#64

# Observatorio de Divulgación Financiera

Febrero 2026
Depósito legal: B 21662-2012

DOCUMENTO DE TRABAJO

# Aplicación de sistemas multiagente de IA al asesoramiento y gestión de inversiones

Júlia Pou
Eric Garcia
Miquel Heredia
Carlos Salinas
Gerard Alba

IEF Instituto de Estudios Financieros – Research Institute

Caja Ingenieros FUNDACIÓN

# Abstract

Este estudio presenta un análisis sobre la innovación y la transformación digital en el sector financiero mediante el uso de la Inteligencia Artificial Generativa, con especial énfasis en el ámbito del asesoramiento y la gestión de inversiones, combinando aspectos generales y de negocio, con la implementación práctica en una entidad. Se destaca el papel emergente de la Inteligencia Artificial Generativa como interlocutor entre clientes y asesores, así como herramienta facilitante de procesos de toma de decisiones más informadas, eficientes y personalizadas. Se quiere demostrar cómo a través de su capacidad para integrar información de investigación y generar respuestas contextualizadas, la Inteligencia Artificial Generativa transforma el rol tradicional del asesor financiero.

En paralelo, se aporta una visión técnica detallada sobre el desarrollo y el funcionamiento de los Sistemas de Multiagentes y Modelos de Lenguaje de gran escala (LLM's), que constituyen la base tecnológica de estas nuevas herramientas. El piloto implementado permite confirmar la viabilidad del enfoque de arquitectura multiagente para generar análisis financieros enriquecidos; la colaboración de agentes especializados con un agente integrador produjo informes comprensivos. La explotación con éxito de datos no estructurados para extraer información relevante en el análisis financiero de inversiones es otra innovación destacada en el sector y una aportación importante de estos agentes de IA.

Finalmente, se muestra cómo está evolucionando el sector con ejemplos, y como MoraBanc ha sabido adaptarse estratégicamente a estas nuevas tendencias. El estudio reflexiona sobre los retos, oportunidades y alcance de esta revolución tecnológica, ofreciendo una visión global e integradora del futuro del asesoramiento financiero potenciado por la inteligencia artificial.

# 1. Introducción

## 1.1. Objetivo del estudio: analizar la transformación del asesoramiento financiero con la aplicación de la IA generativa

El objetivo principal de este estudio es analizar cómo la Inteligencia Artificial Generativa, una tecnología emergente de gran potencial, puede contribuir positivamente en el sector financiero. Se quiere realizar un estudio de la evolución de su integración en el sector, con especial atención a la gestión de inversiones y sus aplicaciones prácticas en el asesoramiento financiero.

Hasta hace pocos años, las entidades financieras tradicionales eran las únicas encargadas de gestionar servicios bancarios. Ahora, nos encontramos en un punto de inflexión en el que la accesibilidad está al alcance de todos. Cualquier persona con conexión a internet puede operar en bolsa, realizar consultas de su situación financiera, solicitar microcréditos o bien contratar seguros. Este factor clave en el desarrollo del sector ha supuesto una apertura económica hacia un sistema más competitivo. (CMS Prime 2025 – AI Revolution 2025: Trends, Market Impact, and Key Stocks).

**Gráfico 1. Evolución del número de oficinas bancarias y del uso de la banca digital en España**

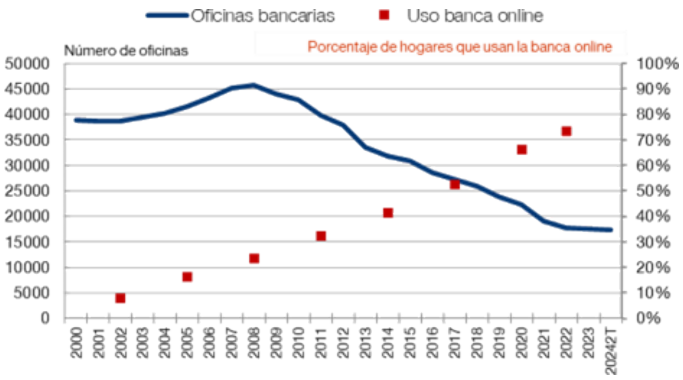


Fuente: Banco de España

https://www.bde.es/wbe/es/noticias-eventos/blog/el-auge-de-la-banca-online-como-mitigar-los-riesgos-de-exclusion-financiera.html

La incorporación de la inteligencia artificial ha sido el factor más transformador de los últimos años. Sin embargo, cabe mencionar que no todos los territorios están igual de preparados para adaptarse a esta situación cambiante. En áreas con fuerte implantación bancaria como los países Occidentales, los nuevos modelos pueden desencadenar una reconfiguración del sector bancario conocido. Otras zonas como en África, donde sólo un 30% de la población dispone de una cuenta bancaria y la presencia física de oficinas bancarias resulta inviable, tener oportunidades digitales puede fomentar una inclusión financiera. (Igual Molina 2018 – Les fintech i la reinvenció de les finances)

Por otro lado, en el proyecto se incluye una visión técnica del desarrollo y funcionamiento de los sistemas multiagente y los modelos de lenguaje de gran escala (LLMs), base tecnológica de estas herramientas. El piloto implementado tiene como objetivo mostrar la viabilidad de los nuevos multiagentes y su uso exitoso de datos no-estructurados en el análisis de inversiones, como gran aportación a los procesos existentes en análisis de inversiones y asesoramiento.

Este estudio también tiene como objetivo mostrar los pasos que está tomando una entidad de banca privada de referencia como MoraBanc para adaptarse a esta revolución tecnológica, asegurándose de que el banco evoluciona a la misma velocidad que los líderes del sector y aprovecha las oportunidades que la IA Generativa ofrece para mejorar su oferta de servicios.

## 1.2. La transformación digital y su evolución en el sector financiero y los servicios de inversión

Vivimos inmersos en un sistema que integra las finanzas en casi todos los aspectos de la vida diaria. Desde las primeras horas del día, cuando una persona despierta en una vivienda financiada a través de un préstamo hipotecario, hasta las últimas, cuando llega a casa y consume alimentos adquiridos con una tarjeta de crédito,

su día transcurre dentro de un circuito constante de decisiones y acciones económicas.

