

TRABAJO DE INVESTIGACIÓN FINAL

La incorporación de la tecnología en la gestión de carteras

Análisis comparativo de gestión humana y gestión algorítmica

Autores:

Gomez Di Gaeta, Ivan Lautaro — LU: 1145006

Jara Anisich, Marcos Gabriel — LU: 1110804

Carrera:

Licenciatura en Finanzas

Tutor:

Zipilivan, Marcos

Años:

2026

Agradecimientos

Queremos expresar nuestro más sincero agradecimiento a todas las personas que nos acompañaron durante el desarrollo de esta tesis.

En primer lugar, agradecemos a nuestra profesora de tesis, Karina, por su guía, dedicación y acompañamiento a lo largo de este proceso. Sus observaciones y recomendaciones fueron fundamentales para poder llevar adelante este trabajo.

También queremos agradecer especialmente a Marcos Zipilivan, nuestro tutor de tesis, por su compromiso, orientación y valiosos aportes durante el desarrollo de la investigación.

Agradecemos, además, a los docentes y a la institución, por la formación académica recibida y por brindarnos las herramientas necesarias para crecer tanto en lo profesional como en lo personal.

A nuestras familias, gracias por el apoyo incondicional, la paciencia y el acompañamiento constante durante toda nuestra carrera. Su confianza fue una motivación esencial para alcanzar este objetivo.

Finalmente, agradecemos a nuestros amigos y compañeros, por estar presentes, compartir este camino y hacer más llevadero cada desafío.

A todos ellos, muchas gracias.

Índice

1. Introducción	6
2. Planteamiento del Problema y Preguntas de Investigación	8
2.1. Planteamiento del Problema	8
2.2. Preguntas de Investigación	8
3. Justificación de la Investigación	9
3.1. Relevancia Académica	9
3.2. Relevancia Práctica	9
3.3. Contribución Diferencial	10
4. Objetivos de la Investigación	11
4.1. Objetivo General	11
4.2. Objetivos Específicos	11
5. Hipótesis	11
5.1. Hipótesis Principal	11
5.2. Hipótesis Secundaria	12
5.3. Diseño de la Investigación	12
6. Marco Teórico: Conceptual y Referencial	13
6.1. Antecedentes de la Investigación	13
6.2. Antecedentes Cuantitativos	14
6.3. Teoría Financiera Clásica	14
6.4. Finanzas Conductuales: Fundamentos y Prospect Theory	15
6.5. Sesgos Conductuales y Su Operacionalización en el Modelo	16
6.6. La Estrategia Algorítmica: Formalización Matemática	18
6.7. Clasificación de Regímenes de Volatilidad	19
6.8. Métricas de Evaluación del Desempeño	19
7. Metodología	20
7.1. Enfoque y Tipo de Investigación	20
7.2. Datos y Universo de Análisis	20
7.3. Estrategia Algorítmica: Especificación Completa	21
7.4. Estrategia Conductual: Sesgos Implementados	23
7.5. Clasificación de Regímenes de Volatilidad	24
7.6. Análisis de Sensibilidad a Costos de Transacción	25
7.7. Herramientas Computacionales	25
8. Análisis de Resultados	26
8.1. Desempeño General de las Estrategias	26
8.2. Análisis por Régimen de Volatilidad	27
8.3. Análisis de Sesgos Conductuales en el Portafolio	29
8.4. Comportamiento del Régimen de Volatilidad	30
8.5. Curvas Acumuladas y Drawdowns	31
9. Conclusiones	33
9.1. Respuesta a las Hipótesis	33
9.2. Contribuciones de la Investigación	34
9.3. Limitaciones de la Investigación	34
9.4. Líneas de Investigación Futura	35
9.5. Reflexión Final	35
Anexos	36
Librerías utilizadas	39
Bibliografía	40

Resumen

El presente trabajo analiza comparativamente el desempeño ajustado por riesgo de una estrategia algorítmica de Cross-Sectional Momentum (CSM) frente a una estrategia conductual que replica seis sesgos cognitivos documentados en la literatura, sobre el universo de acciones del S&P 500 durante el período 2020-2024. La estrategia algorítmica implementa la especificación 12-1 de Jegadeesh y Titman (1993) con ponderación inverse-volatility, estructura long-short y un overlay racional de régimen de volatilidad. La estrategia conductual incorpora el efecto disposición (Shefrin y Statman, 1985), el exceso de confianza (Barber y Odean, 2001), el sesgo de recencia (Kahneman y Tversky, 1979), la aversión a las pérdidas bajo alta volatilidad (Talhartit et al., 2022), el herding (Chang et al., 2000) y el sesgo de anclaje (Odean, 1998).

Los resultados muestran que la estrategia algorítmica obtiene un retorno anual de 12.88% con un Sharpe de 0.664 y un máximo drawdown de -19.45%, frente al 9.91% de retorno, Sharpe de 0.530 y drawdown de -27.26% de la estrategia conductual. El análisis por régimen de volatilidad confirma la hipótesis de heterogeneidad: la ventaja algorítmica es más pronunciada en régimen Normal Vol (Sharpe 1.307 vs 0.791) y High Vol (Sharpe 1.005 vs 0.939), siendo menor en Low Vol (Sharpe 0.349 vs 0.552), donde el Buy & Hold del S&P 500 domina a ambas estrategias activas con un Sharpe de 1.040. El análisis de sensibilidad a costos de transacción confirma que la ventaja algorítmica se mantiene hasta niveles de 20 puntos básicos.

Palabras clave: Cross-Sectional Momentum, gestión algorítmica, finanzas conductuales, Prospect Theory, sesgos cognitivos, régimen de volatilidad, S&P 500, backtesting, ratio de Sharpe, efecto disposición.

Abstract

This paper comparatively analyzes the risk-adjusted performance of an algorithmic Cross-Sectional Momentum (CSM) strategy against a behavioral strategy replicating six documented cognitive biases, on the S&P 500 universe over 2020-2024. The algorithmic strategy implements the Jegadeesh and Titman (1993) 12-1 specification with inverse-volatility weighting, a long-short structure and a rational volatility regime overlay. Results show the algorithmic strategy achieves a 12.88% annual return, Sharpe of 0.664 and maximum drawdown of -19.45%, versus 9.91%, 0.530 and -27.26% for the behavioral strategy. Regime analysis confirms that the algorithmic advantage is largest in Normal and High Vol regimes, consistent with the hypothesis that behavioral biases amplify under market stress.

Keywords: Cross-Sectional Momentum, algorithmic portfolio management, behavioral finance, Prospect Theory, cognitive biases, volatility regime, S&P 500, backtesting, Sharpe ratio, disposition effect.

1. Introducción

La gestión de carteras de inversión ha experimentado en las últimas dos décadas una transformación estructural impulsada por la digitalización, el abaratamiento del poder computacional y la disponibilidad masiva de datos financieros de alta frecuencia. Lo que en los años 90 era patrimonio casi exclusivo de los grandes bancos de inversión y fondos de cobertura —la capacidad de construir y ejecutar estrategias de inversión sistemáticas basadas en algoritmos— es hoy accesible para gestores de cualquier escala. Esta democratización tecnológica ha planteado una pregunta de alta relevancia tanto académica como práctica: ¿genera la gestión algorítmica mejores resultados ajustados por riesgo que la gestión humana activa, y bajo qué condiciones de mercado cada paradigma tiene ventaja?

La teoría financiera clásica, sustentada en la Hipótesis de los Mercados Eficientes (Fama, 1970) y el Capital Asset Pricing Model (Sharpe, 1964), postula que ningún agente puede obtener retornos superiores al mercado de manera sistemática sobre una base ajustada por riesgo. Sin embargo, la evidencia empírica acumulada desde los años 90 documenta anomalías persistentes que contradicen este paradigma, siendo el efecto momentum la más robusta y universalmente documentada: las acciones con mejor desempeño relativo en los últimos 12 meses tienden a continuar superando a las de peor desempeño en los 3 a 12 meses subsiguientes (Jegadeesh y Titman, 1993).

