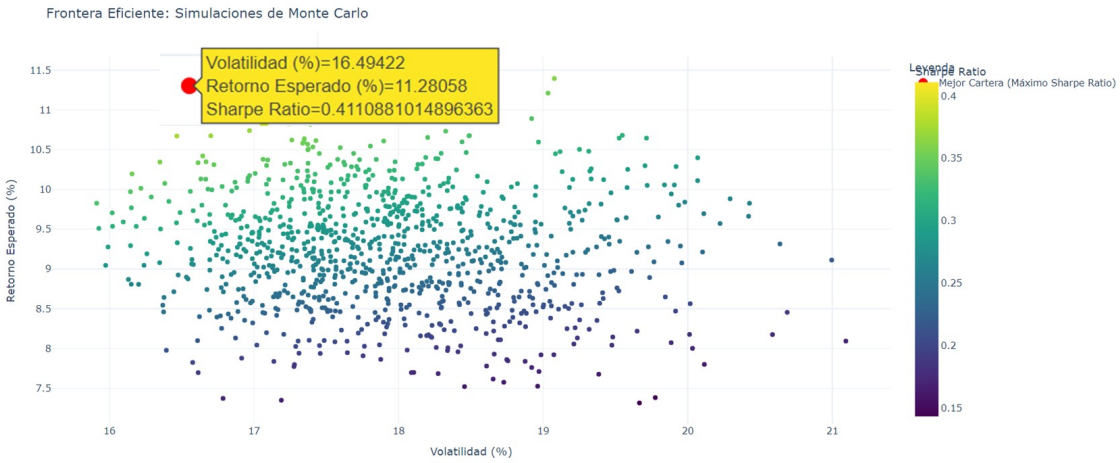

Fuente: elaboración propia con Python.

4.3. Portafolio óptimo representativo del mercado de valores de Japón

La Figura 3 ilustra la frontera eficiente del portafolio resultante de las simulaciones de Monte Carlo, aplicadas a un conjunto de 10 acciones representativas del mercado de valores de Japón: Toyota Motor Corporation, Sony Group Corporation, SoftBank Group, Mizuho Financial Group, Nintendo Co. Ltd., Panasonic Holdings Corporation, NTT Corporation, Honda Motor Co., Ltd., Takeda Pharmaceutical Company Limited, y Renesas Electronics Corporation.

El objetivo fue identificar nuevamente, pero ahora para este mercado, el portafolio con el mejor rendimiento ajustado al riesgo, determinado por el índice de Sharpe más alto, con una tasa libre de riesgo de 4.5%. La visualización de la frontera eficiente resalta el portafolio óptimo con un

rendimiento de 21.35%, una volatilidad de 21.80% y un índice de Sharpe de 0.77, lo que indica una relación de mayor rentabilidad ajustada al riesgo en comparación con el portafolio mexicano.

Aunque este portafolio japonés muestra un rendimiento significativamente superior, también presenta una mayor volatilidad, lo que sugiere que los inversores deben considerar sus tolerancias al riesgo al momento de seleccionar entre diferentes mercados y estrategias de inversión.

Figura 3. Portafolio óptimo resultante de la simulación de Monte Carlo aplicada al mercado de valores de Japón

