

Algoritmos para la asignación de activos: revisión

Chloe Taysom¹ *, Nick Firoozye¹ , Philip Treleven¹

¹Departamento de Ciencias de la Computación de la UCL; *autor correspondiente

Abstracto

Este artículo presenta una taxonomía y una revisión de las áreas de aprendizaje automático relevantes para el dominio de aplicación de los gestores de activos. Los gestores de activos incluyen fondos de dotación, fondos de pensiones y fondos soberanos, que suelen tener horizontes temporales más amplios que otros tipos de inversores y, a menudo, persiguen objetivos de gran importancia social.

Los gestores de activos suelen pasar desapercibidos en la literatura sobre ciencia de datos financieros, a pesar del gran volumen de activos que gestionan a nivel mundial. La aplicación de algoritmos a nivel de gestor de activos ha sido históricamente un desafío debido a la limitación de los conjuntos de datos, los largos ciclos de retroalimentación y la compleja variedad de características subyacentes de las inversiones. El reto de los datos al que se enfrentan los gestores de activos es, sin duda, uno de los problemas más complejos dentro de la gestión de activos. Sin embargo, en los últimos tiempos se ha observado un creciente interés en aplicar métodos de ciencia de datos en todas las áreas de la gestión de activos. industria, incluyendo dentro de este dominio.

Este artículo analiza las aplicaciones de algoritmos de aprendizaje automático y estadística computacional para respaldar casos de uso de análisis de inversiones, gestión de carteras y mejora de la productividad del flujo de trabajo. Se describen los principales desafíos y se examina con mayor detalle la inversión en capital privado, de la cual se pueden extraer varias lecciones transferibles.

1. Introducción

Los gestores de activos pasan desapercibidos en la literatura sobre ciencia de datos financieros, a pesar de la gran cantidad de activos que administran y de representar algunos de los fondos de capital más importantes e influyentes a nivel mundial, como las fundaciones benéficas, los fondos de pensiones y los fondos soberanos.

Los gestores de cartera se sitúan por encima de las jerarquías de los tipos de inversión subyacentes. Los datos que influyen en las decisiones de inversión son amplios y diversos, abarcando desde datos macroeconómicos y de mercado públicos hasta datos difíciles de obtener sobre empresas privadas. En las carteras multiactivos (que invierten en múltiples clases de activos), existe una variación sustancial en la forma en que se recopila y analiza la información. Los horizontes temporales de las inversiones subyacentes varían considerablemente, desde estrategias de negociación táctica a corto plazo hasta estrategias de mercado privado con ciclos de retroalimentación de décadas. Algunos gestores de cartera también tienen conjuntos complejos de objetivos, restricciones o requisitos de seguimiento relacionados con consideraciones ambientales, sociales y de gobernanza (ASG). Por último, muchos gestores de cartera se enfrentan a objetivos de rendimiento particularmente exigentes, como lograr rentabilidades similares a las de la renta variable a lo largo de los ciclos de mercado y dentro de carteras multiactivos. El «problema del gestor de cartera» es, sin duda, uno de los problemas más complejos y multidimensionales del sector de la gestión de activos.

Hasta la fecha, los esfuerzos por aplicar métodos de ciencia de datos en este ámbito se han desarrollado en gran medida de forma discreta dentro de las organizaciones de asignación de recursos. Sin embargo, existe un pequeño pero creciente conjunto de publicaciones del sector y del ámbito académico en esta área, como las de Phalippou (2025), la Universidad de Purdue (2024) y Hayman (2024).

Este documento presenta una taxonomía de áreas clave relevantes para los gestores de activos que aplican métodos de ciencia de datos, incluyendo el análisis de gestores y fondos (Sección 5), la gestión de carteras (Sección 6) y la mejora de la productividad del flujo de trabajo (Sección 7). Describimos los desafíos y riesgos relevantes para esta área (Sección 8) y examinamos los posibles aprendizajes del capital privado, un dominio de aplicación paralelo que comparte muchos desafíos similares (Sección 9). Comenzamos definiendo algoritmos (Sección 2), asignadores de activos (Sección 3) y datos relevantes para este dominio (Sección 4).

2. Algoritmos

Para los fines de este artículo, definimos "algoritmos" basándonos en la taxonomía presentada por Koshiyama, Firoozye y Treleaven (2020):

- Estadística Computacional: modelos estadísticos que requieren una gran capacidad de cálculo, como los métodos de Monte Carlo, descomposición matricial y remuestreo.
- Sistemas complejos – sistemas que comprenden gran cantidad de componentes que interactúan entre sí, cuyo comportamiento no es lineal y resulta difícil de modelar debido a las complejas dependencias entre los elementos que interactúan (por ejemplo, sistemas basados en agentes).
- Algoritmos de IA: áreas clave dentro de la IA
Los algoritmos incluyen: modelos tradicionales de aprendizaje automático, que identifican patrones dentro de un conjunto de datos y hacen predicciones; e inteligencia artificial generativa, que ha cobrado gran importancia en los últimos tiempos y comprende sistemas capaces de producir dinámicamente texto, imágenes, audio, vídeo, código u otras modalidades de una manera que parece sorprendentemente humana.

- Estadística Computacional: métodos estadísticos y probabilísticos que requieren una gran capacidad de cálculo.
- Algoritmos de IA: imitan el aprendizaje biológico, la optimización y la toma de decisiones:
 - Sistemas basados en el conocimiento o en reglas
 - Algoritmos evolutivos
 - Aprendizaje automático tradicional
 - IA generativa
- Sistemas complejos: sistema que presenta un gran número de sistemas de componentes que interactúan entre sí y cuya actividad agregada no es lineal.

Figura 1: Dominios de algoritmos, basados en Koshiyama, Firoozye y Treleaven (2020)

La Tabla 1, tomada de Sharkey, Craciun y Treleaven (2025), presenta una comparación simple de las características principales del aprendizaje automático tradicional y la IA generativa:

Característica	ML tradicional	IA generativa
Primario Función	Extraer características relevantes de conjuntos de datos seleccionados.	Creación de contenido generativo
Enfocar	Procesamiento del lenguaje natural, etc.	Generación de contenido nuevo (texto, imágenes, etc.)
Ejemplos	Recomendaciones, pronósticos, generación de texto, generación de imágenes	
Conceptos clave:	Aprendizaje automático, redes neuronales	Másteres en Derecho, modelos mundiales

Entre las tecnologías de aprendizaje automático importantes que se aplican en el ámbito más amplio de la gestión de activos se incluyen:

- Bosques aleatorios y potenciación de gradiente: métodos populares de aprendizaje de conjuntos para Combina varios clasificadores débiles (árboles de decisión) en un único clasificador fuerte. Un bosque aleatorio construye varios árboles de forma independiente y calcula la media (regresión) o la moda (clasificación) de los resultados. El potenciador de gradiente construye árboles iterativamente, con cada nuevo árbol buscando corregir los errores del anterior.
- Redes neuronales artificiales (RNA): inspiradas en las neuronas biológicas, estas redes constan de capas de nodos y enlaces entre ellos, lo que guarda un paralelismo aproximado con las neuronas, los axones y las sinapsis biológicas. Almacenan conocimiento en forma de pesos que conectan los nodos. Estos pesos se actualizan iterativamente a medida que se adquiere conocimiento. El aprendizaje profundo utiliza redes particularmente profundas, es decir, redes con un gran número de capas de procesamiento.