Paralelamente, la literatura de finanzas conductuales —cuyo fundamento teórico central es la Prospect Theory de Kahneman y Tversky (1979)— documenta que los inversores reales exhiben sesgos cognitivos y emocionales predecibles que distorsionan sus decisiones de manera sistemática y costosa. El efecto disposición (Shefrin y Statman, 1985), el exceso de confianza (Barber y Odean, 2001), el sesgo de recencia, la aversión a las pérdidas bajo alta volatilidad (Talhartit et al., 2022), el herding (Chang et al., 2000) y el anclaje representan los sesgos con mayor evidencia empírica y mayor impacto cuantificado sobre el rendimiento de las carteras.

El presente trabajo contribuye a este debate con un enfoque metodológico de simulación controlada: construye dos estrategias computacionales sobre exactamente el mismo universo, período y condiciones de mercado. La primera es racional y algorítmica; la segunda replica las mismas reglas base pero incorpora los seis sesgos conductuales

operacionalizados como modificaciones específicas y cuantificadas de los parámetros de la estrategia racional. La única diferencia entre ambas es la presencia de los sesgos, lo que permite aislar su costo sobre el desempeño con una precisión que los estudios observacionales no pueden alcanzar.

El período de análisis, 2020-2024, ofrece una variedad histórica de regímenes de mercado difícilmente igualable: el shock de la pandemia en el primer trimestre de 2020, el mercado alcista de 2021, el ciclo inflacionario y la corrección de 2022, la normalización de 2023 y el rally de inteligencia artificial de 2024. Esta diversidad permite evaluar las hipótesis bajo condiciones genuinamente heterogéneas.

El trabajo se estructura de la siguiente manera: planteamiento del problema y preguntas de investigación, justificación, objetivos, hipótesis, marco teórico, metodología, análisis de resultados, conclusiones y referencias bibliográficas.

2. Planteamiento del Problema y Preguntas de Investigación

2.1. Planteamiento del Problema

La incorporación de tecnología en la gestión de carteras ha dado lugar a dos paradigmas diferenciados: la gestión humana, caracterizada por la interpretación subjetiva y la influencia de sesgos conductuales documentados; y la gestión algorítmica, basada en reglas cuantitativas y ejecución sistemática sin intervención discrecional. Pese a la creciente adopción de algoritmos en la industria financiera, existe escasa evidencia sistemática sobre el desempeño relativo de ambos enfoques en condiciones de mercado heterogéneas y sobre el efecto real y cuantificado de los sesgos conductuales sobre el rendimiento de los portafolios.

Mientras la teoría conductual documenta cómo los sesgos cognitivos deterioran las decisiones humanas de inversión (Kahneman, 2011; Thaler, 1993), la gestión algorítmica enfrenta sus propios riesgos: sesgos de diseño, sobreajuste a datos históricos y rigidez frente a cambios de régimen no anticipados. El presente trabajo busca cubrir esta brecha mediante un diseño experimental controlado que permita comparar ambos enfoques en condiciones idénticas.

2.2. Preguntas de Investigación

Pregunta principal.

¿Cómo difiere el desempeño ajustado por riesgo entre una estrategia algorítmica de inversión y la simulación de una misma estrategia con sesgos conductuales?

Preguntas secundarias.

- ¿En qué medida difieren los rendimientos ajustados por riesgo entre ambas estrategias, medidos por el ratio de Sharpe, el ratio de Calmar y el máximo drawdown?
- ¿Cómo varía el desempeño relativo de cada enfoque en distintos regímenes de mercado (alta volatilidad, normal y baja volatilidad)?
- ¿Qué impacto tiene la incorporación de reglas que simulan sesgos conductuales sobre el rendimiento ajustado por riesgo?

3. Justificación de la Investigación

3.1. Relevancia Académica

La investigación se justifica académicamente en tres dimensiones. Primero, contribuye a la literatura sobre el efecto momentum cross-sectional (Jegadeesh y Titman, 1993; Rouwenhorst, 1998; Schlie y Zhou, 2025) evaluando la prima de momentum en el período más reciente disponible, que incluye episodios de volatilidad extrema como el shock de la pandemia de 2020 y el ciclo inflacionario de 2022. Segundo, aporta a la literatura de finanzas conductuales operacionalizando seis sesgos en reglas de trading computacionalmente verificables, permitiendo cuantificar el costo de cada sesgo de manera controlada. Tercero, el análisis por regímenes de volatilidad aporta evidencia sobre la hipótesis de heterogeneidad del costo de los sesgos conductuales a lo largo del ciclo de mercado.

3.2. Relevancia Práctica

Desde la perspectiva práctica, los resultados informan la decisión de asignación entre gestión activa discrecional y gestión sistemática para inversores institucionales,

gestores individuales y diseñadores de robo-advisors. La cuantificación del impacto de sesgos específicos como el efecto disposición o el sesgo de recencia provee incentivos concretos para adoptar mecanismos de disciplina y automatización en el proceso de inversión.

3.3. Contribución Diferencial

La principal contribución metodológica es la construcción de una estrategia conductual prescriptiva y computacionalmente implementada: al codificar los seis sesgos como parámetros específicos del código Python con umbrales numéricos calibrados sobre evidencia empírica, la investigación transforma conceptos psicológicos abstractos en variables de decisión verificables y replicables. Este diseño permite estimar el costo de los sesgos con mayor precisión que los estudios observacionales.

4. Objetivos de la Investigación

4.1. Objetivo General

Comparar el desempeño ajustado por riesgo de una estrategia algorítmica de Cross-Sectional Momentum frente a una estrategia conductual que replica los principales sesgos cognitivos documentados en la literatura, sobre el universo de acciones del S&P 500 durante el período 2020-2024.

4.2. Objetivos Específicos

1. Identificar, los principales sesgos conductuales presentes en la gestión humana de carteras —efecto disposición, exceso de confianza, sesgo de recencia, aversión a las pérdidas, herding y anclaje— describiendo su fundamento teórico en la Prospect Theory (Kahneman y Tversky, 1979) y su evidencia empírica cuantificada.
2. Diseñar dos versiones de una estrategia de Cross-Sectional Momentum: una racional con la especificación 12-1 (Jegadeesh y Titman, 1993), ponderación inverse-volatility y estructura long-short; y una conductual con los seis sesgos operacionalizados.
3. Comparar el desempeño de ambas estrategias mediante Sharpe Ratio, Calmar Ratio, máximo drawdown, win rate y turnover, tanto en el período completo como desagregado por régimen de volatilidad, y realizar un análisis de sensibilidad a costos de transacción de 0 a 20 puntos básicos.

5. Hipótesis

5.1. Hipótesis Principal

La estrategia algorítmica racional obtiene un rendimiento ajustado por riesgo — medido por el ratio de Sharpe y el ratio de Calmar— superior al de la estrategia conductual con sesgos simulados en el mercado de renta variable del S&P 500 durante el período 2020-2024.

5.2. Hipótesis Secundaria

La incorporación de sesgos conductuales en la estrategia algorítmica deteriora significativamente su rendimiento ajustado por riesgo respecto de la versión racional — medido por la caída del ratio de Sharpe, el aumento del máximo drawdown y la reducción del ratio de Calmar—, siendo esta degradación más pronunciada en los regímenes de Normal Vol y High Vol, donde la presión emocional del mercado amplifica los sesgos, y con mayor robustez del modelo racional frente a distintos niveles de costos de transacción de hasta 20 puntos básicos.

5.3. Diseño de la Investigación

El diseño de investigación es cuantitativo, comparativo y de simulación histórica (backtesting). Según la clasificación de hipótesis, el diseño es correlacional-explicativo: se evalúa la relación entre el tipo de estrategia (algorítmica vs conductual) y el desempeño ajustado por riesgo, con el régimen de volatilidad como variable moderadora. Los parámetros de la estrategia algorítmica se basan en especificaciones documentadas en la literatura preexistente, sin optimización sobre el período 2020-2024, garantizando validez externa del backtesting.

6. Marco Teórico: Conceptual y Referencial

El presente marco teórico articula los fundamentos conceptuales, el desarrollo histórico y la formalización matemática que sustentan el modelo de comparación entre gestión algorítmica y gestión conductual de carteras. Cada sección teórica culmina en la especificación precisa de los parámetros y fórmulas utilizados en el código Python desarrollado, estableciendo un puente explícito entre la literatura académica y la implementación computacional.

6.1. Antecedentes de la Investigación

Carencias en la dimensión psicológica de la literatura.