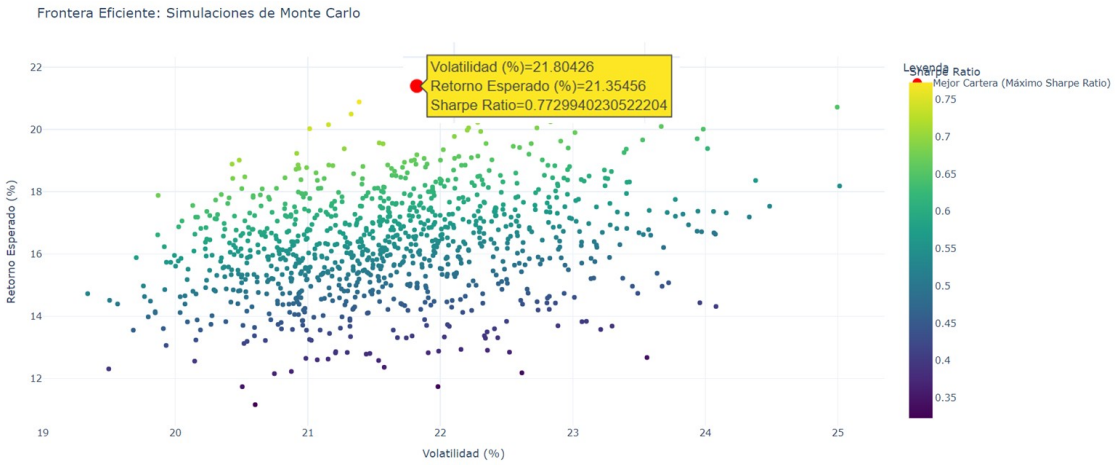

Fuente: elaboración propia con Python.

4.4. Portafolio óptimo representativo del mercado de valores de Colombia

La Figura 4 ilustra la frontera eficiente del portafolio resultante de las simulaciones de Monte Carlo, aplicadas a un conjunto de 10 acciones representativas del mercado de valores de Colombia:

Ecopetrol, Bancolombia, Grupo Energía Bogotá, Grupo de Inversiones Suramericana, Interconexión Eléctrica, Grupo Argos, Cementos Argos, Grupo Aval Acciones y Valores, Banco de Bogotá, y Banco Davivienda. El objetivo fue identificar nuevamente, pero ahora para este mercado, el portafolio con el mejor rendimiento ajustado al riesgo, determinado por el índice de Sharpe más alto, con una tasa libre de riesgo de 4.5%. La visualización de la frontera eficiente resalta el portafolio óptimo con un rendimiento de 13.81%, una volatilidad de 20.57% y un índice de Sharpe de 0.45. Comparado con el portafolio mexicano, que tiene un rendimiento de 11.28%, el portafolio colombiano ofrece un retorno superior, pero con una volatilidad algo mayor (20.57% frente a 16.49%). Esto implica que, aunque el portafolio colombiano tiene una rentabilidad más alta, también conlleva un mayor riesgo, lo que puede ser menos atractivo para los inversores que prefieren una opción con menor volatilidad, como la presentada en el mercado mexicano. Sin embargo, la relación riesgo-retorno del portafolio colombiano, dada su volatilidad, es razonablemente eficiente para quienes buscan una inversión con rendimientos moderados pero relativamente estables.

Figura 4. Portafolio óptimo resultante de la simulación de Monte Carlo aplicada al mercado de valores de Colombia

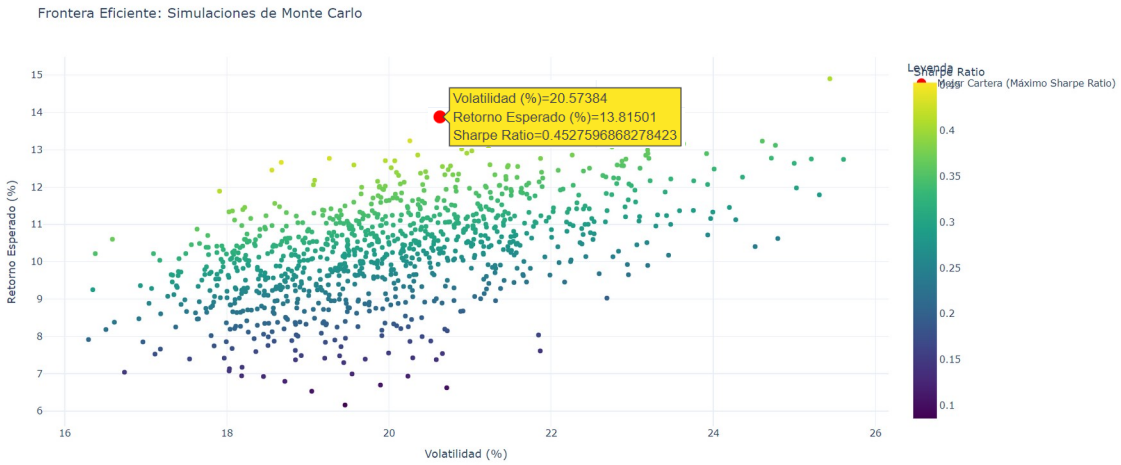

Fuente: elaboración propia con Python.

