

TRABAJO DE INVESTIGACIÓN FINAL

Impacto de los sesgos conductuales en la
gestión humana de carteras frente a sistemas
algorítmicos

Autor/es:

Nicolás Spaccasassi. LU 1155923

Joaquin Bello Bongiovanni. LU 1151516

Carrera:

Lic Finanzas

Tutor/a:

Santiago Barbieri

Año:

2026

Universidad Argentina de la Empresa
Facultad de Ciencias Económicas

UADE

Índice

1	Introducción	4
2	Planteamiento del problema y justificación de la investigación.....	5
2.1	Justificación de la investigación	6
3.	Objetivo General	9
	Hipótesis.....	9
2.2	Estado de conocimiento	7
4.	Marco Teórico	10
4.3	Inversores particulares e institucionales y su rol en el entrenamiento algorítmico	13
4.4.	Sistemas algorítmicos	16
4.5.	Transmisión de sesgos conductuales hacia los sistemas algorítmicos	20
4.6.	El mercado argentino como contexto de análisis	25
5.	Metodología	30
5.1	Tipo y alcance de la investigación	30
5.2	Instrumento 1 — Encuesta de sesgos conductuales	31
5.3	Instrumento 2 — Rendimiento ajustado por riesgo del mercado argentino, 2015–2025	34
5.4	Evidencia complementaria — Sharpe Ratio de Fondos Comunes de Inversión institucionales en momentos de volatilidad	37
5.5	Integración de la evidencia y respuesta a la hipótesis y a las preguntas de investigación	40
	Anexos	44
	Bibliografía:	56

Resumen:

El presente trabajo de investigación analiza la transmisión de sesgos conductuales desde la gestión humana de carteras hacia los sistemas algorítmicos de inversión, con el objetivo de evaluar el impacto de dichos sesgos sobre el rendimiento ajustado por riesgo en el mercado argentino durante el período 2015–2025. En los últimos años, la incorporación de algoritmos en la administración de carteras por parte de Agentes de Administración de Carteras de Inversión (AACI) y Registered Investment Advisors (RIA) ha crecido de manera significativa, impulsada por la búsqueda de mayor eficiencia operativa y reducción de errores asociados a la toma de decisiones humanas.

El enfoque teórico del trabajo se apoya en las finanzas conductuales, identificando los principales sesgos presentes en la gestión de inversiones, entre ellos la sobreconfianza, el efecto disposición, la aversión a la pérdida y el comportamiento de manada. Asimismo, se analiza cómo dichos patrones conductuales pueden ser replicados por los sistemas algorítmicos a través de los datos históricos utilizados para su entrenamiento.

La investigación adopta un enfoque comparativo entre gestión humana y gestión algorítmica, evaluando diferencias de comportamiento y desempeño bajo distintos contextos de mercado, tales como períodos de alta volatilidad, crisis macroeconómica y estabilidad relativa. Para ello, se utilizarán indicadores financieros de rendimiento ajustado por riesgo, particularmente el Sharpe Ratio, junto con herramientas estadísticas aplicadas sobre información histórica del mercado argentino.

Finalmente, este estudio busca aportar evidencia sobre los límites de la supuesta neutralidad algorítmica en la gestión de carteras y contribuir al análisis académico sobre el impacto de los sesgos conductuales en los procesos de inversión automatizados dentro de mercados emergentes.

1. Introducción

La incorporación de sistemas algorítmicos en la gestión de carteras de inversión ha sido presentada, durante las últimas dos décadas, como una solución a las limitaciones cognitivas y emocionales de los gestores humanos. Bajo esta lógica, el algoritmo se posiciona como una herramienta objetiva, sistemática y libre de los sesgos conductuales que la literatura financiera ha documentado extensamente desde los trabajos fundacionales de Kahneman y Tversky (1979) y Thaler (1999). Sin embargo, esta premisa de neutralidad algorítmica merece ser examinada con mayor rigor.

El presente trabajo parte de una distinción conceptual que la literatura existente ha abordado de manera insuficiente: el problema no reside en el algoritmo en sí, sino en los datos con los que es entrenado. Como señala Mullainathan (2023), todo sistema algorítmico está construido sobre un modelo psicológico implícito del usuario, y sus diseñadores asumen erróneamente que el comportamiento observado en los datos históricos refleja preferencias genuinas y racionales. En la práctica, esos datos fueron generados por inversores que decidieron bajo condiciones de tiempo limitado, información incompleta y fuerte influencia. En consecuencia, el algoritmo no aprende de un mercado racional, sino que, aprende de un mercado construido por personas que tienen sus propios sesgos, y finalmente el algoritmo reproduce esos sesgos de forma sistemática e invisible.

En función de ello, la presente investigación tiene como objetivo analizar la transmisión de sesgos conductuales desde la gestión humana de carteras hacia los sistemas algorítmicos de inversión, evaluando su impacto sobre el rendimiento ajustado por riesgo en el mercado argentino durante el período 2015–2025. Particularmente, el estudio busca identificar qué sesgos conductuales se replican en los sistemas algorítmicos, comparar el desempeño ajustado por riesgo entre carteras humanas y automatizadas mediante el Sharpe Ratio y determinar bajo qué condiciones de mercado dicha transmisión resulta más intensa y observable.

2. Planteamiento del problema y justificación de la investigación

La gestión de carteras de inversión consiste en la administración profesional de activos financieros con el objetivo de optimizar el rendimiento de un portafolio en función del perfil de riesgo de cada inversor. En Argentina, esta actividad es ejercida por los Agentes de Administración de Carteras de Inversión (AACI), una de las siete categorías de agentes registrados ante la Comisión Nacional de Valores (CNV) que la normativa del mercado de capitales argentino reconoce. Esta clasificación está establecida en la Ley N° 26.831 y su decreto reglamentario N° 1023/2013. En el plano internacional, la figura equivalente son los Registered Investment Advisors (RIA), regulados por la Securities and Exchange Commission (SEC) conforme al Investment Advisers Act de 1940. Tanto los AACI como los RIA han incorporado de manera creciente sistemas algorítmicos en sus procesos de gestión. Esta tendencia se ha observado con mayor intensidad durante las últimas dos décadas. Su adopción responde a tres factores principales: el avance tecnológico, la reducción de costos operativos y la búsqueda de mayor eficiencia en la toma de decisiones de inversión. Bajo esta lógica de eficiencia y reducción de costos, el algoritmo se presenta como una herramienta capaz de neutralizar las limitaciones cognitivas y emocionales de los gestores humanos, ofreciendo decisiones de inversión objetivas y libres de los sesgos conductuales que afectan al juicio humano.

Estos sesgos conductuales en la toma de decisiones financieras han sido ampliamente documentados por la literatura académica. Kahneman y Tversky (1979), a partir de su desarrollo de la Teoría de la Perspectiva, demostraron que los individuos no toman decisiones bajo incertidumbre de manera racional, sino que evalúan las pérdidas y ganancias de forma asimétrica, siendo las pérdidas percibidas con mayor intensidad que las ganancias equivalentes. Por su parte, Thaler (1999), a través de su teoría de la contabilidad mental, evidenció que los inversores tienden a clasificar y tratar el dinero de manera diferente según su origen y destino, lo que genera decisiones inconsistentes con la maximización del valor esperado. En esa misma línea, Odean (1999) demostró empíricamente que los inversores operan con excesiva frecuencia en los mercados, impulsados por la sobreconfianza en sus propias capacidades de predicción, lo que deteriora sistemáticamente su rendimiento ajustado al riesgo. De los principales estudios de estos autores se pueden extraer los sesgos más frecuentes en la gestión de carteras: la sobreconfianza, el efecto disposición, la aversión a la pérdida y el comportamiento de manada, todos ellos generadores de decisiones subóptimas. Frente a estos sesgos documentados en la gestión humana, la incorporación de sistemas algorítmicos se justificó, como se señaló anteriormente, bajo el supuesto de que el algoritmo constituye una

herramienta neutral capaz de eliminarlos. Sin embargo, esta investigación sostiene que esa neutralidad asumida no resiste el análisis: el problema central no reside en el algoritmo en sí, sino en los datos con los que es entrenado. Esta distinción, aunque sutil, tiene consecuencias profundas: Sendhil Mullainathan, en su paper "Human Bias in Algorithm Design", escrito en el año 2023 demuestra que todo sistema algorítmico está construido sobre un modelo psicológico implícito del usuario, y que sus diseñadores asumen erróneamente que el comportamiento observado refleja preferencias genuinas y racionales. En la práctica, los inversores deciden bajo lo que la literatura conductual denomina "fast thinking": con tiempo limitado, información incompleta y sesgos contextuales. Más aún, los algoritmos aprenden las decisiones que los inversores toman en el momento, "sus *wants*", es decir lo que desean momentáneamente y no las que tomarían con mayor reflexión y horizonte temporal. Y no las que habrían tomado con mayor reflexión y horizonte temporal, sus "*shoulds*". En consecuencia, el autor hace referencia que el algoritmo no corrige los sesgos humanos, sino que, los replica, los institucionaliza y los vuelve invisibles bajo una apariencia de objetividad.

Esta problemática adquiere particular relevancia en el mercado de capitales argentino, caracterizado por una alta volatilidad macroeconómica, inestabilidad cambiaria y escasa regulación sobre el uso de sistemas algorítmicos de inversión. En ese contexto, los sesgos conductuales de los inversores tanto particulares como institucionales no solo afectan las decisiones individuales, sino que se incorporan como patrones sistemáticos en los datos históricos con los que se entrenan los algoritmos.

Argentina representa, por tanto, un caso de estudio especialmente relevante para observar cómo esa transmisión de sesgos opera en condiciones de estrés macroeconómico sostenido, donde la brecha entre el comportamiento real del inversor y sus preferencias racionales es particularmente pronunciada.

2.1 Justificación de la investigación

La relevancia de esta investigación radica en que permite examinar con evidencia empírica si la incorporación de sistemas algorítmicos efectivamente neutraliza los sesgos conductuales en la gestión de carteras, o si, por el contrario, los hereda y los institucionaliza bajo una apariencia de objetividad. Esta pregunta tiene implicancias directas tanto para los AACI y RIA que diseñan y operan estos sistemas, como para los inversores que depositan su capital bajo el supuesto de neutralidad algorítmica.

En el contexto específico del mercado argentino, esta investigación cobra una relevancia adicional dada la ausencia de un marco regulatorio que contemple mecanismos de auditoría sobre el sesgo algorítmico, y dada la intensidad de los episodios de estrés macroeconómico que el país ha atravesado en el período de análisis. Los resultados de esta investigación pueden aportar evidencia útil tanto para el diseño de mejores prácticas de gestión algorítmica como para eventuales desarrollos regulatorios en esta materia.

2.2 Estado de conocimiento

La literatura existente sobre la comparación de rendimiento entre gestión humana y algorítmica de carteras ha producido evidencia significativa, aunque con limitaciones relevantes para los fines de esta investigación.

Si bien los autores citados en el planteamiento del problema —Kahneman, Thaler, Odean y Mullainathan— establecen la base conceptual de los sesgos conductuales y su transmisión algorítmica, la literatura que compara directamente el rendimiento de carteras humanas y algorítmicas proviene de un cuerpo de estudios distinto, que se detalla a continuación.

Un estudio publicado en el *Technological Forecasting and Social Change* comparó el rendimiento ajustado al riesgo de robo-advisors frente a fondos de renta variable, renta fija, money market e híbridos en el mercado estadounidense entre 2016 y 2019, encontrando que los robo-advisors demostraron en promedio un rendimiento superior al de los fondos tradicionales de renta variable, renta fija, money market e híbridos, superando también a tres índices bursátiles relevantes de manera robusta ante distintas especificaciones del modelo. Este hallazgo es representativo del tipo de evidencia disponible: compara rendimientos agregados entre gestión humana y algorítmica, pero no aísla qué proporción de esa diferencia es atribuible específicamente a la presencia o ausencia de sesgos conductuales en cada tipo de gestión.

Un estudio de la Universidad de Minnesota aporta evidencia en la misma dirección al analizar el comportamiento de inversores durante la crisis de COVID-19. El estudio encontró que los usuarios de robo-advisors obtuvieron una ventaja de rendimiento de 12,67% frente a inversores humanos comparables durante el desplome bursátil de la pandemia, en gran parte porque los algoritmos fueron haciendo movimientos de compra y venta de acciones de manera sistemática mientras los inversores humanos reaccionaron con pánico. Si bien este hallazgo sugiere una relación entre el comportamiento sesgado del inversor humano y el diferencial de rendimiento, el estudio no profundiza en qué sesgos conductuales específicos

explican esa reacción de pánico, ni examina si el propio algoritmo incorpora sesgos latentes provenientes de sus datos de entrenamiento.

Esta carencia se vuelve más evidente al considerar la literatura sobre diseño algorítmico fuera del ámbito financiero. Mullainathan (2023) y Obermeyer y Mullainathan (2019) demostraron, en el contexto de sistemas de salud, que un algoritmo entrenado con datos generados por decisiones humanas sesgadas reproduce y amplifica ese sesgo de manera sistemática. Sin embargo, esta línea de evidencia no ha sido aplicada de manera sistemática al estudio de la gestión de carteras de inversión, y mucho menos al contexto específico de mercados emergentes con alta volatilidad macroeconómica como el argentino.

En síntesis, los trabajos existentes comparan rendimientos agregados entre gestión humana y algorítmica, pero no aíslan el canal conductual como variable explicativa. Tampoco distinguen si el perfil de sesgo replicado varía según el tipo de inversor —particular o institucional— que generó los datos de entrenamiento, ni identifican bajo qué condiciones de mercado esa transmisión de sesgos se vuelve más pronunciada. Esta investigación propone abordar esas tres dimensiones de manera integrada: (a) la identificación de los sesgos conductuales que se replican en sistemas algorítmicos, (b) la variación de dichos sesgos según el perfil del inversor que generó los datos de entrenamiento, y (c) las condiciones de mercado bajo las cuales esa transmisión resulta más pronunciada, aportando evidencia que permita cuestionar la neutralidad atribuida a los sistemas algorítmicos de gestión de carteras en mercados emergentes como el argentino.

En virtud del problema planteado y de la carencia identificada en el estado de conocimiento, esta investigación propone las siguientes preguntas de investigación:

1. ¿Qué sesgos comunes en carteras de gestión humana se repiten en carteras de gestión algorítmica?
2. ¿Cómo varían los sesgos del sistema algorítmico según los datos de inversores particulares frente a inversores institucionales con los que fue entrenado?
3. ¿Qué situaciones tienden a sesgar a los algoritmos y no a los inversores?

3. Objetivo general

Analizar la transmisión de sesgos conductuales desde la gestión humana de carteras hacia los sistemas algorítmicos de inversión, evaluando su impacto en el rendimiento ajustado por riesgo en el mercado argentino durante el período 2015–2025.

