



## Análisis comparativo entre momentum tradicional y machine learning (Random Forest): evidencia para el S&P 500 (2000-2024)

Comparative analysis between traditional momentum and machine learning (random forest): evidence from the S&P 500 (2000-2024)

Análise comparativa entre momentum tradicional e machine learning (random forest): evidências do S&P 500 (2000-2024)

Carlos Palomino Selem; Ruth Milagros Delgado Yana

---

Máster en Finanzas Cuantitativas, Universidad Alcalá. Profesor Ordinario, Categoría Asociado, Facultad de Ciencias Económicas, Universidad Nacional Mayor de San Marcos, Perú. ORCID: 0000-0001-9582-2442. E-mail: cpalominos@unmsm.edu.pe, Lima - Perú.

Magíster en Derecho Bancario y Financiero, Pontificia Universidad Católica del Perú (PUCP). Profesor Contratado, adscrito a la Unidad de Post Grado, Universidad ESAN, Perú. ORCID: 0009-0007-8677-3213. E-mail: rdelgado@esan.edu.pe, Lima – Perú

---

**Recibido:** 31 de octubre de 2026

**Aceptado:** 6 de junio de 2026

**DOI:** <https://doi.org/10.22267/rtend.26272.296>

**Cómo citar este artículo:** Palomino S. C. y Delgado, R. (2026). Análisis Comparativo entre Momentum Tradicional y Machine Learning (Random Forest): Evidencia para el S&P 500 (2000-2024). *Tendencias*, 27(2), 32-61. <https://doi.org/10.22267/rtend.26272.296>

### Resumen

**Introducción:** Este estudio examina la validez y persistencia del efecto momentum en el índice S&P 500 (2000–2024), un mercado accionario desarrollado y con alta eficiencia informacional. Se analiza si la evidencia empírica respalda la continuidad del momentum en distintos horizontes temporales. **Objetivo:** Comparar el desempeño del momentum tradicional (MT) con un modelo de aprendizaje supervisado basado en *Random Forest* (RF), evaluando capacidad predictiva, rendimiento ajustado por riesgo y estabilidad fuera de muestra. **Metodología:** Se implementaron estrategias *long-short* de MT para horizontes de 1, 3, 6 y 12 meses, y el modelo RF fue entrenado con retornos acumulados equivalentes. Se aplicó validación fuera de muestra mediante ventana expansiva, *backtesting* homogéneo y pruebas de estabilidad temporal. **Resultados:** El MT mostró desempeño limitado en horizontes cortos y mayor consistencia en horizontes largos. RF presentó mayor capacidad predictiva y rentabilidad, especialmente en horizontes largos, aunque con episodios de volatilidad y riesgo de sobreajuste. **Discusión:** Los modelos de aprendizaje automático capturan patrones no lineales no identificables por métodos tradicionales, pero dependen de condiciones de mercado y presentan menor estabilidad temporal, evidenciando un *trade-off* entre rentabilidad y robustez. **Conclusiones:** Los hallazgos confirman la persistencia del momentum y destacan el valor del *machine learning* en predicción financiera, subrayando la importancia de validación rigurosa y control de riesgo.

**Palabras clave:** aprendizaje automático; inversiones; mercados de capitales; modelos económicos; momentum; Random Forest; riesgo; selección de portafolios.

**JEL:** C45; C53; C58; G11; G12; G14.



## Abstract

**Introduction:** This study examines the validity and persistence of the momentum effect in the S&P 500 index (2000–2024), a developed equity market with high informational efficiency. It analyzes whether the empirical evidence supports the continuity of momentum across different time horizons. **Objective:** To compare the performance of traditional momentum (TM) with a supervised learning model based on Random Forest (RF), assessing predictive ability, risk-adjusted performance, and out-of-sample stability. **Methodology:** Long–short TM strategies were implemented for horizons of 1, 3, 6, and 12 months, and the RF model was trained using equivalent cumulative returns. Out-of-sample validation was applied through an expanding window, homogeneous backtesting, and temporal stability tests. **Results:** TM showed limited performance over short horizons and greater consistency over long horizons. RF exhibited greater predictive ability and profitability, especially over long horizons, although with episodes of volatility and overfitting risk. **Discussion:** Machine learning models capture nonlinear patterns not identifiable by traditional methods, but depend on market conditions and show lower temporal stability, evidencing a trade-off between profitability and robustness. **Conclusions:** The findings confirm the persistence of momentum and highlight the value of machine learning in financial prediction, underscoring the importance of rigorous validation and risk control.

**Keywords:** machine learning; investments; capital markets; economic models; momentum; Random Forest; risk; portfolio selection.

**JEL:** C45; C53; C58; G11; G12; G14.

## Resumo

**Introdução:** Este estudo analisa a validade e a persistência do efeito momentum no índice S&P 500 (2000–2024), um mercado bolsista desenvolvido e com elevada eficiência informacional. Analisa-se se a evidência empírica corrobora a continuidade do momentum em diferentes horizontes temporais. **Objetivo:** Comparar o desempenho do momentum tradicional (MT) com um modelo de aprendizagem supervisionada baseado em Random Forest (RF), avaliando a capacidade preditiva, o rendimento ajustado ao risco e a estabilidade fora da amostra. **Metodologia:** Foram implementadas estratégias long–short de MT para horizontes de 1, 3, 6 e 12 meses, e o modelo RF foi treinado com retornos acumulados equivalentes. A validação fora da amostra foi aplicada através de janela expansiva, backtesting homogêneo e testes de estabilidade temporal. **Resultados:** O MT apresentou um desempenho limitado em horizontes curtos e maior consistência em horizontes longos. O RF apresentou maior capacidade preditiva e rentabilidade, especialmente em horizontes longos, embora com episódios de volatilidade e risco de sobreajuste. **Discussão:** Os modelos de aprendizagem automática captam padrões não lineares não identificáveis por métodos tradicionais, mas dependem das condições de mercado e apresentam menor estabilidade temporal, evidenciando um compromisso entre rentabilidade e robustez. **Conclusões:** Os resultados confirmam a persistência do momentum e destacam o valor da aprendizagem automática na previsão financeira, sublinhando a importância de uma validação rigorosa e do controle de risco.

**Palavras-chave:** aprendizagem automática; investimentos; mercados de capitais; modelos económicos; momentum; Random Forest; risco; seleção de carteiras.

**JEL:** C45; C53; C58; G11; G12; G14.

## Introducción

La hipótesis de los mercados eficientes (HME; EMH, por su sigla en inglés), propuesta por Fama (1970), sostiene que los precios de los activos reflejan de manera inmediata toda la información disponible, lo cual limitaría la posibilidad de obtener retornos anormales de forma sistemática. La creciente incorporación de tecnologías avanzadas como la inteligencia artificial (IA) y el trading de alta frecuencia (HFT, por sus siglas en inglés) ha reforzado este argumento al acelerar la incorporación de información en los precios y reducir las oportunidades de arbitraje. A pesar de ello, numerosos estudios han documentado anomalías persistentes que desafían el paradigma de eficiencia, entre ellas el efecto *momentum*, identificado inicialmente por Jegadeesh y Titman (1993) y posteriormente ampliado por contribuciones como las de Carhart (1997), Novy-Marx (2012), Fama y French (1996) y Asness et al. (2013). Esta anomalía, caracterizada por la continuidad de rendimientos pasados en el corto plazo, ha sido observada en distintos mercados (Rouwenhorst, 1998), clases de activos y periodos históricos (Jegadeesh & Titman, 2001).

Las explicaciones sobre el origen del momentum continúan siendo objeto de debate. Una línea de investigación lo vincula a sesgos conductuales como la sobreconfianza, el efecto disposición y la confirmación según Barberis et al. (1998), junto con la evidencia conductual presentada por Shiller (2003), mientras que Lo (2004) atribuye esto a factores de riesgo no observados o a fricciones propias del mercado. Más recientemente, Bandarchuk e Hilscher (2013) han mostrado que la rentabilidad atribuida al momentum puede concentrarse en activos con retornos previos extremos, sugiriendo que parte del efecto responde a características específicas que los modelos tradicionales no capturan por completo. Paralelamente, el avance del big data y los métodos de aprendizaje automático ha reavivado el interés en el estudio de anomalías de retorno. Modelos como *Random Forest*, XGBoost y redes neuronales permiten detectar patrones no lineales, interacciones complejas y señales predictivas en grandes volúmenes de datos, superando limitaciones de los modelos lineales clásicos según Gu et al. (2020) y Krauss et al. (2017).