Los tipos de redes neuronales artificiales incluyen:

- Redes neuronales de alimentación directa y recurrentes. Las redes de alimentación directa, o Los perceptrones multicapa (MLP) son la forma más simple de red neuronal, y contienen una o más capas ocultas de nodos entre las capas de entrada y salida. Las redes neuronales recurrentes (RNN) son redes con enlaces recurrentes, donde la salida de un paso temporal se convierte en la entrada del siguiente. Estas son especialmente útiles para aplicaciones de modelado de series temporales (Bengio, Simard y Frasconi, 1994).
- Transformers (Vaswani, et al., 2017): una forma de red neuronal profunda, desarrollada para la traducción automática. Utilizan una arquitectura codificador-decodificador y se basan exclusivamente en mecanismos simples de autoatención, sin recurrencia ni convoluciones. Estos modelos han reemplazado a las RNN y CNN como el modelo dominante para las tareas de procesamiento del lenguaje natural (Wolf, et al., 2020) debido a su relativa velocidad de entrenamiento, escalabilidad y capacidad para modelar dependencias de largo alcance; esta es la arquitectura fundamental que subyace a los modelos de lenguaje a gran escala (LLM).

3. Asignadores de activos

El término «gestor de activos» se aplica en diversos contextos, pero generalmente se refiere a los gestores de carteras que abarcan múltiples clases de activos (como renta variable, renta fija e inmuebles) y suele indicar a los inversores que poseen una parte de los activos mediante un enfoque de externalización o delegación, utilizando gestores de fondos externos.

Entre los inversores de este tipo se incluyen fondos benéficos, fundaciones, fondos de pensiones y fondos soberanos.

Los gestores de activos supervisan una parte sustancial del capital de inversión a largo plazo y, por lo tanto, ejercen una influencia significativa en la asignación de capital entre los distintos sectores (Monk, Rook y Sharma, 2026). Si bien no se conocen cifras exactas, Berkelaar, Misic y Stimes (2025) estiman que la categoría más amplia de inversores institucionales controla más de 100 billones de dólares en activos a nivel mundial. En la Tabla 2, que se presenta a continuación, se muestra una taxonomía estándar para los tipos de inversores en este ámbito.

Para los fines de este documento, nos centramos en los inversores del "modelo de dotación", es decir, inversores multiactivos que siguen un enfoque mayoritariamente externalizado con asignaciones significativas a clases de activos alternativos, como el capital privado y los fondos de cobertura.

Tabla 2: Categorías de grandes inversores institucionales

Tipo	Acercarse
Modelo de dotación	O el "Modelo Yale", como lo describe Swensen (2009); este favorece una asignación sustancial a inversiones alternativas (como capital privado y fondos de cobertura) y un enfoque en gran medida externalizado, invirtiendo a través de fondos gerentes.
Modelo canadiense	Este enfoque es el preferido por los fondos de pensiones canadienses, como el CPPIB; además, destina una parte sustancial de sus recursos a alternativas gestionadas internamente, por ejemplo, activos de capital privado gestionados internamente.
Modelo noruega	Impulsado por el fondo de pensiones del gobierno noruego (GPFNG), este programa destina gran parte de sus recursos a activos del mercado público e invierte directamente en ellos.
Modelo LDI	La inversión basada en pasivos es un enfoque que siguen principalmente los planes de pensiones de prestaciones definidas; esto generalmente requiere asignaciones sustanciales a valores de renta fija del mercado público.

Fuente: Berkelaar, Mistic y Stimes (2025).

Dentro del modelo de inversión en fondos de dotación, existen diversos enfoques y estructuras organizativas.

Estructuras. Algunos gestores de activos operan como organizaciones de gestión de activos independientes con múltiples inversores, mientras que otros están fuertemente integrados en los departamentos financieros de las organizaciones a las que prestan servicios. Asimismo, existe una amplia variedad de estructuras y tamaños de equipo en relación con el volumen de activos gestionados.

Entre los inversores del modelo de dotación, el enfoque hacia la innovación varía. Históricamente, las dotaciones universitarias son consideradas líderes en las tendencias más amplias de los inversores institucionales. adentrándose en las acciones en las décadas de 1930 y 1940 (Chambers, Dimson y Foo, 2015), en las inversiones alternativas en la década de 1980 (Chambers, Dimson y Kaffe, 2020), y siendo pioneros en incorporar factores éticos o ESG en sus procesos de inversión, un enfoque que más recientemente ha surgido como una megatendencia más amplia en la gestión de activos. Sin embargo, Monk, Rook y Sharma (2026) argumentan que los asignadores han sido más lentos en innovar, destacando obstáculos como altos grados de escrutinio externo y preocupaciones en torno al riesgo potencial de titulares.

4. Datos

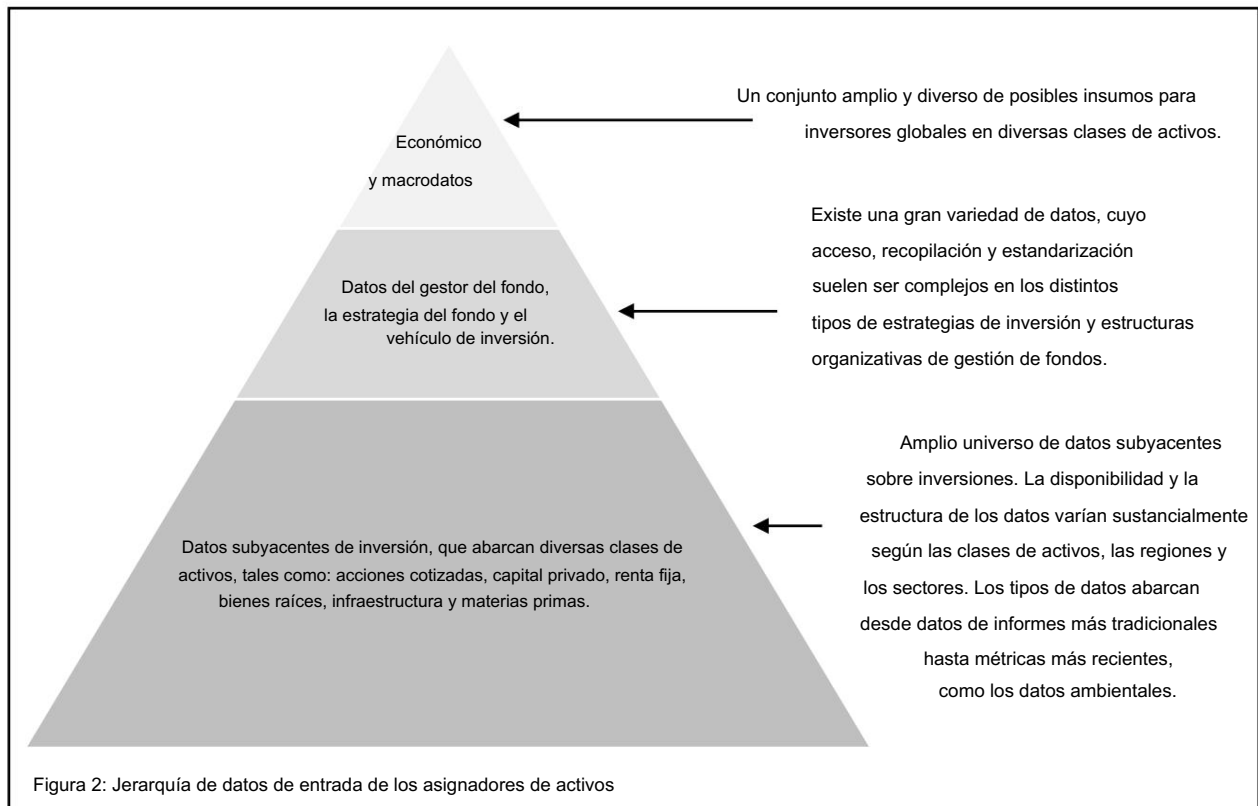
El sector de la inversión está experimentando una explosión sin precedentes en cuanto a la cantidad de datos disponibles para el análisis. Esto se debe a una combinación de factores: la disponibilidad de nuevos conjuntos de datos alternativos, como imágenes satelitales y datos de tarjetas de crédito, en una amplia gama de áreas; la proliferación de actividad en línea, como la actividad en redes sociales, que genera nuevos tipos de datos para rastrear y analizar; y los avances en los métodos de procesamiento del lenguaje natural para extraer datos estructurados de formatos no estructurados. Estos dos últimos factores se han acelerado especialmente en los últimos años con el desarrollo de modelos lineales lógicos basados en transformadores. El efecto de la expansión de los conjuntos de datos, y con ellos la proliferación de herramientas de ciencia de datos accesibles, es que el análisis cuantitativo es cada vez más posible en áreas tradicionalmente caracterizadas por evaluaciones cualitativas.