Objetivos particulares:

1. Identificar qué sesgos conductuales presentes en la gestión humana de carteras, sobreconfianza, efecto disposición, aversión a la pérdida y comportamiento de manada, se replican en los sistemas algorítmicos de gestión de carteras operados por AACI y RIA.
2. Comparar el rendimiento ajustado por riesgo, medido a través del Sharpe Ratio entre carteras de gestión humana y algorítmica, en el mercado argentino durante el período 2015–2025.
3. Determinar bajo qué condiciones de mercado, alta volatilidad, crisis macroeconómica o estabilidad relativa, la transmisión de sesgos conductuales desde inversores humanos hacia sistemas algorítmicos resulta más intensa y observable.

Hipótesis:

Los sesgos conductuales identificados en los inversores —en particular la aversión a la pérdida y el efecto disposición— se asocian con un menor rendimiento ajustado por riesgo de las carteras en el mercado argentino, siendo esta asociación menos pronunciada en la gestión institucional, dado que los Fondos Comunes de Inversión y AACI operan bajo marcos normativos de la CNV que imponen mecanismos formales de control de riesgo, ausentes en la gestión de carteras particulares.

4. Marco Teórico

4.1 Sesgo en finanzas

Para comprender el impacto de los sesgos conductuales en la gestión de carteras de inversión, resulta imprescindible definir con precisión qué se entiende por sesgo en el ámbito financiero y cuál es su origen conceptual.

En términos generales, un sesgo cognitivo puede definirse como una desviación sistemática del pensamiento racional en el proceso de toma de decisiones. Kahneman y Tversky (1979), en su libro *Prospect theory: An analysis of decision under risk*, sostiene de manera rigurosa que los individuos no toman decisiones económicas de acuerdo con los postulados de la teoría de la utilidad esperada, sino que sus juicios están sistemáticamente influenciados por atajos mentales que introducen errores predecibles y recurrentes. Esta evidencia representó una ruptura fundamental con el paradigma del agente racional que dominaba la teoría financiera clásica.

En el contexto específico de las finanzas, Daniel, Hirshleifer y Teoh (2002) definen los sesgos conductuales como patrones sistemáticos de desviación respecto a la racionalidad en el juicio y la toma de decisiones de los agentes financieros, que afectan tanto la formación de expectativas como la valoración de activos y la construcción de portafolios. A diferencia de los errores aleatorios, los sesgos son predecibles en su dirección e intensidad, lo que los convierte en un objeto de estudio especialmente relevante para la gestión de carteras.

Thaler (1999), desde la teoría de la contabilidad mental, amplió esta definición al demostrar que los sesgos no solo afectan la percepción del riesgo, sino también la forma en que los individuos organizan, evalúan y deciden sobre sus posiciones financieras. Según el autor, los inversores no tratan el dinero como un recurso fungible y homogéneo, sino que lo clasifican en categorías mentales diferenciadas, lo que genera inconsistencias sistemáticas en sus decisiones de inversión.

Cabe distinguir, además, entre sesgos cognitivos y sesgos emocionales. Los primeros derivan de limitaciones en el procesamiento de información y en el razonamiento lógico, mientras que los segundos están vinculados a estados afectivos que distorsionan la evaluación objetiva de situaciones financieras. Ambos tipos coexisten en la práctica de la gestión de carteras y, como señalan Barber y Odean (2000), su efecto combinado se traduce en decisiones de inversión que deterioran sistemáticamente el rendimiento ajustado al riesgo de los portafolios gestionados por humanos.

4.2 Tipos de sesgos conductuales en la gestión de carteras

La literatura en finanzas conductuales ha identificado un conjunto amplio de sesgos que afectan las decisiones de los gestores de carteras. Para los fines de esta investigación, se analizan en profundidad los cuatro sesgos con mayor evidencia empírica en el contexto de la gestión de portafolios: la sobreconfianza, el efecto disposición, la aversión a la pérdida y el comportamiento de manada.

4.2.1 Sobreconfianza

La sobreconfianza es uno de los sesgos más documentados en la literatura financiera. Daniel, Hirshleifer y Subrahmanyam (1998) la definen como la tendencia de los inversores a sobreestimar la precisión de su información privada y la calidad de sus capacidades predictivas, lo que los lleva a atribuir los resultados favorables a sus propias habilidades y los desfavorables a factores externos. En términos prácticos, este sesgo se manifiesta en una rotación excesiva de cartera, ya que el inversor sobreconfiado cree poseer información superior que justifica operar con mayor frecuencia de la que sería óptima.

“Operar en exceso puede resultar perjudicial para la riqueza del inversor” (Odean, 1999, p. 1279, traducción propia).

Odean (1999) demostró empíricamente que los inversores individuales operan con una frecuencia significativamente mayor a la que maximizaría su rendimiento, y que esta sobreactividad tiene un impacto negativo y estadísticamente significativo sobre su rendimiento ajustado al riesgo. Barber y Odean (2000) ampliaron este hallazgo al comparar carteras de distintos perfiles de inversores, confirmando que la sobreconfianza es un predictor robusto del deterioro del rendimiento en la gestión activa de portafolios.

4.2.2 Efecto disposición

El efecto disposición fue identificado y formalizado por Shefrin y Statman (1985) como la tendencia sistemática de los inversores a vender demasiado pronto los activos que muestran ganancias y a mantener demasiado tiempo los activos que acumulan pérdidas. Este comportamiento es irracional desde la perspectiva de la teoría financiera clásica, ya que ignora las perspectivas futuras de los activos y responde únicamente a la necesidad psicológica de materializar ganancias y evitar el reconocimiento de pérdidas.

El fundamento teórico del efecto disposición se encuentra en la Teoría de la Perspectiva de Kahneman y Tversky (1979), que establece que los individuos experimentan las pérdidas con mayor intensidad psicológica que las ganancias de igual magnitud. Esta asimetría en la percepción del resultado genera una resistencia a cerrar posiciones perdedoras que resulta costosa en términos de rendimiento ajustado al riesgo.

4.2.3 Aversión a la pérdida

La aversión a la pérdida constituye uno de los pilares conceptuales de la Teoría de la Perspectiva. Kahneman y Tversky (1979) demostraron que, para la mayoría de los individuos, el dolor psicológico asociado a una pérdida de una unidad monetaria es aproximadamente el doble de la satisfacción generada por una ganancia equivalente.

“Las pérdidas tienen un impacto psicológico mayor que las ganancias equivalentes” (Kahneman & Tversky, 1979, p. 279, traducción propia).

Esta asimetría tiene consecuencias directas sobre la construcción y gestión de carteras, ya que lleva a los inversores a adoptar posiciones excesivamente conservadoras en momentos de incertidumbre, a rechazar oportunidades de inversión con valor esperado positivo y a tomar decisiones inconsistentes con sus propios objetivos de largo plazo.

Thaler (1999) vinculó la aversión a la pérdida con la contabilidad mental, señalando que los inversores evalúan las pérdidas y ganancias en términos relativos a un punto de referencia, generalmente el precio de compra, y no en términos del valor absoluto de su cartera, lo que introduce distorsiones sistemáticas en sus decisiones de rebalanceo.

4.2.4 Comportamiento de manada

El comportamiento de manada, o *herding*, describe la tendencia de los inversores a imitar las decisiones de otros participantes del mercado, ignorando su propia información o análisis previo. Daniel, Hirshleifer y Teoh (2002) señalan que este comportamiento es especialmente pronunciado en contextos de alta incertidumbre, donde los agentes interpretan las acciones de otros como señales informativas superiores a las propias.

En el ámbito de la gestión de carteras institucional, el comportamiento de manada tiene implicancias sistémicas relevantes: cuando un número significativo de gestores adopta

posiciones similares de manera simultánea, se generan movimientos de precios que amplifican la volatilidad del mercado y que pueden desconectarse de los fundamentos económicos subyacentes. Este fenómeno ha sido documentado en mercados emergentes como el argentino, donde la escasa profundidad del mercado y la alta sensibilidad a variables macroeconómicas exógenas incrementan la propensión al comportamiento gregario entre los gestores de carteras.

4.3 Inversores particulares e institucionales y su rol en el entrenamiento algorítmico

La distinción entre inversores particulares e institucionales no constituye únicamente una categorización operativa del mercado financiero, sino que representa una variable explicativa central para comprender el perfil de sesgos que un sistema algorítmico puede heredar a través de sus datos de entrenamiento. Como señalan Barber y Odean (2000), ambos tipos de inversores exhiben patrones de comportamiento sistemáticamente diferentes, lo que implica que los algoritmos entrenados predominantemente con datos de uno u otro perfil incorporarán sesgos de distinta naturaleza e intensidad.

4.3.1 El inversor particular y sus sesgos característicos

El inversor particular, denominado en inglés, retail investor, opera generalmente con menor acceso a información, horizontes temporales más cortos y mayor exposición a sesgos emocionales. Barber y Odean (2000) demostraron que los inversores individuales exhiben niveles significativamente más altos de sobreconfianza que los inversores profesionales, lo que se traduce en una rotación de cartera excesiva y en un deterioro sistemático del rendimiento ajustado al riesgo. Odean (1999), afirma que este hallazgo fue consistente a lo largo de diferentes mercados y períodos de análisis, lo que sugiere que la sobreconfianza en el inversor particular no es un fenómeno circunstancial sino un patrón estructural.

Asimismo, el efecto disposición documentado por Shefrin y Statman (1985) resulta especialmente pronunciado en los inversores particulares. Al operar sin marcos institucionales de control de riesgo ni mandatos formales de gestión, el inversor individual toma decisiones guiadas en mayor medida por referencias psicológicas personales, como el precio de compra original del activo, que por criterios objetivos de valoración. En el contexto argentino, este sesgo se ve amplificado por la alta volatilidad macroeconómica, que genera

puntos de referencia cambiantes y decisiones de venta o retención motivadas por el estrés financiero más que por el análisis fundamental.

4.3.2 El inversor institucional y sus sesgos característicos

Los inversores institucionales, como lo son los fondos de inversión, compañías de seguros, fondos de pensión y bancos, operan con estructuras de gobernanza más formales, acceso amplio a información y equipos especializados de análisis. Sin embargo, esto no los exime de sesgos conductuales. Daniel, Hirshleifer y Teoh (2002) señalan que los inversores institucionales exhiben de manera recurrente el comportamiento de manada, motivado tanto por incentivos de reputación como por estructuras de compensación que penalizan el underperformance relativo frente a un benchmark. En este contexto, un benchmark es un índice de referencia, como el S&P 500 en el mercado estadounidense o el Merval en el argentino, contra el cual se evalúa el desempeño del gestor. Apartarse del consenso implica asumir el riesgo de quedar por debajo de ese índice, lo que tiene consecuencias directas sobre la remuneración y la continuidad del gestor en su cargo. Esta estructura de incentivos convierte al seguimiento del consenso en una decisión racionalmente defensiva a nivel individual, aunque colectivamente genera el comportamiento en manada que amplifica la volatilidad del mercado.

Brière, Calamai, Di Giansante, Huynh y Novelli (2023) aportan evidencia empírica más reciente sobre las diferencias conductuales entre ambos tipos de inversores, encontrando que los sesgos institucionales tienden a ser más sistemáticos y correlacionados entre sí, precisamente porque los gestores profesionales comparten marcos de análisis, fuentes de información y estructuras de incentivos similares. Esta correlación de sesgos entre gestores institucionales tiene una implicancia directa sobre los algoritmos: cuando el sistema es entrenado con datos generados mayoritariamente por inversores institucionales, hereda no sólo sesgos individuales sino patrones de comportamiento colectivo que se repiten de manera predecible.

4.3.3 La transmisión diferencial de sesgos al algoritmo

El mecanismo por el cual los sesgos de los inversores se transfieren a los sistemas algorítmicos opera a través de los datos históricos de entrenamiento. Mullainathan (2023) explica que los algoritmos aprenden las decisiones que los inversores tomaron en el

momento de “sus *wants*” y no las que habrían tomado con mayor reflexión y horizonte temporal, sus “*shoulds*”. En consecuencia, el perfil de sesgo que un algoritmo hereda depende directamente de qué tipo de inversor generó los datos con los que fue entrenado.

Esta distinción tiene consecuencias prácticas relevantes. Un algoritmo entrenado predominantemente con datos de inversores particulares tenderá a replicar sesgos de sobreconfianza y efecto disposición, dado que son los más característicos de ese perfil. En cambio, un algoritmo entrenado con datos de inversores institucionales incorporará con mayor probabilidad patrones de comportamiento de manada y sesgos de confirmación vinculados al uso compartido de benchmarks y modelos de valoración. Los modelos de valoración son marcos analíticos estandarizados que los gestores institucionales utilizan para estimar el valor intrínseco de un activo y determinar si está sobrevaluado o subvaluado respecto a su precio de mercado; entre los más extendidos se encuentran el modelo de descuento de dividendos, el flujo de fondos descontados y los múltiplos de valuación como el ratio precio-ganancia. Cuando una proporción significativa de gestores institucionales emplea los mismos modelos, con supuestos similares y calibrados sobre los mismos datos históricos, sus conclusiones tienden a converger, lo que refuerza el comportamiento gregario y genera en los datos de entrenamiento un patrón de decisiones correlacionadas que el algoritmo aprende como señal válida. López de Prado (2018) advierte además que esta transmisión no es transparente: el algoritmo no señala explícitamente qué sesgos está replicando, sino que los incorpora como patrones estadísticos latentes en sus reglas de decisión, lo que los vuelve especialmente difíciles de detectar y corregir.

Obermeyer y Mullainathan (2019), en su análisis sobre sesgo algorítmico en sistemas de salud, demostraron que un algoritmo entrenado con datos generados bajo condiciones de sesgo sistemático reproduce y amplifica ese sesgo de manera proporcional a su prevalencia en los datos de entrenamiento. Trasladado al contexto financiero, este hallazgo sugiere que los sistemas algorítmicos de gestión de carteras no sólo heredan los sesgos de sus datos de entrenamiento, sino que pueden amplificarlos al aplicarlos de manera sistemática y a escala, sin el mecanismo de autocorrección que ocasionalmente opera en el juicio humano.

En síntesis, la distinción entre inversores particulares e institucionales no es irrelevante para el análisis del sesgo algorítmico. Por el contrario, constituye una variable explicativa clave para comprender qué tipo de sesgos replica un sistema algorítmico, con qué intensidad lo hace y bajo qué condiciones de mercado esa replicación resulta más observable. Esta dimensión, ausente en la literatura existente sobre gestión algorítmica de carteras, es precisamente la que esta investigación propone examinar de manera sistemática.

4.4. Sistemas algorítmicos

La incorporación de sistemas algorítmicos en la gestión de carteras de inversión representa una de las transformaciones más significativas que ha experimentado la industria financiera en las últimas dos décadas. Para comprender de qué manera estos sistemas pueden heredar y replicar sesgos conductuales, resulta imprescindible analizar primero cómo funcionan, qué tipos existen y cuál es su rol específico en el proceso de toma de decisiones de inversión.