No es ningún secreto que la inteligencia artificial ha llegado para redefinir los límites de nuestra eficiencia y el ámbito financiero ya no es ajeno a esta revolución tecnológica. Desde el análisis avanzado de datos para predecir tendencias de mercado, controlar riesgos como se menciona en Karasan, A. (2021) - Machine Learning for Financial Risk Management with Python, o mejoras en las operaciones mediante la ciencia de datos y el aprendizaje automático, pasando por el uso de la IA generativa como soporte en la toma de decisiones y detectar fraudes en tiempo real, el potencial impacto es enorme. (Dixon et al, M. (2020) - Machine Learning in Finance From Theory to Practice. Springer). Todo apunta hacia un futuro donde las decisiones económicas serán más rápidas y precisas que nunca. Los servicios financieros: el crédito, la inversión, los seguros o las transacciones de dinero, también evolucionarán, mejorando a su vez el servicio y personalización a clientes.

La transformación digital a nivel financiero se inaugura con el concepto de la tecnología financiera o Fintech (IBM 2025 – Fintech), (CNMV 2025 – Guía rápida Fintech), que describe el uso de tecnologías para mejorar o innovar los servicios financieros. En sus inicios, Fintech se encargó de introducir plataformas digitales para mejorar la realización de pagos, préstamos y gestión de cuentas utilizando tecnologías como aplicaciones móviles, entre muchos otros.

**Gráfico 2. Distribución de las Fintech por segmento de actividad financiera**

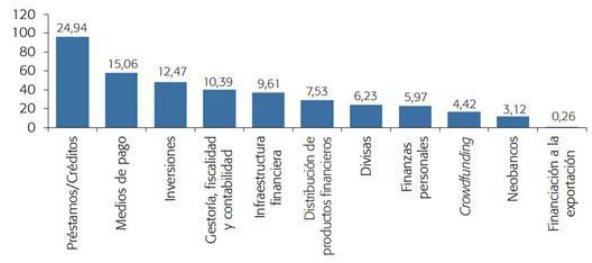


Fuente: Finnovating - Funcas
https://www.funcas.es/wpcontent/uploads/Migracion/Articulos/FUNCAS_CIE/274art05.pdf

El gráfico 1 refleja una concentración de las fintech españolas del 62,86% en los cuatro segmentos señalados: crédito, pagos, inversiones y gestoría.

A medida que el sector evoluciona, se incorpora también la tecnología de la ciencia de datos, el aprendizaje automático o Machine Learning (IBM 2025 – What is Machine Learning), una rama de la Inteligencia Artificial numérica que se centra sobretodo en el desarrollo de modelos, calibrando algoritmos (supervisados, no supervisados o de aprendizaje reforzado) con datos del problema a resolver. Gracias a la construcción de algoritmos matemáticos que definen cómo los sistemas procesan y transforman grandes volúmenes de información para identificar patrones y tendencias, estos modelos ajustan sus parámetros internos para minimizar errores en predicciones, cuyos resultados se interpretan mediante métricas clave propias de cada técnica implementada. En finanzas, pueden resultar muy útiles para detectar anomalías, predecir movimientos de mercado o personalizar servicios para cada cliente.

El uso de modelos Multiagente con IA Generativa ofrece una nueva perspectiva en el Asesoramiento financiero y la Gestión de inversiones. La combinación de arquitecturas multiagente con LLMs para explotar datos multimodales no estructurados — y extraer de ellos información relevante— representa un gran avance en este camino de innovación del sector. Aunque ambos ámbitos de inversiones se ven beneficiados por la revolución tecnológica de la IA generativa, hay que matizar que es necesario continuar desarrollando los modelos para poder llegar a delegar al completo la toma de decisiones finales sobre las inversiones en los robots. Las decisiones de inversión, por la naturaleza eficiente de los mercados, es un ámbito especialmente difícil para su modelización, tal como refleja la literatura abundante del tema. (AQR. (2024) - Machine Learning: Why Finance Is Different). Actualmente, los avances se concentran en la automatización del proceso de búsqueda y recopilación de información, pero todavía no todos los modelos generan resultados fiables sin supervisión humana. En los siguientes apartados, mostraremos la implementación en una organización de servicios de inversión de esta nueva tecnología, con resultados muy prometedores.

Como bien muestra la lectura (Banco de España 2019 – Inteligencia artificial en los servicios financieros) las aplicaciones de la IA generativa en el sector financiero pueden ser infinitas, pero los primeros avances han sido focalizados en la eficiencia operativa y la optimización de tareas rutinarias. Esta evolución en los algoritmos se refleja en áreas como la gestión inteligente de datos o el procesamiento automatizado de transacciones.

Por otro lado, un tema clave que beneficia a las empresas es la incorporación de sistemas de personalización y los chatbots. Gracias a análisis autónomos de las tendencias de cada cliente, la IA puede ofrecer servicios de atención enfocados y adaptados a cada individuo. Tras evaluaciones automatizadas en tiempo real de tendencias y patrones de cada perfil, la entidad puede ofrecer un servicio de asesoramiento personalizado.

Por último, otro ámbito en el que destaca la aplicación de la IA es la gestión de riesgos. (McKinsey & Company 2024 – IA generativa para la gestión de riesgos en bancos). Sean riesgos de crédito, riesgos de mercado, suscripción y siniestralidad en seguros, cibernéticos, riesgos climáticos o posibles delitos financieros, la IA permite automatizar evaluaciones de riesgos, un paso más allá de los modelos de aprendizaje automático de la ciencia de datos tradicional. Además, en base a entrenar a los agentes, éstos acaban identificando automáticamente patrones asociados a movimientos sospechosos y pueden contribuir a reforzar la seguridad de las operaciones financieras, minimizando el impacto de posibles amenazas.

Las entidades financieras están aplicando herramientas de inteligencia artificial en toda la cadena de valor y para todo tipo de servicios.