Esta creciente capacidad de acceder y analizar datos presenta un problema particular para los Asignadores, que se encuentran en la cima de una jerarquía particularmente amplia y compleja de tipos de datos de entrada.

La jerarquía se muestra en la Figura 2. Los datos de toda esta jerarquía se introducen en un Asignador.

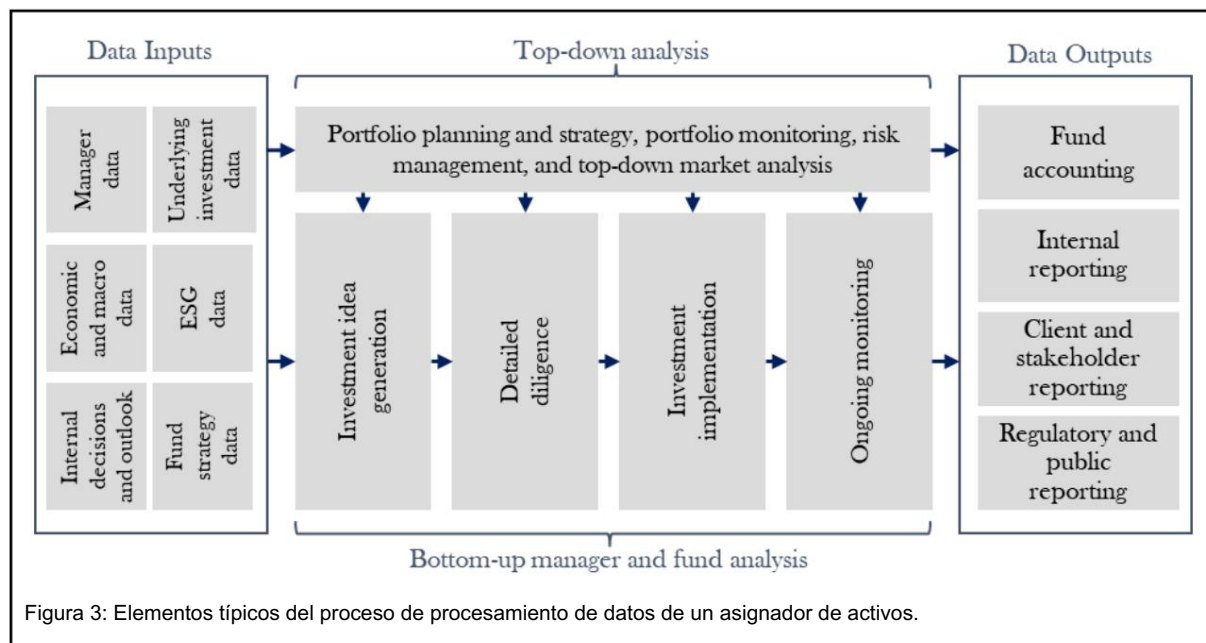
marco de decisión de inversión. Dentro de cada segmento de esta jerarquía, existe una amplia variación en la disponibilidad, frecuencia y estructura de los datos, lo que dificulta la agregación y el análisis.
desafiante.

Esto contrasta con muchas otras áreas de la gestión de activos, donde los gestores se centran únicamente en subsecciones dentro de los segmentos superior o inferior de la Figura 2. Por ejemplo, los macroinversores sistemáticos y discretivos se centran principalmente en el segmento superior. Los inversores de capital privado suelen centrarse únicamente en porciones reducidas del segmento inferior, es decir, generalmente en regiones, sectores y tamaños/velocidades corporativas específicas dentro de sus universos de inversión. A pesar de la amplitud y diversidad de los datos, los datos en muchas áreas de esta jerarquía pueden ser escasos y difíciles de obtener.
acceso.



La Figura 3 a continuación muestra elementos típicos del flujo de procesamiento de datos de un Asignador de Activos. Además de la amplitud y diversidad de los datos de entrada, los Asignadores también se enfrentan a una gama singularmente variada de datos de salida requeridos, incluyendo informes en diversos formatos para una variedad de comités de supervisión y otras partes interesadas externas. Implementación de la inversión

Los procesos también pueden ser largos y complejos desde el punto de vista operativo (una característica compartida con los mismos título obtenido mediante inversión de capital privado).



Si bien la complejidad de los datos representa un desafío particular para los Asignadores, podría decirse que esta complejidad también significa que los Asignadores están en una posición única para beneficiarse de las nuevas tecnologías, en términos de tanto en la extracción de datos de fuentes dispares y no estructuradas, como en el manejo de grandes conjuntos de datos y problemas de alta dimensionalidad de manera más eficaz que los métodos de modelado tradicionales.

5. Modelización de carteras y gestión de riesgos

Además de los desafíos relacionados con los datos mencionados anteriormente (incluida la amplitud de los datos y las diversas características de las inversiones subyacentes), la gestión de carteras para los gestores de activos también se complica por factores como la liquidez variable entre las carteras y, en algunos casos, los objetivos de inversión multifacéticos y no financieros.

En la práctica, los asignadores ya aplican una serie de métodos analíticos computacionalmente complejos.

En esta área, los métodos tradicionales utilizados por los asignadores incluyen:

- Optimización de la media y la varianza (Markowitz, 1952): un marco ampliamente utilizado, aunque con muchas salvedades prácticas para los asignadores en su forma tradicional, como concentraciones poco intuitivas, inestabilidad de la cartera óptima con pequeños cambios en los datos de entrada y características faltantes relevantes para los inversores a largo plazo, como la liquidez y la comerciabilidad (Swensen, 2000).
- Modelado de Monte Carlo: modelado estocástico de resultados probabilísticos a largo plazo para asegurar que los parámetros de la política de cartera se alineen con los objetivos estratégicos, así como evaluar el impacto de diferentes escenarios de mercado. Yale (2010) y Georgetown (2024) incluyen un análisis de este tema.
- Análisis factorial: análisis de regresión o basado en la composición de las inversiones y las carteras de inversión frente a una serie de factores de riesgo sistemáticos (tamaño, valor, impulso, etc.) para comprender la exposición al riesgo dentro de carteras complejas.
- Modelado de escenarios y pruebas de estrés: una gama de metodologías aplicadas al modelado de flujos de efectivo de la cartera y cambios en los valores de los activos para comprender cómo podrían responder las carteras a eventos de riesgo específicos. Esto puede incluir modelos de un solo período y de múltiples períodos, considerando escenarios tanto históricos como hipotéticos.

- Previsión de fondos de compromiso: se utiliza para gestionar los nuevos compromisos con fondos de capital privado y estimar las exposiciones y las necesidades netas de efectivo a lo largo del tiempo. El modelo propuesto por Takahashi y Alexander (2002) es una metodología estándar utilizada por los gestores de activos. Se trata de un modelo sencillo y determinista que se utiliza para prever los flujos de efectivo y las asignaciones a los fondos de compromiso.

Si bien aún no se aplican de forma generalizada en la práctica, en la literatura se han propuesto diversas extensiones y técnicas más novedosas para abordar las deficiencias de algunos de los métodos mencionados anteriormente.