4.4.1 Definición y funcionamiento general

Un sistema algorítmico de gestión de carteras puede definirse como un conjunto de reglas computacionales predefinidas o aprendidas estadísticamente que, a partir de un conjunto de datos de entrada, genera decisiones de inversión de manera automatizada y sistemática. Kissell (2013) describe estos sistemas como herramientas diseñadas para ejecutar estrategias de inversión con mayor velocidad, precisión y consistencia que un gestor humano, eliminando la variabilidad introducida por el juicio discrecional en el proceso de toma de decisiones.

El funcionamiento de un sistema algorítmico de gestión de carteras puede descomponerse en tres etapas fundamentales. En primer lugar, la etapa de carga de datos, en la que el sistema incorpora información histórica de precios, volúmenes, indicadores macroeconómicos y, en los modelos más avanzados, agrega flujos de noticias y datos alternativos más avanzados del mercado, como por ejemplo el sentimiento de mercado, es decir, el estado de ánimo colectivo y actitud general de los inversores y traders hacia un activo, sector o el mercado en su conjunto, determinado por sus expectativas y emociones. En segundo lugar, la etapa de procesamiento, en la que el algoritmo aplica un conjunto de reglas o un modelo estadístico para identificar patrones y generar señales de compra, venta o mantenimiento de posiciones. En tercer lugar, la etapa de ejecución, en la que las señales generadas se traducen en órdenes concretas sobre los activos del portafolio.

López de Prado (2018) advierte que esta secuencia, aunque aparentemente objetiva, está condicionada en cada una de sus etapas por decisiones humanas, qué datos se incluyen, qué variables se consideran relevantes, qué función objetivo se optimiza y qué restricciones se imponen al modelo. Estas decisiones de diseño introducen un sesgo estructural que precede incluso al entrenamiento del sistema con datos históricos.

4.4.2 Tipos de sistemas algorítmicos en gestión de carteras

La literatura financiera distingue varios tipos de sistemas algorítmicos según su arquitectura de toma de decisiones y su grado de autonomía respecto al juicio humano.

Sistemas basados en reglas predefinidas. Son los más simples y los primeros en ser adoptados por la industria financiera. Operan a partir de un conjunto de condiciones lógicas establecidas por el diseñador, por ejemplo, comprar cuando la media móvil de corto plazo supera a la de largo plazo, y no aprenden ni se adaptan a nuevos datos. Su ventaja principal es la transparencia, las reglas son explícitas y auditables. Su limitación es la rigidez: no pueden ajustarse a cambios estructurales en el mercado que no fueron anticipados en su diseño (Kissell, 2013).

Sistemas de machine learning supervisado. Son entrenados a partir de datos históricos etiquetados, donde el algoritmo aprende a asociar patrones de entrada con resultados de salida deseados. López de Prado (2018) señala que estos sistemas son actualmente los más utilizados en la gestión cuantitativa de carteras, dado su capacidad para identificar relaciones no lineales entre variables que escapan al análisis tradicional. Sin embargo, su dependencia de datos históricos los hace especialmente vulnerables a la transmisión de sesgos, si los datos de entrenamiento reflejan decisiones humanas sesgadas, el modelo aprenderá esos sesgos como patrones válidos.

Sistemas de machine learning no supervisado. No requieren datos etiquetados sino que identifican estructuras latentes en los datos de manera autónoma. Se utilizan frecuentemente para la construcción de portafolios mediante técnicas de clustering, es decir, agrupar observaciones similares, reduciendo el número de variables y manteniendo la información relevante. Aunque son menos susceptibles a replicar sesgos de decisión específicos, pueden incorporar sesgos estructurales del mercado si las correlaciones históricas entre activos reflejan comportamientos colectivos sesgados (López de Prado, 2018).

Sistemas de aprendizaje por refuerzo. Aprenden a través de la interacción con el entorno, optimizando una función de recompensa definida por el diseñador. Son los más autónomos de los tres tipos anteriores y los que presentan mayor potencial de amplificación de sesgos, dado que optimizan de manera continua en función de señales de retroalimentación que pueden estar contaminadas por patrones históricos de comportamiento sesgado (Sutton y Barto, 2018; López de Prado, 2018).

4.4.3 Los algoritmos en el marco regulatorio argentino e internacional

En el marco regulatorio argentino, la Ley N° 26.831 y su decreto reglamentario N° 1023/2013, establecen las condiciones bajo las cuales los Agentes de Administración de Carteras de Inversión (AACI) pueden operar, pero no contemplan aún una regulación específica sobre el uso de sistemas algorítmicos en la toma de decisiones de inversión. Esta ausencia regulatoria implica que los algoritmos utilizados por los AACI operan bajo un marco de supervisión diseñado para la gestión humana discrecional, sin mecanismos específicos de auditoría o control del sesgo algorítmico.

En el plano internacional, la Securities and Exchange Commission (SEC) ha comenzado a desarrollar lineamientos sobre el uso de inteligencia artificial y sistemas algorítmicos por parte de la contraparte estadounidense de los AACI, los Registered Investment Advisors (RIA), reconociendo explícitamente el riesgo de que estos sistemas reproduzcan sesgos presentes en sus datos de entrenamiento. Sin embargo, como señala López de Prado (2018), la regulación financiera en materia algorítmica se encuentra aún significativamente rezagada respecto al ritmo de adopción de estas tecnologías por parte de la industria, lo que genera una brecha de supervisión con implicancias directas sobre la protección del inversor.

Esta brecha regulatoria adquiere particular relevancia en el contexto de esta investigación, en ausencia de mecanismos formales de auditoría del sesgo algorítmico, la transmisión de sesgos conductuales desde los datos de entrenamiento hacia las decisiones algorítmicas opera de manera invisible y sin contrapeso institucional, tanto en Argentina como en la mayoría de los mercados emergentes.

4.4.4 Arquitectura algorítmica y perfil de sesgo replicado

Los tres tipos de sistemas algorítmicos descritos en las secciones anteriores no son igualmente vulnerables a la transmisión de sesgos conductuales, ni replican el mismo tipo de sesgo cuando esa transmisión ocurre. La arquitectura de cada sistema determina qué patrones del comportamiento humano tienen mayor probabilidad de ser aprendidos como reglas de decisión válidas.

Los sistemas de machine learning supervisado son los más susceptibles a replicar sesgos individuales y sistemáticos, precisamente porque su mecanismo de aprendizaje consiste en

identificar patrones predictivos en datos históricos etiquetados sin distinguir si esos patrones reflejan decisiones racionales o sesgadas. Un sistema supervisado entrenado con datos de inversores individuales aprenderá con alta fidelidad la sobreconfianza, al encontrar que la rotación frecuente de cartera es un patrón estadísticamente consistente en los datos, y el efecto disposición, al identificar la asimetría sistemática entre la velocidad de venta de activos ganadores y perdedores. En cambio si está entrenado con datos de inversores institucionales, en cambio, aprenderá el comportamiento de manada como una señal informativa válida, dado que las decisiones correlacionadas entre gestores generan patrones de alta consistencia estadística que el modelo interpreta como evidencia de una estrategia exitosa.

Los sistemas de machine learning no supervisado presentan una vulnerabilidad diferente. Al identificar estructuras latentes en los datos sin una variable objetivo explícita, tienden a capturar sesgos estructurales del mercado más que sesgos individuales de decisión. En el contexto argentino, esto implica que un sistema no supervisado entrenado con datos del período 2015–2025 incorporará como estructura válida la correlación histórica entre episodios de estrés macroeconómico y dolarización masiva de carteras, un patrón que refleja la aversión a la pérdida colectiva de los inversores locales y que el algoritmo aprenderá como una regla general de construcción de portafolios, independientemente de si las condiciones que lo originaron siguen vigentes.

Los sistemas de aprendizaje por refuerzo son los que presentan el mayor potencial de amplificación de sesgos, dado que optimizan de manera continua en función de señales de recompensa que pueden estar contaminadas por los mismos patrones sesgados presentes en los datos históricos. A diferencia de los sistemas supervisados, que replican el sesgo de manera estática, un sistema de refuerzo puede reforzarlo iterativamente, si una estrategia sesgada, como la rotación excesiva de cartera, generó retornos positivos en el período de entrenamiento, el sistema la consolidará como política óptima y la aplicará con creciente convicción en períodos futuros, incluso cuando las condiciones de mercado ya no la justifiquen.

Esta diferenciación por arquitectura tiene una implicancia directa para el análisis que desarrolla el capítulo siguiente: la intensidad y el tipo de sesgo que un sistema algorítmico replica no dependen únicamente del perfil del inversor que generó los datos de entrenamiento, sino también de la arquitectura del modelo que procesa esos datos. Ambas dimensiones, perfil del inversor y tipo de sistema, operan de manera conjunta en la determinación del sesgo algorítmico resultante, y su interacción es precisamente lo que el capítulo 5 analiza en profundidad.

4.5. Transmisión de sesgos conductuales hacia los sistemas algorítmicos

Los capítulos anteriores establecieron que los inversores humanos toman decisiones sistemáticamente influenciadas por sesgos conductuales, y que los sistemas algorítmicos aprenden sus reglas de decisión a partir de datos históricos generados por esos mismos inversores. Este capítulo analiza el mecanismo específico por el cual esa transmisión opera, la evidencia empírica que la respalda y las condiciones bajo las cuales se vuelve más pronunciada.

4.5.1 El mecanismo de transmisión

La transmisión de sesgos conductuales hacia los sistemas algorítmicos no es un proceso aleatorio sino estructural. Mullainathan (2023), explica que todo sistema algorítmico está construido sobre un modelo psicológico implícito del usuario, y que ese modelo asume erróneamente que el comportamiento observado en los datos históricos refleja preferencias genuinas y racionales. En la práctica, esos datos fueron generados por inversores que decidieron bajo condiciones de *fast thinking*: con tiempo limitado, información incompleta y fuerte influencia de atajos mentales que el cerebro utiliza para formar juicios y tomar decisiones de manera rápida y eficiente, especialmente bajo condiciones de incertidumbre o con información limitada

El mecanismo puede describirse en tres etapas. En primer lugar, el inversor humano toma decisiones de inversión influenciadas por sesgos conductuales, vende los activos ganadores demasiado rápido, mantiene perdedores demasiado tiempo, (efecto disposición), opera con excesiva frecuencia (sobreconfianza), y las pérdidas duelen aproximadamente el doble que el placer de una ganancia de magnitud equivalente. En segundo lugar, esas decisiones quedan registradas como datos históricos que no reflejan las preferencias racionales del inversor sino “sus *wants*” momentáneos, lo que desean momentáneamente y no las que tomarían con mayor reflexión y horizonte temporal. En tercer lugar, el algoritmo entrenado con esos datos aprende esos patrones como reglas válidas de decisión, incorporándolos de manera latente en su arquitectura sin señalarlos explícitamente como sesgos.

López de Prado (2018) advierte que este proceso es especialmente problemático en los modelos de machine learning supervisado, donde el algoritmo optimiza su capacidad

predictiva sobre datos históricos sin distinguir entre patrones informativos genuinos y patrones que reflejan comportamiento sesgado. Para el modelo, ambos tipos de patrones son igualmente válidos si tienen poder predictivo sobre los datos de entrenamiento.

4.5.2 Evidencia empírica sobre el sesgo algorítmico

La evidencia empírica sobre la transmisión de sesgos humanos hacia sistemas algorítmicos proviene principalmente de estudios realizados fuera del ámbito financiero, aunque sus implicancias son directamente aplicables a la gestión de carteras.

Obermeyer y Mullainathan (2019), en su análisis publicado en *Science*, demostraron que un algoritmo utilizado en el sistema de salud estadounidense para asignar recursos médicos reproducía y amplificaba sistemáticamente los sesgos presentes en sus datos de entrenamiento. El hallazgo central fue que el algoritmo no sólo heredaba el sesgo sino que lo institucionalizaba, al aplicarlo de manera sistemática y a escala, lo convertía en una regla de decisión invisible e incuestionable. Este mecanismo de institucionalización del sesgo es directamente transferible al contexto financiero, donde los algoritmos de gestión de carteras aplican sus reglas aprendidas sobre volúmenes de transacciones que amplifican cualquier patrón sesgado presente en sus datos de origen.

En el ámbito financiero específico, Mullainathan y Ludwig (2022) demostraron que los modelos de machine learning aplicados a decisiones económicas tienden a replicar las preferencias reveladas de los agentes que generaron los datos, incluso cuando esas preferencias están distorsionadas por sesgos cognitivos. Su análisis evidenció que la capacidad predictiva de un modelo, medida por métricas estándar como el error cuadrático medio, no garantiza la ausencia de sesgo, ya que un modelo puede ser altamente predictivo precisamente porque aprendió a replicar patrones sesgados de manera precisa

4.5.3 Condiciones que amplifican la transmisión

La transmisión de sesgos conductuales hacia los sistemas algorítmicos no opera con igual intensidad en todas las condiciones de mercado. La literatura identifica al menos tres factores que amplifican este fenómeno.

El primero es la concentración de los datos de entrenamiento. Cuando los datos históricos utilizados para entrenar el algoritmo provienen de un período particular de mercado, una burbuja, una crisis, un período de alta volatilidad, el modelo aprende los patrones de comportamiento sesgado que caracterizaron ese período y los generaliza como reglas

universales. López de Prado (2018) denomina a este fenómeno *overfitting* conductual, es decir, que el algoritmo se ajusta perfectamente al comportamiento sesgado de un período específico y falla cuando las condiciones de mercado cambian.

El segundo factor es la alta volatilidad macroeconómica. En contextos de incertidumbre extrema, los inversores humanos toman decisiones más influenciadas por sesgos emocionales que en períodos de estabilidad. Si esos datos de alta volatilidad tienen un peso significativo en el entrenamiento del algoritmo, el sistema aprenderá patrones de decisión especialmente sesgados como reglas generales de inversión. Este factor es particularmente relevante para el caso argentino, donde la alta frecuencia de crisis macroeconómicas implica que una proporción significativa de los datos históricos disponibles fue generada bajo condiciones de estrés financiero extremo.

El tercer factor es la ausencia de mecanismos de corrección. A diferencia del inversor humano, que ocasionalmente puede reconocer y corregir sus sesgos a través de la reflexión o la experiencia, el algoritmo aplica sus reglas aprendidas de manera consistente y sin autocorrección espontánea. Daniel, Hirshleifer y Teoh (2002) señalan que, si bien en condiciones de racionalidad sería una ventaja, esta consistencia se convierte en una vulnerabilidad cuando las reglas aprendidas reflejan patrones sesgados, es decir, el algoritmo replica el sesgo con una regularidad y una escala que ningún inversor humano podría igualar.