A pesar del avance en la literatura, persisten importantes interrogantes respecto a la vigencia del efecto momentum en mercados altamente automatizados y sobre la capacidad de

los modelos de aprendizaje automático para generar mejoras consistentes en términos económicos. En particular, la literatura reciente ha enfatizado la diferencia entre capacidad predictiva estadística y rentabilidad económicamente explotable, así como los riesgos de sobreajuste y la necesidad de validación rigurosa fuera de muestra (Gu et al., 2020). Sin embargo, aún existe evidencia limitada sobre si estos enfoques permiten mejorar de manera consistente el desempeño de estrategias clásicas de momentum en contextos reales de inversión.

En este marco, el presente estudio analiza si los modelos de aprendizaje supervisado son capaces de predecir retornos mensuales en acciones pertenecientes al índice S&P 500. Como universo inicial se consideran las empresas que han formado parte del índice durante el periodo 2000–2024. A partir de este conjunto, la muestra final está compuesta por 352 empresas que presentan cotización continua y disponibilidad completa de datos de precios a lo largo de todo el periodo de análisis.

El criterio de inclusión se basa en la disponibilidad de series temporales completas sin interrupciones, lo que permite garantizar consistencia en la construcción de variables y en la implementación de las estrategias. En consecuencia, se excluyen aquellas empresas con datos incompletos o discontinuidades en la cotización que impidan la continuidad de la serie.

No obstante, este procedimiento puede introducir sesgo de supervivencia, al concentrarse en empresas con mayor estabilidad temporal y excluir aquellas que dejaron de cotizar o salieron del índice. Este sesgo no es corregido explícitamente en el presente estudio, por lo que los resultados deben interpretarse como representativos de un subconjunto más estable del universo del S&P 500.

El objetivo central es evaluar si, en un mercado que debería operar bajo condiciones de eficiencia, los métodos no paramétricos son capaces de identificar señales predictivas suficientes para construir portafolios con rendimientos ajustados por riesgo superiores, medidos mediante Sharpe, *drawdown* máximo y alpha Fama-French-Carhart. Asimismo, se analiza si dichas estrategias pueden generar retornos anormales de manera consistente.

En este contexto, el presente estudio realiza tres contribuciones principales. En primer lugar, aporta evidencia empírica actualizada sobre la vigencia del efecto momentum en un

mercado desarrollado y altamente automatizado como el S&P 500 durante el periodo 2000–2024, evaluando su comportamiento en distintos horizontes temporales. En segundo lugar, introduce un enfoque metodológico basado en aprendizaje supervisado mediante Random Forest, que permite capturar relaciones no lineales y comparar su desempeño frente a estrategias tradicionales bajo un esquema riguroso de validación fuera de muestra. En tercer lugar, analiza la aplicabilidad económica de estas estrategias, evaluando no solo su rentabilidad, sino también su estabilidad, riesgo y viabilidad de implementación en contextos reales de inversión.

### **Revisión de literatura**

El estudio del momentum en los mercados de capitales financieros tiene su origen empírico más influyente en el trabajo de Jegadeesh y Titman (1993) en su artículo “*Returns to buying winners and selling losers: Implications for stock market efficiency*”, la estrategia consistió en comprar acciones con altos retornos pasados y vender acciones con bajos retornos, generando rendimientos positivos en horizontes de 3 a 12 meses. Este hallazgo desafió la Hipótesis de los Mercados Eficientes (EMH) en sus formas débil y semifuerte (Fama, 1970). Posteriormente, los mismos autores confirmaron que el efecto momentum había persistido durante décadas y no podía explicarse plenamente mediante los factores de riesgo tradicionales (Jegadeesh & Titman, 2001).

En términos empíricos, la evidencia ha mostrado que el momentum es un fenómeno global. Rouwenhorst (1998) lo documentó en mercados europeos, mientras que Asness et al. (2013) demostraron su presencia en múltiples clases de activos como bonos, divisas y materias primas, resaltando su naturaleza transversal. Chui et al. (2010), por su parte, evidenciaron que el momentum es más débil en mercados con mayor participación de inversionistas individuales, lo que sugiere que la estructura del mercado influye en la magnitud del efecto.

En años recientes, el análisis del momentum se ha extendido hacia el uso de métodos de aprendizaje automático, como lo demostraron Bui et al. (2023), extendiendo el análisis del momentum con aprendizaje automático, en línea con Gu et al. (2020), quienes compararon estrategias momentum tradicionales y modelos de *machine learning* en el mercado de Taiwán. Sus resultados señalan que las características institucionales condicionan la estabilidad del momentum y que los modelos supervisados capturan relaciones no lineales complejas.

La EMH, en su formulación original, sostiene que los precios reflejan toda la información disponible (Fama, 1970); sin embargo, el momentum permanece como una de las anomalías más robustas. Estudios realizados por Carhart (1997) y Novy-Marx (2012) mostraron que el efecto conserva su poder explicativo aun después de incorporar modelos multifactoriales. En esta línea, Yao et al. (2022) ampliaron los enfoques clásicos mediante redes neuronales profundas, integrando factores tradicionales y variables generadas de forma no lineal. Sus resultados indican que estas arquitecturas capturan interacciones complejas y mejoran la capacidad predictiva en contextos dinámicos.

No obstante, estos avances también plantean interrogantes sobre si dichas mejoras en la capacidad predictiva se traducen efectivamente en estrategias de inversión económicamente explotables, especialmente en presencia de costos de transacción y cambios de régimen y limitaciones asociadas a la validación fuera de muestra. En este sentido, la literatura reciente enfatiza que la superioridad predictiva de los modelos de machine learning no garantiza necesariamente mejoras en términos de rentabilidad ajustada por riesgo ni robustez fuera de muestra (Bagnara, 2022; Gu et al., 2020).

Las explicaciones del momentum se agrupan en dos grandes perspectivas. La primera es la hipótesis conductual, que atribuye el fenómeno a reacciones lentas o excesivas de los inversionistas ante nueva información (Barberis et al., 1998; Hong & Stein, 1999; Shiller, 2003). La segunda es la hipótesis de riesgo, según la cual el momentum representa una prima por riesgos no capturados por los modelos tradicionales (Conrad & Kaul, 1998; Lo, 2004). Más recientemente, Bandarchuk y Hilscher (2013) mostraron que, al controlar los retornos extremos pasados, gran parte de los beneficios del momentum desaparece, sugiriendo que el fenómeno puede estar concentrado en activos con comportamientos atípicos no incorporados en los modelos de riesgo estándar. Estos resultados sugieren que el momentum no es un fenómeno homogéneo, sino que su rentabilidad puede depender de características específicas de los activos y de la dinámica del mercado. En este sentido, la evidencia apunta a que enfoques más flexibles, capaces de capturar heterogeneidad y relaciones no lineales, podrían ofrecer una mejor representación del fenómeno (Gu et al., 2020).

De forma complementaria, estudios recientes (Bagnara, 2022; Zhang, 2022) sugieren que los modelos no lineales y las técnicas de aprendizaje profundo permiten capturar con mayor precisión la dinámica del riesgo en mercados con fricciones. Asimismo, Daniel y Moskowitz

(2016) demostraron que las estrategias momentum son vulnerables a los llamados *momentum crashes*, caídas abruptas típicas de períodos de alta volatilidad o reversión del mercado. Este riesgo ha impulsado el desarrollo de enfoques condicionales y el uso de machine learning para identificar cambios estructurales y reducir la exposición en regímenes adversos (Chin et al., 2022).

El avance en métodos de machine learning ha ampliado sustancialmente las herramientas disponibles para estudiar anomalías de retorno. Modelos como Random Forest, XGBoost, *Support Vector Machines* y redes neuronales permiten modelar relaciones no lineales, capturar interacciones complejas entre variables y procesar grandes volúmenes de información financiera.

Dentro de los modelos de machine learning, Random Forest presenta ventajas relevantes en finanzas cuantitativas debido a su capacidad para modelar relaciones no lineales, reducir la varianza mediante procesos de agregación y controlar parcialmente el sobreajuste a través de la combinación de múltiples árboles de decisión. Estas características han favorecido su creciente utilización en problemas de predicción financiera y clasificación *cross-sectional* de activos.

Gu et al. (2020) mostraron que estos métodos de machine learning superan a las regresiones tradicionales en predicción *cross-sectional*. De forma similar, Fieberg et al. (2023) encontraron mejoras significativas en la predicción de retornos accionarios europeos mediante modelos de aprendizaje automático. Krauss et al. (2017) demostraron que el *deep learning* puede generar estrategias rentables incluso después de costos de transacción, y estudios como Beckmeyer y Wiedemann (2025), Goyal et al. (2025), Mattusch (2024) y Ye et al. (2024), destacan que el uso de IA avanzada, incluida la IA generativa, está transformando el modelo de valoración de activos financieros al introducir componentes de aprendizaje adaptativo.