5. Conclusión y discusión

Los resultados obtenidos en esta investigación ofrecen una visión clara sobre las diferencias en la eficiencia de los portafolios de inversión al comparar diversos mercados de valores, específicamente el índice Dow Jones y los mercados bursátiles de México, Japón y Colombia. El portafolio óptimo, determinado a partir de las simulaciones de Monte Carlo, mostró que el índice Dow Jones presenta el mejor rendimiento ajustado al riesgo, con un rendimiento anualizado de 33.44%, una volatilidad de 22.54%, y un índice de Sharpe de 1.28. Estos valores indican que el portafolio compuesto por acciones de Apple, Nvidia, Microsoft, Amazon, Walmart, JPMorgan, Visa, United Health, Home Depot y Procter & Gamble es significativamente más eficiente en términos de riesgo y retorno en comparación

con los portafolios de los mercados de México, Japón y Colombia, cuyas relaciones entre riesgo y retorno fueron más bajas, con índices de Sharpe de 0.41, 0.77 y 0.45, respectivamente.

Estos resultados subrayan la ventaja de los mercados desarrollados, como el estadounidense representado por el índice Dow Jones, en términos de retorno ajustado al riesgo, lo que puede deberse a factores como una mayor estabilidad económica, una mayor diversificación de activos y una mayor liquidez en estos mercados. Los mercados emergentes, aunque ofrecen rendimientos positivos, no alcanzan el mismo nivel de eficiencia debido a su mayor volatilidad, menor diversificación y otros riesgos inherentes a su naturaleza. Este hallazgo resalta la importancia de considerar el contexto económico y financiero al seleccionar portafolios de inversión, especialmente en mercados con características diferentes.

Es importante destacar que, aunque las simulaciones de Monte Carlo proporcionan una herramienta útil para la optimización de portafolios, la investigación tiene algunas limitaciones. En primer lugar, los datos utilizados en esta investigación se limitan a los precios históricos de las acciones y no consideran otros factores macroeconómicos, políticos o sociales que pueden influir en el rendimiento de los activos. Además, la simulación de Monte Carlo, aunque robusta, depende de la calidad de los datos históricos y de los supuestos sobre el comportamiento de los activos en el futuro. Las fluctuaciones imprevistas del mercado o eventos inesperados, como crisis financieras o pandemias, podrían alterar los resultados obtenidos, lo que sugiere que las simulaciones deben considerarse como una herramienta complementaria, y no como una predicción exacta del futuro.

Otra limitación es el uso de una tasa libre de riesgo fija del 4.5%, que puede no ser representativa de las condiciones económicas cambiantes de cada mercado. La tasa libre de riesgo varía según las políticas monetarias de cada país, y su fijación arbitraria podría haber influido en la selección de los portafolios óptimos. Además, aunque se utilizaron 1,000 simulaciones, un número mayor de simulaciones podría

proporcionar resultados aún más precisos, especialmente al considerar la complejidad y el comportamiento no lineal de los mercados financieros.

A pesar de estas limitaciones, los resultados obtenidos abren la puerta a futuros estudios que podrían ampliar y profundizar en este análisis. Un posible estudio posterior podría incluir la incorporación de más variables macroeconómicas, como tasas de interés, inflación o políticas fiscales, para evaluar su impacto en la optimización de portafolios. Además, se podrían analizar otros índices bursátiles internacionales y mercados emergentes para comprender mejor las dinámicas globales y las oportunidades de diversificación. También sería interesante explorar la optimización de portafolios con activos no tradicionales, como bonos, bienes raíces o criptomonedas, lo que podría ofrecer un enfoque más amplio para la gestión de riesgos en un portafolio. Adicionalmente, debe considerarse como una limitación importante el sesgo cambiario, ya que los rendimientos de las acciones se mantuvieron en la moneda local de cada mercado, lo que omite el impacto de las fluctuaciones del tipo de cambio al consolidar o comparar portafolios internacionalmente.