4.5.4 Implicancias para la gestión de carteras

La transmisión de sesgos conductuales hacia los sistemas algorítmicos tiene implicancias directas sobre la calidad de las decisiones de gestión de carteras. Si el algoritmo hereda el efecto disposición, tenderá sistemáticamente a señalar la venta de activos ganadores y el mantenimiento de activos perdedores, replicando el patrón irracional documentado por Shefrin y Statman (1985) pero a una escala y velocidad imposibles para un gestor humano. Si hereda la sobreconfianza, generará una rotación excesiva de cartera que deteriorará el rendimiento ajustado al riesgo de manera consistente.

Lo más relevante desde la perspectiva de esta investigación es que estos sesgos heredados operan de manera invisible. A diferencia del gestor humano cuyo comportamiento sesgado puede ser observado y cuestionado, el algoritmo presenta sus decisiones como el resultado de un proceso objetivo y sistemático, lo que dificulta su detección y corrección. Como señala Mullainathan (2023), esta invisibilidad del sesgo

algorítmico es precisamente lo que lo hace más peligroso que el sesgo humano, no sólo replica el error sino que lo legitima bajo una apariencia de objetividad.

4.5.5 Sesgos conductuales con mayor frecuencia de replicación en sistemas algorítmicos

Si bien la evidencia empírica específica sobre la replicación de sesgos conductuales en sistemas algorítmicos financieros es aún limitada, dado que se trata de un campo de investigación emergente, los trabajos de Mullainathan (2023), López de Prado (2018) y Obermeyer y Mullainathan (2019), permiten identificar un orden de prevalencia en la replicación de sesgos conductuales por parte de los sistemas algorítmicos de gestión de carteras. No todos los sesgos se transmiten con igual intensidad, aquellos que generan patrones estadísticamente más consistentes en los datos históricos son los que el algoritmo aprende con mayor facilidad y replica con mayor regularidad.

La sobreconfianza es el sesgo con mayor evidencia de replicación algorítmica. Dado que se manifiesta en una rotación excesiva de cartera, un patrón altamente regular y medible en los datos históricos, los algoritmos entrenados con datos de inversores sobreconfiados tienden a generar señales de compra y venta con una frecuencia superior a la óptima. Odean (1999) demostró que esta sobreactividad deteriora el rendimiento ajustado al riesgo de manera consistente, y Mullainathan y Ludwig (2022) confirmaron que los modelos de machine learning aplicados a decisiones financieras replican este patrón cuando los datos de entrenamiento provienen de inversores con alta rotación de cartera.

El efecto disposición es el segundo sesgo con mayor evidencia de replicación. Shefrin y Statman (1985) documentaron que este sesgo genera un patrón asimétrico y altamente predecible en los datos históricos, los activos ganadores son vendidos sistemáticamente antes que los perdedores. Esta asimetría es fácilmente detectable por un algoritmo de machine learning supervisado, que la aprende como una regla estadísticamente válida y la replica en sus decisiones futuras. López de Prado (2018) advierte que este es uno de los sesgos más difíciles de detectar en un sistema algorítmico precisamente porque el patrón que lo genera tiene alta consistencia estadística y puede confundirse con una estrategia deliberada de gestión de riesgo.

El comportamiento de manada, presenta una dinámica de replicación diferente. A diferencia de la sobreconfianza y el efecto disposición, que se originan en decisiones individuales, el comportamiento de manada, es un fenómeno colectivo que se manifiesta en correlaciones

elevadas entre las decisiones de distintos inversores durante períodos específicos. Daniel, Hirshleifer y Teoh (2002) señalan que los algoritmos entrenados con datos que incluyen episodios de comportamiento de manada aprenden esas correlaciones como señales informativas válidas, son alertas o recomendaciones que indican oportunidades de compra o venta lo que los lleva a replicar movimientos en condiciones de mercado similares a las que generaron el patrón original.

La aversión a la pérdida, en cambio, es el sesgo más difícil de replicar algorítmicamente en su forma pura, dado que su manifestación en los datos históricos es menos regular y más dependiente del contexto emocional específico de cada decisión. Sin embargo, Mullainathan (2023) señala que sus efectos sobre el comportamiento del inversor, posiciones excesivamente conservadoras en momentos de incertidumbre, rechazo de oportunidades con valor esperado positivo, sí quedan registrados como patrones estadísticos en los datos históricos y pueden ser aprendidos por el algoritmo como reglas implícitas de gestión del riesgo.

4.5.6 Evidencia comparativa de rendimiento entre gestión humana y algorítmica

La literatura financiera ha documentado de manera creciente las diferencias de rendimiento entre carteras gestionadas por humanos y carteras gestionadas por sistemas algorítmicos, aunque los resultados no son uniformes y dependen fuertemente del contexto de mercado, el horizonte temporal y el tipo de sesgo predominante en los datos de entrenamiento. A continuación se presenta una síntesis de los hallazgos más relevantes en este campo, que constituyen el antecedente empírico directo sobre el cual esta investigación propone avanzar.

Barber y Odean (2000) establecieron el antecedente empírico más citado en este campo al demostrar que los inversores individuales que operan con mayor frecuencia, (efecto sobreconfianza), obtienen rendimientos ajustados al riesgo significativamente inferiores a los de estrategias pasivas o sistemáticas. Este hallazgo sugiere que la eliminación del sesgo de sobreconfianza a través de la automatización debería mejorar el rendimiento, pero esta conclusión sólo es válida si el algoritmo no replica ese mismo sesgo a través de sus datos de entrenamiento.

López de Prado (2018) aporta evidencia desde la perspectiva de la gestión cuantitativa, señalando que los fondos algorítmicos sistemáticos han superado consistentemente a los fondos de gestión activa discrecional en términos de rendimiento ajustado al riesgo durante

períodos de mercado estable. Sin embargo, advierte que esta ventaja se revierte en períodos de cambio estructural de mercado, precisamente porque el algoritmo no puede adaptarse a condiciones que no estaban representadas en sus datos de entrenamiento, una limitación que en mercados de alta volatilidad como el argentino resulta especialmente relevante.

Brière, Calamai, Di Giansante, Huynh y Novelli (2023) aportaron evidencia más reciente al comparar el comportamiento de inversores particulares e institucionales en diferentes condiciones de mercado, encontrando que las diferencias de rendimiento entre gestión humana y algorítmica son más pronunciadas en períodos de alta volatilidad, donde los sesgos emocionales de los gestores humanos tienen mayor impacto sobre las decisiones y donde, simultáneamente, los algoritmos entrenados en condiciones de estabilidad exhiben sus mayores limitaciones adaptativas.

Este cuerpo de evidencia constituye el antecedente directo sobre el cual esta investigación propone avanzar, mientras la literatura existente compara rendimientos agregados sin aislar el canal conductual como variable explicativa, el presente trabajo busca identificar específicamente qué sesgos son responsables de las diferencias de rendimiento observadas y bajo qué condiciones de mercado esa relación se vuelve más pronunciada.

4.6. El mercado argentino como contexto de análisis

El análisis de la transmisión de sesgos conductuales hacia los sistemas algorítmicos de gestión de carteras adquiere una dimensión particular cuando se examina en el contexto del mercado de capitales argentino. Las características estructurales de este mercado, su alta volatilidad macroeconómica, su escasa profundidad, su inestabilidad cambiaria recurrente y su marco regulatorio en desarrollo, configuran un entorno donde los sesgos conductuales de los inversores operan con mayor intensidad que en mercados desarrollados, y donde su transmisión hacia los sistemas algorítmicos presenta particularidades que merecen un análisis específico.

4.6.1 Características estructurales del mercado de capitales argentino

El mercado de capitales argentino se encuentra regulado por la Ley N° 26.831 de Mercado de Capitales y su decreto reglamentario N° 1023/2013, que establece siete categorías de

agentes registrados ante la Comisión Nacional de Valores (CNV). Entre estas categorías se encuentran los Agentes de Administración de Carteras de Inversión (AACI), que constituyen el equivalente local de los Registered Investment Advisors (RIA) regulados por la SEC en los Estados Unidos conforme al Investment Advisers Act de 1940.

A diferencia de los mercados desarrollados, el mercado argentino presenta una profundidad limitada, con un número reducido de activos con liquidez suficiente para la gestión activa de carteras y una base de inversores institucionales relativamente pequeña en comparación con el tamaño de la economía. Esta escasa profundidad implica que los movimientos de un número reducido de actores institucionales tienen un impacto desproporcionado sobre los precios, lo que amplifica la propensión al comportamiento de manada documentada por Daniel, Hirshleifer y Teoh (2002) y refuerza los mecanismos de transmisión de sesgos conductuales entre inversores.

4.6.2 La volatilidad macroeconómica como amplificador de sesgos

La característica más distintiva del mercado argentino en el período 2015–2025 es su extrema volatilidad macroeconómica. Durante este período el mercado experimentó una secuencia de eventos de alta perturbación, la unificación cambiaria de 2015, la crisis de deuda y el salto devaluatorio de 2018, la reintroducción del control de cambios en 2019, el impacto de la pandemia de COVID-19 en 2020, la aceleración inflacionaria sostenida entre 2021 y 2023, y la implementación del programa de estabilización de 2024. Cada uno de estos eventos generó condiciones de estrés financiero extremo que, como señalan Kahneman y Tversky (1979), amplifican la influencia de los sesgos conductuales en la toma de decisiones de los inversores.

En este contexto, la aversión a la pérdida opera con especial intensidad, los inversores argentinos han desarrollado históricamente una fuerte preferencia por activos que preserven valor en términos reales, entre ellos los dólares, los activos dolarizados e inmuebles, como respuesta adaptativa a décadas de inestabilidad monetaria. Esta preferencia, aunque racional en términos individuales, introduce un sesgo sistemático en los datos históricos de decisiones de inversión que cualquier algoritmo entrenado con esos datos heredará inevitablemente.

Asimismo, el comportamiento de manada resulta especialmente pronunciado en el mercado argentino durante los episodios de crisis. La escasa profundidad del mercado y la alta sensibilidad de los precios a variables exógenas, decisiones de política cambiaria, anuncios

del Fondo Monetario Internacional, resultados electorales, generan episodios recurrentes de movimientos masivos y correlacionados entre los inversores institucionales, que quedan registrados en los datos históricos como patrones de comportamiento que los algoritmos aprenden y replican.

4.6.3 El contexto regulatorio y la ausencia de supervisión algorítmica

Como se señaló en el Capítulo 4, el marco regulatorio argentino no contempla aún disposiciones específicas sobre el uso de sistemas algorítmicos en la gestión de carteras de inversión. La Ley N° 26.831 y las normas de la CNV fueron diseñadas para supervisar la gestión humana discrecional y no incorporan mecanismos de auditoría del sesgo algorítmico ni requisitos de transparencia sobre los modelos utilizados por los AACI.

Esta ausencia regulatoria tiene una consecuencia directa sobre el fenómeno que esta investigación estudia, en el mercado argentino, la transmisión de sesgos conductuales hacia los sistemas algorítmicos opera sin ningún mecanismo institucional de detección o corrección. A diferencia de jurisdicciones como la Unión Europea, donde la regulación de inteligencia artificial está avanzando hacia requisitos de explicabilidad y auditoría de modelos algorítmicos, en Argentina los algoritmos de gestión de carteras pueden replicar sesgos históricos de manera sistemática sin que exista obligación de documentar, revelar ni corregir ese comportamiento.

4.6.4 Argentina como caso de estudio relevante

La combinación de alta volatilidad macroeconómica, escasa profundidad de mercado, fuerte presencia de sesgos conductuales amplificados por el contexto de crisis recurrente y ausencia de regulación algorítmica específica convierte al mercado argentino en un caso de estudio especialmente valioso para el análisis de la transmisión de sesgos hacia los sistemas algorítmicos.

En mercados desarrollados, la mayor profundidad del mercado, la diversidad de actores y la presencia de mecanismos regulatorios más avanzados pueden atenuar parcialmente los efectos de la transmisión de sesgos hacia los algoritmos. En el mercado argentino, en cambio, esos mecanismos de atenuación están ausentes o son débiles, lo que permite observar el fenómeno con mayor claridad y en condiciones más extremas. Como señalan Brière, Calamai, Di Giansante, Huynh y Novelli (2023), los mercados emergentes con alta

volatilidad estructural representan contextos privilegiados para el estudio de los sesgos conductuales precisamente porque en ellos las condiciones que amplifican estos sesgos se presentan con mayor frecuencia e intensidad que en los mercados desarrollados.

El período 2015–2025 seleccionado para esta investigación captura una secuencia completa de ciclos macroeconómicos argentinos que incluye episodios de estabilidad relativa, crisis agudas y procesos de estabilización, lo que permite analizar cómo varía la transmisión de sesgos hacia los sistemas algorítmicos en función de las condiciones de mercado, respondiendo directamente a la tercera pregunta de investigación planteada en este trabajo.

4.6.5 Episodios específicos del mercado argentino como observatorios del sesgo algorítmico

El período 2015–2025 del mercado argentino ofrece una secuencia de episodios macroeconómicos que permiten examinar en condiciones reales cómo varía la transmisión de sesgos conductuales hacia los sistemas algorítmicos según el contexto de mercado.

Crisis cambiaria de 2018. La devaluación abrupta del peso argentino durante el segundo semestre de 2018, que llevó al tipo de cambio de 20 a 40 pesos por dólar en pocas semanas, generó un episodio de comportamiento de manada de alta intensidad entre los inversores institucionales locales. La salida masiva y correlacionada de activos en pesos hacia activos dolarizados quedó registrada en los datos históricos como un patrón de alta consistencia estadística. Un algoritmo entrenado con datos que incluyan este episodio aprenderá esa correlación como una señal válida de gestión del riesgo cambiario, replicando el comportamiento de manada en situaciones de estrés cambiario futuro sin distinguir entre una crisis sistémica y una corrección moderada (Frenkel y Rapetti, 2019; Brière et al., 2023)

Pandemia de COVID-19 en 2020. El impacto de la pandemia sobre el mercado argentino se superpuso con una crisis de deuda soberana y una renegociación con acreedores externos, generando condiciones de incertidumbre extrema que amplificaron todos los sesgos conductuales documentados en la literatura. La aversión a la pérdida se manifestó en una dolarización masiva de carteras, el efecto disposición en la retención prolongada de activos locales depreciados, y la sobreconfianza en decisiones de rebalanceo frecuente motivadas por lecturas de corto plazo del contexto político. Los datos generados durante este período concentran una densidad inusualmente alta de decisiones sesgadas que cualquier algoritmo

entrenado con ellos incorporará como patrones regulares de comportamiento. (Ministerio de Economía de Argentina, 2020; Kahneman y Tversky, 1979)

Aceleración inflacionaria 2022–2023. El período de aceleración inflacionaria que llevó a Argentina a superar el 200% de inflación anual en 2023 (INDEC, 2023), generó condiciones donde la aversión a la pérdida en términos reales dominó las decisiones de todos los tipos de inversores. La preferencia sistemática por activos que preserven valor real, acciones de empresas exportadoras, activos dolarizados, instrumentos indexados, quedó registrada como un patrón altamente consistente en los datos históricos. Un algoritmo entrenado con estos datos aprenderá esa preferencia como una regla general de asignación de activos, lo que podría generar decisiones subóptimas en contextos de menor presión inflacionaria donde esa preferencia ya no está justificada por sus principales fundamentos. (Mullainathan, 2023)

Estos tres episodios ilustran de manera concreta cómo las condiciones específicas del mercado argentino generan datos históricos cargados de sesgos conductuales amplificadas, que los sistemas algorítmicos de gestión de carteras incorporan inevitablemente como parte de su aprendizaje. La identificación de estos episodios y su impacto sobre el perfil de sesgo de los algoritmos constituye uno de los aportes originales que esta investigación propone realizar al análisis de la gestión algorítmica de carteras en mercados emergentes.