A continuación se detallan algunos ejemplos:

- Optimización de cartera: se han propuesto diversas extensiones y alternativas para abordar algunos de los problemas que presenta la optimización tradicional de media-varianza (MVO). Estas incluyen: MVO con medidas de riesgo alternativas (por ejemplo, Righi y Borenstein, 2018); factorización de MVO para iliquidez (véase, por ejemplo, Lo et al. (2003), Kinlaw et al. (2013), Hayes et al. (2015)); y modelado multiperíodo (por ejemplo, Garleanu y Pedersen, 2013). Si bien no se centra en un caso de uso de Allocator, las alternativas más recientes a MVO propuestas en la literatura incluyen: Deep Portfolios, un enfoque sin modelo en el que los pesos óptimos de la cartera se producen como capas en una red neuronal (Zhang, Zohren y Roberts, 2021); algoritmos evolutivos (Metaxiotis y Liagkouras, 2012) e inteligencia de enjambre (Ertenlice y Kalayci, 2018).
- Previsión del fondo de compromiso: se han propuesto varias extensiones al Takahashi. El modelo de Alexander ('TA') incluye: Hirsu et al. (2024), que se basa en el modelo TA y lo combina con la corrección de errores basada en aprendizaje automático y el modelado de bosques aleatorios; Erikson y Holmberg (2024), que investiga la inclusión de macrodatos para mejorar el rendimiento del modelo TA; y Kieffer et al. (2021), que investiga la programación genética para adaptar dinámicamente el ritmo de re-compromiso.

También están surgiendo diversos métodos más novedosos en este ámbito que son relevantes para los asignadores de recursos. Entre ellos destacan el análisis del régimen de mercado y la modelización de los puntos de inflexión del régimen.

Si bien resulta excepcionalmente difícil en la práctica, comprender los regímenes de mercado e identificar con éxito los cambios de régimen antes que el mercado en general representaría un "santo grial" para los gestores de cartera, para quienes realizar pequeños ajustes en la asignación de carteras antes de períodos de mayor euforia o incertidumbre en el mercado podría generar ganancias financieras sustanciales y un rendimiento superior a lo largo de los extensos horizontes temporales de sus carteras.

En la literatura se han observado diversos enfoques para el análisis de regímenes, incluyendo métodos de filtrado (Mulvey y Liu, 2016) y clasificadores de regímenes (Chen y Tsang, 2020; Benoit y Raffinot, 2018; Vishwakarma, 1994). La relevancia de este campo para los gestores de fondos se refleja en un módulo de Coursera, que se centra específicamente en el modelado de regímenes para el ámbito de la gestión de fondos (Mulvey, 2019). Pomorski (2024), que combina el modelado de bosques aleatorios con indicadores técnicos para la detección de regímenes, también aplica este enfoque específicamente en el contexto de los gestores de fondos.

Otro ámbito relevante es la previsión a corto plazo para inversiones en mercados privados. La valoración de carteras con activos subyacentes diversos supone un reto para los gestores de carteras, quienes suelen recibir las valoraciones de los mercados privados con cierto retraso tras el cierre del período de presentación de informes. Esto cobra especial relevancia en las transacciones del mercado secundario de fondos de inversión privados, como se analiza, por ejemplo, en el estudio de Carnelli Dompe y Ferri (2021).

6. Análisis de gestores y fondos

Un problema fundamental para los gestores de fondos es identificar gestores y estrategias que puedan generar un rendimiento sólido a largo plazo y superar a los enfoques pasivos más económicos después de deducir las comisiones.

El análisis ascendente de gestores y fondos se lleva a cabo durante todo el ciclo de vida de una inversión, desde la concepción de la idea y la debida diligencia hasta el seguimiento y, en el caso de las estrategias de capital privado, la renovación periódica de la inversión una vez realizada. Esto implica un gran esfuerzo para evaluar datos cuantitativos y cualitativos en áreas como: las características de la estrategia de inversión; las competencias y la trayectoria del equipo gestor; la estructura de la sociedad gestora y del fondo; las características de las empresas de la cartera subyacente; y la dinámica del mercado del universo de inversión objetivo. Como se indicó en la Sección 4, cada decisión de inversión de un fondo implica un conjunto de datos de entrada de alta dimensionalidad.

Hasta la fecha, la bibliografía que aplica métodos de ciencia de datos al análisis de gestión ha sido limitada. La tabla 3 a continuación proporciona algunos ejemplos.

	Fondos del mercado público	Los fondos de inversión
Máquina Aprendiendo	Wu et al. (2019) utilizan varios modelos, incluidos bosques aleatorios y redes neuronales, para pronosticar el rendimiento de los fondos de cobertura. Morningstar (2018) Utiliza bosques aleatorios para modelar las calificaciones de los analistas. Otros ejemplos incluyen DeMiguel et al. (2021), Trichilo (2020) y Ludwig & Piovoso (2005).	privada Sigrist y Perfetto (2019) aplican clasificadores de aprendizaje automático a datos sobre rendimiento, estrategia, equipo y mercado para predecir el rendimiento por encima de un umbral determinado. Véase también Camelli Dompe y Ferri (2021), sobre valoraciones de pronóstico inmediato y Karatas, Klinkert y Hirsra (2021) sobre pronóstico de flujos de efectivo de fondos de compromiso.
Red Análisis	Rossi et al. (2018) hallaron una relación positiva entre la centralidad y el rendimiento ajustado al riesgo en redes de gestores, fondos de pensiones y consultores. Satone et al. (2021) aplicaron representaciones de red al modelado de similitud de fondos. Otros ejemplos incluyen a Ozsoylev et al. (2014) y Guo et al. (2015).	Kaffe (2020) encuentra que la centralidad de la red está relacionada positivamente tanto con el rendimiento como con la capacidad de captación de fondos en redes de gestores e inversores. Hochberg et al. (2007) también encuentran que las medidas de centralidad de la red son predictivas del rendimiento en el capital de riesgo.
Texto Análisis	Zhang (2020) aplica modelos BERT y LSTM para identificar fondos con rendimiento superior basándose en las cartas de los gestores de fondos de inversión. Hillert et al. (2020) analizan el tono en las cartas de los gestores de fondos estadounidenses mediante un enfoque de bolsa de palabras y medidas de frecuencia. Véase también Abis (2020), Kostovetsky y Warner (2020) y Baade y Ovrelid (2020).	Fernández Tamayo et al. (2023) aplican modelos de Gradient Boosting, Random Forest y Lasso Regression a vectores TF-IDF extraídos de prospectos de fondos para predecir el rendimiento futuro de los fondos.

Los enfoques se pueden dividir en tres áreas principales: la aplicación de modelos de regresión y clasificación de aprendizaje automático; la aplicación de métodos de análisis de redes (como medidas de centralidad) a redes de fondos, inversores y sus empresas subyacentes; y la aplicación de modelos de aprendizaje automático a datos extraídos del texto de los informes de fondos y los prospectos de fondos privados.

Nuestra investigación hasta la fecha indica que un mayor número de estudios se centran en fondos del mercado público que en fondos del mercado privado. Esto probablemente se deba a una mayor disponibilidad general de datos relacionados con los fondos públicos.

Si bien los estudios que aplican métodos de ciencia de datos han sido limitados hasta la fecha, la literatura financiera más amplia produce una gran cantidad de estudios que aplican métodos cuantitativos más tradicionales a esto.

problema. Las áreas de análisis incluyen factores como: género – ver por ejemplo Atkinson et al.