Un aspecto que la literatura sobre momentum cross-sectional trata de manera sistemáticamente incompleta es la dimensión psicológica del gestor humano. Los trabajos fundacionales del área —Jegadeesh y Titman (1993), Carhart (1997) y Fama y French (1993)— abordan el momentum exclusivamente como una anomalía de mercado o como un factor de riesgo, sin incorporar una descripción de los mecanismos cognitivos que generan y sostienen esa anomalía. Esta ausencia no es menor: si el momentum existe precisamente porque los inversores procesan la información de manera sistemáticamente sesgada, entonces cualquier estrategia que intente capturar esa prima debería contemplar qué sucede cuando los sesgos del gestor interactúan con la estructura de la propia estrategia.

También los estudios que cuantifican el impacto de los sesgos —Barber y Odean (2000, 2001), Odean (1998) y Talhartit et al. (2022)— presentan una limitación complementaria: documentan el costo agregado de los sesgos sobre el rendimiento neto, pero no descomponen ese costo en funciones de cada sesgo individual ni lo vinculan formalmente con las decisiones operacionales de una estrategia cuantitativa. En otras palabras, la literatura conductual sabe que los sesgos cuestan retorno, pero no especifica a través de qué canal de decisión —selección de activos, ponderación, timing

de entrada, timing de salida, gestión en crisis o rebalanceo— produce cada sesgo su mayor daño en el contexto específico de una estrategia de momentum.

El presente trabajo aborda ambas carencias simultáneamente: al operacionalizar cada sesgo conductual como una regla específica dentro de la estrategia de simulación, y al evaluar su impacto sobre el rendimiento en un entorno controlado, permite asignar una responsabilidad cuantificada a cada mecanismo psicológico. Esta conexión entre psicología cognitiva y diseño de estrategia cuantitativa es la que las tradiciones de investigación previas no han tendido a establecer de manera sistemática y computacionalmente verificable.

6.2. Antecedentes Cuantitativos

Jegadeesh y Titman (1993) documentaron que las acciones con mejor desempeño relativo en los últimos 3 a 12 meses tienden a continuar superando a las de peor desempeño en los meses subsiguientes. Este hallazgo inauguró una extensa literatura sobre el momentum cross-sectional. Carhart (1997) incorporó el factor momentum UMD al modelo de Fama y French (1993), reconociendo al momentum como prima de riesgo estructural. Daniel y Moskowitz (2016) documentaron los momentum crashes, períodos de pérdidas extremas durante recuperaciones abruptas de mercados bajistas, que representan el principal riesgo de las estrategias de momentum.

En el frente conductual, la Prospect Theory de Kahneman y Tversky (1979) y el trabajo de Shefrin y Statman (1985) sobre el efecto disposición establecieron las bases para comprender las decisiones subóptimas de los inversores. Odean (1998) cuantificó el efecto disposición en 10.000 cuentas de corretaje, y Barber y Odean (2000, 2001) estimaron su costo en retorno neto. Más recientemente, Kivelä (2025) y Schlie y Zhou (2025) confirmaron la vigencia del momentum cross-sectional en el S&P 500 y en mercados globales.

6.3. Teoría Financiera Clásica

La Hipótesis de los Mercados Eficientes.

La EMH de Fama (1970) postula que los precios incorporan toda la información disponible:

$$E[P_{t+1} \mid I_t] = (1 + r^*) \cdot P_t$$

donde r^* es la tasa de retorno de equilibrio ajustada por riesgo. Shiller (2000) cuestionó empíricamente la EMH demostrando volatilidad excesiva de precios respecto de los fundamentales. El efecto momentum documentado por Jegadeesh y Titman (1993) representa una anomalía directamente incompatible con la forma débil de la EMH.

El CAPM y el Modelo de Factores.

El CAPM de Sharpe (1964) establece:

$$E[R_i] = R_f + \beta_i \cdot (E[R_m] - R_f)$$

Fama y French (1993) extendieron el modelo a tres factores (MKT, SMB, HML) y Carhart (1997) añadió el factor momentum UMD:

$$R_i - R_f = \alpha_i + \beta_i \cdot \text{MKT} + s_i \cdot \text{SMB} + h_i \cdot \text{HML} + m_i \cdot \text{UMD} + \varepsilon_i$$

La Anomalía Momentum.

Jegadeesh y Titman (1993) documentaron que la estrategia de momentum con ventana de formación de 12 meses y período de tenencia de 3 meses generó retornos anualizados de aproximadamente 12% en el período 1965-1989. El skip period de 21 días hábiles evita la reversión de corto plazo documentada por Jegadeesh (1990). Rouwenhorst (1998) confirmó el efecto en 12 mercados europeos. Schlie y Zhou (2025) documentaron su vigencia global y variación con las condiciones de volatilidad.

6.4. Finanzas Conductuales: Fundamentos y Prospect Theory

El Programa Conductual.

Las finanzas conductuales emergen de la convergencia entre psicología cognitiva y economía financiera. Thaler (1993) sistematizó el programa integrando la psicología al análisis financiero; el Premio Nobel de Economía a Richard Thaler en 2017 reconoció estas contribuciones. Talhartit et al. (2022) clasifican los sesgos en cognitivos (mitigables mediante educación) y emocionales (más resistentes a la corrección consciente).

La Prospect Theory.

La Prospect Theory de Kahneman y Tversky (1979) reemplaza la utilidad esperada por una función de valor sobre ganancias y pérdidas relativas a un punto de referencia. La parametrización de Tversky y Kahneman (1992) establece:

$$v(x) = x^{\alpha} \quad \text{si } x \geq 0 \quad (\alpha \approx 0.88)$$

$$v(x) = -\lambda \cdot (-x)^{\beta} \quad \text{si } x < 0 \quad (\beta \approx 0.88, \lambda \approx 2.25)$$

donde $\lambda > 1$ es el coeficiente de aversión a las pérdidas. Las tres propiedades centrales —evaluación relativa al punto de referencia, asimetría ganancia/pérdida y $\lambda \approx 2.25$ — fundamentan directamente los seis sesgos implementados en el modelo conductual. Kahneman (2011) extendió estos fundamentos con el marco del sistema 1 (rápido, emocional) y sistema 2 (lento, deliberado), explicando por qué los sesgos se amplifican en períodos de estrés de mercado.

6.5. Sesgos Conductuales y Su Operacionalización en el Modelo

Efecto disposición.

Shefrin y Statman (1985) describieron la tendencia a vender ganadores prematuramente y mantener perdedores indefinidamente. Odean (1998) cuantificó que los inversores realizan ganancias un 50% más rápido que pérdidas. En el modelo, se

implementa con un take profit de +8% (venta prematura de ganadores) y stop loss de -20% (retención tardía de perdedores), reflejando la asimetría $\lambda \approx 2.25$ de la Prospect Theory.

Exceso de confianza.

Barber y Odean (2001) demostraron que los inversores más confiados obtienen retornos netos inferiores por mayor costo de transacción y menor diversificación. En el modelo, se replica seleccionando solo top 4 activos (vs 15 del algorítmico) y sobreponderando el top-1 con un factor de 1.5x y el top-2 con 1.125x.

Sesgo de recencia.

Baser y Dashora (2023) documentan que el sesgo de recencia lleva a usar ventanas de análisis más cortas de lo óptimo. La señal del agente conductual combina:

$$\text{Señal_conductual} = 0.60 \times \text{Retorno}(20d) + 0.40 \times \text{Retorno}(63d)$$

contrastando con la ventana de 252 días del modelo algorítmico, identificada como óptima por Jegadeesh y Titman (1993) y Sheikh (2023).

Aversión a las pérdidas bajo alta volatilidad.

Daniel y Moskowitz (2016) documentaron los momentum crashes. Talhartit et al. (2022) muestran que en períodos de estrés el inversor reduce la exposición desproporcionadamente. El modelo replica esta sobre-reducción emocional: scale = 0.30 en High Vol (reducción del 70%), frente al 50% del modelo racional.

Herding y demora en la ejecución.

Chang et al. (2000) documentaron el herding en mercados internacionales. Kivelä (2025) cuantificó que un retraso de una semana reduce el retorno anual del CSM entre 2 y 3 puntos porcentuales. Se implementa con una condición de confirmación de 5 días y un delay adicional de 3 días.

Sesgo de anclaje.