4.7. Síntesis del marco teórico: convergencia de las dimensiones de análisis

Los seis capítulos anteriores desarrollaron de manera progresiva los elementos conceptuales que estructuran esta investigación. El capítulo 1 establece qué se entiende por sesgo en finanzas y por qué su carácter sistemático lo distingue del error aleatorio. El capítulo 2 identificó los cuatro sesgos con mayor evidencia empírica en la gestión de carteras. El capítulo 3 introdujo la distinción entre inversores particulares e institucionales como variable explicativa del perfil de sesgo que un algoritmo hereda. El capítulo 4 mostró que la arquitectura del sistema algorítmico determina qué tipo de sesgo replica con mayor intensidad. El capítulo 5 describió el mecanismo de transmisión y las condiciones que lo amplifican. El capítulo 6 situó ese mecanismo en el contexto específico del mercado argentino durante el período 2015–2025.

Articulados en conjunto, estos seis capítulos convergen en una proposición central: el rendimiento ajustado por riesgo de un sistema algorítmico de gestión de carteras no depende exclusivamente de la calidad técnica del modelo, sino de la interacción entre tres

dimensiones que este marco teórico ha desarrollado de manera sistemática. La primera es el tipo de sesgo predominante en los datos de entrenamiento, que determina en qué dirección se desviarán las decisiones del algoritmo respecto a la racionalidad. La segunda es el perfil del inversor que generó esos datos, que determina la intensidad y consistencia estadística con que ese sesgo quedó registrado. La tercera son las condiciones de mercado bajo las cuales opera el algoritmo, que determinan si el sesgo heredado se amplifica, se atenúa o se vuelve indetectable en los resultados de rendimiento.

5. Metodología

5.1 Tipo y alcance de la investigación

La presente investigación adopta un enfoque cuantitativo, dado que su objetivo central es medir y comparar variables observables —la presencia de sesgos conductuales en distintos perfiles de inversores y el rendimiento ajustado por riesgo del mercado argentino— a través de instrumentos estandarizados y técnicas de análisis estadístico. Este enfoque permite someter a prueba la hipótesis de trabajo con evidencia empírica sistemática, en lugar de basarse exclusivamente en argumentación teórica.

El alcance de la investigación es descriptivo-explicativo. Es descriptivo en tanto caracteriza la presencia y distribución de sesgos conductuales según el nivel de conocimiento financiero del inversor, y caracteriza también el comportamiento histórico del rendimiento ajustado por riesgo del mercado argentino en el período 2015–2025, medido a través del Sharpe Ratio del índice S&P Merval. Es explicativo en tanto propone identificar la relación entre la presencia de esos sesgos conductuales y el deterioro de ese Sharpe Ratio —es decir, una caída en el rendimiento obtenido por cada unidad de riesgo asumida—, así como las condiciones de mercado bajo las cuales ese deterioro se vuelve más pronunciado. Este razonamiento responde directamente a la hipótesis de trabajo, que vincula la presencia de sesgos conductuales con un menor rendimiento ajustado por riesgo, y a la tercera pregunta de investigación, que indaga bajo qué condiciones de mercado esa relación se intensifica.

Para responder de manera integrada a la hipótesis y a las tres preguntas de investigación, esta investigación combina dos instrumentos complementarios: una encuesta propia sobre sesgos conductuales en inversores, y una serie propia de rendimiento ajustado por riesgo del mercado argentino, construida a partir de datos de mercado obtenidos de la plataforma Bloomberg.

5.2 Instrumento 1 — Encuesta de sesgos conductuales

Diseño y aplicación. Se diseñó un cuestionario estructurado en escenarios de decisión financiera cotidiana, siguiendo la metodología de obtención de preferencias bajo incertidumbre desarrollada por Kahneman y Tversky (1979) en la Teoría de la Perspectiva. Cada escenario presenta opciones de respuesta codificadas previamente como sesgada, racional o neutral, sin que el respondente conozca qué sesgo conductual está siendo medido en cada caso. Este diseño busca reducir el sesgo de deseabilidad social, dado que una pregunta directa del tipo "¿actuás de manera sesgada?" sería respondida casi universalmente de forma negativa, independientemente del comportamiento real del respondente.

Muestra. Se obtuvieron 46 respuestas válidas a través de un formulario autoadministrado. Los respondentes fueron clasificados según el nivel de conocimiento sobre inversiones que declararon al inicio del cuestionario, en dos grupos: nivel básico, compuesto por personas con poco conocimiento previo y poca experiencia en inversiones ($n=32$; 69,6% de la muestra), y nivel avanzado, compuesto por personas con formación académica o experiencia laboral relacionada a las finanzas ($n=14$; 30,4% de la muestra). Esta segmentación por nivel de conocimiento se utiliza como variable proxy para aproximar, dentro de las limitaciones de un instrumento de encuesta autoadministrado, la distinción entre un perfil de inversor más cercano al particular no profesionalizado y un perfil más cercano al de un gestor o analista profesional. Esta encuesta fue elegida para demostrar el nivel de sesgo de las personas tanto con como sin conocimiento sobre el tema. La encuesta fue administrada durante el mes de mayo del 2026, a través de un formulario digital autoadministrado distribuido por medios digitales.

les. **Sesgos medidos.** El instrumento relevó ocho sesgos conductuales, seleccionados por su relevancia en la literatura de finanzas conductuales y su conexión directa con los objetivos de esta investigación: efecto disposición, comportamiento de manada, aversión a la pérdida, sobreconfianza, sesgo de recencia, contabilidad mental, sesgo de status quo y sesgo de confirmación. Los primeros cuatro corresponden a los sesgos centrales identificados en el planteamiento del problema y desarrollados en profundidad en el Capítulo 2 del marco teórico; los restantes cuatro se incorporaron como sesgos complementarios para enriquecer el análisis exploratorio.

Técnica de análisis. Para cada uno de los ocho sesgos se calculó la proporción de respuestas codificadas como sesgadas dentro de cada grupo de conocimiento financiero, y se aplicó el test exacto de Fisher para evaluar si la diferencia de proporciones entre el grupo básico y el grupo avanzado es estadísticamente significativa. Se utilizó este test, en lugar del test de chi-cuadrado convencional, dado que este último pierde precisión en tablas de contingencia con frecuencias esperadas bajas en alguna de sus celdas, condición presente en este análisis dado el tamaño acotado de la submuestra del grupo avanzado (n=14). El test exacto de Fisher calcula la probabilidad exacta de observar una distribución igual o más extrema que la obtenida, bajo la hipótesis nula de que no existe asociación entre el nivel de conocimiento financiero y la presencia de sesgo conductual. Un p-valor inferior a 0,05 indica que la diferencia de proporciones entre ambos grupos es estadísticamente significativa, es decir, que es improbable que esa diferencia sea producto del azar. El cálculo del test exacto de Fisher para cada uno de los ocho sesgos fue realizado mediante el lenguaje de programación Python, utilizando la función `fisher_exact` de la biblioteca `scipy.stats*`, que implementa el test de manera exacta sobre tablas de contingencia de 2x2. Para cada sesgo se construyó una tabla de contingencia cruzando el nivel de conocimiento financiero (básico / avanzado) con la presencia o ausencia de respuesta sesgada, y se reportó el p-valor asociado a la hipótesis alternativa bilateral.

Resultados.

Sesgo	Grupo básico (n=32)	Grupo avanzado (n=14)	p-valor (Fisher)
Aversión a la pérdida	65,6%	0,0%	0,0000*
Efecto disposición	25,0%	0,0%	0,0845
Contabilidad mental	25,0%	0,0%	0,0845
Sesgo de recencia	15,6%	0,0%	0,3034
Sesgo de confirmación	15,6%	0,0%	0,3034

Sesgo de status quo	12,5%	0,0%	0,2979
Sobreconfianza	6,2%	0,0%	1,0000
Comportamiento de manada	3,1%	0,0%	1,0000

p<0,05. Elaboración propia en base a los resultados de la encuesta administrada para esta investigación.

En los ocho sesgos relevados, el grupo de conocimiento avanzado no seleccionó la opción codificada como sesgada en ninguno de los escenarios planteados, mientras que el grupo de conocimiento básico mostró presencia de sesgo en proporciones variables, con la aversión a la pérdida como el más extendido (65,6% de los respondientes de ese grupo).

Este resultado requiere una interpretación cuidadosa. La literatura conductual —desde Kahneman y Tversky (1979) hasta Barber y Odean (2000)— sostiene que los sesgos cognitivos son inherentes al procesamiento humano de la información y afectan en algún grado a la generalidad de los individuos, incluyendo a los profesionales financieros; lo que la evidencia empírica muestra que varía no es la existencia del sesgo sino su intensidad, su frecuencia de activación ante distintos estímulos, y la capacidad del individuo para reconocerlo y corregirlo en el momento de la decisión final. Por lo tanto, el hallazgo de 0% de respuestas sesgadas en el grupo avanzado no debe interpretarse como una ausencia real y absoluta de sesgo conductual en esa población, sino como evidencia de que, ante los escenarios específicos planteados en este instrumento, los respondientes con mayor formación financiera lograron identificar y evitar la opción conductualmente sesgada con mayor frecuencia que el grupo de menor formación. Esta lectura es consistente con los hallazgos de Barber y Odean (2000), quienes no reportan ausencia de sesgo en inversores profesionales, sino una menor magnitud del efecto de esos sesgos sobre las decisiones efectivamente tomadas, en comparación con inversores particulares.

Es necesario señalar, además, que un resultado de 0% sobre una submuestra de 14 personas, replicado de manera uniforme en los ocho sesgos relevados, puede reflejar en parte una limitación de potencia estadística asociada al tamaño reducido de esa submuestra, además de un efecto genuino de la formación financiera sobre la toma de decisiones. La diferencia entre grupos alcanza significancia estadística únicamente en el

caso de la aversión a la pérdida ($p < 0,001$); en los restantes siete sesgos, si bien la dirección del resultado es consistente con la hipótesis de trabajo —menor presencia de sesgo observable a mayor conocimiento financiero— las diferencias no alcanzan significancia estadística con el tamaño de muestra disponible en esta investigación. Una ampliación futura de este instrumento, con una submuestra de mayor tamaño en el segmento de conocimiento avanzado, permitiría confirmar con mayor robustez estos hallazgos preliminares.

5.3 Instrumento 2 — Rendimiento ajustado por riesgo del mercado argentino, 2015–2025

Fuente y construcción de los datos. Esta investigación construye una serie propia de rendimiento ajustado por riesgo para el período completo 2015–2025, a partir de datos de mercado obtenidos de la plataforma Bloomberg. Se utilizó como representativo del mercado de capitales argentino al índice S&P Merval, medido en dólares estadounidenses con periodicidad mensual, y como tasa libre de riesgo el rendimiento de las Letras del Tesoro de Estados Unidos a 3 meses (Treasury Bill, ticker GB03 Govt), también con periodicidad mensual, para el mismo período.

La elección de medir el Merval en dólares y no en pesos argentinos responde a una necesidad metodológica concreta: calcular el rendimiento en moneda local introduciría una distorsión significativa producto de la inflación y la devaluación recurrente del peso durante el período de análisis, lo que dificultaría aislar el rendimiento real del activo del efecto puramente nominal de la pérdida de valor de la moneda. Al medir en dólares y comparar contra una tasa libre de riesgo también denominada en dólares, se obtiene una métrica de rendimiento ajustado por riesgo homogénea y comparable a lo largo de todo el período, incluso en los tramos de mayor inestabilidad cambiaria.

Fórmula aplicada. Para cada mes del período se calculó el retorno mensual del Merval y el exceso de ese retorno sobre la tasa libre de riesgo mensualizada. A partir de esos datos se calculó el Sharpe Ratio anualizado para cada año completo y para los sub-períodos de interés, según la siguiente fórmula:

$$\text{Sharpe Ratio anualizado} = (\mu(R_p - R_f) / \sigma(R_p - R_f)) \times \sqrt{12}$$

Donde μ es la media del exceso de retorno mensual en el período considerado, σ es su desviación estándar, y el factor $\sqrt{12}$ anualiza la métrica a partir de datos de frecuencia mensual, siguiendo la convención estándar para la anualización de ratios de rendimiento ajustado por riesgo. Los cálculos fueron realizados mediante el lenguaje de programación Python, utilizando las bibliotecas pandas para el procesamiento de las series temporales y numpy para el cálculo de medias, desviaciones estándar y la anualización del ratio.

Resultados — Sharpe Ratio anualizado por año (2015–2025).

Año	Sharpe Ratio anualizado	Contexto macroeconómico
2015	0,05	Unificación cambiaria, fin del cepo
2016	0,85	Estabilización inicial
2017	2,01	Fuerte optimismo de mercado
2018	-1,25	Crisis cambiaria y de deuda soberana
2019	0,29	Recuperación parcial, alta volatilidad electoral
2020	0,08	Pandemia de COVID-19, alta dispersión intra-anual
2021	1,15	Recuperación post-pandemia

2022	1,00	Aceleración inflacionaria, sector energético favorable
2023	0,35	Año electoral, alta incertidumbre cambiaria
2024	1,65	Programa de estabilización macroeconómica
2025	0,00	Mercado lateral

Elaboración propia en base a datos mensuales del S&P Merval (MERVAL:IND) en USD y de las Letras del Tesoro de EE.UU. a 3 meses, extraídos de Bloomberg.

El año 2018 es el único de toda la serie 2015–2025 con un Sharpe Ratio anual negativo (–1,25), coincidiendo exactamente con el episodio de crisis cambiaria y de deuda descrito en el Capítulo 6 de esta investigación. Este resultado constituye evidencia empírica directa, construida con datos propios, de que las condiciones de estrés macroeconómico identificadas teóricamente en el marco teórico se traducen efectivamente en un deterioro medible del rendimiento ajustado por riesgo del mercado argentino en su conjunto.