**Esquema 1. Ejemplos de uso de la Inteligencia Artificial**

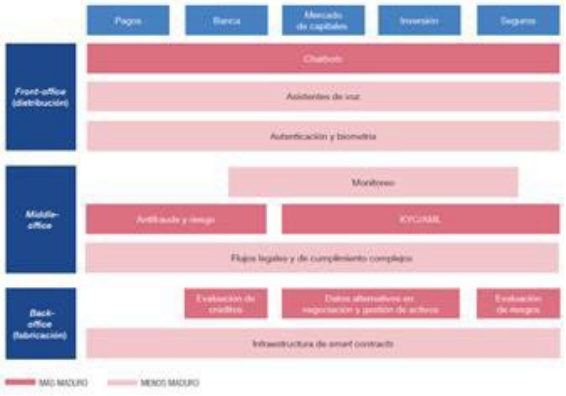


Fuente: Finnovating - Funcas

https://www.bde.es/wbe/es/publicaciones/publicaciones-discontinuadas/articulos-analiticos/inteligencia-artificial-servicios-financieros.html

### 1.3. Las grandes tecnológicas como nuevos players en el sector financiero y en los servicios de inversión

Más allá de los bancos tradicionales, el sector financiero ha empezado a ver la entrada de nuevos competidores procedentes del ámbito digital. Apple, Google, Amazon... son ahora las grandes tecnológicas del sector. (Banco de España 2025 – Gigantes tecnológicos: big tech y su papel en el sector financiero). Las llamadas big tech se hicieron un sitio en el mundo financiero aprovechando su oligopolio de la actividad digital, con el objetivo de desarrollar más negocios y ofrecer más servicios al usuario. Empezando por los pagos electrónicos, se introdujeron en el mercado financiero de una forma ágil, rápida y estable. Poco a poco empezaron a abrir otros servicios como las concesiones de crédito o las operaciones con criptomonedas. En el ámbito de los servicios de inversión, la relevancia de las big tech no se limita a pagos o crédito: su capacidad de distribuir productos digitales a gran escala, personalizar servicios mediante datos y desplegar IA avanzada facilita la aparición de nuevas formas de inversión integradas en plataformas (por ejemplo, acceso simplificado a productos de inversión, herramientas de análisis y soporte automatizado al asesoramiento). En este sentido, su entrada acelera la digitalización del ciclo inversor (recopilación de información, análisis y generación de recomendaciones), que es precisamente el foco de este

trabajo mediante sistemas multiagente basados en IA generativa.

A estas alturas, las grandes tecnológicas son o estadounidenses o chinas. Funciones tan conocidas como el ApplePay creado por Meta en 2022 o la integración de la función BNPL (Buy Now, Pay Later) por Amazon en 2021, son algunas de las iniciativas recientes de las big tech que han llegado para marcar un antes y un después en las aplicaciones de la tecnología en las finanzas. El potencial y crecimiento de estas empresas es extraordinario, además de su valor en bolsa muy por encima de cualquier principal grupo financiero.

Su éxito nace de la capacidad de innovar constantemente y adaptarse a las necesidades tanto del mercado como de los usuarios. Empresas como Microsoft o Google han sabido utilizar su infraestructura tecnológica, el inmenso volumen de datos e información que poseen y la confianza de sus clientes para expandirse hacia el sector financiero. El nacimiento de las big tech en el sector financiero supone un cambio estructural en la forma de entender las finanzas. Su enfoque centrado en el usuario, la personalización de servicios y la eficiencia operativa está estableciendo nuevos estándares que las instituciones financieras tradicionales tendrán que asimilar si quieren seguir siendo competitivas. Más que una moda pasajera, la entrada de las big tech es una señal clara de que el futuro del sector financiero será cada vez más digital, más integrado y, sobre todo, más influenciado por el ecosistema tecnológico. (BIS, 2019 - Annual Economic Report 2019)

En este contexto, también es fundamental mencionar a las compañías que lideran el desarrollo de inteligencia artificial generativa aplicada a los servicios financieros. Un ejemplo destacado es Anthropic, con su iniciativa Claude for Financial Services. Esta propuesta está diseñada específicamente para el sector financiero, ofreciendo soluciones basadas en modelos de lenguaje avanzados capaces de mejorar la atención al cliente, automatizar procesos de análisis de riesgo y reforzar la seguridad y la transparencia en las operaciones. Con esta iniciativa, Anthropic se suma al conjunto de empresas tecnológicas que están configurando una nueva etapa en la intersección entre la IA generativa y las finanzas. (Anthropic, 2025 – Claude for Financial Services)

En el presente estudio, analizamos los multiagentes de IA generativa que varias de estas compañías tecnológicas han estado desarrollando. El interés de estas empresas por el sector de los servicios de inversión es manifiesto. Podemos tomar como ejemplo reciente la adquisición por parte de OpenAI (participada por Microsoft) en una startup fintech de IA Generativa para el asesoramiento financiero (Engadget 2025 – *OpenAI acquires an AI-powered personal investing app*)

**Gráfico 3. Capitalización bursátil (2024): Big Tech frente a Bancos Grandes (Big Banks)**

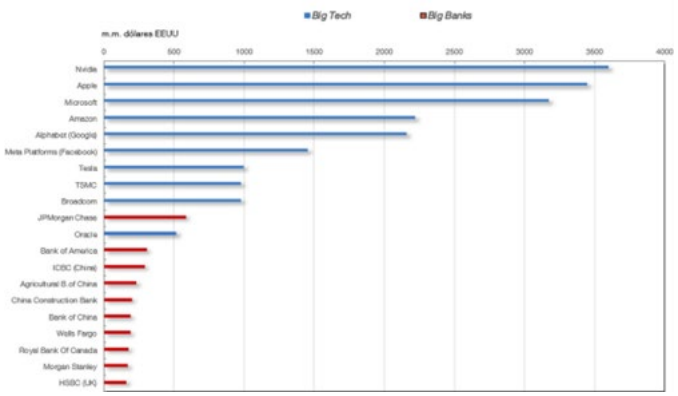


Fuente: Banco de España, Statista y Companies Market Cap (2024) https://www.bde.es/wbe/es/noticias-eventos/blog/gigantes-tecnologicos-big-tech-en-el-sector-financiero-.html

## 1.4. Las grandes tecnológicas como nuevos players en el sector financiero y en los servicios de inversión

En un contexto donde los usuarios son sometidos a tanta innovación es necesario asegurar la confianza y seguridad en el uso de estas nuevas tecnologías y servicios. Por eso, tanto la IA como el propio sector financiero están controlados por un marco regulatorio que vela por la seguridad. Aparte de aportar beneficios, tiene unos riesgos que hay que tener muy presentes.