(2003), Hu et al. (2012), Niessen-Ruenzi & Ruenzi (2017) y Helgesson & Lindblad (2020);

y rasgos de personalidad: los estudios indican un rendimiento superior relativo de los gerentes que evitan las sensaciones (Brown, Lu, Ray y Teo, 2018) con menos tendencias psicopáticas (Brinke, Kish y Keltner, 2018) y sin distracciones por eventos matrimoniales (Lu, Ray y Teo, 2016).

7. Herramientas de IA para la mejora de la productividad

Además de los casos de uso analíticos descritos en las secciones 5 y 6 anteriores, las herramientas inteligentes, en particular las herramientas de IA generativa, tienen muchas aplicaciones potenciales para mejorar la productividad del flujo de trabajo a lo largo del proceso de inversión de un Asignador.

Los asignadores reciben datos no estructurados y semiestructurados a lo largo de estos procesos, entre los que se incluyen: Presentaciones y materiales para salas de datos de los gestores de fondos; cartas periódicas de actualización de fondos e informes de riesgos; y fuentes de noticias en línea. Los asignadores también generan contenido no estructurado a lo largo de estos procesos, que incluye: redactar notas que resumen reuniones externas, recopilar actualizaciones internas de la cartera y elaborar informes externos para inversores, comités de supervisión y otras partes interesadas.

La figura 4 muestra algunos ejemplos de posibles casos de uso de herramientas de IA para gestionar datos no estructurados a lo largo del proceso de inversión.

Idea sourcing	Diligence	Portfolio monitoring and transacting	Reporting and Client Management
<ul style="list-style-type: none"> • Intelligent online search • Summarising pitch decks • Call transcription and summaries • Network analysis • Responding to marketing emails 	<ul style="list-style-type: none"> • Drafting investment case • Initial legal reviews • Operational document reviews • ESG data collection and risk summaries • Intelligent proofreading 	<ul style="list-style-type: none"> • Collecting fund reporting • Summarising fund reporting • Querying fund reporting • News monitoring and summarisation • Manager meeting transcriptions and summaries 	<ul style="list-style-type: none"> • Drafting internal portfolio summaries • Drafting quarterly client reporting • Drafting marketing materials and DDQs • Drafting responses to client queries • Client meeting transcriptions • Draft reporting to oversight committees • Drafting ESG, regulatory and compliance reporting

Figura 4: Casos de uso potenciales para herramientas de IA en los procesos de inversión de los asignadores.

Existe una amplia gama de herramientas y plataformas destinadas a mejorar la productividad en diferentes elementos del proceso de inversión. La tabla 4 a continuación muestra algunos ejemplos de plataformas actuales.

Utilizado por los responsables de la asignación de tareas para la automatización de flujos de trabajo, según la información disponible en línea de la plataforma. Esta información se basa en datos disponibles en línea al momento de redactar este texto y puede no reflejar de forma exhaustiva todas las funcionalidades ofrecidas.

Tabla 4: Herramientas de mejora del flujo de trabajo de IA: ejemplos de funcionalidad

Plataforma	Base de clientes principal	Descomposición	Generación aumentada de recuperación	Indicación de cadena de pensamiento	Agentes de IA	IA agéntica	Modelos LLM específicos del dominio	Indicadores de precisión	Intervención humana
Hebbia	Capital privado								
IA de Llama azul	Capital privado								
Dashti	Asignadores de activos								
DiligenceVault	Asignadores de activos								
Canoa Inteligencia	Asignadores de activos								
Accelex	Asignadores de activos								
Harvey IA	bufetes de abogados								
Rogo	Bancos / fondos de cobertura								

Entre las tecnologías clave que se analizan en los materiales en línea de estas plataformas se incluyen:

- Modelos LLM específicos del dominio: Harvey y Rogo, por ejemplo, utilizan modelos LLM entrenados a medida centrados respectivamente en casos de uso legales y financieros.
- Generación aumentada de recuperación ("RAG") y alternativas: RAG es un enfoque estándar para la generación de respuestas LLM, que ayuda a reducir las alucinaciones al recuperar dinámicamente y proporcionar al LLM subyacente el contexto más relevante en el momento de la consulta. (Pisaneschi, 2025). Hebbia analiza el desarrollo de una evolución de RAG en su arquitectura de Descomposición Iterativa de Fuentes (ISD) (Ramanathan, 2025).
- Indicación de cadena de pensamiento: una secuencia de indicaciones que descomponen las tareas en pasos intermedios para mejorar la capacidad de un LLM para manejar tareas complejas (Gadesha, Kavliakoglu y Winland, 2025).
- Agentes de IA e IA agéntica: Los agentes de IA son sistemas modulares autónomos para la automatización de tareas específicas; la IA agéntica se define como sistemas de múltiples agentes autónomos que colaboran para lograr objetivos complejos (Sakopta, Roumeliotis y Karkee, 2025). Varios Las plataformas utilizan agentes de IA, como por ejemplo "Sidekick" de Dashti y "Blueprints" de Blueflame. Algunas plataformas también abordan los sistemas de IA con agentes en sus materiales (véase, por ejemplo, Bakhr, 2025), aunque hasta la fecha no existe mucha información pública sobre su uso.

Los temas destacados en estas plataformas incluyen: el papel central de los grandes modelos de lenguaje en las herramientas de eficiencia del flujo de trabajo; la importancia de la precisión: los enfoques van desde establecer los parámetros de temperatura del LLM en cero hasta desarrollar nuevas técnicas de generación de respuestas para limitar las alucinaciones del modelo; la importancia de la "intervención humana" (por ejemplo, señalar la incertidumbre en los resultados y proporcionar herramientas útiles para facilitar la validación humana); y paralelismos entre

Asignadores de activos y capital privado: como puede observarse, varias plataformas que ofrecen herramientas para asignadores de activos tienen al capital privado como su principal base de clientes.

8. Desafíos y riesgos

Es probable que la implementación de métodos de ciencia de datos en el ámbito de la asignación de activos presente desafíos sustanciales, tanto desde una perspectiva técnica como organizativa y de gobernanza.

Desafíos técnicos

Como ya se mencionó en la Sección 4, los gestores de fondos se enfrentan a diversos problemas técnicos relacionados con la alta dimensionalidad, la falta de uniformidad y la escasez de datos de entrada. Además, los datos se reciben en una amplia variedad de formatos y con intervalos variables, que suelen oscilar entre diarios y trimestrales. Otros problemas relacionados con los datos incluyen sesgos de selección (dado que el sector de los fondos tiene obligaciones mínimas de divulgación pública) y desequilibrios entre clases (por ejemplo, casos excepcionales de gestores que generan un rendimiento persistentemente superior).

Los ciclos de retroalimentación prolongados representan un desafío en materia de datos para los gestores de carteras, como por ejemplo los horizontes de inversión de más de 10 años en ciertos fondos de capital privado. En estos casos, se requieren series temporales extremadamente largas para obtener datos suficientes para el entrenamiento, el ajuste y la prueba de los modelos; sin embargo, la recopilación de estas series resulta compleja e introduce problemas derivados de la variabilidad en la calidad de los datos y la no estacionariedad del entorno de inversión.

Como se señala en la Sección 5, otros desafíos técnicos incluyen: la agregación de métodos analíticos en distintas clases de activos con diferentes roles y características subyacentes de la cartera; y formas de optimización multicriterio: además de los objetivos de rendimiento, los asignadores a menudo deben tener en cuenta la gestión de la liquidez y los factores relacionados con los criterios ESG, así como, en algunos casos, los objetivos no financieros.