Resultados — Sharpe Ratio anualizado en episodios específicos de volatilidad. Para profundizar el análisis y conectar de manera más precisa con los episodios desarrollados en el Capítulo 6, se calculó también el Sharpe Ratio anualizado dentro de ventanas temporales más acotadas, correspondientes a los momentos de mayor estrés macroeconómico identificados en el marco teórico.

Episodio	Sharpe Ratio anualizado	Duración
Crisis cambiaria 2018 (abril–diciembre)	–1,41	9 meses
Crisis post-PASO 2019 (agosto–septiembre)	–1,14	2 meses

Inicio de pandemia COVID-19 (febrero–abril 2020)	–0,67	3 meses
Rebote post-pandemia (mayo–agosto 2020)	+1,79	4 meses
Aceleración inflacionaria (2022–2023)	+0,56	24 meses
Período de estabilización (diciembre 2023–2025)	+0,24	25 meses

Elaboración propia en base a datos mensuales del S&P Merval en USD y de las Letras del Tesoro de EE.UU. a 3 meses, extraídos de Bloomberg.

Los tres episodios identificados en el Capítulo 6 como momentos de mayor estrés macroeconómico —la crisis cambiaria de 2018, la crisis post-PASO de 2019 y el inicio de la pandemia en 2020— son precisamente los tres únicos sub-períodos de toda la serie con Sharpe Ratio anualizado negativo. En los tres casos, además, el deterioro fue seguido por una recuperación marcada en el período inmediatamente posterior, particularmente visible en el rebote post-pandemia (+1,79 entre mayo y agosto de 2020), lo que sugiere un patrón de reversión relativamente rápido del mercado en su conjunto una vez superado el shock inicial.

Limitación metodológica. Esta serie mide el rendimiento ajustado por riesgo del mercado argentino en su conjunto, representado por el índice S&P Merval, y no el rendimiento específico y diferenciado de carteras de gestión particular frente a carteras de gestión institucional o algorítmica. Por lo tanto, constituye una medida del contexto de mercado dentro del cual operan todos los tipos de gestión, y no una comparación directa entre ellos. La comparación específica con un segmento de gestión institucional se aborda de manera complementaria en la sección siguiente.

5.4 Evidencia complementaria — Sharpe Ratio de Fondos Comunes de Inversión institucionales en momentos de volatilidad

Para contrastar el comportamiento del mercado en su conjunto con el de carteras de gestión institucional específicas, se incorpora como evidencia complementaria el trabajo de

Mastrangelo y Salvatierra (2022), quienes calcularon el Sharpe Ratio trimestral de seis Fondos Comunes de Inversión (FCI) de renta variable argentinos —con benchmark en el índice ROFEX 20— durante los años 2019 y 2020, utilizando la tasa BADLAR privada en pesos publicada por el Banco Central de la República Argentina como tasa libre de riesgo, y datos primarios de la Cámara Argentina de Fondos Comunes de Inversión (CAFCI) y de la Comisión Nacional de Valores (CNV). Los fondos son identificados en el trabajo original con numeración propia por razones de confidencialidad, sin que se revelen los nombres comerciales de cada fondo. Esto permite contrastar el comportamiento del mercado argentino en su conjunto (medido a través del Merval en dólares, como hace este trabajo) con el de una muestra concreta de fondos de gestión institucional, en los mismos períodos de estrés macroeconómico identificados en el Capítulo 6 del marco teórico: la crisis post-PASO de 2019 y el inicio de la pandemia de COVID-19 en 2020.

Tabla 4. Comparación del Sharpe Ratio entre el mercado argentino y los FCI institucionales en episodios de volatilidad seleccionados

Período	Sharpe promedio de los 6 FCI (Mastrangelo y Salvatierra, 2022)	Sharpe del mercado en el mismo período (cálculo propio, Merval USD)
Crisis post-PASO (III-2019)	-0,83	-1,14
Inicio de pandemia (I-2020)	-1,54	-0,67
Rebote post-pandemia (II-2020)	+1,69	+1,79

Fuente: Mastrangelo y Salvatierra (2022) para los FCI; elaboración propia en base a datos de Bloomberg para el Merval USD.

Es importante señalar que el promedio de los seis FCI utilizado en la comparación anterior encubre una dispersión considerable entre fondos, que los propios Mastrangelo y Salvatierra (2022) documentan en detalle. En el análisis de correlación con el índice ROFEX 20, cinco de los seis fondos exhiben una correlación promedio superior a 0,97, mientras que uno de ellos, identificado por los autores como Fondo 2, presenta una correlación promedio de 0,847, con caídas puntuales a 0,599 y 0,728 en determinados trimestres, lo que indica un apartamiento más marcado de la estrategia pasiva de réplica del benchmark que caracteriza a los demás fondos de la muestra. De manera similar, el Alpha promedio trimestral de los fondos individuales varía entre $-0,7\%$ (el mejor desempeño relativo) y $-4,3\%$ (el peor), una diferencia de casi cuatro puntos porcentuales que el promedio agregado no refleja. En la misma línea, los autores señalan explícitamente que, en términos de Sharpe Ratio, los Fondos 3, 4 y 5 obtienen un rendimiento por unidad de riesgo sistemáticamente superior a los Fondos 1, 2 y 6.

Esta heterogeneidad entre fondos no debilita, sin embargo, el argumento desarrollado en esta sección, dado que el foco de esta investigación no es comparar el desempeño relativo entre fondos individuales sino identificar si la gestión institucional en su conjunto exhibe o no los patrones conductuales —en particular el efecto disposición— que la literatura asocia a la gestión particular no profesionalizada. Para ese propósito, el hallazgo más relevante de Mastrangelo y Salvatierra (2022) no es el ranking de rendimiento entre fondos sino el análisis de persistencia trimestral: al evaluar para cada uno de los seis fondos individuales si los resultados relativamente mejores se sostienen de un trimestre a otro mediante una matriz de doble entrada ganador-perdedor, los autores concluyen que las performances de los seis FCI analizados deben calificarse como no persistentes. Es decir, ningún fondo institucional de la muestra exhibe un patrón sostenido de buen o mal desempeño relativo a lo largo de los ocho trimestres analizados. Este resultado es directamente relevante para la pregunta sobre el efecto disposición planteada en esta investigación, dado que dicho sesgo, tal como lo definieron Shefrin y Statman (1985), predice precisamente un patrón de retención prolongada y sostenida de posiciones perdedoras. La ausencia de persistencia documentada por Mastrangelo y Salvatierra (2022) constituye, por tanto, evidencia adicional —más allá de la sola coincidencia direccional de los episodios de crisis ya señalada— de que la gestión institucional analizada no exhibe el patrón de anclaje a pérdidas característico de ese sesgo conductual.

Tabla 5. Síntesis de indicadores de desempeño relativo por fondo institucional

Indicador	Mejor desempeño	Peor desempeño / outlier	Lectura
Correlación con el índice (Pearson, promedio)	5 de 6 fondos > 0,97	Fondo 2: 0,847 (cae a 0,599 en IV-19)	Un fondo se apartó del benchmark en trimestres puntuales
Alpha promedio trimestral (vs. ROFEX 20)	Fondo 3: -0,7 %	Fondo 1: -4,3 %	Rango de casi 4 p.p. entre el mejor y el peor fondo
Sharpe Ratio (ranking relativo)	Fondos 3, 4 y 5	Fondos 1, 2 y 6	Ranking estable entre fondos, no un comportamiento uniforme
Persistencia trimestral por fondo (matriz G/P)	—	Ningún fondo individual	Los 6 FCI se califican como “no persistentes” en el período

Fuente de los datos de la tabla: Mastrangelo, M. E., y Salvatierra, J. M. (2022). Análisis de rendimientos ajustados por riesgo de fondos de inversión de renta variable en Argentina. Escritos Contables y de Administración, 13(2), 75–103.

Esta comparación, si bien limitada por la diferencia de moneda y de tasa de referencia entre ambas series —la de Mastrangelo y Salvatierra está calculada en pesos con tasa BADLAR, mientras que la serie propia de esta investigación está calculada en dólares con tasa de Letras del Tesoro de EE.UU.— muestra una dirección consistente: tanto el mercado en su conjunto como una muestra específica de fondos institucionales experimentaron su peor desempeño ajustado por riesgo durante los mismos episodios de estrés macroeconómico, y ambos se recuperaron con fuerza en el trimestre inmediatamente posterior. Esta coincidencia direccional, aunque no estrictamente comparable en magnitud por la diferencia metodológica señalada, sustenta la idea de que la gestión institucional, si bien no es inmune al deterioro de rendimiento durante la crisis, no exhibe en esta evidencia un patrón de retención prolongada de posiciones perdedoras —el efecto disposición documentado por Shefrin y Statman (1985)— sino una recuperación relativamente rápida una vez superado el shock inicial.

5.5 Integración de la evidencia y respuesta a la hipótesis y a las preguntas de investigación

La hipótesis de esta investigación sostiene que los sesgos conductuales identificados en los inversores —en particular la aversión a la pérdida y el efecto disposición— se asocian con un menor rendimiento ajustado por riesgo de las carteras en el mercado argentino, siendo

esta asociación menos pronunciada en la gestión institucional, dado que los Fondos Comunes de Inversión y los AACI operan bajo marcos normativos de la Comisión Nacional de Valores que imponen mecanismos formales de control de riesgo, ausentes en la gestión de carteras particulares.

La evidencia construida en esta investigación sustenta esta hipótesis desde tres ángulos complementarios. En primer lugar, el Instrumento 1 confirma que la aversión a la pérdida está presente de manera significativamente más intensa en inversores de menor formación financiera que en inversores de mayor formación (65,6% frente a 0%, $p < 0,001$), lo que da sustento a la primera parte de la hipótesis. En segundo lugar, la serie propia de Sharpe Ratio del mercado argentino 2015–2025 confirma empíricamente, con datos primarios obtenidos de Bloomberg, que los episodios de mayor estrés macroeconómico identificados teóricamente en el Capítulo 6 del marco teórico coinciden exactamente con los únicos períodos de rendimiento ajustado por riesgo negativo de toda la serie, lo que respalda directamente la tercera pregunta de investigación sobre las condiciones de mercado que amplifican el sesgo.

En tercer lugar, la evidencia complementaria de Mastrangelo y Salvatierra (2022) —publicada en la revista académica con referato Escritos Contables y de Administración, y desarrollada específicamente sobre Fondos Comunes de Inversión de renta variable argentinos— muestra que, si bien la gestión institucional también se deteriora durante esos episodios, lo hace con un patrón de recuperación rápida que no replica el comportamiento de retención prolongada de pérdidas característico de la gestión particular sesgada.

En términos simples, la idea es la siguiente: la tabla comparativa muestra que tanto el mercado (Merval en USD) como los seis FCI institucionales tuvieron Sharpe Ratio negativo durante la crisis post-PASO de 2019 y durante el inicio de la pandemia en 2020, y que ambos volvieron a tener Sharpe Ratio positivo en el trimestre siguiente, el del rebote post-pandemia (Sharpe del mercado: +1,79; Sharpe promedio de los FCI: +1,69). Es decir, el deterioro de rendimiento es real en ambos casos, pero no se prolonga: una vez que el shock macroeconómico pasa, tanto el índice como los fondos institucionales recuperan rendimiento positivo casi de inmediato.

Esa recuperación rápida es justamente lo que permite descartar, en esta evidencia puntual, que los FCI institucionales estén incurriendo en efecto disposición. El efecto disposición, tal como lo definieron Shefrin y Statman (1985), no es simplemente “perder dinero en una crisis”; es un patrón conductual específico que consiste en vender demasiado rápido los activos ganadores y, sobre todo, mantener demasiado tiempo los activos perdedores,

porque el inversor se resiste psicológicamente a reconocer la pérdida. Si los FCI institucionales estuvieran sesgados de esa manera, se esperaría ver un Sharpe Ratio que permanece negativo o deprimido durante varios trimestres después de la crisis, porque los gestores seguirían sosteniendo posiciones perdedoras en lugar de reasignar la cartera. Lo que la tabla muestra, en cambio, es exactamente lo opuesto: una reversión rápida y de magnitud similar a la del mercado en su conjunto.

Por eso esta evidencia “no replica el comportamiento de retención prolongada de posiciones perdedoras”: no es que los FCI institucionales no hayan sufrido pérdidas durante la crisis —las sufrieron, igual que el mercado—, sino que la velocidad con la que esas pérdidas se revierten es la señal que permite distinguir un deterioro coyuntural y generalizado de mercado de un sesgo conductual específico como el efecto disposición.

Es importante notar que esta lectura tiene una limitación metodológica explícita: las dos series no son estrictamente comparables en magnitud, porque están calculadas en monedas y tasas libres de riesgo distintas (la de Mastrangelo y Salvatierra en pesos con tasa BADLAR; la propia de esta investigación en dólares con tasa de Letras del Tesoro de EE. UU.). Por eso el argumento se apoya en la coincidencia direccional de ambas series —ambas caen en los mismos trimestres y ambas se recuperan en el mismo trimestre posterior— y no en una comparación exacta de magnitudes.

Respecto a las preguntas de investigación, esta integración de evidencia permite responder de manera empírica a la Pregunta 1 —identificando la aversión a la pérdida como el sesgo más robustamente presente en la población de inversores relevada— y a la Pregunta 3 —identificando los episodios de crisis cambiaria y pandemia como las condiciones de mercado bajo las cuales el rendimiento ajustado por riesgo se deteriora de manera más pronunciada—. La Pregunta 2, referida específicamente a la variación de sesgos según el perfil de inversor particular o institucional que entrenó el sistema algorítmico, se aborda principalmente a través de la evidencia documental desarrollada en el Capítulo 3 del marco teórico y de la comparación complementaria entre el Sharpe Ratio del mercado y el de los FCI institucionales presentada en esta metodología, dado que el instrumento de encuesta diseñado para esta investigación no incluyó una muestra específica de gestores institucionales en ejercicio.

Esta combinación de evidencia propia y documental no permite afirmar de manera concluyente y aislada el canal estrictamente conductual de la diferencia de rendimiento entre gestión particular e institucional, pero sí constituye una base empírica sólida y convergente que sustenta la dirección general de la hipótesis planteada, dejando

explícitamente identificadas las líneas de profundización —acceso a series primarias homogéneas de mayor extensión y a datos de composición de cartera institucional— para una eventual ampliación de esta investigación.