Finalmente, una preocupación clave en finanzas cuantitativas es el sobreajuste. Los modelos pueden capturar ruido en lugar de patrones genuinos, generando resultados artificialmente sobresalientes en *backtesting*, pero con limitada capacidad de generalización fuera de muestra (Liao et al., 2025; López, 2018). Por ello, la literatura enfatiza la necesidad de esquemas rigurosos de validación, incluyendo validación cruzada para series temporales, análisis *walk-forward* y técnicas de regularización, a fin de garantizar la robustez estadística y la capacidad de generalización de los modelos. Desde esta perspectiva, el valor del machine

learning en finanzas no depende solo de su sofisticación algorítmica, sino de la solidez de sus mecanismos de control de riesgo y validación.

En este contexto, surge la necesidad de evaluar si la incorporación de técnicas de machine learning permite mejorar de manera consistente el desempeño de estrategias tradicionales de momentum, no solo en términos de capacidad predictiva, sino también en términos de rentabilidad ajustada por riesgo y robustez fuera de muestra.

En síntesis, la literatura ha documentado de forma robusta la existencia del efecto momentum en distintos mercados y clases de activos, así como el potencial de los modelos de aprendizaje automático para mejorar la capacidad predictiva en contextos financieros. Sin embargo, persisten importantes interrogantes respecto a si estas mejoras se traducen en resultados económicamente significativos y robustos fuera de muestra, especialmente en mercados desarrollados, caracterizados por altos niveles de eficiencia y automatización. En este sentido, el presente estudio contribuye a esta discusión al evaluar de manera comparativa el desempeño del momentum tradicional y un modelo basado en Random Forest en el S&P 500, incorporando un enfoque riguroso de validación y analizando tanto la rentabilidad como la estabilidad de las estrategias.

---

## Metodología

El estudio se basa en una muestra de 352 acciones correspondientes al universo del índice S&P 500 que presentan cotización continua durante todo el periodo de análisis. Se utilizan precios de cierre diarios ajustados por dividendos y eventos corporativos (*splits*), obtenidos de Bloomberg. A partir de esta información, se construyen retornos mensuales para el análisis empírico.

La restricción de cotización continua responde a la necesidad de contar con series homogéneas y completas a lo largo del periodo de análisis, lo cual resulta especialmente relevante para la estimación de modelos de aprendizaje automático bajo esquemas de entrenamiento temporal. No obstante, este criterio puede introducir sesgo de supervivencia, por lo que los resultados deben interpretarse considerando esta limitación.

El objetivo metodológico es comparar el desempeño de dos enfoques de *cross-sectional momentum*:

1. Estrategia tradicional basada en el ordenamiento de retornos pasados en horizontes de 1, 3, 6 y 12 meses.
2. Enfoque de aprendizaje supervisado basado en el algoritmo Random Forest, orientado a la predicción de retornos futuros y la construcción de portafolios.

### **Momentum tradicional (cross-sectional) con múltiples horizontes:**

Para cada horizonte  $h \in \{1, 3, 6 \text{ y } 12\}$ , se construye una señal de momentum basada en retornos acumulados pasados, excluyendo el último mes con el fin de evitar sesgos de *look-ahead*. En cada periodo, los activos se ordenan de acuerdo con dicha señal y se conforman portafolios *long-short* mediante la selección del decil superior (activos con mayores retornos pasados) y el decil inferior (activos con menores retornos).

El portafolio resultante mantiene una posición neta long-short con rebalanceo mensual, independientemente del horizonte de *lookback*. Este enfoque sigue la metodología clásica de Jegadeesh y Titman (1993; 2001).

La formulación matemática de la señal de momentum y la construcción del portafolio se presentan a continuación.

#### **Ecuación 1:**

$$MOM_{i,t}^{(h)} = \sum_{k=2}^{h+1} R_{i,t-k} \quad (1)$$

donde  $MOM_{i,t}^{(h)}$  representa la señal de momentum del activo  $i$  en el periodo  $t$  para un horizonte  $h$ , y  $R_{i,t-k}$  denota el retorno del activo  $i$  en el periodo  $t - k$ . La sumatoria excluye el mes más reciente ( $t - 1$ ) con el fin de evitar sesgos de look-ahead.

En cada periodo  $t$  y para cada horizonte  $h$ , se define el vector de señales de momentum del conjunto de activos como:

#### **Ecuación 2:**

$$\mathbf{MOM}_t^{(h)} = \left( MOM_{1,t}^{(h)}, \dots, MOM_{N,t}^{(h)} \right) \quad (2)$$

donde  $\mathbf{MOM}_t^{(h)}$  representa el vector de señales de momentum para el conjunto de  $N$  activos en el periodo  $t$  y horizonte  $h$ .

A partir de este vector, se determinan los cuantiles de la distribución cross-sectional.

**Ecuación 3:**

$$q_{p,t}^{(h)} = Q_p(\mathbf{MOM}_t^{(h)}), \quad p \in \{0.1, 0.9\} \quad (3)$$

donde  $Q_p(\cdot)$  denota el operador cuantil de orden  $p$ .

Los conjuntos de activos en posición larga y corta se definen como:

**Ecuación 4:**

$$L_t^{(h)} = \{i \mid MOM_{i,t}^{(h)} \geq Q_{0.9}(\mathbf{MOM}_t^{(h)})\} \quad (4)$$

**Ecuación 5:**

$$S_t^{(h)} = \{i \mid MOM_{i,t}^{(h)} \leq Q_{0.1}(\mathbf{MOM}_t^{(h)})\} \quad (5)$$

donde  $L_t^{(h)}$  y  $S_t^{(h)}$  representan los conjuntos de activos seleccionados para posiciones largas y cortas, respectivamente.

La ponderación de los activos en el portafolio long-short se define de forma equiproporcional como:

**Ecuación 6:**

$$w_{i,t}^{(h)} = \begin{cases} \frac{1}{|L_t^{(h)}|}, & \text{si } i \in L_t^{(h)} \\ -\frac{1}{|S_t^{(h)}|}, & \text{si } i \in S_t^{(h)} \end{cases} \quad (6)$$

donde  $|L_t^{(h)}|$  y  $|S_t^{(h)}|$  representan el número de activos en las posiciones largas y cortas, respectivamente

El retorno del portafolio long-short se define como:

**Ecuación 7:**

$$R_{t+h}^{LS,(h)} = \sum_{i \in L_t^{(h)}} \frac{1}{|L_t^{(h)}|} R_{i,t+h} - \sum_{i \in S_t^{(h)}} \frac{1}{|S_t^{(h)}|} R_{i,t+h} \quad (7)$$

### Ecuación 8:

$$C_{t+h}^{(h)} = C_t^{(h)} \left( 1 + R_{t+h}^{LS,(h)} \right) \quad (8)$$

donde  $C_{t+h}^{(h)}$  representa el capital del portafolio en el horizonte  $h$ , el cual evoluciona a partir del capital en  $t$  según los retornos del portafolio long–short, con condición inicial  $C_0^{(h)} = 1$ .

### Momentum con aprendizaje supervisado por el modelo Random Forest

El modelo Random Forest se entrena utilizando retornos acumulados en distintos horizontes (1, 3, 6 y 12 meses), excluyendo el mes más reciente con el fin de evitar sesgos de look-ahead. La estimación se realiza bajo un esquema de ventana expansiva (*expanding window*), en el cual el modelo se ajusta dinámicamente empleando únicamente la información disponible hasta cada periodo.

El modelo se implementa como un clasificador basado en ensambles de árboles de decisión, haciendo uso de 200 árboles ( $n\_estimators = 200$ ) y una profundidad máxima restringida ( $max\_depth = 5$ ), con el objetivo de controlar el sobreajuste y mejorar la capacidad de generalización. En cada periodo, el modelo es reentrenado utilizando toda la información histórica disponible hasta ese momento, garantizando un entorno estrictamente fuera de muestra.

En términos operativos, el modelo emplea el criterio de impureza Gini para la partición de los nodos y utiliza muestreo *bootstrap* en la construcción de los árboles, lo que contribuye a la reducción de la varianza y mejora la estabilidad de las predicciones. La selección de hiperparámetros se realiza de manera conservadora, fijando el número de árboles y la profundidad máxima con el objetivo de evitar sobreajuste, sin implementar procesos de optimización exhaustiva, en línea con enfoques que priorizan la robustez fuera de muestra.

El objetivo del modelo es predecir la probabilidad de que un activo pertenezca al decil superior de la distribución cross-sectional de retornos en el periodo siguiente. En función de estas probabilidades, se construyen portafolios long–short mediante el ordenamiento cross-sectional de los activos, seleccionando aquellos con mayor y menor probabilidad estimada, respectivamente. El rebalanceo se realiza de forma mensual, manteniendo consistencia con la estrategia de momentum tradicional.