Finalmente, sería útil llevar a cabo un análisis dinámico que simule condiciones de mercado cambiantes, como fluctuaciones en las tasas de interés o crisis económicas, para evaluar cómo los portafolios pueden adaptarse a escenarios impredecibles. Estos estudios podrían contribuir significativamente a la toma de decisiones informadas por parte de inversores y gestores de fondos en un entorno financiero cada vez más globalizado y volátil.

6. Declaraciones

Financiamiento: el trabajo no recibió financiamiento externo para su desarrollo.

Conflicto de interés: el autor declara que no existe ningún conflicto de interés relacionado con la investigación, la elaboración y la publicación del artículo.

Uso de inteligencia artificial: el autor declara que no se utilizaron herramientas de inteligencia artificial en el desarrollo de la investigación ni en la elaboración del manuscrito.

7. Referencias

Abensur, E. O., & de Carvalho, W. P. (2022). Improving portfolio selection by balancing liquidity-risk-return: Evidence from stock markets. *Theoretical Economics Letters*, 12(2), 479-497. https://www.scirp.org/journal/paperinformation?paperid=116460

Gunjan, A., & Bhattacharyya, S. (2023). A brief review of portfolio optimization techniques. *Artificial Intelligence Review*, 56(5), 3847-3886. https://link.springer.com/article/10.1007/s10462-022-10273-7

Gutiérrez, T., Pagnoncelli, B., Valladão, D., & Cifuentes, A. (2019). Can asset allocation limits determine portfolio risk–return profiles in DC pension schemes? *Insurance: Mathematics and Economics*, 86, 134-144. https://www.sciencedirect.com/science/article/abs/pii/S0167668718301331

Huang, D., Schlag, C., Shaliastovich, I., & Thimme, J. (2019). Volatility-of-volatility risk. *Journal of Financial and Quantitative Analysis*, 54(6), 2423-2452. https://www.cambridge.org/core/journals/journal-of-financial-and-quantitative-analysis/article/abs/volatilityofvolatility-risk/9D8ABBDE874D8259A5176FA455C674B7

Hunjra, A. I., Hanif, M., Mehmood, R., & Nguyen, L. V. (2021). Diversification, corporate governance, regulation and bank risk-taking. *Journal of Financial Reporting and Accounting*,

19(1), 92-108. https://www.emerald.com/insight/content/doi/10.1108/jfra-03-2020-0071/full/html

Koumou, G. B. (2020). Diversification and portfolio theory: a review. *Financial Markets and Portfolio Management*, 34(3), 267-312. https://link.springer.com/article/10.1007/s11408-020-00352-6

Li, H., & Webster, S. (2023). Optimizing risk-balancing return under discrete choice models. *Operations Research*, 71(6), 2232-2244. https://doi.org/10.1287/opre.2023.2465

Ma, Y., Han, R., & Wang, W. (2021). Portfolio optimization with return prediction using deep learning and machine learning. *Expert Systems with Applications*, 165, 113973. https://www.sciencedirect.com/science/article/abs/pii/S0957417420307521

Mendonça, G. H., Ferreira, F. G., Cardoso, R. T., & Martins, F. V. (2020). Multi-attribute decision making applied to financial portfolio optimization problem. *Expert Systems with Applications*, 158, 113527. https://www.sciencedirect.com/science/article/abs/pii/S0957417420303511

Nystrup, P., Lindström, E., & Madsen, H. (2020). Hyperparameter optimization for portfolio selection. *Journal of Financial Data Science*, 2(3), 40-54. https://orbit.dtu.dk/en/publications/hyperparameter-optimization-for-portfolio-selection

Oyedeko, Y. O., Kolawole, O. S., Samson, R., & Voloshyna, O. (2023). Moderating Effect of Tactical Asset Allocation on the Risk-Return Relationship in the Nigerian Stock Market. *Oblik i finansi*, 100, 83-91. https://www.proquest.com/openview/7b30f3b6bc2622eea10acab4fcf1b5fb/1?pq-origsite=gscholar&cbl=2042771