Anexos

Tabla 1. Muestra del formulario

Sesgo	Grupo básico (n=32)	Grupo avanzado (n=14)	p-valor (Fisher)
Aversión a la pérdida	65,6%	0,0%	0,0000*
Efecto disposición	25,0%	0,0%	0,0845
Contabilidad mental	25,0%	0,0%	0,0845
Sesgo de recencia	15,6%	0,0%	0,3034
Sesgo de confirmación	15,6%	0,0%	0,3034
Sesgo de status quo	12,5%	0,0%	0,2979
Sobreconfianza	6,2%	0,0%	1,0000
Comportamiento de manada	3,1%	0,0%	1,0000

Tabla 2. Ratio de Sharpe anualizado y Contexto Macroeconómico

Año	Sharpe Ratio anualizado	Contexto macroeconómico
------------	------------------------------------	--------------------------------

2015	0,05	Unificación cambiaria, fin del cepo
2016	0,85	Estabilización inicial
2017	2,01	Fuerte optimismo de mercado
2018	-1,25	Crisis cambiaria y de deuda soberana
2019	0,29	Recuperación parcial, alta volatilidad electoral
2020	0,08	Pandemia de COVID-19, alta dispersión intra-anual
2021	1,15	Recuperación post-pandemia
2022	1,00	Aceleración inflacionaria, sector energético favorable
2023	0,35	Año electoral, alta incertidumbre cambiaria
2024	1,65	Programa de estabilización macroeconómica
2025	0,00	Mercado lateral

Tabla 3. Ratio de Sharpe anualizado en episodios específicos de volatilidad

Episodio

**Sharpe Ratio
anualizado**

Duración

Crisis cambiaria 2018 (abril–diciembre)	–1,41	9 meses
Crisis post-PASO 2019 (agosto–septiembre)	–1,14	2 meses
Inicio de pandemia COVID-19 (febrero–abril 2020)	–0,67	3 meses
Rebote post-pandemia (mayo–agosto 2020)	+1,79	4 meses
Aceleración inflacionaria (2022–2023)	+0,56	24 meses
Período de estabilización (diciembre 2023–2025)	+0,24	25 meses

Tabla 4. Comparación del Sharpe Ratio entre el mercado argentino y los FCI institucionales en episodios de volatilidad seleccionados

Período	Sharpe promedio de los 6 FCI (Mastrangelo y Salvatierra, 2022)	Sharpe del mercado en el mismo período (cálculo propio, Merval USD)
Crisis post-PASO (III-2019)	–0,83	–1,14
Inicio de pandemia (I-2020)	–1,54	–0,67
Rebote post-pandemia (II-2020)	+1,69	+1,79

Tabla 5. Síntesis de indicadores de desempeño relativo por fondo institucional

Indicador	Mejor desempeño	Peor desempeño / outlier	Lectura
Correlación con el índice (Pearson, promedio)	5 de 6 fondos > 0,97	Fondo 2: 0,847 (cae a 0,599 en IV-19)	Un fondo se apartó del benchmark en trimestres puntuales
Alpha promedio trimestral (vs. ROFEX 20)	Fondo 3: -0,7 %	Fondo 1: -4,3 %	Rango de casi 4 p.p. entre el mejor y el peor fondo
Sharpe Ratio (ranking relativo)	Fondos 3, 4 y 5	Fondos 1, 2 y 6	Ranking estable entre fondos, no un comportamiento uniforme
Persistencia trimestral por fondo (matriz G/P)	—	Ningún fondo individual	Los 6 FCI se califican como “no persistentes” en el período

Tablas de contingencia 2×2 y test exacto de Fisher

Para cada uno de los ocho sesgos conductuales relevados en la encuesta, se construyó una tabla de contingencia 2×2 cruzando el nivel de conocimiento financiero (básico / avanzado) con la presencia o ausencia de respuesta codificada como sesgada. El test exacto de Fisher bilateral fue calculado mediante la función `fisher_exact` de la biblioteca `scipy.stats` (Python). Un p-valor inferior a 0,05 indica que la diferencia de proporciones entre grupos es estadísticamente significativa.

Nota sobre los Odds Ratio: dado que el grupo avanzado presentó 0 respuestas sesgadas en la totalidad de los sesgos relevados, los Odds Ratio resultan no definidos (∞) en todos los casos. Esto refleja la ausencia absoluta de respuestas sesgadas en ese grupo ante los escenarios planteados, no una limitación del test.

1 Aversión a la pérdida

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	21	11	32
Conocimiento avanzado (n=14)	0	14	14
Total	21	25	46

Proporción sesgada — Básico: 65,6% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,0000 → $p < 0,001$ — estadísticamente significativo (*)**

2 Efecto disposición

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	8	24	32

Grupo	Sesgado	No sesgado	Total
Conocimiento avanzado (n=14)	0	14	14
Total	8	38	46

Proporción sesgada — Básico: 25,0% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,0845 $\rightarrow$ p = 0,0845 — no significativo al 5%

3 Contabilidad mental

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	8	24	32
Conocimiento avanzado (n=14)	0	14	14
Total	8	38	46

Proporción sesgada — Básico: 25,0% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,0845 $\rightarrow$ p = 0,0845 — no significativo al 5%

4 Sesgo de recencia

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	5	27	32
Conocimiento avanzado (n=14)	0	14	14
Total	5	41	46

Proporción sesgada — Básico: 15,6% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,3034 $\rightarrow$ p = 0,3034 — no significativo al 5%

5 Sesgo de confirmación

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	5	27	32
Conocimiento avanzado (n=14)	0	14	14
Total	5	41	46

Proporción sesgada — Básico: 15,6% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,3034 $\rightarrow$ p = 0,3034 — no significativo al 5%

6 Sesgo de status quo

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	4	28	32
Conocimiento avanzado (n=14)	0	14	14
Total	4	42	46

Proporción sesgada — Básico: 12,5% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 0,2979 $\rightarrow$ p = 0,2979 — no significativo al 5%

7 Sobreconfianza

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	2	30	32
Conocimiento avanzado (n=14)	0	14	14
Total	2	44	46

Proporción sesgada — Básico: 6,2% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 1,0000 $\rightarrow$ p = 1,0000 — no significativo al 5%

8 Comportamiento de manada

Grupo	Sesgado	No sesgado	Total
Conocimiento básico (n=32)	1	31	32
Conocimiento avanzado (n=14)	0	14	14
Total	1	45	46

Proporción sesgada — Básico: 3,1% | Avanzado: 0,0%

Odds Ratio: ∞ (grupo avanzado sin respuestas sesgadas)

p-valor (Fisher bilateral): 1,0000 $\rightarrow$ p = 1,0000 — no significativo al 5%

Sharpe Ratio anualizado del S&P Merval USD (2015–2025)

Serie construida con datos mensuales del índice S&P Merval denominado en dólares estadounidenses (ticker Merval:IND en Bloomberg), utilizando como tasa libre de riesgo el rendimiento de las Letras del Tesoro de EE.UU. a 3 meses (GB03 Govt). La fórmula aplicada fue: Sharpe Ratio anualizado = $[\mu(R_p - R_f) / \sigma(R_p - R_f)] \times \sqrt{12}$, donde μ es la media mensual del exceso de retorno y σ su desviación estándar. Los cálculos se realizaron en Python (bibliotecas pandas y numpy).

Año	Sharpe Ratio	Contexto macroeconómico
2015	0,05	Unificación cambiaria, fin del cepo
2016	0,85	Estabilización inicial
2017	2,01	Fuerte optimismo de mercado

Año	Sharpe Ratio	Contexto macroeconómico
2018	-1,25	Crisis cambiaria y de deuda soberana
2019	0,29	Recuperación parcial, alta volatilidad electoral
2020	0,08	Pandemia de COVID-19, alta dispersión intra-anual
2021	1,15	Recuperación post-pandemia
2022	1,00	Aceleración inflacionaria, sector energético favorable
2023	0,35	Año electoral, alta incertidumbre cambiaria
2024	1,65	Programa de estabilización macroeconómica
2025	0,00	Mercado lateral

Nota: el valor en rojo (2018) corresponde al único año con Sharpe Ratio negativo en toda la serie, coincidiendo con la crisis cambiaria y de deuda soberana. Los cálculos fueron realizados por los autores sobre datos primarios extraídos de Bloomberg.

Estadísticas descriptivas de la serie (2015–2025)

Estadístico	Valor
Media	0,5618
Mediana	0,3500
Desvío estándar	0,9008
Mínimo (año 2018)	-1,2500
Máximo (año 2017)	2,0100
Años con SR > 0	9 de 11
Años con SR < 0	1 de 11 (2018)

Sharpe Ratio en episodios específicos de volatilidad macroeconómica

Se calculó el Sharpe Ratio anualizado dentro de ventanas temporales acotadas correspondientes a los episodios de estrés macroeconómico identificados en el Capítulo 6 del marco teórico, así como a los períodos de recuperación inmediatamente posteriores. La misma fórmula de anualización ($\times \sqrt{12}$) fue aplicada sobre retornos mensuales dentro de cada ventana.

Episodio	Sharpe	Meses	Tipo de período
Crisis cambiaria 2018 (abr–dic)	-1,41	9	Crisis
Crisis post-PASO 2019 (ago–sep)	-1,14	2	Crisis
Inicio pandemia COVID-19 (feb–abr 2020)	-0,67	3	Crisis
Rebote post-pandemia (may–ago 2020)	+1,79	4	Recuperación
Aceleración inflacionaria (2022–2023)	+0,56	24	Recuperación
Período de estabilización (dic 2023–2025)	+0,24	25	Recuperación

Los tres sub-períodos con Sharpe Ratio negativo (en rojo) corresponden exactamente a los episodios de estrés macroeconómico identificados teóricamente. En los tres casos, el deterioro fue seguido por

una recuperación marcada en el período inmediatamente posterior, en particular el rebote post-pandemia (+1,79 entre mayo y agosto de 2020).

Comparación Sharpe Ratio: FCI institucionales vs. S&P Merval USD

Se compara el Sharpe Ratio trimestral promedio de los seis Fondos Comunes de Inversión (FCI) analizados por Mastrangelo y Salvatierra (2022) —calculado en pesos argentinos con tasa BADLAR privada como tasa libre de riesgo— con el Sharpe Ratio del S&P Merval en USD calculado por los autores de este trabajo en los mismos períodos de referencia. Por razones de confidencialidad, los fondos son identificados con numeración propia en el trabajo fuente.

Período	SR promedio FCI(Mastrangelo y Salvatierra)	SR Merval USD(elaboración propia)	Dirección
Crisis post-PASO (III-2019)	-0,83	-1,14	✓ Coincide
Inicio pandemia (I-2020)	-1,54	-0,67	✓ Coincide
Rebote post-pandemia (II-2020)	+1,69	+1,79	✓ Coincide

Fuentes: Mastrangelo, M. E. y Salvatierra, J. M. (2022). Análisis de rendimientos ajustados por riesgo de fondos de inversión de renta variable en Argentina. *Escritos Contables y de Administración*, 13(2), 75–103. Merval USD: elaboración propia en base a datos de Bloomberg.

Nota metodológica: las dos series no son estrictamente comparables en magnitud (la de Mastrangelo y Salvatierra está expresada en pesos con tasa BADLAR; la propia está expresada en dólares con tasa de Letras del Tesoro de EE.UU.). La comparación se apoya en la coincidencia direccional de ambas series y no en diferencias de magnitud.

Estadísticas descriptivas de la encuesta e indicadores de desempeño relativo de FCI

1 Composición de la muestra (encuesta, n=46)

Segmento	n	% del total
Total de respuestas válidas	46	100,0%
Conocimiento básico	32	69,6%
Conocimiento avanzado	14	30,4%

El nivel de conocimiento financiero fue autoreportado por los respondentes al inicio del cuestionario. El grupo «básico» corresponde a personas con poca experiencia e inversión previa; el grupo «avanzado», a personas con formación académica o laboral en finanzas. La encuesta fue administrada durante mayo de 2026 mediante formulario digital.

2 Resumen consolidado de resultados del test exacto de Fisher

Sesgo	Básico n	Básico %	Avanz. n	Avanz. %	p-valor	Sig.
Aversión a la pérdida	21	65,6%	0	0,0%	0,0000	***
Efecto disposición	8	25,0%	0	0,0%	0,0845	n.s.
Contabilidad mental	8	25,0%	0	0,0%	0,0845	n.s.
Sesgo de recencia	5	15,6%	0	0,0%	0,3034	n.s.

Sesgo	Básico n	Básico %	Avanz. n	Avanz. %	p-valor	Sig.
Sesgo de confirmación	5	15,6%	0	0,0%	0,3034	n.s.
Sesgo de status quo	4	12,5%	0	0,0%	0,2979	n.s.
Sobreconfianza	2	6,2%	0	0,0%	1,0000	n.s.
Comportamiento de manada	1	3,1%	0	0,0%	1,0000	n.s.

*** $p < 0,001$ | n.s. = no significativo al nivel $\alpha=0,05$. Test exacto de Fisher bilateral (scipy.stats.fisher_exact, Python).

3 Indicadores de desempeño relativo por fondo institucional (Mastrangelo y Salvatierra, 2022)

La tabla reproduce la síntesis de indicadores reportada en la Tabla 2 del trabajo de Mastrangelo y Salvatierra (2022), incorporada en la Sección 5.4 de este trabajo como evidencia complementaria sobre el comportamiento de la gestión institucional. Los fondos son identificados con numeración propia por razones de confidencialidad.

Indicador	Mejor desempeño	Peor desempeño / outlier	Lectura
Correlación con ROFEX 20 (Pearson, promedio)	5 de 6 fondos > 0,97	Fondo 2: 0,847 (cae a 0,599 en IV-19)	Un fondo se apartó del benchmark en trimestres puntuales
Alpha promedio trimestral (vs. ROFEX 20)	Fondo 3: -0,7%	Fondo 1: -4,3%	Rango de casi 4 p.p. entre el mejor y el peor fondo
Sharpe Ratio (ranking relativo)	Fondos 3, 4 y 5	Fondos 1, 2 y 6	Ranking estable entre fondos, no comportamiento uniforme
Persistencia trimestral (matriz G/P)	—	Ningún fondo individual	Los 6 FCI se califican como «no persistentes»

Fuente: Mastrangelo, M. E. y Salvatierra, J. M. (2022). Análisis de rendimientos ajustados por riesgo de fondos de inversión de renta variable en Argentina. *Escritos Contables y de Administración*, 13(2), 75–103.

Modelo Lineal de Probabilidad: presencia de sesgo conductual ~ nivel de conocimiento financiero

1 Justificación del enfoque de regresión

La regresión logística binaria es el modelo canónico para variables dependientes dicotómicas. Sin embargo, cuando existe separación perfecta o cuasi-perfecta en los datos —esto es, cuando una categoría del predictor predice de manera exacta uno de los valores de la variable de resultado— el estimador de máxima verosimilitud no converge y los coeficientes divergen hacia el infinito ($\beta \rightarrow \infty$, p

→ 1). Este es el caso de los datos de la encuesta: en la totalidad de los ocho sesgos relevados, el grupo de conocimiento avanzado no registró ninguna respuesta sesgada ($n_{\text{sesgado}} = 0$ sobre $n = 14$), configurando una separación cuasi-completa respecto del grupo de conocimiento básico.