Dado que la variable objetivo se define como la pertenencia al decil superior de retornos, el problema presenta un desbalance de clases. Este aspecto se aborda implícitamente mediante el uso de probabilidades estimadas y el ordenamiento cross-sectional, en lugar de técnicas explícitas de rebalanceo, lo que permite mantener la coherencia económica de la estrategia.

El esquema de entrenamiento y validación sigue un enfoque de ventana expansiva (expanding window), donde en cada periodo el modelo es entrenado utilizando toda la información disponible hasta ese momento y evaluado en el periodo siguiente. El modelo se entrena manejando un mínimo de 24 meses de información histórica antes de generar las primeras predicciones, con el fin de garantizar estabilidad en la estimación inicial. Este procedimiento garantiza una validación estrictamente fuera de muestra y evita sesgos de look-ahead, siendo equivalente a un esquema walk-forward ampliamente utilizado en finanzas cuantitativas.

Este enfoque metodológico se sustenta en la evidencia reciente que destaca la capacidad de los algoritmos de machine learning para capturar relaciones no lineales y patrones complejos en los mercados financieros (Gu et al., 2020), así como en la creciente adopción de modelos basados en Random Forest en el análisis cuantitativo de precios de activos (Healy et al., 2024).

### **El modelo general de Momentum con Random Forest**

El modelo de Random Forest utiliza como variables explicativas las señales de momentum previamente definidas. La predicción se formula como un problema de clasificación binaria.

#### **Ecuación 9 - Variable objetivo**

$$y_{i,t+h} = \begin{cases} 1, & \text{si } R_{i,t+h} \geq Q_{0.9}(\mathbf{R}_{t+h}) \\ 0, & \text{en otro caso} \end{cases} \quad (9)$$

donde  $y_{i,t+h}$  es una variable binaria que toma el valor de 1 si el retorno del activo  $i$  en el periodo  $t + h$  pertenece al decil superior de la distribución cross-sectional de retornos, y 0 en caso contrario.

**Ecuación 10 - Modelo de predicción:**

$$\widehat{P}_{i,t}^{(h)} = \mathbb{P}(y_{i,t+h} = 1 \mid \mathbf{X}_{i,t}) \quad (10)$$

**Ecuación 11 - Vector de características**

$$\mathbf{X}_{i,t} = (MOM_{i,t}^{(1)}, MOM_{i,t}^{(3)}, MOM_{i,t}^{(6)}, MOM_{i,t}^{(12)}) \quad (11)$$

donde  $\widehat{P}_{i,t}^{(h)}$  es la probabilidad estimada de que el activo  $i$  pertenezca al decil superior de retornos futuros, y  $\mathbf{X}_{i,t}$  representa el vector de características construido a partir de las señales de momentum en distintos horizontes.

**Construcción de portafolios (cross-sectional)**

En cada periodo  $t$ , los activos se ordenan en función de las probabilidades estimadas  $\widehat{P}_{i,t}^{(h)}$ , definiéndose los conjuntos de posiciones largas y cortas como:

**Ecuación 12:**

$$L_t^{(h)} = \{i \mid \widehat{P}_{i,t}^{(h)} \geq Q_{0.9}(\mathbf{P}_t^{(h)})\} \quad (12)$$

**Ecuación 13:**

$$S_t^{(h)} = \{i \mid \widehat{P}_{i,t}^{(h)} \leq Q_{0.1}(\mathbf{P}_t^{(h)})\} \quad (13)$$

La ponderación de los activos se realiza de forma uniforme, siguiendo el mismo esquema empleado en la estrategia de momentum tradicional. En consecuencia, el retorno del portafolio long–short se define como:

**Ecuación 14:**

$$R_{t+h}^{LS,(h)} = \sum_{i=1}^N w_{i,t}^{(h)} R_{i,t+h} \quad (14)$$

donde  $R_{t+h}^{LS,(h)}$  representa el retorno realizado del portafolio long–short en el periodo  $t + h$ , correspondiente al horizonte de inversión  $h$ .

La curva de capital se define como:

### Ecuación 15:

$$C_{t+h}^{(h)} = C_t^{(h)} \left( 1 + R_{t+h}^{LS,(h)} \right) \quad (15)$$

donde  $C_0^{(h)} = 1$  representa la condición inicial del capital del portafolio.

### Backtesting y métricas de evaluación

Ambos enfoques son evaluados bajo un esquema de backtesting homogéneo, con el fin de garantizar la comparabilidad de los resultados. En particular, se considera un rebalanceo mensual de los portafolios, con ponderación equiponderada de los activos en cada lado (largo y corto). Los resultados se presentan en términos brutos, sin incorporar explícitamente costos de transacción.

La evaluación del desempeño se realiza mediante un conjunto de métricas financieras ampliamente utilizadas en la literatura, incluyendo la rentabilidad anualizada, el ratio de Sharpe, el máximo drawdown (max drawdown), el hit rate y el alpha ajustado de acuerdo con el modelo de Fama–French–Carhart.

Este diseño metodológico permite analizar si la incorporación de algoritmos de machine learning, en particular Random Forest, mejora el desempeño ajustado por riesgo en comparación con el enfoque tradicional de momentum, así como evaluar la significancia económica de dichas diferencias.

---

## Resultados

Los gráficos de resultados incluyen franjas grises que identifican los principales episodios de crisis financieras entre 2000 y 2024, permitiendo evaluar la sensibilidad y robustez de cada horizonte de inversión (1M, 3M, 6M y 12M) bajo condiciones de estrés de mercado. Las crisis consideradas son:

- **Burbuja puntocom (2000–2002):** colapso del sector tecnológico.
- **Crisis financiera global (2007–2009):** Crisis *subprime* y quiebra de Lehman Brothers.
- **Crisis de deuda soberana europea (2010–2012):** tensiones fiscales en la periferia europea.

- **Crisis del COVID-19 (2020):** shock de liquidez y caídas abruptas en mercados globales.
- **Crisis de inflación, política monetaria restrictiva y conflicto en Ucrania (2022):** alta inflación mundial, subidas de tasas y tensiones geopolíticas.

La superposición de estas zonas permite comparar el desempeño acumulado en condiciones normales y durante episodios de fuerte disrupción.

### **Momentum tradicional (cross-sectional) por horizontes (1M, 3M, 6M, 12M)**

La Figura 1 presenta la evolución del capital acumulado para las estrategias de momentum tradicional en los horizontes de 1, 3, 6 y 12 meses. Los resultados reflejan un patrón claro: el desempeño mejora con el horizonte de inversión, aunque con dificultades para mantener un crecimiento sostenido y estable del capital en el largo plazo.

En los horizontes de corto plazo (1M y 3M), las estrategias muestran un desempeño marcadamente débil, caracterizado por una pérdida persistente de capital. Este comportamiento es consistente con la evidencia de reversión a la media en frecuencias altas documentada por Jegadeesh y Titman (2011) y Lehmann (1990), lo que limita la capacidad de capturar tendencias y refleja una alta sensibilidad al ruido de mercado.

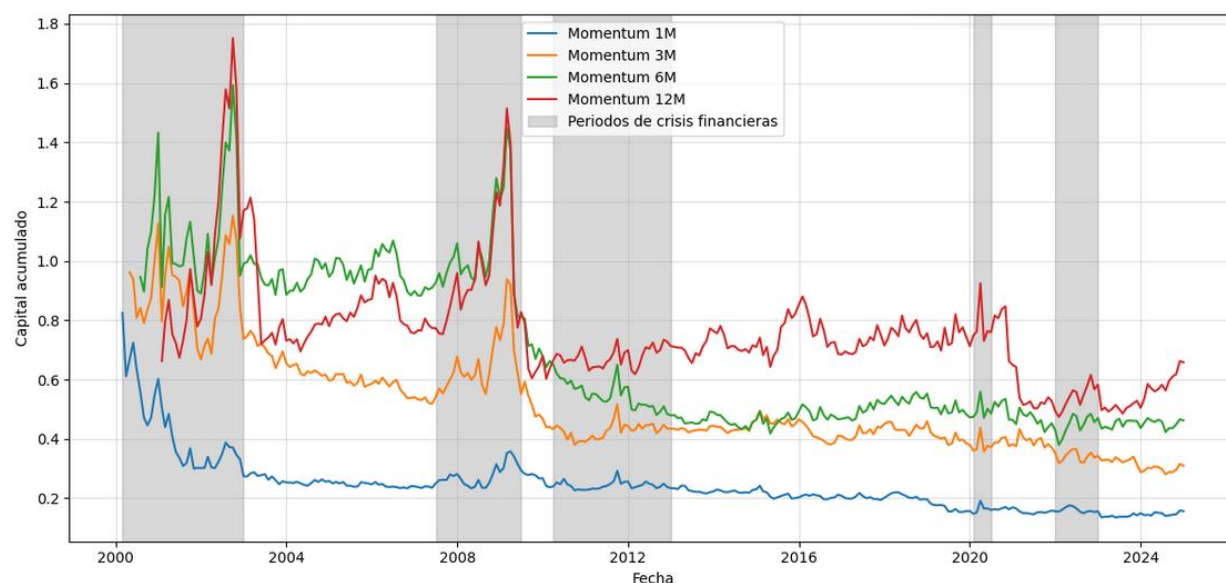
En el horizonte de 6 meses, la estrategia presenta un comportamiento relativamente más estable, aunque con episodios de crecimiento seguidos de caídas abruptas, particularmente en periodos de crisis. Este patrón es consistente con la evidencia de “momentum crashes” documentada por Daniel y Moskowitz (2016), lo que indica que, aunque la persistencia es mayor, el riesgo de reversión sigue siendo significativo.