En primer lugar, la Unión Europea crea THE EU AI ACT, un reglamento concebido para garantizar que los ciudadanos europeos puedan confiar en los sistemas de IA. La regulación establece cuatro niveles de riesgo (inaceptable, alto riesgo, riesgo limitado y riesgo mínimo o

nulo) e impone obligaciones diferentes según la categoría del sistema: por ejemplo, los sistemas de alto riesgo tendrán que cumplir con medidas estrictas de transparencia, fiabilidad, supervisión humana, calidad de datos, evaluación y mitigación del riesgo, y documentación detallada para garantizar la trazabilidad y la
En paralelo, el sector financiero global y europeo se desarrolla dentro de un entorno altamente regulado. Específicamente, también dispone de un marco normativo consolidado para proteger a los inversores en el sector de los servicios de inversión. La normativa MiFID (Markets in Financial Instruments Directive), vigente desde 2007, establece obligaciones estrictas para las entidades financieras que ofrecen servicios como asesoramiento, gestión de carteras o comercialización de productos de inversión. El principal objetivo de la MiFID es garantizar que los clientes reciban información clara y adecuada, y entiendan los riesgos asociados a los servicios que contratan. Además, regula el comportamiento de las entidades para asegurar una actuación responsable. (CaixaBank – *Información sobre MiFID*)

En este contexto, la aplicación de sistemas de inteligencia artificial, especialmente en procesos de asesoramiento

responsabilidad. También incluye prohibiciones por usos que la UE considera inaceptables, y dispone de períodos de implementación gradual para adaptar a los operadores y desarrolladores a las nuevas normativas. ( EU Artificial Intelligence Act Explorer)

automatizado, debe ser compatible con las exigencias de transparencia, idoneidad y protección al consumidor establecidas por la MiFID, que plantea nuevos retos reguladores que obligan a integrar los requerimientos del AI Act con los principios básicos de conducta financiera.

Por último, la nueva figura del Chief Data Protection Officer (CDPO) (TermsFeed. (2022, November 25). *CDPO )* juega un papel esencial en este contexto, ya que debe garantizar que los algoritmos de IA utilizados operar bajo principios de transparencia, equidad y cumplimiento normativo. El CDPO lidera la implementación de políticas de gobernanza de datos, auditorías de modelos de IA y medidas de anonimización y seguridad. De esta manera, su función no solo protege a la organización frente a sanciones regulatorias, sino que también refuerza la confianza del consumidor y la credibilidad institucional en un entorno cada vez más digitalizado y automatizado.

# 2. Bases Tecnológicas

## 2.1. Sistemas Multiagentes: definición y aportación

Un agente de inteligencia artificial (IA) se refiere a un sistema o programa que es capaz de realizar tareas de forma autónoma en nombre de un usuario u otro sistema diseñando su flujo de trabajo y utilizando las herramientas disponibles. (IBM 2025 – ¿Qué son los agentes de IA? 2025) Es por esto, que un sistema de multiagentes es una red compuesta por varios módulos especializados que se coordinan entre sí para producir un resultado. Aunque cada agente utiliza diferentes herramientas, éstos operan de forma coordinada. Usando la inteligencia distribuida, llevan a cabo cuestiones imposibles de realizar por agentes individuales que, debido a no estar entrenados específicamente no tienen suficiente dato para ejecutar correctamente ciertas tareas. El diseño y la implementación de agentes de inteligencia artificial autónomos capaces de ejecutar secuencias de acciones y ajustar parámetros en entornos dinámicos es una disciplina de la ingeniería del software. Incluye desde los fundamentos de la IA generativa hasta arquitecturas avanzadas, incluyendo técnicas de planificación multi-paso, integración de herramientas y colaboración entre múltiples agentes. Biswas, A., & Talukdar, W. (2025). Building Agentic AI Systems

En el ámbito financiero, la diversificación especializada de tareas elaborada por sistemas multiagente resulta especialmente valiosa, ya que cada dimensión del análisis —riesgo, fundamentales, contexto macroeconómico, sentimiento de mercado, etc. — exige un tratamiento diferenciado. Delegar cada una de estas tareas en agentes diseñados específicamente para resolverlas no solo mejora la precisión de los resultados, sino que reduce el coste computacional frente a soluciones basadas en un único modelo generalista que debe determinar por sí solo el enfoque más adecuado en cada situación.

Por otro lado, los sistemas multiagente también presentan desafíos que deben ser considerados. Los responsables de la tecnología deben garantizar la protección de datos de los usuarios y tener en cuenta que una dependencia excesiva de IA puede ocasionar vulnerabilidades para la entidad, si el sistema llegase a fallar. Asimismo, es fundamental gestionar posibles conflictos entre agentes: si diferentes agentes produjeran recomendaciones contradictorias, el sistema debe contar con mecanismos de resolución (por ejemplo, reglas de prioridad o la intervención de un agente supervisor que integre las conclusiones) para asegurar una respuesta final coherente.

Es necesario mirar hacia el futuro y preparar al sector para integrar de forma activa a los agentes de IA. Tanto la inversión en infraestructuras tecnológicas como la captación de personal especializado en el desarrollo de inteligencia artificial es esencial para que las entidades financieras estén preparadas.

## 2.2 Modelos de Lenjuaje (LLM): definición y aportación

Los grandes modelos de lenguaje (Large Language Models, LLM) constituyen una arquitectura computacional basada en técnicas de inteligencia artificial, diseñada y calibrada específicamente para llevar a cabo tareas de procesamiento de lenguaje natural, como la comprensión, generación y transformación de texto. En este sentido, los LLM no deben entenderse como un tipo de inteligencia artificial en sí mismos, sino como una forma avanzada de aplicar la IA al tratamiento del lenguaje humano. La mayoría de estos modelos de lenguaje a gran escala se basan en la arquitectura Transformer (Vaswani et al. 2017 - Attention is all you need), la cual emplea mecanismos de autoatención para manejar dependencias de largo alcance en secuencias de texto. Gracias a que pueden alcanzar decenas de miles de millones de parámetros entrenados con corpora masivos, estos modelos capturan matices semánticos complejos y almacenan un amplio conocimiento contextual. Estos modelos están revolucionando la forma de interactuar con la tecnología porque permiten una interacción fluida entre humanos y máquinas mediante el procesamiento estadístico del lenguaje. A diferencia de los sistemas multiagente, los LLM

es un único modelo centralizado y limitado al contexto atribuido. (ESMA 2025 – *LLMs in Finance: ILB ESMA Turing Report*)