Pankunni, N., & Kumar, S. R. (2020). Risk Adjusted Efficient Market Return for Stocks. Pacific *Business Review International*, 13(2). https://www.researchgate.net/profile/Rajitha-Kumar-S-2/publication/346419111_Risk_Adjusted_Efficient_Market_Return_for_Stocks/links/5fc0da6f458515b797788620/Risk-Adjusted-Efficient-Market-Return-for-Stocks.pdf

Perrin, S., & Roncalli, T. (2020). Machine learning optimization algorithms & portfolio allocation. *Machine Learning for Asset Management: New Developments and Financial Applications*, 261-328. https://doi.org/10.1002/9781119751182.ch8

Plyakha, Y., Uppal, R., & Vilkov, G. (2021). *Equal or value weighting? Implications for asset-pricing tests*. Springer International Publishing. https://link.springer.com/chapter/10.1007/978-3-030-66691-0_9

Rahman, M., & Gan, S. S. (2020). Generation Y investment decision: an analysis using behavioural factors. *Managerial Finance*, 46(8), 1023-1041. https://www.emerald.com/insight/content/doi/10.1108/mf-10-2018-0534/full/html

Raza, M. W., & Ye, J. (2025). Beyond Sharpe ratio: comparison of risk-adjusted performance of Shariah-compliant and conventional indices. *International Journal of Islamic and Middle Eastern Finance and Management*, 18(1), 184-200. https://www.emerald.com/insight/content/doi/10.1108/imefm-01-2024-0013/full/html

Sarwar, S., Shahbaz, M., Anwar, A., & Tiwari, A. K. (2019). The importance of oil assets for portfolio optimization: The analysis of firm level stocks. *Energy Economics*, 78, 217-234. https://www.sciencedirect.com/science/article/abs/pii/S0140988318304614

Saunders, A., Cornett, M. M., & Erhemjamts, O. (2021). *Financial institutions management: A risk management approach*. McGraw-Hill. https://thuvienso.hoasen.edu.vn/handle/123456789/12867

Sharpe, W. F. (1966). Mutual fund performance. The Journal of business, 39(1), 119-138. http://www.web.stanford.edu/~wfsharpe/art/mfp.pdf

Vo, D. H., Pham, T. N., Pham, T. T. V., Truong, L. M., & Nguyen, T. C. (2019). Risk, return and portfolio optimization for various industries in the ASEAN region. *Borsa Istanbul Review*, 19(2), 132-138. https://www.sciencedirect.com/science/article/pii/S2214845018301698

Wu, J., Chen, L., Chen, M., & Jeon, B. N. (2020). Diversification, efficiency and risk of banks: Evidence from emerging economies. *Emerging Markets Review*, 45, 100720. https://www.sciencedirect.com/science/article/abs/pii/S1566014120302284

Xiang, Y., & Borjigin, S. (2024). High–low volatility spillover network between economic policy uncertainty and commodity futures markets. *Journal of Futures Markets*, 44(8), 1295-1319. https://doi.org/10.1002/fut.22511

Zhang, J. (2021). Modern Monte Carlo methods for efficient uncertainty quantification and propagation: A survey. *Wiley Interdisciplinary Reviews: Computational Statistics*, 13(5), e1539. https://wires.onlinelibrary.wiley.com/doi/10.1002/wics.1539

Zheng, D., Yu, L., Wang, L., & Tao, J. (2019). Integrating willingness analysis into investment prediction model for large scale building energy saving retrofit: Using fuzzy multiple attribute

decision making method with Monte Carlo simulation. *Sustainable Cities and Society*, 44, 291-309. https://www.sciencedirect.com/science/article/abs/pii/S2210670718307698