Por su parte, el horizonte de 12 meses exhibe el mejor desempeño relativo dentro de los horizontes analizados, manteniendo niveles de capital superiores a los demás periodos. Este resultado es consistente con la evidencia clásica que identifica al momentum de 12 meses como el más robusto (Asness et al., 2013; Jegadeesh & Titman, 1993; 2001). No obstante, su trayectoria presenta episodios de alta volatilidad y episodios de drawdowns pronunciados, lo que sugiere que su efectividad no es completamente estable en el tiempo.

En conjunto, la evidencia propone que el momentum tradicional es altamente dependiente del horizonte temporal; mientras los horizontes más largos permiten capturar mejor la persistencia de los retornos, los horizontes cortos se ven dominados por ruido y reversión; sin embargo, la ausencia de un crecimiento sostenido del capital acumulado en todos los horizontes sugiere limitaciones estructurales en la capacidad del enfoque tradicional para generar retornos consistentes en el largo plazo.

### Figura 1

*Estrategia Momentum Tradicional 1M, 3M, 6M y 12M Long-Short*



*Fuente:* Elaboración propia.

### **Análisis de momentum con aprendizaje supervisado - modelo Random Forest**

En este enfoque se incorpora un modelo de aprendizaje supervisado no lineal basado en Random Forest, el cual clasifica activos utilizando múltiples retornos pasados como variables explicativas y un rendimiento futuro esperado como variable objetivo. A diferencia del momentum tradicional, este modelo puede capturar interacciones complejas y patrones no lineales en los datos, aunque su eficacia depende de una adecuada calibración, calidad de la información y control del sobreajuste.

El desempeño de la estrategia con Random Forest se evalúa para cada uno de los horizontes de inversión (1, 3, 6 y 12 meses), permitiendo comparar su capacidad predictiva frente al momentum tradicional.

La Figura 2 presenta la evolución del capital acumulado para las estrategias de momentum basadas en Random Forest en los horizontes de 1, 3 y 6 meses. Los resultados muestran una relación clara entre el horizonte de inversión y el desempeño de la estrategia, mostrando que la capacidad predictiva del modelo mejora a medida que aumenta el plazo de análisis.

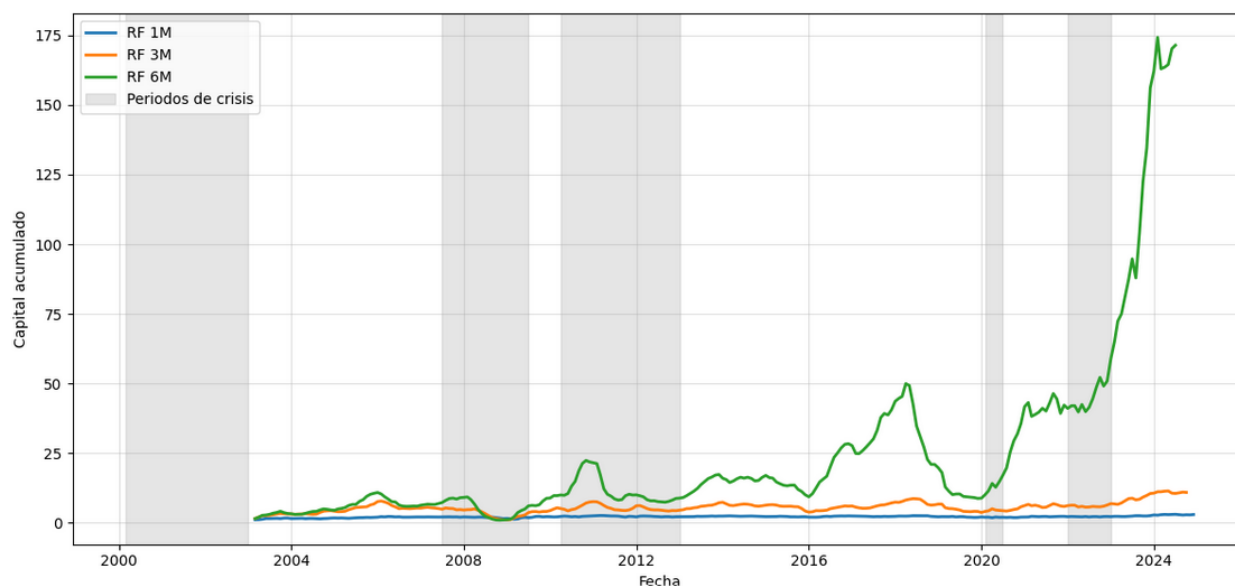
En el horizonte de un mes, la estrategia exhibe un crecimiento moderado y una trayectoria relativamente estable, lo que sugiere una limitada capacidad para extraer señales predictivas en presencia de ruido de alta frecuencia. En contraste, el horizonte de 3 meses muestra una mejora sustancial en la rentabilidad, indicando que el modelo logra capturar con mayor eficacia la persistencia de los retornos en horizontes intermedios.

El caso más destacado corresponde al horizonte de seis meses, donde se observa una expansión significativa del capital acumulado, especialmente después de junio de 2022, lo que sugiere que el modelo Random Forest es más efectivo en la identificación de patrones de momentum cuando estos presentan mayor estabilidad temporal. No obstante, este mayor nivel de rentabilidad viene acompañado de una mayor volatilidad y de episodios de caídas pronunciadas, reflejando un incremento en la exposición al riesgo.

En conjunto, la evidencia indica que el desempeño del modelo mejora con el horizonte de inversión, pero a costa de una menor estabilidad, lo que refleja un *trade-off* entre retorno y riesgo. Asimismo, se observa que una parte relevante del crecimiento en el horizonte de 6 meses se concentra en periodos recientes, lo que sugiere una posible dependencia de condiciones específicas del mercado (cambios de regímenes) y refuerza la necesidad de interpretar estos resultados con cautela.

## Figura 2

### *Estrategia Momentum 1M, 3M y 6M Long-Short con Random Forest*



*Fuente:* Elaboración propia.


La Figura 3 presenta la evolución del capital acumulado para la estrategia de momentum basada en Random Forest en el horizonte de 12 meses. A diferencia de los horizontes más cortos, esta estrategia exhibe el mayor nivel de rentabilidad, sugiriendo una mayor capacidad del modelo para capturar patrones de persistencia en el largo plazo.

Sin embargo, este desempeño está fuertemente concentrado en periodos recientes (después de junio de 2022), lo que sugiere una dependencia significativa de condiciones específicas del mercado. En este sentido, el crecimiento acelerado del capital podría estar reflejando la explotación de episodios particulares de alta rentabilidad más que relaciones estructurales estables.

Asimismo, la estrategia presenta el mayor nivel de riesgo entre todos los horizontes analizados, con drawdowns extremadamente elevados y una alta sensibilidad a cambios de régimen. En conjunto, estos resultados indican que, si bien el modelo puede generar retornos significativamente superiores en horizontes largos, su estabilidad es limitada, lo que requiere una interpretación cautelosa desde una perspectiva de implementación práctica.

### Figura 3

#### Estrategia Momentum 12M Long-Short con Random Forest



Fuente: Elaboración propia.

### Validando el rendimiento de las estrategias Momentum Tradicional vs. Random Forest para 1M, 3M, 6M y 12M

Con el objetivo de evaluar la robustez del desempeño de las estrategias de momentum, la Tabla 1 presenta las principales métricas de validación del backtest para los horizontes de 1, 3, 6 y 12 meses, comparando el enfoque tradicional y el modelo basado en Random Forest, tanto para la muestra completa (2000–2024) como para el periodo restringido (2000–junio 2022).