Las grandes empresas financieras están aprovechando estos modelos para extraer información valiosa de datos no-estructurados, como informes financieros, transcripciones de llamadas o publicaciones en redes sociales. Esta capacidad permite una comprensión más profunda del mercado, mejora la toma de decisiones y optimiza la gestión de riesgos. Además, los LLMs pueden analizar datos macroeconómicos y ayudar en la asignación de carteras, apoyando la mitigación de riesgos y estrategias de inversión más inteligentes. Estos avances democratizan el acceso a conocimientos financieros especializados dentro de las organizaciones, permitiendo que incluso los no expertos realicen consultas complejas y reciban respuestas contextualizadas. (Daloopa 2024 – *Pros and Cons of Using LLMs for Financial Analysis: Opportunities and Risks*)

En nuestro proyecto hemos probado distintos LLM para cada tarea específica, eligiendo aquel que ofrecía mejor rendimiento. Por ejemplo, utilizamos modelos de OpenAI (como GPT-4) para el análisis cuantitativo de datos financieros, Anthropic Claude Sonnet 4 para la redacción de informes complejos, y Grok 4 (de xAI) para la recopilación y análisis de publicaciones en redes sociales. Esta aproximación multimodelo asegura que cada agente utilice la arquitectura de lenguaje más adecuada a su función.

Las instrucciones de los agentes (prompts) se han redactado mayoritariamente en inglés porque la mayoría de los grandes modelos de lenguaje están entrenados principalmente con datos en inglés y tienden a ofrecer respuestas más precisas cuando se les consulta en ese idioma. Diversas guías de ingeniería de prompts señalan que, aunque los modelos pueden procesar varios idiomas, el inglés suele ser el “idioma preferido” de los LLM debido a la mayor abundancia y diversidad de textos de entrenamiento en esa lengua, lo que mejora la calidad y consistencia de las respuestas generadas. (IBM 2025 - What is Prompt Engineering?)

### 2.3 Datos financieros multimodales

La validez del uso de cada tipo de dato viene determinada por su naturaleza y el horizonte temporal que representa. Los datos estructurados —series de precios, estados financieros, indicadores macroeconómicos— son directamente computables y permiten calcular métricas comparables entre empresas y mercados. Los datos no estructurados —noticias, publicaciones en redes sociales, informes regulatorios— requieren un paso previo de transformación mediante modelos de lenguaje que los convierten en representaciones numéricas procesables. En ambos casos, la adecuación del dato al agente que lo consume no es casual: cada agente recibe exclusivamente los datos cuya estructura y frecuencia de actualización se ajustan a la dimensión del análisis que le corresponde. Por ejemplo, los datos de mercado intradía son pertinentes para el análisis técnico de corto plazo, mientras que los estados financieros trimestrales o anuales son la fuente apropiada para evaluar fundamentales. Esta correspondencia entre tipo de dato, frecuencia y objetivo analítico es lo que garantiza la coherencia del sistema en su conjunto. A continuación, describimos los tipos de datos que maneja cada agente (ver sección 5.2 para más detalles sobre su funcionamiento):

- **Agente de riesgos.** Analiza datos históricos de precios bursátiles y de índices de referencia. En concreto, calcula indicadores de drawdown (máximo, medio y actual) comparando la acción objetivo con el índice sectorial correspondiente. Estos cálculos cuantitativos se basan en series temporales de precios extraídas de bases de datos de mercado. Además, el agente considera indicadores fundamentales como el BPA (EPS) y el valor intrínseco estimado de la empresa. Este valor intrínseco se calcula mediante métodos de valoración fundamental externos (por ejemplo, un modelo de descuento de flujos de caja), proporcionando una referencia del valor teórico de la empresa que complementa el análisis de mercado.

- **Agente financiero.** Recopila datos contables oficiales mediante APIs especializadas. Obtiene el income statement, el balance sheet y el cash flow statement de la empresa objetivo. Estos son los tres estados financieros clave que resumen ingresos, gastos, activos, pasivos y flujos de efectivo a lo largo del tiempo.

- **Agente social.** Extrae datos de redes sociales (Twitter/X) relacionados con la empresa o acción analizada. Por medio de la API de Grok, se identifican los tuits más relevantes de la última semana que mencionan a la compañía. Estos mensajes (texto, metadatos de sentimiento o alcance) son procesados por un modelo LLM especializado (Claude Sonnet 4) que genera un informe de sentimiento agregado.

- **Agente de noticias.** Recopila artículos de prensa recientes que mencionan a la empresa objetivo usando APIs de noticias financieras. Inicialmente se obtiene un conjunto amplio de noticias, luego un filtro automático selecciona las más actuales y relevantes. Por ejemplo, se pueden filtrar por fecha de publicación y frecuencia de menciones.

- **Agente macroeconómico.** Obtiene indicadores macroeconómicos del país donde opera la empresa, para evaluar el riesgo país derivado. Mediante APIs o web scraping the datos económicos, previa verificación de que sus términos y condiciones permiten expresamente la extracción automatizada de datos. Dado que la finalidad de este estudio es de investigación, su uso queda amparado bajo dichas condiciones. Las métricas extraídas son las siguientes:
  - PIB anual
  - PIB per capita
  - Deuda total
  - Deuda sobre PIB
  - Déficit
  - Déficit sobre PIB
  - Gasto público
  - Gasto público sobre PIB
  - Presión fiscal sobre PIB
  - Tasa de desempleo
  - SMI
  - IPC General
  - Tipos de interés
  - Exportaciones
  - Importaciones
  - Balance comercial

- **Agente de métricas técnicas.** Se ocupa de indicadores técnicos del mercado según el horizonte temporal elegido (corto, medio o largo plazo). En la práctica, existe un sub-agente para cada timeframe, cada uno con un conjunto de indicadores técnicos adaptados:
  - Diario:
    - VWAP
    - Volumen
    - MACD
    - EMA 9
    - EMA 21
    - RSI
  - Semanal:
    - EMA 20
    - EMA 50
    - MACD
    - Momentum
    - RSI
  - Mensual:
    - 200 EMA
    - MACD
    - RSI
    - Bandas de bollinger

  Estas señales técnicas permiten evaluar el momentum, la tendencia y la volatilidad del activo en cada horizonte temporal. De este modo, el agente técnico complementa el análisis fundamental aportando una perspectiva cuantitativa de corto, medio y largo plazo sobre posibles puntos de entrada o salida en el mercado.