Kahneman y Tversky (1979) identificaron el anclaje al precio de compra como fuente de inercia en el rebalanceo. El modelo lo replica con un delay adicional de 10 días y retención de posiciones con pérdidas menores al 3%.

6.6. La Estrategia Algorítmica: Formalización Matemática

Señal de momentum 12-1.

$$\text{Mom}_{\{i,t\}} = (P_{\{i,t-21\}} / P_{\{i,t-252\}}) - 1$$

donde el skip period de 21 días hábiles evita la reversión de corto plazo. Los retornos extremos ($> 300\%$ o $< -90\%$) se excluyen como errores de datos.

Filtro de volatilidad y selección long-short.

$$\sigma_{\{i,t\}} = \sqrt{252} \cdot \text{std}(\{r_{\{i,s\}}\}_{s=t-63}^{t})$$

Se excluye el 20% más volátil del universo. Los 15 activos con mayor $\text{Mom}_{\{i,t\}}$ forman la pata larga y los 15 de menor Mom forman la pata corta. Sheikh (2023) demuestra que la estrategia long-short captura la prima de momentum completa.

Ponderación inverse-volatility y retorno long-short.

$$w_i = (1/\sigma_i) / \sum_j (1/\sigma_j)$$

$$R_t^{\{LS\}} = \sum_i w_{\{i,t-1\}^{\{long\}}} \cdot r_{\{i,t\}} - \sum_j w_{\{j,t-1\}^{\{short\}}} \cdot r_{\{j,t\}}$$

El uso de shift(1) sobre los pesos garantiza que la señal del día t se ejecuta al cierre del día t+1, eliminando el lookahead bias.

6.7. Clasificación de Regímenes de Volatilidad

La señal de régimen combina tres z-scores rolling de 252 días hábiles:

$$\text{RegimeSignal}_t = (\text{VIX}_{z,t} + \text{SPXvol}_{z,t} + \text{Disp}_{z,t}) / 3$$

$$\text{Régimen} = \text{'High Vol'} \quad \text{si } \text{RegimeSignal} > +0.5$$

$$\text{Régimen} = \text{'Normal Vol'} \quad \text{si } -0.5 \leq \text{RegimeSignal} \leq +0.5$$

$$\text{Régimen} = \text{'Low Vol'} \quad \text{si } \text{RegimeSignal} < -0.5$$

La corrección de lookahead bias aplica shift(1) sobre la señal de régimen antes de usarla en las decisiones de inversión. Esto garantiza que el régimen clasificado al cierre del día t no se usa hasta el cierre del día t+1.

6.8. Métricas de Evaluación del Desempeño

$$\begin{aligned} \text{Retorno_anual} &= \text{mean}(r_t) \times 252 \\ \text{Sharpe} &= [\text{mean}(r_t) \times 252] / [\text{std}(r_t) \times \sqrt{252}] \\ \text{MaxDD} &= \min_t [(\text{Cum}_t - \max_{\{s \leq t\}} \text{Cum}_s) / \max_{\{s \leq t\}} \text{Cum}_s] \\ \text{Calmar} &= \text{Retorno_anual} / |\text{MaxDD}| \\ \text{WinRate} &= \#\{t: r_t > 0\} / \#\{t: r_t \neq \text{NaN}\} \\ \text{Turnover}_t &= \sum_i |w_{\{i,t\}} - w_{\{i,t-1\}}| \\ \text{TC_drag} &= \text{mean}(\text{Turnover}_t) \times 252 \times c \end{aligned}$$

Las métricas también se calculan condicionadas por régimen, donde Ω_k es el conjunto de días en el régimen k:

$$\text{Sharpe}^k = [\text{mean}(\{r_t: t \in \Omega_k\}) \times 252] / [\text{std}(\{r_t: t \in \Omega_k\}) \times \sqrt{252}]$$

7. Metodología

7.1. Enfoque y Tipo de Investigación

La investigación adopta un enfoque cuantitativo, comparativo y de simulación histórica (backtesting). El diseño es correlacional-explicativo según la taxonomía de hipótesis: se evalúa la relación entre el tipo de estrategia de gestión —algorítmica racional versus conductual con sesgos— y el desempeño ajustado por riesgo, con el régimen de volatilidad de mercado como variable moderadora. La unidad de análisis es el portafolio diario construido por cada estrategia sobre el universo de acciones del S&P 500.

El backtesting se realiza de manera puramente histórica, sin reoptimización de parámetros dentro del período de análisis. Los parámetros de la estrategia algorítmica se basan íntegramente en especificaciones documentadas en la literatura académica preexistente, eliminando el riesgo de data snooping. Los parámetros de la estrategia conductual se calibran sobre la evidencia empírica de la literatura de finanzas conductuales, sin ajuste al período específico de análisis.

7.2. Datos y Universo de Análisis

Fuente de datos.

Los datos de precios diarios de las acciones constituyentes del S&P 500 se obtuvieron mediante terminales Bloomberg. Los datos del índice S&P 500 (utilizado como benchmark) y del VIX (Volatility Index del CBOE, utilizado como uno de los tres indicadores de régimen) provienen de la misma fuente. El período de cobertura de los datos es enero de 2020 a julio de 2024, resultando en 1.148 observaciones diarias para el período analizado (2020-01-02 a 2024-07-25).

Universo de activos.

El universo inicial comprende todas las acciones constituyentes del S&P 500 disponibles en la base de datos Bloomberg para el período de análisis. Se aplica un filtro mínimo de historia: se retienen únicamente los activos con al menos el 60% de las observaciones diarias disponibles en el período completo. Este criterio elimina acciones que ingresaron tardíamente al índice o que tienen datos faltantes extensos, garantizando la comparabilidad de las señales de momentum entre activos. El universo resultante es de 480 activos.

Preprocesamiento de datos.

Los precios se alinean a las fechas de cotización comunes entre el universo de acciones, el S&P 500 y el VIX. Los retornos diarios se calculan como variaciones porcentuales simples. Se aplican caps de $\pm 30\%$ sobre los retornos diarios individuales para controlar el impacto de datos erróneos o eventos corporativos extraordinarios (splits, dividendos no ajustados). Los retornos de lookback de momentum se capean entre -90% y $+300\%$ con el mismo propósito.

7.3. Estrategia Algorítmica: Especificación Completa***Señal de momentum.***

La señal de Cross-Sectional Momentum sigue la especificación 12-1 de Jegadeesh y Titman (1993): para cada activo i en el día t , la señal de momentum se calcula como el retorno acumulado de los 252 días hábiles previos, excluyendo los 21 días más recientes (skip period). La exclusión del último mes evita la contaminación por

reversión de corto plazo documentada por Jegadeesh (1990). Los retornos extremos se excluyen:

$$\text{Mom}_{\{i,t\}} = (P_{\{i,t-21\}} / P_{\{i,t-252\}}) - 1$$

Filtro de volatilidad.

En cada fecha de rebalanceo, se calcula la volatilidad realizada anualizada de cada activo sobre una ventana de 63 días hábiles. Se excluye del universo candidato el 20% de activos más volátiles (por encima del percentil 80 de la distribución de volatilidades del universo ese día). Este filtro, documentado como mejora del Sharpe en Kivelä (2025), reduce la exposición a activos con mayor riesgo idiosincrásico sin deteriorar el retorno esperado de la señal de momentum.

Selección y ponderación.

De los activos candidatos que pasan el filtro de volatilidad, se seleccionan los 15 con mayor señal de momentum para la pata larga (winners) y los 15 con menor señal para la pata corta (losers). La ponderación utiliza el esquema inverse-volatility por separado en cada pata, asignando mayor peso a los activos más estables dentro de cada grupo. Sheikh (2023) demuestra que la estrategia long-short captura la prima de momentum completa, frente al 55-65% que captura la long-only.

Rebalanceo y overlay de régimen.

El rebalanceo se realiza mensualmente (cada 21 días hábiles), en línea con la práctica estándar de las estrategias de momentum 12-1. En los días de no rebalanceo, los pesos del período anterior se mantienen constantes. El overlay de régimen de volatilidad escala los pesos en un 50% durante el régimen High Vol, reduciendo la exposición de manera racional para gestionar el riesgo de momentum crash documentado por Daniel y Moskowitz (2016).