Los resultados indican diferencias sustanciales entre ambos enfoques. En el caso del momentum tradicional, los retornos son consistentemente negativos en la mayoría de los horizontes, con tasa de crecimiento anual compuesto (CAGR, por sus siglas en inglés) que oscilan entre -6,46% y -0,03% en la muestra completa. Esto sugiere limitaciones del enfoque tradicional para generar rentabilidad sostenida en el periodo analizado, especialmente en horizontes de corto y mediano plazo.

En contraste, las estrategias basadas en Random Forest presentan un desempeño numéricamente superior, con un incremento sistemático del rendimiento a medida que aumenta el horizonte de inversión. En la muestra completa, el CAGR pasa de 4.91% en RF 1M a 52.00% en RF 12M, patrón que se mantiene en la muestra restringida, aunque con niveles menores (40.90% en RF 12M y 18.89% en RF 6M). Este resultado sugiere que el modelo parece capturar

de manera más efectiva la persistencia de los retornos, pero parte del desempeño está asociado a condiciones recientes del mercado.

En términos de riesgo, ambos enfoques presentan un aumento en volatilidad y drawdown a medida que se amplía el horizonte temporal. Sin embargo, las estrategias de Random Forest exhiben niveles considerablemente más altos de volatilidad y drawdowns más profundos, alcanzando valores cercanos a -95% en el horizonte de 12 meses. Esto evidencia que la mejora en rentabilidad está acompañada de una mayor exposición a eventos extremos.

El desempeño ajustado por riesgo, medido a través del ratio Sharpe, también favorece al modelo de Random Forest, especialmente en horizontes largos (0.95 en RF 12M frente a valores cercanos a cero o negativos en el momentum tradicional). No obstante, esta mejora se reduce en el periodo restringido, lo que indica que la eficiencia del modelo no es completamente estable en el tiempo.

En conjunto, la evidencia sugiere que, si bien el enfoque basado en Random Forest mejora significativamente la capacidad de generación de retornos frente al momentum tradicional, esta ventaja está asociada a un mayor nivel de riesgo y a una dependencia relevante de condiciones específicas del mercado. En este sentido, la evaluación del desempeño debe considerar no solo la magnitud de los retornos, sino también su estabilidad y viabilidad de implementación.

**Tabla 1**  
*Comparación de métricas de desempeño y riesgo: momentum tradicional vs. Random Forest*

	Momentum tradicional (MOM)				Momentum Random Forest (RF)			
	Full Sample (2000 – 2024)							
	MOM 1M	MOM 3M	MOM 6M	MOM 12M	RF 1M	RF 3M	RF 6M	RF 12M
CAGR (%)	-6.46	-4.48	-2.88	-0.03	4.91	9.68	25.01	52.00
Vol. Anual (%)	19.55	21.39	23.65	24.89	18.24	30.06	42.13	54.68
Sharpe Ratio	-0.33	-0.21	-0.12	0.00	0.27	0.32	0.59	0.95
Max. Drawdown (%)	-83.61	-75.65	-76.17	-72.92	-44.17	-87.30	-91.84	-95.3
Hit Rate (%)	47.65	50.68	51.19	54.36	52.11	57.14	62.50	63.20
	PRE-2022 (2000 – Junio 2022)							
	MOM 1M	MOM 3M	MOM 6M	MOM 12M	RF 1M	RF 3M	RF 6M	RF 12M
CAGR (%)	-6.92	-4.26	-3.07	-0.80	3.60	7.15	18.89	40.90
Volatilidad anualizada (%)	19.98	22.03	24.47	25.61	18.70	31.24	43.35	55.55
Sharpe Ratio	-0.35	-0.19	-0.13	-0.03	0.19	0.23	0.44	0.74
Drawdown máximo (%)	-82.37	-72.43	-76.17	-72.92	-44.17	-87.30	-91.84	-95.30
Hit Rate (%)	46.64	50.75	51.33	53.31	51.29	55.60	59.91	60.78

Fuente: Elaboración propia.

En la Tabla 2 se indica la estimación del alpha ajustado mediante el modelo de Fama–French–Carhart para las estrategias de momentum tradicional y Random Forest, tanto en la muestra completa como en el periodo previo a junio de 2022. Los resultados muestran que el momentum tradicional no genera alphas estadísticamente significativos en ninguno de los horizontes analizados, lo que sugiere que su desempeño puede ser explicado por exposiciones a factores de riesgo sistemáticos.

En contraste, las estrategias basadas en Random Forest presentan alphas positivos y estadísticamente significativos en horizontes intermedios y largos, particularmente en 6M y 12M, donde los valores de t-stat y p-value evidencian significancia estadística robusta. Este resultado indica que el modelo de aprendizaje automático logra capturar patrones en los retornos que no son explicados por los factores tradicionales de riesgo. Sin embargo, al restringir el análisis al periodo previo a 2022, se observa una ligera reducción en la magnitud y significancia de los alphas, especialmente en horizontes más cortos, lo que sugiere que parte del desempeño del modelo puede estar influenciado por condiciones recientes del mercado. En conjunto, estos resultados refuerzan la evidencia de que, si bien el enfoque basado en Random Forest mejora la capacidad de generación de retornos anormales, su efectividad no es completamente estable en el tiempo.

**Tabla 2**

*Alpha ajustado por el modelo de Fama–French–Carhart para estrategias de momentum tradicional y Random Forest*

	Momentum Tradicional (MOM)				Momentum Random Forest (RF)			
	Full Sample (2000 – 2024)							
	MOM 1M	MOM 3M	MOM 6M	MOM 12M	RF 1M	RF 3M	RF 6M	RF 12M
Alpha (%)	-0.2467	-0.1647	-0.0805	0.0466	-0.0902	1.0308	2.646	4.6533
Error estándar	0.2954	0.2811	0.2556	0.2023	0.2276	0.5486	0.7529	0.9965
t-stat	-0.8352	-0.5858	-0.3148	0.2301	-0.3965	1.8789	3.5144	4.6695
p-value	0.4043	0.5585	0.7532	0.8182	0.6921	0.0614	0.0005	0
N	298	296	293	287	261	259	256	250
	PRE-2022 (2000 – junio 2022)							
	MOM 1M	MOM 3M	MOM 6M	MOM 12M	RF 1M	RF 3M	RF 6M	RF 12M
Alpha (%)	-0.2375	-0.1444	-0.0981	0.0208	-0.1453	0.9203	2.3056	4.0552
Error estándar	0.316	0.3033	0.2742	0.2168	0.2443	0.5977	0.8078	1.0438
t-stat	-0.7514	-0.4761	-0.3579	0.096	-0.5948	1.5397	2.8542	3.885
p-value	0.4531	0.6344	0.7207	0.9236	0.5526	0.125	0.0047	0.0001
N	268	266	263	257	232	232	232	232

*Fuente:* Elaboración propia.

En conjunto, los resultados reflejan que el uso de Random Forest mejora significativamente la capacidad de generación de retornos en comparación con el momentum tradicional, particularmente en horizontes intermedios y largos. Esta evidencia se ve reforzada por los resultados de la Tabla 2, donde las estrategias basadas en Random Forest presentan alphas positivos y estadísticamente significativos en horizontes de 6 y 12 meses, incluso después de controlar por los factores de riesgo del modelo de Fama–French–Carhart.

En contraste, el momentum tradicional no muestra evidencia de generación de retornos anormales; lo que propone un desempeño puede ser explicado en gran medida por exposiciones sistemáticas a factores de riesgo. Sin embargo, esta mejora no es uniforme ni completamente estable en el tiempo, ya que los mayores niveles de rentabilidad están asociados a incrementos sustanciales en el riesgo y a una dependencia relevante de condiciones específicas del mercado, especialmente en periodos recientes. Asimismo, al restringir el análisis al periodo previo a 2022, se observa una reducción en la magnitud y significancia de los alphas, lo que sugiere que parte del desempeño del modelo podría estar influenciado por dinámicas recientes del mercado.

En este sentido, mientras el momentum tradicional presenta un desempeño débil y en muchos casos negativo, el enfoque basado en machine learning logra capturar patrones no lineales que permiten mejorar la predicción de retornos y generar valor económico adicional. No obstante, esta ventaja viene acompañada de una mayor volatilidad, drawdowns más profundos y una menor consistencia temporal, lo que plantea un trade-off claro entre rentabilidad y estabilidad.

En consecuencia, los resultados sugieren que la evaluación del desempeño no debe centrarse únicamente en la magnitud de los retornos, sino también en su robustez estadística y su viabilidad de implementación. Estos hallazgos refuerzan la necesidad de incorporar mecanismos de validación rigurosa y control del riesgo al aplicar técnicas de aprendizaje automático en la construcción de estrategias de inversión.