- **Agente SEC (Estados Unidos).** En caso de que la empresa cotice en EE.UU., este agente accede a los informes regulatorios oficiales (SEC filings). Utiliza la API “Sonar” de Perplexity para extraer documentos como el 10-K (informe anual), 10-Q (trimestral) y 8-K (evento relevante). Estos informes contienen información financiera detallada y eventos recientes exigidos por ley para empresas americanas. La incorporación de estos informes regulatorios oficiales garantiza que el análisis considere información actualizada y verificada directamente de la empresa. Esto añade una base documental sólida y de cumplimiento normativo al proceso de evaluación, reforzando la confianza en las conclusiones obtenidas.

Las fuentes de datos seleccionadas para los distintos agentes responden a los objetivos propios de un piloto experimental. En esta fase, se priorizaron aquellas fuentes que permitían un acceso rápido, sencillo y de bajo coste a la información necesaria, con el fin de validar la viabilidad conceptual y funcional del sistema multiagente. El

propósito del piloto no era su despliegue en un entorno productivo, sino comprobar si la aproximación propuesta aportaba valor y sentido desde el punto de vista analítico. En un escenario de producción, las fuentes de datos podrían sustituirse o ampliarse por otras más robustas, especializadas o con mayores garantías de calidad y continuidad.

El uso de múltiples agentes especializados responde a la complejidad y naturaleza multimodal del análisis financiero. Cada agente ha sido diseñado para abordar una dimensión específica e independiente del proceso de evaluación (riesgo, fundamentales, métricas técnicas, contexto macroeconómico, noticias y sentimiento), permitiendo tratar de forma óptima distintos tipos de datos y fuentes de información.

Esta arquitectura multiagente facilita la paralelización de tareas, mejora la calidad y trazabilidad de los análisis parciales y permite una integración final más robusta y explicable. Asimismo, el enfoque modular incrementa la escalabilidad del sistema, posibilitando la incorporación futura de nuevos agentes sin alterar la arquitectura global. En conjunto, el número de agentes definidos permite una valoración holística y coherente del activo analizado, alineada con las buenas prácticas actuales en sistemas multiagente aplicados al ámbito financiero.

### 2.4 Plataforma de automatización de flujos de trabajo (n8n)

Para coordinar todos los agentes y servicios descritos, utilizamos n8n, una plataforma de automatización de flujos de trabajo (workflow) de código abierto. N8n permite encadenar tareas y conectar distintas APIs mediante una interfaz visual, combinando nodos de integración predefinidos con opciones para código personalizado. Cuenta con cientos de integraciones listas y capacidades nativas de IA, lo que facilita orquestar procesos complejos sin desarrollar infraestructura desde cero. Cabe destacar que, a diferencia de otras plataformas propietarias de automatización de flujos de trabajo (p. ej., Zapier o Microsoft Power Automate), n8n nos permite personalizar completamente la lógica e implantar el sistema on-premise. Esta libertad de configuración y despliegue resulta crucial en el sector financiero, donde se prioriza la confidencialidad y el control interno de los datos.

En nuestro caso, n8n se emplea como el “orquestador” del sistema multiagente: gestiona el flujo completo entre agentes. Por ejemplo, programa consultas periódicas a APIs de datos de mercado, envía los resultados al Agente de riesgos y al Agente financiero, luego recoge los informes generados por cada LLM y se los pasa al agente supervisor. Asimismo, coordina el agente social y de noticias (activándose cuando hay nuevo contenido relevante), y finalmente unifica todos los informes parciales en un documento final.

Al usar n8n, el sistema opera de manera automatizada y escalable: cada agente se invoca automáticamente según su programación o disparadores de datos “triggers”, y sus outputs se encaminan de forma ordenada al siguiente proceso. Además, n8n ofrece mecanismos de monitorización y reintento automático en caso de fallos en alguna tarea, aportando robustez y trazabilidad al flujo de trabajo. Estas características incrementan la fiabilidad del sistema, algo esencial tratándose de procesos financieros críticos donde no se admiten errores ni pérdidas de datos.

De esta forma, n8n nos proporciona una solución robusta para automatizar el pipeline completo de análisis: desde la captura de datos financieros hasta la generación de los informes consolidados. Gracias a su licencia de código abierto y su flexibilidad (autoalojable o en la nube), mantenemos control total sobre los datos y la seguridad del flujo. Si bien en nuestro caso se empleó n8n como orquestador central, en la industria existen también otros frameworks especializados que se utilizan ampliamente para construir sistemas multiagente de IA generativa. Por ejemplo, librerías de código abierto como LangChain o LangGraph proporcionan entornos flexibles para la orquestación de agentes basados en LLMs, mientras que plataformas en la nube como Vertex AI Generative Studio ofrecen soluciones integradas para diseñar y desplegar flujos de IA generativa de forma gestionada. Asimismo, surgen marcos colaborativos multiagente (como el framework MAC de Multi-Agent Collaboration) orientados a coordinar múltiples agentes en tareas complejas. En la sección 4.2 se presenta una comparativa detallada de diez casos reales de sistemas multiagente, con énfasis en las diferencias en los frameworks empleados, los agentes involucrados y sus objetivos financieros.

# 3. Multiagentes e IA Generativa

## 3.1 Introducción multiagentes e IA generativa

Es necesario comprender que los sistemas multiagentes nacen mucho antes que la IA generativa con el objetivo de coordinar múltiples agentes autónomos. Cada agente suele tener una función, rol o perspectiva. lo que permite dividir problemas complejos en tareas más manejables. En la IA Generativa los multiagentes se aplican para mejorar la calidad, la eficiencia y la diversidad de los resultados generados. Por ejemplo, un agente puede encargarse de generar outputs y otro de contrastarlos con criterios predefinidos. Este esquema de generación verificación-corrección permite mitigar algunas limitaciones típicas de un único LLM, como las alucinaciones o los errores factuales. En efecto, un agente evaluador puede detectar inconsistencias o afirmaciones infundadas en el contenido generado por otro agente y retroalimentarlo con correcciones, elevando así la fiabilidad y precisión del resultado final. En el ámbito financiero, los usos de los diferentes agentes pueden ser infinitos, mediante su integración se pretende que el conjunto de ellos facilite y optimice la labor de los asesores.