7.4. Estrategia Conductual: Sesgos Implementados

La estrategia conductual parte de la misma estructura base que la algorítmica pero incorpora los seis sesgos conductuales mediante modificaciones específicas de los parámetros de decisión. La lógica del diseño es que cada sesgo genera un error predecible y cuantificable en una decisión de la estrategia (selección de activos, ponderación, timing de entrada, timing de salida, gestión en crisis o rebalanceo). La Tabla 1 sintetiza la correspondencia entre cada sesgo, su parámetro en el código y su justificación en la literatura.

Tabla 1

Operacionalización de los sesgos conductuales en el modelo

Sesgo	Parámetro Python	Valor	Efecto sobre la estrategia	Referencia
Efecto disposición	DISP_TAKE_PROFIT	+8%	Vende ganadores prematuramente	Shefrin y Statman (1985)
Efecto disposición	DISP_STOP_LOSS	-20%	Retiene perdedores demasiado tiempo	Odean (1998)
Exceso de confianza	OVERCONF_TOP_N	4	Cartera más concentrada (vs 15)	Barber y Odean (2001)
Exceso de confianza	OVERCONF_WEIGHT_BOOST	1.5x	Sobreponderación del top activo	Negi y Gupta (s.f.)
Sesgo de recencia	RECENCY_LOOKBACK	20d	Ventana corta de momentum	Kahneman y Tversky (1979)
Sesgo de recencia	RECENCY_WEIGHT	60%	Peso sesgado a pasado reciente	Baser y Dashora (2023)
Aversión pérdidas	FEAR_FACTOR_HIGH_VOL	0.30	Reducción 70% en High Vol	Talhartit et al. (2022)
Herding	HERD_CONFIRM_DAYS	5d	Confirmación antes de entrar	Chang et al. (2000)
Herding	HERD_ENTRY_DELAY	3d	Delay operacional adicional	Kivelä (2025)

Sesgo	Parámetro Python	Valor	Efecto sobre la estrategia	Referencia
Anclaje	ANCHOR_REBALANCE_DELAY	10d	Retraso en rebalanceo	Kahneman y Tversky (1979)
Anclaje	ANCHOR_STAY_THRESHOLD	-3%	Retención posiciones -3%	Odean (1998)

Nota. Elaboración propia.

La estrategia conductual opera únicamente con posiciones largas, sin pata corta. Esta decisión de diseño refleja el comportamiento documentado de los gestores individuales: la operación en corto requiere mayor sofisticación técnica y la aversión a las pérdidas amplificada por el efecto disposición genera renuencia a mantener posiciones cortas en acciones que suben (Shefrin y Statman, 1985).

7.5. Clasificación de Regímenes de Volatilidad

El régimen de mercado se clasifica diariamente mediante una señal compuesta de tres indicadores de volatilidad. Cada indicador se normaliza mediante un z-score rolling de 252 días hábiles respecto de su propia historia, y la señal compuesta es el promedio simple de los tres z-scores:

$$\text{RegimeSignal}_t = (\text{VIX}_z,t + \text{SPXvol}_z,t + \text{Disp}_z,t) / 3$$

El VIX_z captura la volatilidad implícita futura percibida por el mercado. El SPXvol_z captura la volatilidad realizada del índice en la ventana de 20 días hábiles, anualizada. El Disp_z captura la dispersión cross-sectional del universo como media de las desviaciones estándar rolling de los retornos individuales. El uso de tres indicadores complementarios reduce la dependencia de cualquier indicador individual y provee una clasificación más robusta.

La corrección de lookahead bias es crítica: el régimen del día t se calcula usando información disponible al cierre de t , pero solo se utiliza para las decisiones de inversión del día $t+1$. Esto se implementa mediante $\text{shift}(1)$ sobre la serie de régimen. Sin esta corrección, la estrategia utilizaría información futura (el régimen del día t) para tomar decisiones en t , generando un sesgo de rendimiento no realizable en la práctica.

7.6. Análisis de Sensibilidad a Costos de Transacción

El backtesting base asume costos de transacción nulos. Para evaluar la robustez de los resultados a los costos de implementación práctica, se realizan simulaciones con cinco niveles de costos por operación: 0 puntos básicos (sin costos), 1 punto básico (costos muy bajos, típicos de grandes institucionales), 5 puntos básicos (costos bajos, típicos de fondos medianos), 10 puntos básicos (costos medios) y 20 puntos básicos (costos altos, típicos de inversores minoristas). El costo se aplica proporcionalmente al turnover diario de cada estrategia:

$$\text{Retorno_neto_t} = R_t^{\{LS\}} - \text{Turnover_t} \times c$$

Esta metodología de descuento de costos es conservadora porque asume que todos los cambios en los pesos (incluyendo los generados por movimientos de precios entre rebalanceos) implican costos de transacción, cuando en la práctica solo los rebalanceos activos los generan.

7.7. Herramientas Computacionales

El modelo se implementa en Python 3.14 utilizando las librerías pandas para la manipulación de series temporales, numpy para el cálculo numérico y matplotlib para la visualización. Los datos se cargan desde archivos Excel (.xlsx) obtenidos de terminales Bloomberg. Los resultados se exportan a un archivo Excel multipestañas y a cinco figuras en formato PNG.

8. Análisis de Resultados

En esta sección se presentan e interpretan los resultados obtenidos de la simulación histórica para el período enero 2020 - julio 2024. Los resultados se organizan en cinco subsecciones: desempeño general, análisis por régimen de volatilidad, análisis de sesgos conductuales en el portafolio, comportamiento del régimen de volatilidad y sensibilidad a costos de transacción.

8.1. Desempeño General de las Estrategias

La Tabla 2 presenta las métricas de desempeño agregadas para el período completo de análisis. La estrategia algorítmica (CSM_Algoritmico) obtiene un retorno anual de 12.88% con un ratio de Sharpe de 0.664 y un máximo drawdown de -19.45%. La estrategia conductual (CSM_Humano) obtiene un retorno anual de 9.91% con un ratio de Sharpe de 0.530 y un máximo drawdown de -27.26%. El benchmark Buy & Hold del S&P 500 obtiene el mayor retorno anual con 13.51%, pero con mayor volatilidad (21.90%) y el peor drawdown (-33.92%).

Tabla 2

Métricas de desempeño comparativas — Período completo 2020-2024

Estrategia	Retorno Anual	Vol. Anual	Sharpe	Calmar	Max. Drawdown	Win Rate	Turnover Anual
CSM_Algoritmico	12.88%	19.39%	0.664	0.662	-19.45%	39.9%	9.0
CSM_Humano	9.91%	18.70%	0.530	0.364	-27.26%	36.8%	10.3
Buy & Hold SPX	13.51%	21.90%	0.617	0.398	-33.92%	53.4%	N/A

Nota. Elaboración propia.

Estos resultados confirman la hipótesis H1 de superioridad general del modelo algorítmico: el Sharpe de 0.664 supera al 0.530 de la estrategia conductual, una diferencia de 25.3% en términos relativos. El ratio de Calmar es especialmente ilustrativo

de la diferencia en gestión del riesgo: 0.662 para el algorítmico frente a 0.364 para el conductual, una diferencia de 81.9%. Esto indica que la estrategia conductual genera significativamente más pérdida máxima por unidad de retorno obtenido, consecuencia directa del efecto disposición (que retiene perdedores) y de la sobre-reducción de exposición en alta volatilidad (que materializa pérdidas en los peores momentos).

El Buy & Hold del S&P 500 obtiene el mayor retorno absoluto (13.51%), lo cual es esperable dado el fuerte mercado alcista que domina el período 2020-2024, especialmente el rally de 2021 y el de inteligencia artificial de 2024. Sin embargo, su drawdown de -33.92% refleja el impacto pleno de la corrección de 2022, que el modelo algorítmico mitiga significativamente gracias al overlay de régimen y a la estructura long-short que genera retorno positivo cuando los activos perdedores caen.

El win rate del Buy & Hold (53.4%) es superior al de ambas estrategias activas. Esto es consistente con la literatura: las estrategias de momentum long-short tienen un win rate intrínsecamente bajo (cercano al 40%) porque su fuente de alpha es la magnitud de los movimientos en ambas patas, no la frecuencia de los días positivos. La relación ganancia/pérdida es la métrica relevante para estas estrategias, no el win rate.