Ante esta condición, la literatura estadística recomienda dos alternativas principales: (a) la regresión logística penalizada de Firth (Firth, 1993), que corrige el sesgo del estimador mediante una penalización de la función de verosimilitud, o (b) el Modelo Lineal de Probabilidad (LPM), que estima mediante mínimos cuadrados ordinarios la probabilidad de la variable dependiente como función lineal del predictor. El LPM produce estimaciones interpretables directamente como diferencias de proporciones entre grupos, es consistente con el análisis descriptivo del Anexo E y, en muestras pequeñas con predictores binarios, sus p-valores son más conservadores que los de la logística sin penalización. Por estas razones, se adoptó el LPM como modelo de regresión para este análisis.

2 Especificación del modelo

El modelo estimado para cada sesgo i es:

$$P(\text{Sesgado} = 1)_i = \beta_0 + \beta_1 \cdot \text{KnowBásico} + \varepsilon_i$$

donde KnowBásico es una variable binaria que toma valor 1 si el respondiente pertenece al grupo de conocimiento básico y 0 si pertenece al grupo avanzado. La constante β_0 representa la probabilidad basal de respuesta sesgada en el grupo de referencia (conocimiento avanzado); β_1 captura la diferencia de probabilidad entre el grupo básico y el avanzado. La muestra total es $n = 46$ (básico: 32; avanzado: 14). Dado que $P(\text{sesgado} \mid \text{avanzado}) = 0$ en todos los sesgos, la constante estimada es $\beta_0 = 0$ en todos los casos, y β_1 coincide directamente con la proporción sesgada del grupo básico.

3 Resultados — tabla de coeficientes

Variable dependiente: $P(\text{sesgado} = 1)$. Variable independiente: conocimiento básico (KnowBásico = 1) vs. avanzado (KnowBásico = 0). $n = 46$. Método: MCO. Errores estándar de Eicker-White (robustos a heterocedasticidad).

Sesgo conductual	β_1	Error est.	t	p-valor	R ²	Sig.
Aversión a la pérdida	0,6562	0,1298	5,0562	0,0000	0,3675	***
Efecto disposición	0,2500	0,1183	2,1128	0,0403	0,0921	*
Contabilidad mental	0,2500	0,1183	2,1128	0,0403	0,0921	*
Sesgo de recencia	0,1562	0,0992	1,5748	0,1225	0,0534	n.s.
Sesgo de confirmación	0,1562	0,0992	1,5748	0,1225	0,0534	n.s.
Sesgo de status quo	0,1250	0,0904	1,3831	0,1736	0,0417	n.s.
Sobreconfianza	0,0625	0,0661	0,9449	0,3499	0,0199	n.s.
Comportamiento de manada	0,0312	0,0475	0,6572	0,5144	0,0097	n.s.

*** $p < 0,001$ | * $p < 0,05$ | n.s. = no significativo ($\alpha = 0,05$). Elaboración propia en Python (statsmodels). Nota: β_1 equivale numéricamente a la proporción sesgada del grupo básico dado que $P(\text{sesgado} \mid \text{avanzado}) = 0$ en todos los sesgos (separación cuasi-completa).

4 Interpretación de resultados

Aversión a la pérdida registra el único coeficiente estadísticamente significativo al nivel del 1% ($\beta_1 = 0,6562$; $t = 5,06$; $p < 0,001$; $R^2 = 0,37$): pertenecer al grupo de conocimiento básico incrementa en 65,6 puntos porcentuales la probabilidad de responder de manera sesgada en la pregunta correspondiente a ese sesgo. Esta magnitud es consistente con la diferencia de proporciones reportada en el Anexo A.1 (65,6% vs. 0,0%) y con el resultado del test exacto de Fisher ($p < 0,001$).

Efecto disposición y contabilidad mental presentan coeficientes significativos al 5% ($\beta_1 = 0,25$; $t = 2,11$; $p = 0,04$ en ambos casos): el grupo básico muestra una probabilidad 25 puntos porcentuales mayor de respuesta sesgada. Nótese que el test de Fisher arrojó $p = 0,0845$ para ambos (no

significativo al 5%), mientras que el LPM lo ubica en el umbral de significancia. La diferencia se debe al menor conservadurismo del estadístico t frente al test exacto de Fisher, en especial con muestras pequeñas: en este caso se recomienda dar mayor peso al test de Fisher como referencia primaria.

Los cinco sesgos restantes (recencia, confirmación, status quo, sobreconfianza y comportamiento de manada) no alcanzan significancia estadística en ninguno de los dos métodos, lo que indica que las diferencias de proporciones observadas son compatibles con variabilidad muestral a los tamaños de muestra disponibles. El bajo R^2 en estos casos (entre 0,010 y 0,053) confirma que el nivel de conocimiento financiero explica una fracción mínima de la varianza en la respuesta para estos sesgos

Regresión OLS: Sharpe Ratio anualizado del S&P Merval USD ~ contexto macroeconómico

1 Especificación del modelo

Se estima un modelo de regresión lineal por mínimos cuadrados ordinarios (MCO/OLS) en el que la variable dependiente es el Sharpe Ratio anualizado del S&P Merval denominado en dólares estadounidenses para cada año del período 2015–2025 ($n = 11$ observaciones). Como predictores se incluyen tres variables dummy de contexto macroeconómico que clasifican cada año en uno de cuatro regímenes mutuamente excluyentes y colectivamente exhaustivos:

Especificación: $SR_t = \beta_0 + \beta_1 \cdot D_crisis_t + \beta_2 \cdot D_recuperacion_t + \beta_3 \cdot D_estabilizacion_t + \varepsilon_t$

La categoría de referencia (omitida) corresponde al período de optimismo inicial (2015–2017), capturado por la constante β_0 . Las tres dummies codifican: $D_crisis = 1$ para los años de estrés macroeconómico severo (2018: crisis cambiaria y deuda soberana; 2019: volatilidad electoral; 2020: pandemia de COVID-19); $D_recuperacion = 1$ para los años de recuperación (2021–2022); $D_estabilizacion = 1$ para el período de consolidación macroeconómica (2023–2025). La asignación de años a regímenes sigue la taxonomía establecida en el Capítulo 6 del marco teórico.

Resultados — tabla de coeficientes

Variable dependiente: Sharpe Ratio anualizado del S&P Merval USD. $n = 11$ (2015–2025). Método: MCO. $R^2 = 0,401$ | R^2 ajustado = 0,144 | $F(3,7) = 1,562$ | $p(F) = 0,282$.

Variable	Coeficiente	Error est.	t	p-valor	IC 95%	Sig.
Constante (β_0 — ref.: optimismo inicial 2015–2017)	0,9700	0,4812	2,0161	0,0836	[−0,168 ; 2,108]	n.s.
D_crisis (2018–2020)	−1,2633	0,6802	−1,8572	0,1060	[−2,872 ; 0,345]	n.s.
D_recuperacion (2021–2022)	0,1050	0,7613	0,1379	0,8941	[−1,694 ; 1,904]	n.s.
D_estabilizacion (2023–2025)	−0,3033	0,6802	−0,4459	0,6687	[−1,912 ; 1,305]	n.s.

n.s. = no significativo al nivel $\alpha = 0,05$. Elaboración propia en Python (statsmodels). Categoría de referencia: período de optimismo inicial (2015–2017). Diagnósticos: Durbin-Watson = 2,669 (sin autocorrelación severa); Omnibus $p = 0,664$; Jarque-Bera $p = 0,736$ (normalidad de residuos no rechazada).

3 Diagnósticos del modelo

Diagnóstico	Valor	Interpretación
R^2	0,401	El contexto macro explica el 40,1% de la varianza del SR

Diagnóstico	Valor	Interpretación
R ² ajustado	0,144	Penalizado por el bajo n relativo al número de predictores
F(3, 7)	1,562 (p = 0,282)	Modelo global no significativo al 5%
Durbin-Watson	2,669	Sin evidencia de autocorrelación positiva en residuos
Omnibus (norm.)	p = 0,664	No se rechaza la normalidad de los residuos
Jarque-Bera	p = 0,736	Consistente con distribución normal de residuos

4 Interpretación de resultados

La constante estimada ($\beta_0 = 0,970$) representa el Sharpe Ratio promedio del período de referencia (optimismo inicial 2015–2017) y es marginalmente significativa ($p = 0,084$), próxima al umbral del 10%. El coeficiente de D_crisis ($\beta_1 = -1,263$) indica que, en relación con el período de referencia, los años clasificados como de estrés macroeconómico severo presentaron un Sharpe Ratio inferior en aproximadamente 1,26 unidades, lo cual implica un SR promedio en crisis de $0,970 - 1,263 \approx -0,29$. Este signo negativo es consistente con la evidencia del Anexo C (Sharpe negativos en los tres episodios de crisis), si bien el coeficiente no alcanza significancia estadística al 5% ($p = 0,106$), en parte por el reducido tamaño muestral ($n = 11$).

Los coeficientes de D_recuperacion ($\beta_2 = 0,105$; $p = 0,894$) y D_estabilizacion ($\beta_3 = -0,303$; $p = 0,669$) no difieren estadísticamente de cero, lo que indica que el Sharpe Ratio en esos períodos no se distingue del nivel de referencia de manera estadísticamente confiable a este tamaño muestral. El modelo en su conjunto no resulta globalmente significativo ($F = 1,562$; $p = 0,282$), lo cual es esperable con $n = 11$ y tres predictores: la pérdida de grados de libertad es severa y las bandas de incertidumbre de los coeficientes son amplias.

La interpretación sustantiva no queda invalidada por la ausencia de significancia estadística. El R² de 0,40 —aunque ajustado a 0,14— indica que el régimen macroeconómico explica una fracción no trivial de la variabilidad del desempeño ajustado por riesgo del mercado argentino. La dirección de los coeficientes es coherente con las hipótesis teóricas (las crisis deterioran el SR; los períodos de recuperación lo elevan relativamente), y el patrón es consistente con la evidencia descriptiva. La limitación principal es estructural: la serie de tiempo anual 2015–2025 comprende únicamente 11 observaciones, por lo que cualquier inferencia estadística formal debe interpretarse con cautela.

5 Nota metodológica — limitaciones

Tres advertencias metodológicas son relevantes para la interpretación de este Anexo. Primera, la clasificación de años en regímenes macroeconómicos se realiza ex post sobre la base de la periodización establecida en el Capítulo 6; distintas taxonomías de periodización producirían coeficientes diferentes. Segunda, la regresión OLS sobre datos de serie de tiempo puede estar afectada por autocorrelación serial; el estadístico Durbin-Watson (2,669) sugiere que no existe autocorrelación positiva severa, aunque con $n = 11$ este diagnóstico tiene poder limitado. Tercera, la unidad de análisis es el año calendario, lo cual implica que episodios de estrés que abarcan parte de dos años quedan aproximados mediante la asignación anual de las dummies. A pesar de estas limitaciones, el ejercicio de regresión constituye un complemento válido a la evidencia descriptiva.

Bibliografía:

Kahneman, D., & Tversky, A. (1979). *Prospect theory: An analysis of decision under risk*. *Econometrica*, 47(2), 263–291. <https://doi.org/10.2307/1914185>

Tversky, A., & Kahneman, D. (1974). *Judgment under uncertainty: Heuristics and biases*. *Science*, 185(4157), 1124–1131. <https://doi.org/10.1126/science.185.4157.1124>

Kahneman, D. (2011). *Thinking, Fast and Slow*. Farrar, Straus and Giroux.

Kahneman, D. (2012). *Pensar rápido, pensar despacio*. Debate.
(Edición traducida al español)

Thaler, R. H. (1999). *Mental accounting matters*. *Journal of Behavioral Decision Making*, 12(3), 183–206. [https://doi.org/10.1002/\(SICI\)1099-0771\(199909\)12:3](https://doi.org/10.1002/(SICI)1099-0771(199909)12:3)

Odean, T. (1999). *Do investors trade too much?* *American Economic Review*, 89(5), 1279–1298. <https://doi.org/10.1257/aer.89.5.1279>

Barber, B. M., & Odean, T. (2000). *Trading is hazardous to your wealth: The common stock investment performance of individual investors*. *The Journal of Finance*, 55(2), 773–806. <https://doi.org/10.1111/0022-1082.00226>

Daniel, K., Hirshleifer, D., & Subrahmanyam, A. (1998). *Investor psychology and security market under- and overreactions*. *The Journal of Finance*, 53(6), 1839–1885. <https://doi.org/10.1111/0022-1082.00077>

Daniel, K., Hirshleifer, D., & Teoh, S. H. (2002). *Investor psychology in capital markets: Evidence and policy implications*. *Journal of Monetary Economics*, 49(1), 139–209. [https://doi.org/10.1016/S0304-3932\(01\)00091-5](https://doi.org/10.1016/S0304-3932(01)00091-5)

Mullainathan, S. (2023). *Human Bias in Algorithm Design*.

Mullainathan, S., & Spiess, J. (2017). *Machine learning: An applied econometric approach*. *Journal of Economic Perspectives*, 31(2), 87–106. <https://doi.org/10.1257/jep.31.2.87>

Mullainathan, S., & Ludwig, J. (2022). *Behavioral machine learning: Predictive modeling and economic decision-making*.

López de Prado, M. (2018). *Advances in Financial Machine Learning*

Obermeyer, Z., Powers, B., Vogeli, C., & Mullainathan, S. (2019). *Dissecting racial bias in an algorithm used to manage the health of populations*. *Science*, 366(6464), 447–453. <https://doi.org/10.1126/science.aax2342>

Brière, P., Calamai, P., Di Giansante, M., Huynh, T. L. D., & Novelli, C. (2023). *Behavioral biases in institutional and retail investors: Evidence from portfolio management*. *Finance Research Letters*, 58, 104112. <https://doi.org/10.1016/j.frl.2023.104112>

Kissell, R. (2013). *The Science of Algorithmic Trading and Portfolio Management*. Academic Press.

Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.

O’Neil, C. (2016). *Weapons of Math Destruction: How Big Data Increases Inequality and Threatens Democracy*. Crown Publishing Group.

INDEC. (2023). *Índice de precios al consumidor (IPC): Cobertura nacional*. Instituto Nacional de Estadística y Censos de la República Argentina. <https://www.indec.gob.ar/indec/web/Nivel4-Tema-3-5-31>

Ministerio de Economía de la República Argentina. (2020). *Reestructuración de la deuda pública bajo ley extranjera*. <https://www.argentina.gob.ar/economia/finanzas/deudapublica>

International Monetary Fund. (2020). *Argentina: Request for extended arrangement under the extended fund facility*. IMF Country Report No. 22/382.

<https://www.imf.org/en/Publications/CR/Issues/2022/12/20/Argentina>

Normativa argentina

Comisión Nacional de Valores

Argentina. Congreso de la Nación. (2012). *Ley N.º 26.831: Ley de Mercado de Capitales*. Boletín Oficial de la República Argentina.

Argentina. Poder Ejecutivo Nacional. (2013). *Decreto Reglamentario N.º 1023/2013*. Boletín Oficial de la República Argentina.