Desafíos organizativos y de gobernanza

Los desafíos organizativos y de gobernanza no son exclusivos de los asignadores de fondos, pero sin duda son consideraciones particularmente importantes para las organizaciones que se encuentran por encima de grandes jerarquías de datos y que están sujetas a un alto escrutinio externo, como los fiduciarios de activos benéficos. Los desafíos incluyen:

- Riesgo de seguridad de los datos: el riesgo de seguridad es generalmente una de las principales preocupaciones de los asignadores (Lopez, 2025).
Esto abarca una amplia gama de riesgos; un área de especial preocupación en la actualidad se relaciona con el riesgo de fugas de datos no intencionadas mediante el uso de nuevas herramientas y plataformas de IA.
- Requisito de calidad y precisión de los datos: las herramientas de IA cometen errores y generan ilusiones, y la comprensión de las limitaciones de los modelos sigue siendo un área de investigación de vanguardia. El rendimiento de las herramientas de IA puede ser poco intuitivo y deficiente en ciertos contextos; véase, por ejemplo, Shojaee et al. (2025).
Será fundamental desarrollar marcos sólidos para validar los resultados de estas herramientas si se pretende integrarlas plenamente y utilizarlas de forma fiable en los procesos de inversión de Allocated.
- Requisito de toma de decisiones explicable y auditable: decisiones a las que se refiere la "caja negra".
Los modelos contribuyen y plantean desafíos desde la perspectiva de la auditoría, especialmente para los asignadores, quienes pueden verse obligados a explicar sus decisiones a una amplia gama de partes interesadas externas.
- Tiempo y coste financiero: integrar herramientas de IA en los flujos de trabajo puede ser costoso y requerir mucho tiempo. En la práctica, los resultados pueden ser inferiores a las expectativas y a la percepción del usuario.

(Becker, Rush, Barnes y Rein, 2025). La limitada experiencia colectiva dentro de la industria en torno a la efectividad de estas herramientas significa que los asignadores deben dar un salto de fe para invertir tiempo y recursos en estas áreas.

Si bien no es exclusivo de los responsables de la asignación de recursos, las organizaciones también deben considerar una amplia gama de cuestiones relacionadas con nuevas prácticas laborales no probadas. Por ejemplo, surgen preguntas sobre cómo las herramientas de transcripción de llamadas y reuniones pueden cambiar la naturaleza de las conversaciones informales; cómo capacitar a los nuevos miembros del equipo si se automatizan las tareas tradicionales de los analistas junior; y cómo integrar la validación de los resultados generados por la IA en los flujos de trabajo, para evitar depender de la validación humana, que podría fallar en períodos de alta demanda.

Desarrollos para abordar estos desafíos

Si bien estos problemas representan un camino espinoso para los gestores de activos, es probable que muchos desafíos disminuyan con el tiempo gracias a: una mayor precisión de los modelos de lenguaje a gran escala; prácticas más consolidadas en torno al uso de herramientas de IA; un crecimiento continuo de los conjuntos de datos externos relevantes; y la mejora de las herramientas y plataformas para gestionar jerarquías de datos complejas y extraer información valiosa de ellas.

Áreas importantes de investigación actual, que también pueden ayudar a abordar algunos de estos desafíos, incluir:

- IA explicable (o 'XAI'): si bien la explicabilidad siempre es una consideración importante para los métodos de modelado no lineales y de alta dimensión, como las redes neuronales, la XAI es un área destacada de la investigación actual, que contribuye progresivamente a abordar aspectos de la explicabilidad. Además de una amplia gama de enfoques emergentes específicos para cada modelo, los métodos con amplia aplicación incluyen: técnicas para evaluar la importancia de las características, como las Explicaciones Aditivas de Shapley (SHAP) (Lundberg y Lee, 2017) y técnicas para extraer reglas simplificadoras, como las Explicaciones Locales Interpretables e Independientes del Modelo (LIME). (Ribeiro, Singh y Guestrin, 2016). Véase Arrieta et al. (2020) para un estudio de esta área.
- Métodos de generación de datos sintéticos, incluidas las redes generativas antagónicas.
Las redes generativas antagónicas (GAN) (Goodfellow et al., 2014) tienen un gran potencial para enriquecer conjuntos de datos escasos. Véase, por ejemplo, Kieffer et al. (2023) sobre la generación de datos sintéticos de flujo de caja en el sector de capital privado.

9. Paralelismos con el capital privado

El capital privado está experimentando su propia transformación tecnológica, como lo describen, por ejemplo, Chmimo (2025) y Astebro (2021). Chmimo argumenta que el uso de herramientas de IA, en particular en torno a aspectos de la automatización de flujos de trabajo impulsados por IA, ya no es una innovación periférica en la industria del capital privado, sino una necesidad para que los gestores de activos mantengan competitividad.

Los gestores de capital privado se enfrentan a muchos retos similares a los de los gestores de activos, como por ejemplo: datos de entrada escasos, difíciles de recopilar y caracterizados por largos ciclos de retroalimentación; marcos de decisión en los que el análisis cualitativo y las evaluaciones de las personas desempeñan un papel importante; y procesos de implementación de inversiones que pueden ser laboriosos y requerir mucha documentación, para los que la eficiencia operativa es fundamental.

Entre los aprendizajes transferibles del capital privado se podrían incluir:

- Modelo de experto aumentado: énfasis en un enfoque de experto aumentado en lugar de la automatización completa. Es probable que los humanos siempre sean quienes tomen las decisiones finales en procesos de inversión largos y complejos, tanto para inversores de capital privado como para gestores de activos.
- Importancia de la experiencia del usuario ('UX'): una serie de estudios de caso de capital privado destacan la importancia de diseñar una experiencia de usuario sencilla para impulsar la adopción de nuevas herramientas y tecnologías, y para garantizar la continuidad del compromiso del equipo a lo largo del tiempo.
- Importancia de la gobernanza de datos: en particular, la estructuración de los datos internos en cada etapa del proceso y la prevención de la fragmentación de datos en sistemas dispares. La fragmentación de datos se considera un desafío importante tanto para los proyectos de big data como para la eficiencia de los flujos de trabajo.
- Importancia de la explicabilidad: los estudios de caso de capital privado indican, en general, una preferencia por los métodos de modelado sencillos, con una explicabilidad inherentemente mejor, así como por los métodos de IA explicable.

Otros aspectos, como la importancia del compromiso del liderazgo y la preparación cultural dentro de las organizaciones que determinan el éxito o el fracaso de los proyectos en este ámbito también se debaten con frecuencia tanto en el contexto del capital privado como en el de los gestores de activos. Véase, por ejemplo, Monk & Rook (2020) y Chmimo (2025).

10. Conclusión

Este artículo analiza a los gestores de activos como un campo de aplicación incipiente, pero cada vez más relevante, para el aprendizaje automático y otros métodos computacionales. Hasta la fecha, los gestores de activos han estado poco representados en la literatura sobre ciencia de datos, a pesar de que representan una cantidad sustancial de activos financieros a nivel mundial y, en muchos casos, cumplen funciones de gran importancia social (como fondos universitarios, organizaciones benéficas y fondos de pensiones).

Situados en la cúspide de complejas jerarquías de datos de entrada, los Asignadores se encuentran en una posición privilegiada para beneficiarse de los métodos de ciencia de datos si se logran superar los desafíos técnicos y organizativos. La aparición de grandes modelos de lenguaje en los últimos años marca un punto de inflexión importante, tanto para generar interés en las herramientas de IA en el ámbito de los Asignadores como para sus posibles aplicaciones en la mejora de la recopilación de datos en un área donde se reciben grandes cantidades de datos en formatos heterogéneos y no estructurados. Tras la transformación que se está produciendo en el capital privado, el grupo de investigación de Ciencias de la Dotación de la UCL considera que los Asignadores de Activos representan una importante nueva frontera en la ciencia de datos financieros.

Agradecemos sus comentarios, sugerencias e ideas; pueden enviarlas a: chloe.taysom.20@ucl.ac.uk.

Expresiones de gratitud

Los autores agradecen al Dr. Michael Recce, director ejecutivo de Alpha ROC, su valiosa orientación y sugerencias.