8.2. Análisis por Régimen de Volatilidad

La Figura 2 y la Tabla 3 presentan el desempeño de cada estrategia desagregado por régimen de volatilidad. Esta dimensión del análisis es clave para testear la hipótesis H2 de heterogeneidad de régimen.

Tabla 3

Retorno anual y Sharpe Ratio por régimen de volatilidad

Estrategia	Low Vol — Retorno	Low Vol — Sharpe	Normal Vol — Retorno	Normal Vol — Sharpe	High Vol — Retorno	High Vol — Sharpe
CSM_Algoritmico	6.6%	0.349	31.2%	1.307	26.8%	1.005
CSM_Humano	12.8%	0.552	19.5%	0.791	4.7%	0.939
Buy & Hold SPX	12.7%	1.040	10.4%	0.590	10.8%	0.440

Nota. Elaboración propia.

Los resultados por régimen revelan un patrón que confirma la hipótesis H2 de manera parcial, con matices importantes. En el régimen Normal Vol, el modelo algorítmico exhibe una ventaja muy pronunciada: Sharpe de 1.307 frente a 0.791 del conductual y 0.590 del Buy & Hold. Este es el régimen donde el momentum cross-sectional funciona mejor: las tendencias son claras, la dispersión es moderada y la señal de 12 meses tiene alta relación señal-ruido. Los sesgos conductuales —especialmente el sesgo de recencia (que usa ventanas cortas) y el herding (que demora la entrada)— deterioran significativamente la capacidad de capturar esta prima.

En el régimen High Vol, el modelo algorítmico sigue siendo superior (Sharpe 1.005 vs 0.939 del conductual), pero la diferencia es notablemente menor que en Normal Vol. Esto es consistente con la hipótesis de Daniel y Moskowitz (2016) sobre los momentum crashes: durante los episodios de alta volatilidad de 2022, el factor de correlación entre activos aumenta y la señal de momentum pierde diferenciación entre ganadores y perdedores. El overlay de régimen del algorítmico (que reduce la exposición al 50% en High Vol) mitiga el riesgo de crash pero también limita el upside. Interesantemente, la estrategia conductual, pese a su sobre-reducción por fear factor (70%), no desempeña mucho peor que el algorítmico en este régimen porque el mercado en general presenta menor dispersión.

El resultado más llamativo e inesperado es el del régimen Low Vol: aquí la estrategia conductual (Sharpe 0.552) supera al algorítmico (Sharpe 0.349), y el Buy & Hold del S&P 500 supera ampliamente a ambos con un Sharpe de 1.040. Esto responde a la dinámica particular del mercado alcista de 2021 y 2023-2024: en períodos de baja volatilidad con suba generalizada del mercado, la estrategia long-short tiene una desventaja estructural porque la pata corta (que vende los perdedores relativos) pierde dinero cuando prácticamente todos los activos suben. La estrategia conductual, que opera solo con posiciones largas, captura mejor el beta del mercado en estos períodos. El modelo algorítmico paga el costo de la cobertura short en un mercado que sube parejo.

Estos resultados tienen una implicación práctica importante: la ventaja del modelo algorítmico long-short es más pronunciada en regímenes de mercado con alta dispersión (Normal Vol) y en episodios de estrés (High Vol), pero el Buy & Hold es difícil de superar en mercados tendenciales de baja volatilidad. Esta conclusión es consistente con la amplia literatura empírica sobre momentum (Kivelä, 2025; Schlie y Zhou, 2025).

8.3. Análisis de Sesgos Conductuales en el Portafolio

La Figura 3 permite visualizar el impacto de los sesgos conductuales sobre cuatro dimensiones del portafolio: número de posiciones abiertas, concentración (peso máximo por día), turnover y sensibilidad a costos de transacción.

Número de posiciones y concentración.

El modelo algorítmico mantiene consistentemente 10 posiciones abiertas (las correspondientes a la pata larga del long-short), mientras que el modelo conductual oscila entre 1 y 4 posiciones, con una media de aproximadamente 3 activos cuando está invertido. Esta diferencia es la expresión directa del sesgo de exceso de confianza ($OVERCONF_TOP_N = 4$): el gestor conductual concentra su cartera en pocos activos percibidos como "ganadores seguros", sacrificando la diversificación que provee el modelo racional. La concentración del peso máximo por día es consistente con este patrón: el modelo humano frecuentemente tiene un activo con peso superior al 30-35%, frente al 10-15% del algorítmico. Esta sobre-concentración amplifica tanto las ganancias cuando el activo elegido sube como las pérdidas cuando cae, contribuyendo al mayor drawdown del modelo conductual.

Turnover.

El turnover diario (media móvil de 63 días) muestra que el modelo conductual tiene mayor rotación que el algorítmico en términos absolutos: 10.3 vs 9.0 en turnover anual (Tabla 2). Esto puede resultar contraintuitivo dado que el modelo conductual tiene sesgos de retención (efecto disposición en pérdidas, anclaje) y delays (herding, anclaje en rebalanceo). La explicación es que el efecto disposición genera alta rotación en la pata de ganancias: el gestor conductual vende frecuentemente las posiciones que superan el take profit del +8%, introduciendo muchas operaciones de salida que el modelo algorítmico no realiza. Esto es precisamente el patrón documentado por Odean (1998): los inversores con efecto disposición operan más, no menos, porque venden sus ganadores rápidamente.

Sensibilidad a costos de transacción.

El panel inferior derecho de la Figura 3 muestra el Sharpe Ratio bajo los cinco escenarios de costos de transacción. En el escenario sin costos, el algorítmico tiene Sharpe 0.664 y el conductual 0.530. A medida que aumentan los costos, ambas estrategias se deterioran, pero el modelo algorítmico mantiene una ventaja que persiste hasta los 20 puntos básicos. Esto confirma la robustez a costos de transacción postulada en la hipótesis secundaria. La razón es que aunque el modelo algorítmico tiene mayor turnover por la pata short, su mayor retorno bruto compensa el incremento de costos. El modelo conductual, con su turnover elevado por el efecto disposición, es más penalizado en términos relativos a medida que los costos aumentan.

8.4. Comportamiento del Régimen de Volatilidad

La Figura 4 presenta la señal agregada de volatilidad (RegimeSignal) a lo largo del período de análisis, con los umbrales de clasificación (+0.5 para High Vol, -0.5 para Low Vol). La distribución de los 896 días de la muestra con régimen asignado (el comienzo del período no tiene régimen por el período de warmup de los z-scores) resultó en: 503 días de Low Vol (56.1%), 208 días de Normal Vol (23.2%) y 185 días de High Vol (20.6%).

El patrón temporal es coherente con los eventos de mercado del período. El primer episodio de High Vol se concentra en el período 2021-07 a 2022-07, coincidiendo con el inicio de las presiones inflacionarias post-pandemia, el cambio de política monetaria de la Reserva Federal y la corrección de los activos de riesgo. El pico más elevado de la señal (aproximadamente 3.0) ocurre en los primeros meses de 2022, cuando la invasión de Rusia a Ucrania se superpuso con la suba de tasas de la Fed, generando el mayor shock simultáneo en múltiples indicadores de volatilidad. Un segundo episodio de High Vol más breve se observa a mediados de 2022, coincidiendo con la fase más aguda del ajuste monetario.

El régimen Low Vol domina la primera parte del período (2020-2021, con la notable excepción del shock inicial de la pandemia que no es capturado como High Vol

porque el z-lookback de 252 días necesita historia previa para calcular las desviaciones estándar de referencia) y la segunda mitad del período analizado (segunda mitad de 2022 hasta 2024). Esto refleja el mercado tendencial alcista post-corrección, con baja volatilidad relativa a los estándares históricos propios del período.

El régimen Normal Vol ocupa los períodos de transición entre estados extremos. Su distribución temporal es consistente con la hipótesis de que los regímenes de volatilidad son persistentes (los episodios de High Vol y Low Vol se mantienen por semanas o meses) pero no permanentes, con transiciones graduales que el promedio de los tres z-scores capta de manera suavizada.

8.5. Curvas Acumuladas y Drawdowns

La Figura 1 presenta las curvas de capital acumulado (base 1) en escala logarítmica para las tres series, con los regímenes de volatilidad superpuestos como áreas sombreadas. Las curvas acumuladas ilustran de manera visual los resultados cuantitativos de la Tabla 2.