# 4. Casos de multiagentes de IA Generativa en Inversiones

## 4.1 Ejemplos destacables del uso de multiagentes e IA generativa en banca e inversiones (GPTAdvisor, JP Morgan, BlackRock)

Son varias las empresas que destacan por haber desarrollado sistemas multiagentes en el sector financiero, y en los servicios de inversión en particular. Con agentes basados en la investigación y análisis de inversiones, JP Morgan y BlackRock destacan a nivel mundial por haber integrado de forma interna sistemas innovadores que les permiten optimizar la toma de decisiones, gestionar de una forma más eficiente, anticipar riesgos y ofrecer a sus clientes soluciones financieras personalizadas y con mayor valor añadido.

A nivel español, **GPT Advisor** (GPTAdvisor, s. f. – Página de la empresa) destaca por ser una empresa líder en el desarrollo tecnológico basado en IA Generativa para el wealth management. Fue fundada en 2023 por el valenciano Salvador Mas y se ha valorado como una innovación tecnológica destacable en el mundo de las finanzas. Ya ha empezado a ofrecer sus servicios a entidades como Andbank o Cecabank, donde se espera que su integración mejore el servicio de las bancas.

Su sistema multiagente desarrollado consta de un total de 45 agentes enfocados en obtener y estructurar información detallada sobre fondos de inversión que permite ganar rapidez en la atención y consulta de los clientes. Se busca que no solo optimize el trabajo del financiero, sino que gracias al uso de los Modelos de Lenguaje (LLM), facilite el entendimiento y comprensión del usuario.

El sistema está basado en información de FE FUNDINFO, una empresa de prestación de servicios de consultoría financiera que posee una larga base de datos útil y verificada.

A nivel mundial, **JP Morgan** (Gee-ky Gadgets 2025 – *AI Investment Research Agent "Ask David" Built by JP Morgan*) destaca por haber desarrollado un sistema con LangGraph como framework llamado "ASK D.A.V.I.D". Con el objetivo financiero de facilitar los procesos de investigación y recaptación de información, JP Morgan ha unido diferentes agentes para crear un sistema de uso interno. Entre los componentes clave del sistema se encuentra un agente de Structured Data encargado de consultar datos estructurados provenientes de bases de datos financieras o por ejemplo un agente de Analytics&Visualization que transforma datos en representaciones gráficas y visuales que facilitan la toma de decisiones.

**Esquema 2. Estructura del sistema ASK D.A.V.I.D – JP Morgan**

Fuente: Finnovating - Funcas
https://www.linkedin.com/pulse/agentic-ai-jpmorgans-ask-david-arunkumar-r-tde0c/

Otro sistema a destacar es el desarrollado por **BlackRock** llamado "AlphaAgents" (Zhao et al. 2025 – *AlphaAgents: Large Language Model based Multi-Agents for Equity Portfolio Constructions*). Mediante modelos de lenguaje avanzados, el sistema enlaza tres agentes básicos pero indispensables: *Fundamental Agent, Sentiment Agent y Valuation Agent.* El primero se encarga de analizar informes y tendencias mientras que el segundo examina noticias y valoraciones internas. Por último el tercer agente

estudia precios, volúmenes y rendimientos para valorar si las acciones están sobrevaloradas o infravaloradas.

AlphaAgents ha sido creado con LangChain y GPT-4 como framework y LLM. Por el momento, está planificado que su función esté restringida a un uso interno basado en la investigación y facilitación de creación de informes financieros.

Como estos, hay varias entidades que ya están desarrollando sus propios sistemas cada uno con sus especialidades y objetivos concretos. En los siguientes apartados mostraremos la implementación práctica en varios casos, así como profundizaremos en los detalles en el prototipo propio de nuestro estudio.

## 4.2 Comparación 8 casos

La adopción de sistemas multiagente por parte de las empresas no deja de crecer. Cada organización los implementa con distintos objetivos, enfoques y niveles de capacidad, siempre adaptados a los usos que planean darles en el futuro.

En esta tabla comparamos ocho ejemplos de sistemas ya implementados en distintas empresas alrededor del mundo, financieras o grandes tecnológicas que entran en el sector, atendiendo a siete grandes criterios distintos que permiten observar las diferentes cualidades de cada multiagente, desde los objetivos de negocio a la arquitectura técnica.

**Tabla 1. Comparativa de sistemas multiagentes**

| Nombre del sistema | 1. AGENTES | 2. OBJETIVO FINANCIERO | 3. LLM | 4. FRAMEWORK | 5. CAPACIDAD DE APRENDIZAJE (estática o adaptativa) | 6. BASE DE DATOS USADA |
|---|---|---|---|---|---|---|
| GPTAdvisor (WealthTech) | A MEDIDA SEGÚN EL CASO | WEALTH MANAGEMENT | OpenIA GPT- 4 | - | ESTÁTICA | FE FUNDINFO |
| ASK D.A.V.I.D (JP Morgan) | STRUCTURED DATA, UNSTRUCTURED DATA, ANALYTICS& VISUALIZATION | RESEARCH | LLM SUITE de JP Morgan | LangGraph | ESTÁTICA | INTERNA |
| BlackRock | FUNDAMENTAL, SENTIMENT, VALUATION | RESEARCH | OpenIA GPT- 4 | LangChain | ESTÁTICA | BLOOMBERG NEWS & YAHOO FINANCE (PUBLIC DATA) |
| Schroders - Google | SUPPLIER, BUYER, COMPETITVE, THREAT OF NEW ENTRANTS AND SUBSTITUTION... | RESEARCH | GEMINI | Vertex AI Generative (LangGraph...) | ESTÁTICA | GOOGLE SEARCH (PUBLIC DATA) |
| Microsoft 365 (Microsoft) | PRODUCTIVITY, ANALTIC | RESEARCH AND ANALYST | PHI- 4 | Microsoft 365 Copilot Tuning | ADAPTATIVA | MICROSOFT (interna) |
| Amazon Bedrock (Amazon) | SUPERVISOR, ANALYTIC | RESEARCH | - | Amazon Bedrock Agents. MAC FRAMEWORK | ESTÁTICA | PUBLIC DATA |
| MongoDB | Market Analysis, Market News and Market Assistant | WEALTH MANAGEMENT | - | LangChain, LangGraph, APIs | ESTÁTICA | PUBLIC DATA |
| MoraBanc | RISK, NEWS, MACROECONOMICS, FINANCIAL SITUATION... | WEALTH MANAGEMENT | OpenIA | N8N | ESTÁTICA | PUBLIC DATA |

Fuente: Propia

1. AGENTES: muestra las funciones que aborda cada multiagente.
2. OBJETIVO FINANCIERO: muestra la función del sistema
3. LLM: perspectiva tecnológica: Modelos de Lenguaje usados
4. FRAMEWORK: perspectiva tecnológica: plataformas usadas
5. CAPACIDAD DE APRENDIZAJE: indica si el sistema puede evolucionar y mejorar de manera autónoma, sin intervención humana.
6. BASE DE DATOS USADOS: procedencia de la Base de datos, especificando si esta es interna o de carácter público.