## Discusión

Los resultados obtenidos en este estudio permiten identificar patrones consistentes en la efectividad de las estrategias de momentum, tanto en su versión tradicional como en su implementación mediante modelos de aprendizaje automático. En particular, la comparación de horizontes de inversión sugiere que la predictibilidad de los retornos no es uniforme, sino que depende de la escala temporal considerada.

En el caso del momentum tradicional, la evidencia respalda que los horizontes intermedios y largos presentan un mejor desempeño relativo, al capturar de manera más consistente la persistencia de las tendencias, mientras que los horizontes de corto plazo se ven afectados por reversión y ruido de mercado (Daniel & Moskowitz, 2016; Jegadeesh & Titman, 1993). Este resultado es consistente con la literatura clásica y refuerza la idea de que el momentum es un fenómeno dependiente del horizonte temporal.

Este resultado también está vinculado a la forma en que se construyen las señales de momentum en el enfoque tradicional, las cuales se basan en el ordenamiento cross-sectional de los retornos pasados y la formación de portafolios long-short entre activos ganadores y perdedores. Si bien esta metodología permite capturar la persistencia de tendencias, su efectividad depende críticamente de la estabilidad temporal de dichas señales y de la ausencia de reversión en el corto plazo. En este sentido, los resultados obtenidos sugieren que, en el periodo analizado, las señales tradicionales presentan limitaciones para generar retornos consistentes, particularmente en horizontes cortos, donde el ruido de mercado y la reversión afectan de manera significativa la capacidad predictiva del modelo.

En relación con la implementación mediante Random Forest, los resultados muestran que el modelo parece mejorar la capacidad de predicción en comparación con el enfoque tradicional, particularmente en horizontes intermedios y largos. No obstante, este mejor desempeño no es uniforme. Mientras que el horizonte de un mes presenta mayor estabilidad, pero limitada rentabilidad, los horizontes de tres y seis meses logran un mejor equilibrio entre retorno y riesgo, aunque con mayor sensibilidad a episodios de volatilidad y cambios de régimen.

El caso del horizonte de 12 meses resulta especialmente relevante. Si bien presenta el mayor nivel de rentabilidad y métricas de desempeño superiores, este comportamiento se encuentra altamente concentrado en periodos recientes y se caracteriza por una dinámica no lineal, con episodios de crecimiento acelerado seguidos de correcciones abruptas. Este patrón, junto con la presencia de drawdowns extremos, sugiere que parte del desempeño podría estar asociado a condiciones específicas del mercado o a problemas de sobreajuste, fenómeno ampliamente documentado en la literatura de machine learning aplicado a finanzas (Gu et al., 2020).

Desde una perspectiva de asset pricing, estos resultados sugieren que existen patrones no lineales en la dinámica de los retornos que no son completamente capturados por modelos tradicionales, y que logran ser modelados mediante técnicas de aprendizaje automático. Sin embargo, la evidencia también indica que estos patrones no son necesariamente estables en el tiempo, y pueden depender de cambios estructurales en el mercado, como los observados en el periodo posterior a la pandemia COVID-19, caracterizado por una mayor concentración y dispersión de retornos entre activos.

Este resultado se ve reforzado por la evidencia presentada en la Tabla 2, donde las estrategias basadas en Random Forest generan alphas positivos y estadísticamente significativos en horizontes intermedios y largos, incluso después de controlar por los factores de riesgo del modelo de Fama–French–Carhart. En contraste, el momentum tradicional no muestra evidencia de retornos anormales, lo que sugiere que su desempeño puede estar explicado por exposiciones sistemáticas. Desde esta perspectiva, los resultados refuerzan la idea de que los modelos de aprendizaje automático capturan componentes predictivos no lineales en ciertos periodos y horizontes, aunque dicha capacidad no es necesariamente estable en el tiempo.

En términos de implicaciones prácticas, los resultados muestran la existencia de un trade-off claro entre rentabilidad y riesgo. Si bien los horizontes largos permiten alcanzar mayores niveles de retorno, también implican una mayor exposición a eventos extremos y una menor estabilidad temporal. En este sentido, la implementación de estrategias basadas en machine learning requiere complementar el proceso de selección de activos con mecanismos de control de riesgo, tales como estrategias de timing o reducción de exposición en periodos de alta volatilidad.

No obstante, este estudio presenta algunas limitaciones que deben ser consideradas; en particular, el uso de una muestra con empresas con cotización continua puede introducir sesgo de supervivencia, y la ausencia de costos de transacción podría sobreestimar el desempeño de las estrategias. Asimismo, aunque se emplea un esquema de validación fuera de muestra, los resultados pueden estar influenciados por condiciones específicas del periodo analizado.

Finalmente, futuras investigaciones podrían extender este análisis incorporando costos de transacción, evaluando la robustez en otros mercados y explorando modelos alternativos de machine learning que permitan mejorar la estabilidad de las predicciones. Asimismo, resulta relevante analizar la interacción entre factores macroeconómicos y modelos predictivos, con el fin de entender mejor la dependencia del desempeño respecto al entorno de mercado.

En conjunto, la evidencia sugiere que, si bien el uso de Random Forest mejora la capacidad de capturar patrones de momentum, su efectividad depende de manera crítica del horizonte de inversión, del régimen de mercado y de la implementación de mecanismos adecuados de control de riesgo.

---

## Conclusiones

Los resultados empíricos aportan evidencia compatible con la persistencia del momentum en la muestra analizada a favor de la persistencia del efecto, particularmente en horizontes intermedios y largos. En el enfoque tradicional, el horizonte de 12 meses presenta el mejor desempeño relativo, en línea con la evidencia clásica (Jegadeesh & Titman, 1993; 2001), mientras que los horizontes de corto plazo (1M y 3M) muestran resultados limitados debido a la alta rotación, la sensibilidad al ruido de mercado y la presencia de reversión a la media.

En relación con el objetivo de investigación, los hallazgos muestran que el modelo basado en Random Forest presenta un desempeño relativamente superior al momentum tradicional en términos de generación de retornos, especialmente en horizontes intermedios y largos. Esto sugiere que los modelos no lineales pueden capturar patrones de persistencia y relaciones complejas en los datos financieros que no son identificados por enfoques lineales tradicionales.

Este resultado se ve reforzado por la evidencia presentada en la Tabla 1, donde se observa que el momentum tradicional exhibe retornos negativos o cercanos a cero en la mayoría de los horizontes, mientras que las estrategias basadas en Random Forest generan rendimientos positivos y crecientes con el horizonte de inversión. En particular, la diferencia en términos de CAGR y ratio de Sharpe entre ambos enfoques es sustancial, lo que sugiere que el modelo de aprendizaje automático no solo mejora la rentabilidad, sino también la eficiencia en la relación riesgo-retorno. No obstante, esta ventaja cuantitativa viene acompañada de mayores niveles de volatilidad y drawdowns, lo que refuerza la existencia de un trade-off estructural entre desempeño y estabilidad.

Este resultado se complementa con la evidencia presentada en la Tabla 2, donde se observa que las estrategias basadas en Random Forest generan alphas positivos y estadísticamente significativos en horizontes intermedios y largos, incluso después de controlar por los factores de riesgo del modelo de Fama–French–Carhart. En contraste, el momentum tradicional no presenta evidencia de generación de retornos anormales, lo que sugiere que su desempeño puede ser explicado principalmente por exposiciones sistemáticas. Estos hallazgos refuerzan la idea de que los modelos de aprendizaje automático no solo mejoran la rentabilidad, sino que también permiten capturar componentes adicionales de información en los retornos que no son explicados por los modelos tradicionales de valoración de activos.

No obstante, esta mejora en el desempeño no es uniforme ni completamente robusta. Los resultados muestran que las estrategias basadas en Random Forest presentan mayores niveles de volatilidad y drawdowns más pronunciados, particularmente en el horizonte de 12 meses, lo que evidencia una mayor exposición a riesgos extremos. En este sentido, se identifica un trade-off claro entre rentabilidad y estabilidad, mientras el enfoque de machine learning ofrece mayores retornos potenciales, también implica una menor consistencia en el tiempo.

Asimismo, el análisis de robustez evidencia que una parte significativa del desempeño en horizontes largos está concentrada en periodos recientes, lo que sugiere una dependencia relevante de condiciones específicas del mercado. Este resultado plantea interrogantes sobre la capacidad de generalización de estos modelos y refuerza la necesidad de interpretar con cautela los resultados derivados de backtesting.

En este contexto, los hallazgos resaltan la importancia de complementar el uso de

modelos de aprendizaje automático con mecanismos robustos de validación y gestión del riesgo. En particular, la validación fuera de muestra, el análisis walk-forward y la incorporación de indicadores de riesgo para ajustar dinámicamente la exposición del portafolio resultan fundamentales para mejorar la estabilidad y viabilidad de implementación de estas estrategias.