Bibliografía

- Alonso, MN, y Srivastava, S. (2020). Aprendizaje profundo por refuerzo para la asignación de activos en acciones estadounidenses. arXiv:2010.04404v1 .
- Arrieta, AB, Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., . . . Herrera, F. (2020). Explicable Inteligencia Artificial (XAI): conceptos, taxonomías, oportunidades y desafíos para una IA responsable. Información Fusión doi:10.1016/j.inffus.2019.12.012
- Assefa, S., Dervovic, D., Mahfouz, M., Balch, T., Reddy, P., & Veloso, M. (2019). Generación de datos sintéticos en finanzas: oportunidades, desafíos y escollos. NeurIPS.
- Astebro, T. (2021). Una mirada al interior del uso de la IA en el capital privado. Revista de Ciencia de datos financieros.
- Atkinson, SM, Baird, SB y Frye, MB (2003). ¿GESTIONAN LAS MUJERES FONDOS MUTUOS DE FORMA DIFERENTE? La Revista de Investigación financiera
- Bakhr, R. (2025, 25 de febrero). Comprender el Poder de AI Agentes en Gestión de inversiones . Obtenido de Blueflame AI: <https://www.blueflame.ai/blog/understanding-the-power-of-ai-agents-in-investment-management>
- Bartram, SM, Branke, J. y Motahari, M. (2020). Inteligencia artificial en la gestión de activos. Investigación del Instituto CFA Base.
- Becker, J., Rush, N., Barnes, B., y Rein, D. (2025). Medir la Impacto de Principios de 2025^{IA} en software de código abierto con experiencia Productividad del desarrollador. Obtenido de arXiv:2507.09089
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Aprender dependencias a largo plazo con descenso de gradiente es difícil. IEEE Transacciones sobre redes neuronales, 5(2) , 157-66. doi:10.1109/72.279181
- Benoit, S., & Raffinot, T. (2018). Inversión a través de ciclos económicos con algoritmos de aprendizaje automático de conjunto. Disponible en SSRN: <https://ssrn.com/abstract=2785583>Gestión . doi:10.2139/ssrn.2785583
- Berkelaar, A., Misis, K. y Stimes, PC (2022). de carteras para inversores institucionales, CFA Nivel III, Lectura 24. Instituto CFA.
- Berkelaar, A., Misis, K., & Stimes, PC (2025). Construcción de carteras: Gestión de carteras para inversores institucionales. CFA Instituto.
- Brinke, LT, Kish, A., & Keltner, D. (2018). Los gestores de fondos de cobertura con tendencias psicopáticas empeoran las cosas. Inversores. Boletín de Psicología Social Personal , 214-233. doi:10.1177/0146167217733080
- Brown, S., Lu, Y., Ray, S., & Teo, M. (2018). Búsqueda de sensaciones y fondos de cobertura. Revista de Finanzas .
- Carnelli Dompe, A. y Ferri, D. (2021). <https://www.pantheon.com/wp-content/uploads/2021/06/Machine-learning-The-value-edge.pdf> Aprendizaje automático: La ventaja en la valoración. Panteón. Obtenido de www.pantheon.com/wp-content/uploads/2021/06/Machine-learning-The-value-edge.pdf
- Chambers, D., Dimson, E., & Foo, J. (2015). Keynes, el inversor en bolsa: un análisis cuantitativo. La Revista de Análisis financiero y cuantitativo .
- Chambers, D., Dimson, E., y Kaffe, C. (2020). Setenta y cinco años invirtiendo para las generaciones futuras. Analistas financieros Diario . doi:10.1080/0015198X.2020.1802984
- Chen, J., y Tsang, EP (2020). Detección de cambios de régimen en Finanzas Computacionales: Ciencia de Datos, Aprendizaje Automático y Comercio algorítmico.
- Chmimo, W. (2025). Transformación de las operaciones de capital privado mediante la automatización de flujos de trabajo impulsada por IA: una revisión integral Revisar. Revista Internacional de Negocio & Ciencias Computacionales .
- Creswell, A., White, T., Dumoulin, V., Arulkumaran, K., Sengupta, B., & Bharath, AA (2018). Generative Adversarial Redes: Una visión general. Revista de Procesamiento de Señales del IEEE doi:10.1109/MSP.2017.2765202
- Da Silva, B., & Shi, SS (2019). Transferencia de estilo con series temporales: Generación de datos financieros sintéticos. arXiv:1906.03232v2 .
- Dasetti. (2025). www.digitization.com proceso ODD: Guía de mejores prácticas 2025.
- Emerson, S., Kennedy, R., O'Shea, L., & O'Brien, J. (2019). Tendencias y aplicaciones del aprendizaje automático en métodos cuantitativos Finanzas. 8ª Conferencia Internacional sobre Investigación Económica y Financiera (ICEFR 2019).
- Erikson, G., & Holmberg, M. (2024). Modelización de los rendimientos del capital privado: revisión del modelo de Takahashi-Alexander.
- Ertelice, O., & Kalayci, CB (2018). Un estudio sobre la inteligencia de enjambre para la optimización de carteras: algoritmos y aplicaciones. Computación de enjambre y evolutiva . doi:10.1016/j.swevo.2018.01.009
- Feiner, A. (2018). El aprendizaje automático y el big data permiten un enfoque cuantitativo para la inversión ESG. Investigación del Instituto CFA Fundación: Integrando la inversión sostenible .
- Fernández Tamayo, B., Braun, R., López-de-Silanes, F., Phallipou, L. y Sigrist, N. (2023). Socios limitados versus ilimitados Máquinas; Inteligencia Artificial y el Rendimiento de los Fondos de Capital Privado. SSRN .
- Gadesha, V., Kavlakoglu, E. y Winland, V. (2025). ¿Qué es la inducción de cadena de pensamiento (CoT)? Obtenido de IBM El Guía 2025 para la ingeniería ágil: <https://www.ibm.com/think/topics/chain-of-thoughts>
- Garleanu, N., y Pedersen, LH (2013). Comercio dinámico con rendimientos y costos de transacción predecibles. La Revista de Finanzas doi:10.1111/jofi.12080
- Oficina de Inversiones de la Universidad de Georgetown. Informe anual de la Oficina de Inversiones de la Universidad de Georgetown - 2024. Recuperado (2024). Disponible en <https://investments.georgetown.edu/team/annual-report/>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., . . . Bengio, Y. (2014). Generativo Redes adversarias. Avances en Sistemas de Procesamiento de Información Neuronal 27 (NIPS 2014).