El modelo algorítmico (línea azul) presenta una trayectoria gradual y consistente a lo largo del período, con su inicio de operaciones desplazado hacia la derecha respecto del conductual porque el período de warmup para calcular la señal de 252 días requiere esperar hasta que haya suficiente historia disponible. La curva acumulada del algorítmico no alcanza los picos del conductual en los períodos de mercado alcista fuerte (2021, 2024), pero tampoco experimenta los valles pronunciados que caracterizan al conductual. Esta asimetría es la expresión del mejor Calmar Ratio (0.662 vs 0.364).

El modelo conductual (línea roja) exhibe un perfil de retorno más volátil: períodos de fuerte apreciación seguidos de correcciones pronunciadas. El máximo drawdown de -27.26% ocurre en el período de alta volatilidad de 2022-2024, precisamente cuando el fear factor reduce la exposición al 30% pero ya después de que parte de las pérdidas se han materializado por el efecto de anclaje (que retiene las posiciones hasta que las pérdidas superan el -20% del stop loss) y por el retraso del herding al reconstruir la posición.

El Buy & Hold del S&P 500 (línea verde) es el activo de mayor retorno absoluto al final del período, pero experimentó el mayor drawdown (-33.92%) durante la corrección de 2022. Su trayectoria refleja íntegramente el ciclo del mercado: fuerte caída

en 2020, recuperación acelerada en 2021, corrección en 2022, recuperación en 2023 y rally de AI en 2024.

El panel de drawdowns confirma visualmente los resultados de la Tabla 2. Los drawdowns del modelo algorítmico son más contenidos y de menor duración que los del conductual. El mayor drawdown del conductual en 2022-2024 es notablemente más profundo y prolongado que el del algorítmico en el mismo período, ilustrando el costo combinado del efecto disposición (que retiene posiciones perdedoras), el fear factor excesivo (que reduce la exposición demasiado tardíamente) y el anclaje (que retrasa la reconstrucción de posiciones después del drawdown).

9. Conclusiones

9.1. Respuesta a las Hipótesis

Los resultados de la simulación histórica permiten evaluar la hipótesis principal y la hipótesis secundaria de la investigación de manera directa y cuantificada.

La hipótesis principal se confirma: el Sharpe Ratio del modelo algorítmico (0.664) supera al del conductual (0.530) en el período completo 2020-2024, con una diferencia relativa del 25.3%. El ratio de Calmar exhibe una diferencia aún más pronunciada (0.662 vs 0.364, diferencia de 81.9%), indicando que la estrategia conductual genera significativamente más pérdida máxima por unidad de retorno obtenido, y que la ventaja algorítmica es más pronunciada en los regímenes de Normal Vol y High Vol que en Low Vol.

La hipótesis secundaria se confirma en sus dimensiones centrales. El deterioro por sesgos es evidente: el máximo drawdown se deteriora de -19.45% (algorítmico) a -27.26% (conductual), un empeoramiento del 40.2%, y el Calmar cae 45.0%. El patrón de heterogeneidad entre regímenes se verifica con el matiz de que la mayor ventaja algorítmica aparece en Normal Vol (diferencia de Sharpe de 0.516) y no en High Vol como postulaba la hipótesis, porque en High Vol la estructura long-short también sufre por la convergencia de correlaciones. La robustez a costos de transacción se confirma hasta los 20 puntos básicos. La única dimensión no confirmada es la superioridad en Low Vol, donde la estrategia conductual long-only supera al algorítmico long-short (0.552 vs 0.349) por una razón estructural —la desventaja de la pata corta en mercados alcistas generalizados— y no por los sesgos conductuales per se.

El mecanismo principal de deterioro por sesgos es la combinación del efecto disposición (que retiene posiciones perdedoras más allá del óptimo) con el fear factor excesivo (que materializa pérdidas al reducir la exposición en el peor momento) y el anclaje (que retrasa la reconstrucción de posiciones después del drawdown).

9.2. Contribuciones de la Investigación

Esta investigación realiza tres contribuciones concretas a la literatura. La primera es metodológica: la operacionalización de seis sesgos conductuales como parámetros cuantificados de una estrategia computacional permite aislar el costo de cada sesgo con una precisión que los estudios observacionales no pueden alcanzar. El diseño de simulación controlada, donde la única diferencia entre ambas estrategias es la presencia de los sesgos, es una contribución al rigor metodológico de la literatura sobre finanzas conductuales.

La segunda contribución es empírica: los resultados aportan evidencia sobre la prima de momentum cross-sectional en el S&P 500 en el período 2020-2024, uno de los más heterogéneos en términos de regímenes de mercado de la historia reciente. La confirmación de la viabilidad de la estrategia algorítmica long-short 12-1 en este período es relevante para la literatura sobre la persistencia del efecto momentum.

La tercera contribución es práctica: el análisis por régimen de volatilidad provee una guía concreta para inversores sobre cuándo la gestión sistemática tiene mayor ventaja (Normal Vol) y cuándo el Buy & Hold puede ser difícil de superar (Low Vol). Esta información es directamente aplicable a la toma de decisiones de asignación táctica entre estilos de gestión.

9.3. Limitaciones de la Investigación

El trabajo tiene cinco limitaciones que deben considerarse al interpretar los resultados. Primero, la estrategia conductual simula sesgos mediante reglas paramétricas fijas, mientras que los sesgos reales de los gestores humanos son dinámicos y varían entre individuos. Los parámetros elegidos (take profit +8%, fear factor 0.30, etc.) representan valores de referencia calibrados sobre la literatura, pero no capturan la heterogeneidad del comportamiento humano real.

Segundo, el período de análisis (2020-2024) es relativamente corto para evaluar la robustez estadística de los resultados. La literatura de momentum generalmente trabaja con períodos de 20-30 años. Los resultados aquí obtenidos deben interpretarse como evidencia preliminar consistente con la hipótesis, no como evidencia estadísticamente concluyente.

Tercero, el análisis no considera la dimensión de los costos de gestión ni los honorarios de asesoramiento, que en la práctica favorecerían adicionalmente a la gestión algorítmica (típicamente de menor costo) frente a la gestión humana activa.

Cuarto, la estrategia conductual solo implementa la pata larga, mientras que la algorítmica tiene estructura long-short. Parte de la diferencia de desempeño en Low Vol (donde el Buy & Hold supera a ambos) podría atribuirse a esta diferencia estructural más que a los sesgos conductuales per se.

Quinto, el modelo no considera el impacto de mercado (market impact) de las operaciones, lo que podría ser relevante para fondos de mayor tamaño que operen con este tipo de estrategias.

9.4. Líneas de Investigación Futura

Los resultados del trabajo sugieren al menos tres líneas de investigación futura. La primera es la extensión del análisis a períodos más largos (1990-2024) para evaluar la robustez estadística de los resultados y comparar el desempeño en ciclos de mercado anteriores (la burbuja tecnológica de 2000, la crisis financiera de 2008). La segunda es la incorporación de un modelo de agente conductual dinámico, donde la intensidad de los sesgos varía en función del estado emocional del gestor —capturado por indicadores como la variación reciente del VIX o el retorno de la cartera propia— en lugar de parámetros fijos. La tercera es la extensión a otros mercados geográficos para testear si los resultados son específicos al S&P 500 o se generalizan a mercados europeos y emergentes, siguiendo la metodología de Rouwenhorst (1998) y Schlie y Zhou (2025).

9.5. Reflexión Final

Los resultados de esta investigación confirman que la gestión algorítmica sistemática genera mejores resultados ajustados por riesgo que la gestión con sesgos conductuales en el mercado de renta variable del S&P 500 durante el período 2020-2024. La ventaja del algoritmo no reside en una capacidad superior para predecir el futuro —ambas estrategias usan la misma señal de momentum— sino en la disciplina para aplicar esa señal de manera consistente, sin los errores de timing introducidos por


el efecto disposición, el sesgo de recencia, el herding y el anclaje, y sin las sobre-reacciones emocionales ante la volatilidad que caracterizan la aversión a las pérdidas en períodos de estrés de mercado.