Finalmente, este estudio contribuye a la literatura al proporcionar evidencia comparativa entre estrategias de momentum tradicionales y enfoques basados en machine learning en un mercado accionario desarrollado. Los resultados muestran que, si bien el uso de Random Forest puede mejorar el desempeño predictivo, su efectividad depende críticamente del horizonte de inversión, del régimen de mercado y de la implementación de mecanismos adecuados de control del riesgo. Futuras investigaciones podrían explorar la incorporación de variables macroeconómicas, modelos híbridos y técnicas más avanzadas de aprendizaje automático, así como evaluar la robustez de estos enfoques en distintos mercados y contextos económicos.

---

### **Consideraciones éticas**

El presente estudio no requirió de aval de un Comité de Ética o Bioética dado que no utilizó ningún recurso vivo, agente, muestra biológica o datos personales que representen algún riesgo sobre la vida, el ambiente o los derechos humanos.

---

### **Conflicto de interés**

Todos los autores realizaron aportes significativos al documento y declaran que no existe ningún conflicto de interés relacionado con este artículo.

---

### **Declaración de contribución de los autores**

Carlos Palomino Selem: conceptualización, metodología, análisis formal, supervisión, administración de proyecto, validación, investigación, escritura - borrador original, redacción: revisión y edición.

Ruth Milagros Delgado Yana: análisis formal, software, investigación, recursos, curación de datos, escritura - borrador original, redacción: revisión y edición, visualización.

---

### **Fuente de financiación**

Artículo financiado con recursos propios de los autores.

## Referencias

- (1) Asness, C., Moskowitz, T. & Pedersen, L. (2013). Value and momentum everywhere. *Journal of Finance*, 68(3), 929–985. <https://doi.org/10.1111/jofi.12021>
- (2) Bagnara, M. (2022). Asset pricing and machine learning: a critical review. *Journal of Economic Surveys*, 38(1), 27–56. <https://doi.org/10.1111/joes.12532>
- (3) Bandarchuk, P. & Hilscher, J. (2013). Sources of momentum profits: evidence on the irrelevance of characteristics. *Review of Finance*, 17(2), 809–845. <https://doi.org/10.1093/rof/rfr036>
- (4) Barberis, N., Shleifer, A. & Vishny, R. (1998). A model of investor sentiment. *Journal of Financial Economics*, 49(3), 307–343. [https://doi.org/10.1016/S0304-405X\(98\)00027-0](https://doi.org/10.1016/S0304-405X(98)00027-0)
- (5) Beckmeyer, H. & Wiedemann, T. (2025). All days are not created equal: understanding momentum by learning to weight past returns. *Journal of Banking & Finance*, 181, 107565. <https://doi.org/10.1016/j.jbankfin.2025.107565>
- (6) Bui, D. G., Kong, D. R., Lin, C. Y. & Lin, T. C. (2023). Momentum in machine learning: evidence from the Taiwan stock market. *Pacific-Basin Finance Journal*, 82, 102178. <https://doi.org/10.1016/j.pacfin.2023.102178>
- (7) Carhart, M. M. (1997). On persistence in mutual fund performance. *Journal of Finance*, 52(1), 57–86. <https://doi.org/10.2307/2329556>
- (8) Chin, J. T., Lin, H. & Mei, Y. (2022). *Machine learning and the cross-section of stock returns*. SSRN Electronic Journal. <https://doi.org/10.2139/ssrn.4282614>
- (9) Chui, A., Titman, S. & Wei, K. (2010). Individualism and momentum around the world. *The Journal of Finance*, 65(1), 361–392. <https://doi.org/10.1111/j.1540-6261.2009.01532.x>
- (10) Conrad, J. & Kaul, G. (1998). An Anatomy of trading strategies. *The Review of Financial Studies*, 11(3), 489–519. <https://doi.org/10.1093/rfs/11.3.489>
- (11) Daniel, K. & Moskowitz, T. (2016). Momentum crashes. *Journal of Financial Economics*, 122(2), 221–247. <https://doi.org/10.1016/j.jfineco.2015.12.002>
- (12) Fama, E. & French, K. (1996). Multifactor explanations of asset pricing anomalies. *Journal of Finance*, 51(1), 55–84. <https://doi.org/10.2307/2329302>
- (13) Fama, E. (1970). Efficient capital markets: a review of theory and empirical work. *Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>

- (14) Fieberg, C., Metko, D., Poddig, T. & Loy, T. (2023). Machine learning techniques for cross-sectional equity returns prediction. *OR Spectrum*, 45, 289–323. <https://doi.org/10.1007/s00291-022-00693-w>
- (15) Goyal, A., Jegadeesh, N. & Subrahmanyam, A. (2025). Empirical determinants of momentum: a perspective using international data. *Review of Finance*, 29(1), 241–273. <https://doi.org/10.1093/rof/rfae038>
- (16) Gu, S., Kelly, B. & Xiu, D. (2020). Empirical asset pricing via machine learning. *Review of Financial Studies*, 33(5), 2223–2273. <https://doi.org/10.1093/rfs/hhaa009>
- (17) Healy, J. V., Gregoriou, A. & Hudson, R. (2024). Automated machine learning and asset pricing. *risk*, 12(9), 148. <https://doi.org/10.3390/risks12090148>
- (18) Hong, H. & Stein, J. (1999). A unified theory of underreaction, momentum trading, and overreaction in asset markets. *The Journal of Finance*, 54(6), 2143–2184. <https://doi.org/10.1111/0022-1082.00184>
- (19) Jegadeesh, N. & Titman, S. (1993). Returns to buying winners and selling losers: implications for stock market efficiency. *Journal of Finance*, 48(1), 65-91. <https://doi.org/10.2307/2328882>
- (20) Jegadeesh, N. & Titman, S. (2001). Profitability of momentum strategies: an evaluation of alternative explanations. *The Journal of Finance*, 56(2), 699–720. <https://doi.org/10.1111/0022-1082.00342>
- (21) Jegadeesh, N. & Titman, S. (2011). Momentum. *Annual Review of Financial Economics*, 3, 493–509. <https://doi.org/10.1146/annurev-financial-102710-144850>
- (22) Krauss, C., Do, X. & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: statistical arbitrage on the S&P 500. *European Journal of Operational Research*, 259(2), 689–702. <https://doi.org/10.1016/j.ejor.2016.10.031>
- (23) Lehmann, B. N. (1990). Fads, martingales and market efficiency. *The Quarterly Journal of Economics*, 105(1), 1–28. <https://doi.org/10.2307/2937816>
- (24) Liao, Y., Ma, X., Neuhierl, A. & Schilling, L. (2025). *The uncertainty of machine learning predictions in asset pricing*. arXiv preprint. <https://doi.org/10.48550/arXiv.2503.00549>
- (25) Lo, A. W. (2004). The adaptive markets hypothesis. *Journal of Portfolio Management*, 30(5), 15-29. <https://doi.org/10.3905/jpm.2004.442611>
- (26) López, M. (2018). *Advances in financial machine learning*. Wiley. <https://www.wiley.com/en-us/Advances+in+Financial+Machine+Learning-p-9781119482086>

- (27) Mattusch, M. (2024). Generative AI for european asset pricing: alleviating the momentum anomaly. *The European Journal of Finance*, 31(7), 850–888. <https://doi.org/10.1080/1351847X.2024.2439979>
- (28) Novy-Marx, R. (2012). Is momentum really momentum? *Journal of Financial Economics*, 103(3), 429-453. <https://doi.org/10.1016/j.jfineco.2011.05.003>
- (29) Rouwenhorst, K. (1998). International momentum strategies. *Journal of Finance*, 53(1), 267–284. <https://doi.org/10.1111/0022-1082.95722>
- (30) Shiller, R. J. (2003). From efficient markets theory to behavioral finance. *Journal of Economic Perspectives*, 17(1), 83-104. <https://doi.org/10.1257/089533003321164967>
- (31) Yao, H., Zhang, X., Zhou, G. & Yang, C. (2022). Six-factor asset pricing and portfolio investment via deep learning: evidence from the Chinese stock market. *Pacific-Basin Finance Journal*, 76, 101886. <https://doi.org/10.1016/j.pacfin.2022.101886>
- (32) Ye, J., Goswami, B., Gu, J., Uddin, A. & Wang, G. (2024). *From factor models to deep learning: Machine learning in reshaping empirical asset pricing*. arXiv preprint. <https://doi.org/10.48550/arXiv.2403.06779>
- (33) Zhang, C. (2022). *Asset Pricing and Deep Learning*. Cornell University - arXiv. <https://doi.org/10.48550/arXiv.2209.12014>