Anexo 1

Código en Python

```
# FRONTERA EFICIENTE
import yfinance as yf
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import plotly.express as px

# Lista de tickers (DOW JONES Y BOLSAS DE VALORES MÉXICO, JAPÓN Y COLOMBIA
tickers = ['10 TICKERS ACCIONES OBJETO DE ESTUDIO']


# Fechas de inicio y fin
start_date = '2014-01-02'
end_date = '2024-12-31'

# Descargar los datos de las acciones
data = yf.download(tickers, start=start_date, end=end_date)

# Extraer solo los precios de cierre
close_prices = data['Close']

# Limpiar los datos: reemplazar NaNs y ceros con el precio más reciente disponible
```

```
# Primero reemplazamos ceros por NaN
close_prices.replace(0, np.nan, inplace=True)

# Propagar los últimos precios válidos hacia adelante (forward fill)
close_prices.ffill(inplace=True)

# Función para escalar los precios para que todos comiencen en 1
def price_scaling(df):
    return df.div(df.iloc[0], axis=1)

# Escalar precios
scaled_prices = price_scaling(close_prices)

# Número de simulaciones
sim_runs = 1000

# Generar pesos aleatorios que sumen 1
def generate_portfolio_weights(n):
    weights = np.random.random(n)
    return weights / weights.sum()

# Inicializar listas para almacenar los resultados
expected_returns = []
volatility = []
sharpe_ratios = []

# Tasa libre de riesgo
rf = 0.045

# Realizar las simulaciones de Monte Carlo
for _ in range(sim_runs):
    weights = generate_portfolio_weights(len(tickers))
```

```
    # Calcular los rendimientos diarios de las simulaciones
    portfolio_daily_return_df = scaled_prices.pct_change(1)

    # Calcular el rendimiento esperado del portafolio (promedio ponderado de los rendimientos diarios)
    expected_return = np.sum(weights * portfolio_daily_return_df.mean()) * 252  # anualizado

    # Matriz de covarianza y volatilidad anualizada del portafolio
    covariance = portfolio_daily_return_df.cov() * 252  # anualizado
    portfolio_volatility = np.sqrt(np.dot(weights, np.dot(covariance, weights)))  # volatilidad

    # Calcular el Sharpe Ratio
    sharpe_ratio = (expected_return - rf) / portfolio_volatility

    # Almacenar los resultados
    expected_returns.append(expected_return)
    volatility.append(portfolio_volatility)
    sharpe_ratios.append(sharpe_ratio)

# Convertir los resultados en un DataFrame
simulation_results_df = pd.DataFrame({
    'Expected Return (%)': np.array(expected_returns) * 100,
    'Volatility (%)': np.array(volatility) * 100,
    'Sharpe Ratio': sharpe_ratios
})

# Encontrar el índice de la simulación con el mejor Sharpe Ratio
best_sharpe_index = sharpe_ratios.index(max(sharpe_ratios))
best_sharpe_ratio = sharpe_ratios[best_sharpe_index]
best_return = expected_returns[best_sharpe_index] * 100
best_volatility = volatility[best_sharpe_index] * 100
```

```
# Mostrar los resultados de la simulación óptima
print(f"Best Sharpe Ratio Portfolio: {best_sharpe_ratio:.4f}")
print(f"Expected Return: {best_return:.2f}%")
print(f"Volatility: {best_volatility:.2f}%")

# Graficar la frontera eficiente con Plotly
fig = px.scatter(
    simulation_results_df,
    x='Volatility (%)',
    y='Expected Return (%)',
    color='Sharpe Ratio',
    color_continuous_scale='viridis',
    hover_data=['Sharpe Ratio'],
    title='Frontera Eficiente: Simulaciones de Monte Carlo',
    labels={'Volatility (%)': 'Volatilidad (%)', 'Expected Return (%)': 'Retorno Esperado (%)'}
)

# Destacar la simulación con el mejor Sharpe Ratio
fig.add_scatter(
    x=[best_volatility],
    y=[best_return],
    mode='markers',
    marker=dict(size=12, color='red', symbol='circle'),
    name='Mejor Cartera (Máximo Sharpe Ratio)'
)

# Actualizar el diseño del gráfico
fig.update_layout(
    coloraxis_colorbar=dict(title='Sharpe Ratio'),
    legend=dict(title='Leyenda'),
    xaxis=dict(title='Volatilidad (%)'),
    yaxis=dict(title='Retorno Esperado (%)'),
```

```
    template='plotly_white'
)

# Mostrar el gráfico interactivo
fig.show()
```