Kahneman (2011) argumentó que el sistema 2 —el pensamiento deliberado y analítico— puede corregir los errores del sistema 1, pero requiere esfuerzo cognitivo y se desactiva bajo presión. Un algoritmo de inversión bien diseñado es, en este sentido, una implementación permanente del sistema 2: aplica las mismas reglas en todos los contextos, incluidos aquellos en que la presión emocional del mercado haría más difícil mantenerlas. Los resultados de este trabajo son consistentes con esta interpretación: la ventaja del algorítmico es mayor precisamente en los regímenes de mercado donde la presión sobre el gestor humano es más intensa.

Anexos

Figura 1


Curvas de capital acumulado y drawdowns por estrategia (2020–2024)



Nota. Elaboración propia a partir de los resultados del backtesting (S&P 500, período 2020–2024).

Figura 2

Desempeño por régimen de volatilidad: retorno anual, Sharpe Ratio y volatilidad anual



Nota. Elaboración propia a partir de los resultados del backtesting (S&P 500, período 2020–2024).

Figura 3


Impacto de los sesgos conductuales sobre el portafolio: posiciones, concentración, turnover y costos



Nota. Elaboración propia a partir de los resultados del backtesting (S&P 500, período 2020–2024).

Figura 4

Señal agregada de volatilidad (RegimeSignal) y umbrales de clasificación de régimen



Nota. Elaboración propia a partir de los resultados del backtesting (S&P 500, período 2020–2024).

Figura 5

Síntesis visual de métricas de desempeño comparativas

Tabla de Métricas Comparativas

Estrategia	Retorno Anual	Vol Anual	Sharpe	Calmar	Max Drawdown	Win Rate	Turnover Anual
CSM_Algoritmico	12.88%	19.39%	0.664	0.662	-19.45%	39.9%	9.0
CSM_Humano	9.91%	18.70%	0.530	0.364	-27.26%	36.8%	10.3
BuyHold_SPX	13.51%	21.90%	0.617	0.398	-33.92%	53.4%	N/A

Nota. Elaboración propia a partir de los resultados del backtesting (S&P 500, período 2020–2024).

Código de Python

<https://colab.research.google.com/drive/1J8cD4gzqp-kJQseXXKcOMmwMkSXvYRPs>

Librerías utilizadas

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

Eso es todo — solo 5 imports, todos de la biblioteca estándar o del ecosistema científico básico de Python.

pandas

La más usada del script. Maneja todas las series temporales y DataFrames: carga los Excel, alinea fechas, calcula retornos con `.pct_change()`, hace rolling windows con `.rolling()`, agrupa por régimen con `.groupby()`, y exporta los resultados al Excel final con `ExcelWriter`. Sin pandas el script no existe.

numpy

Complementa a pandas para operaciones numéricas vectorizadas. Se usa para calcular la raíz cuadrada en la anualización de la volatilidad (`np.sqrt(252)`), manejar valores faltantes (`np.nan`), construir arrays de pesos y hacer operaciones matemáticas sobre los retornos. Es la capa de cálculo numérico que corre por debajo de pandas.

matplotlib.pyplot

Genera los 5 gráficos del análisis: las curvas acumuladas con zonas de régimen sombreadas, los gráficos de barras de performance por régimen, los paneles de sesgos conductuales (posiciones, concentración, turnover, costos), la señal de volatilidad con áreas rellenas, y la tabla visual de métricas. Los guarda como PNG en la carpeta de Downloads.

warnings

Una línea sola: `warnings.filterwarnings("ignore")`. Silencia advertencias de deprecación o de pandas que no son errores reales pero ensucian el output de la consola durante la ejecución.

os

Se usa para construir las rutas de archivos con `os.path.join()` y verificar que existen con `os.path.exists()` antes de intentar abrirlas. Es lo que hace que el script funcione igual en Windows, Mac o Linux sin hardcodear barras / o \

Bibliografia

- Baltussen, G. (2008). New insights into behavioral finance [Tesis doctoral]. Erasmus University Rotterdam. <https://repub.eur.nl/pub/14104/>
- Barber, B. M., & Odean, T. (2000). Trading is hazardous to your wealth: The common stock investment performance of individual investors. *Journal of Finance*, 55(2), 773–806. <https://doi.org/10.1111/0022-1082.00226>
- Barber, B. M., & Odean, T. (2001). Boys will be boys: Gender, overconfidence, and common stock investment. *Quarterly Journal of Economics*, 116(1), 261–292. <https://doi.org/10.1162/003355301556400>
- Baser, D. K., & Dashora, P. (2023). A study of behavioral finance in investment decisions. *International Journal of Innovative Research and Technology*, 9(10), 114–119.
- Carhart, M. M. (1997). On persistence in mutual fund performance. *Journal of Finance*, 52(1), 57–82. <https://doi.org/10.1111/j.1540-6261.1997.tb03808.x>
- Chang, E. C., Cheng, J. W., & Khorana, A. (2000). An examination of herd behavior in equity markets: An international perspective. *Journal of Banking & Finance*, 24(10), 1651–1679. [https://doi.org/10.1016/S0378-4266\(99\)00096-5](https://doi.org/10.1016/S0378-4266(99)00096-5)
- Daniel, K., & Moskowitz, T. J. (2016). Momentum crashes. *Journal of Financial Economics*, 122(2), 221–247. <https://doi.org/10.1016/j.jfineco.2015.12.002>
- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
- Fama, E. F., & French, K. R. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, 33(1), 3–56. [https://doi.org/10.1016/0304-405X\(93\)90023-5](https://doi.org/10.1016/0304-405X(93)90023-5)

- Jegadeesh, N. (1990). Evidence of predictable behavior of security returns. *Journal of Finance*, 45(3), 881–898. <https://doi.org/10.1111/j.1540-6261.1990.tb05110.x>
- 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/10.1111/j.1540-6261.1993.tb04702.x>
- Kahneman, D. (2011). *Thinking, fast and slow*. Farrar, Straus and Giroux.
- Kahneman, D., & Tversky, A. (1979). Prospect theory: An analysis of decision under risk. *Econometrica*, 47(2), 263–292. <https://doi.org/10.2307/1914185>
- Kivelä, T. (2025). Cross-sectional and time-series momentum strategies' performance in the S&P 500 index [Tesis de grado]. LUT Business School. https://lutpub.lut.fi/bitstream/handle/10024/171138/Bachelorsthesis_Kivela_Tuomas.pdf
- Markowitz, H. M. (1959). *Portfolio selection: Efficient diversification of investments*. John Wiley & Sons.
- Negi, R., & Gupta, G. (s.f.). Behavioural finance and its biases: A study on investors investing through stock trading platforms. *International Journal of Research and Analytical Reviews*.
- Odean, T. (1998). Are investors reluctant to realize their losses? *Journal of Finance*, 53(5), 1775–1798. <https://doi.org/10.1111/0022-1082.00072>
- Remorov, A. (2016). *Dynamic trading and behavioral finance* [Tesis doctoral]. Massachusetts Institute of Technology. <https://dspace.mit.edu/handle/1721.1/107017>
- Rouwenhorst, K. G. (1998). International momentum strategies. *Journal of Finance*, 53(1), 267–284. <https://doi.org/10.1111/0022-1082.95722>

- Schlie, S., & Zhou, X. (2025). Interday cross-sectional momentum: Global evidence and determinants. SSRN Working Paper 4934543. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4934543
- Shefrin, H., & Statman, M. (1985). The disposition to sell winners too early and ride losers too long: Theory and evidence. *Journal of Finance*, 40(3), 777–790. <https://doi.org/10.1111/j.1540-6261.1985.tb05002.x>
- Sheikh, F. (2023). Time-series versus cross-sectional versus dual momentum strategies: Which is the most profitable? [Tesis de grado]. Erasmus School of Economics. <https://thesis.eur.nl/pub/60109/>
- Shiller, R. J. (2000). *Irrational exuberance*. Princeton University Press.
- Talhartit, I., Ait Jilali, S., & El Kabbouri, M. (2022). Behavioral finance: How are traders' financial decisions and performance impacted by behavioral biases under uncertainty? *International Journal of Sciences Academic Research*, 3(10), 4588–4597. <https://shs.hal.science/halshs-03844737/document>
- Thaler, R. H. (1993). *Advances in behavioral finance*. Russell Sage Foundation.
- Tversky, A., & Kahneman, D. (1992). Advances in prospect theory: Cumulative representation of uncertainty. *Journal of Risk and Uncertainty*, 5(4), 297–323. <https://doi.org/10.1007/BF00122574>