- Hayes, M., Primbs, JA, & Chiquoine, B. (2015). Un enfoque de costo de penalización para la asignación estratégica de activos con activos ilíquidos. *Clases. Revista de Gestión de cartera*.
- Hayman, G. (2024, diciembre). Pensiones en la era de la inteligencia artificial. CFA Institute.
- Helgesson, A. y Lindblad, C. (2020). ¿Son las mujeres los verdaderos machos alfa? Universidad de Gotemburgo.
- Hu, J.-L., Yu, H.-E., & Wang, Y.-T. (2012). Atributos del gestor y rendimiento del fondo: evidencia de Taiwán. *Revista de Finanzas Aplicadas y Banca*.
- Huuhka, T. (2022). Modelo Black-Litterman basado en regímenes para la asignación estratégica de activos de inversores institucionales. *Alto Universidad*.
- En, SY, Rook, D., & Monk, A. (2019). Integrating Alternative Data (Also Known as ESG Data) in Investment Decision Making. *Revista Económica Global*. doi:10.1080/1226508X.2019.1643059
- Kieffer, E., Meyer, T., Gloukoviezoff, G., Lucius, H. y Bouvry, P. (2023). Aprender estrategias de renovación de compromisos de capital privado para inversores institucionales. *Front. Artificial. Intell.*
- Kinlaw, W., Kritzman, M., & Turkington, D. (2013). Liquidez y elección de cartera: un enfoque unificado. *Revista de Cartera Gestión*.
- Koshiyama, A., Firoozye, N. y Treleaven, P. (2020). <https://ssrn.com/abstract=3527511> Algoritmos en los futuros mercados de capitales. Obtenido de
- LeCun, Y. (28 de julio de 2016). ¿Cuáles son algunos de los avances recientes y potencialmente futuros en el aprendizaje profundo? Obtenido de Quora: <https://quorassessionwithyannlecn.quora.com/What-are-some-recent-and-potentially-upcoming-breakthroughs-in-deep-learning>
- Lo, AW, Petrov, C., & Wierzbicki, M. (2003). Son las 11 pm - ¿Sabes dónde está tu liquidez? La media-varianza Frontera de liquidez. *Diario De Gestión de inversiones*.
- López, M. (26 de agosto de 2025). La brecha en la implementación de la IA: ¿Qué está deteniendo a los asignadores de activos? Con Melissa López. (A. Calvello, entrevistador)
- Lu, Y., Ray, S., & Teo, M. (2016). Atención limitada, eventos matrimoniales y fondos de cobertura. *Revista de Economía financiera*.
- Lundberg, SM, & Lee, SI (2017). Un enfoque unificado para interpretar las predicciones de los modelos. *Avances en Información neuronal* Sistemas de procesamiento, 4765-4774.
- Mariani, G., Zhu, Y., Li, J., Scheidegger, F., Istrate, R., Bekas, C. y Malossi, AC (2019). PAGAN: Análisis de Cartera con Redes generativas antagónicas. [arXiv:1909.10578](https://arxiv.org/abs/1909.10578)The.
- Markowitz, H. (1952). Selección de cartera. *Journal of Finance* doi:10.2307/2975974
- Metaxiotis, K., & Liagkouras, K. (2012). Algoritmos evolutivos multiobjetivo para la gestión de carteras: una revisión exhaustiva. doi:10.1016/j.eswa.2012.04.053
- Milne, R., & Wigglesworth, R. (1 de mayo de 2025). El fondo petrolero de Noruega busca ahorrar 400 millones de dólares en costos de negociación mediante IA. Recuperado de <https://www.ft.com/content/6cda7685-40f7-493a-9d24-8355083c8ecd>
- Monk, AH y Rook, D. (2020). El inversor tecnificado: Innovación a través de la reorientación. *Editorial de la Universidad de Stanford*.
- Monk, A., Rook, D., & Sharma, R. (2026). La caja de cambios del propietario de activos: por qué la innovación en la inversión se estanca y cómo hacerla efectiva. *se gira. SSRN*.
- Mulvey, J. (2019). Un modelo multirégimen para un Fondo de dotación universitaria Obtenido de Coursera: <https://www.coursera.org/lecture/python-machine-learning-for-investment-management/a-multi-regime-model-for-a-university-endowment-84L90>
- Mulvey, J., & Liu, H. (2016). Identificación de regímenes económicos: reducción de riesgos a la baja para las dotaciones universitarias y 100-108. *Cimientos. Revista de Gestión de cartera*.
- Mulvey, J., & Martellini, L. (2020). Python y aprendizaje automático para la gestión de activos. *Coursera* Disponible en línea en: <https://www.coursera.org/learn/python-machine-learning-for-investment-management>.
- Niessen-Ruenzi, A., y Ruenzi, S. (2017). El sexo importa: sesgo de género en la industria de los fondos mutuos. *Ciencias de la gestión*.
- Phalippou, L. (2025). Socios limitados frente a tecnologías ilimitadas: cómo la tecnología podría transformar la inversión en capital privado. *Fondos*.
- Pisaneschi, B. (2025). RAG para Finanzas: Automatización del análisis de documentos con LLM Obtenido del CFA Institute: <https://rpc.cfainstitute.org/research/the-automation-ahead-content-series/retrieval-augmented-generation>
- Pomorski, P. (2024). Construcción de carteras eficaces para el cambio de régimen mediante a Combinación de Aprendizaje automático y enfoques tradicionales. *UCL*.
- Oficina de Inversiones de la Fundación de Investigación de Purdue. (30 de julio de 2024). Un Perspectiva del asignador de activos sobre AI Casos de uso. Obtenido de <https://business.purdue.edu/daniels-insights/posts/2024/an-asset-allocators-perspective-on-ai-use-cases.php>
- Ramanathan, A. (2025, 14 de febrero). Adiós RAG: cómo Hebbia resolvió la recuperación de información para Hebbia: <https://www.hebbia.com/blog/goodbye-rag-how-hebbia-solved-information-retrieval-for-lms> Obtenido de Hebbia en Oracle LLM.
- Ribeiro, MT, Singh, S., & Guestrin, C. (2016). ¿Por qué debería confiar en ti? Explicando las predicciones de cualquier clasificador. *Actas de la 22ª Conferencia Internacional ACM SIGKDD sobre Descubrimiento de Conocimiento y Minería de Datos*.
- Righi, MB, & Borenstein, D. (2018). Una comparación mediante simulación de medidas de riesgo para la optimización de carteras. *Investigación financiera Letras*.
- Sakopta, R., Roumeliotis, KI, & Karkee, M. (2025). Agentes de IA frente a IA agéntica: una taxonomía conceptual, aplicaciones y Desafíos. [arXiv:2505.10468v1](https://arxiv.org/abs/2505.10468v1).
- Sharkey, E., Craciun, S., y Treleaven, P. (2025). Desarrollos de modelos de lenguaje a gran escala.
- Shojaee, P., Mirzadeh, I., Alizadeh, K., Horton, M., Bengio, S., y Farajtabar, M. (2025, junio). La ilusión del pensamiento: comprender las fortalezas y limitaciones de los modelos de razonamiento a través del prisma de la complejidad del problema. *Recuperado de https://machinelearning.apple.com/research/illusion-of-thinking*
- Swensen, DF (2000). *Gestión de carteras pionera: Un Enfoque no convencional a Inversión institucional*.

- Swensen, DF (2000). *Gestión de carteras innovadora: un enfoque no convencional*. Edición revisada y actualizada. Prensa libre. ^a Inversión institucional, totalmente
- Swensen, DF (2009). *Gestión de carteras innovadora: un enfoque no convencional* (Revisado y actualizado). Prensa libre. ^a Inversión institucional, totalmente
- Takahashi, D., y Alexander, S. (2002). Modelización de fondos de activos alternativos ilíquidos. *Revista de Gestión de cartera*,
- Takahashi, S., Chen, Y., & Tanaka-Ishii, K. (2019). Modelado de series temporales financieras con redes generativas antagónicas. *Física A: Mecánica estadística y sus Aplicaciones*. doi:10.1016/j.physa.2019.121261
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, AN, . . . Polosukhin, I. (2017). La atención es todo tú Necesidad. NIPS.
- Vishwakarma, KP (1994). Reconocimiento de puntos de inflexión del ciclo económico mediante una red neuronal. *Computational Ciencias económicas*.
- Wolf, T., Debut, L., Sanh, V., Chaumond, J., Delangue, C., Moi, A., . . . Rush, A. (2020). Transformers: Estado del arte Procesamiento del lenguaje natural. *Natural: Demos y Centros de Investigación sobre Métodos Empíricos Procesamiento del Lenguaje*
- Oficina de Inversiones de Yale. (2010). Actualización del Fondo de Dotación de Yale de 2010. Yale. Obtenido de <https://investments.yale.edu/reports>
- Zhang, Z., Zohren, S., & Roberts, S. (2021). Aprendizaje profundo para la optimización de carteras. arXiv:2005.13665v3 .