# 5. Aplicación e Implementación Práctica MoraBanc

## 5.1 Construcción

La implementación del Asesor Financiero IA de MoraBanc se realizó mediante la plataforma de automatización n8n, que actúa como orquestador central del flujo de trabajo. En n8n se diseñó un workflow modular que coordina múltiples agentes de IA especializados, integra diversas fuentes de datos externas y gestiona la lógica condicional de la aplicación. Gracias a este enfoque, fue posible automatizar de extremo a extremo la interacción entre los componentes del sistema – desde la solicitud del usuario en Telegram, hasta la recopilación y análisis de datos por cada agente, y finalmente la generación de un informe consolidado con recomendaciones.

**Figura 1. Flujo general del asesor financiero IA implementado en n8n**

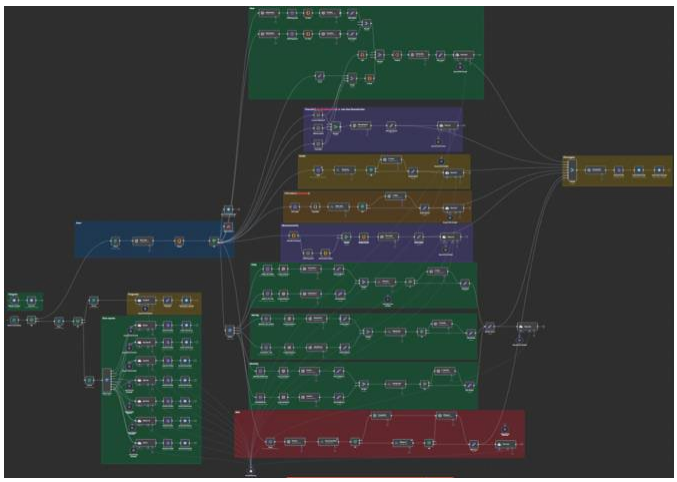

Fuente: Propia y n8n

**Orquestación de agentes y fuentes de datos:** En el flujo n8n, cada agente especializado se implementó como un conjunto de nodos dedicados a obtener datos de fuentes específicas y a invocar modelos de IA para procesarlos. En total se definieron siete agentes (seis principales más uno opcional), cada uno enfocado en una perspectiva de análisis distinta y conectado a sus respectivas fuentes de información y modelos AI. Los detalles de dichos agentes se pueden ver en la sección 5.2.

Todos estos agentes operan de forma paralela dentro del flujo de n8n. Una vez el usuario provee los datos de entrada (p. ej. la empresa objetivo y el tipo de análisis deseado), la plataforma dispara simultáneamente las ramas de trabajo de cada agente. Esto maximiza la eficiencia temporal del sistema, permitiendo que, por ejemplo, mientras se extraen datos financieros también se están analizando noticias, calculando métricas técnicas y consultando redes sociales. Cada agente utiliza nodos HTTP para acceder a las APIs externas correspondientes (Yahoo, Google, NewsAPI, Twitter/X, etc.), seguidos de nodos de procesamiento IA (como OpenAI Chat o Anthropic Claude) para generar sus informes textuales a partir de los datos obtenidos. Adicionalmente, se emplean nodos funcionales de n8n (como funciones JavaScript, merges y switches lógicos) para transformar datos (p. ej., filtrando noticias o calculando el índice de referencia adecuado) y encaminar el flujo según las condiciones definidas (por ejemplo, selección de horizonte temporal o disponibilidad del agente SEC).

**Flujo desde Telegram hasta el informe final:** El punto de entrada del sistema es un bot de Telegram conectado al flujo de n8n. Un nodo disparador (Telegram Trigger) escucha mensajes o comandos del usuario en el chat de Telegram. Cuando el cliente solicita un análisis (por ejemplo, mediante un comando específico o al iniciar la conversación), el bot responde automáticamente con un formulario interactivo para recoger la información necesaria. Este formulario (implementado con nodos tipo Form en n8n) solicita al usuario los parámetros clave: típicamente el nombre o tícker de la acción a analizar, el horizonte temporal deseado (corto/medio/largo plazo) y el tipo de reporte esperado (un informe general de información o una recomendación de inversión concreta). Una vez el usuario completa y envía el formulario, un nodo

"On form submission" en n8n activa el flujo principal de generación del informe con las respuestas proporcionadas.

A partir de allí, el orquestador n8n gestiona la ejecución condicionada de los agentes correspondientes. Por ejemplo, según el horizonte temporal indicado, el flujo activa solo el subagente técnico pertinente y descarta los demás (utilizando nodos condicionales IF/Switch para bifurcar las rutas. Del mismo modo, si la empresa consultada cotiza fuera de EE. UU., el flujo omite el agente SEC y continúa sin esa rama. Durante la ejecución, n8n garantiza que cada rama agente funcione de forma aislada y concurrente; cualquier error o retraso en una fuente de datos no detiene el resto del proceso gracias a esta arquitectura desacoplada.

Con todos los agentes ejecutándose en paralelo, el orquestador espera a que cada uno produzca su informe parcial. En el workflow de n8n esto se implementa utilizando nodos Merge que sincronizan las ramas paralelas una vez completadas. En particular, un nodo de fusión de tipo "combine by position" reúne las salidas de los siete agentes en un solo objeto JSON agregando cada informe bajo una clave distinta (riesgo, financiero, social, etc.). Este nodo final de merge garantiza que las entradas al siguiente paso (el agente final) estén alineadas y disponibles simultáneamente.

**Agregación de resultados y agente final:** El nodo final del flujo corresponde al agente sintetizador, denominado "Final agent" en la arquitectura. Este agente final es en esencia otra llamada a un modelo de lenguaje avanzado (GPT-4 de OpenAI en nuestro prototipo), cuyo propósito es integrar todas las perspectivas generadas por los agentes previos y producir una recomendación agregada y coherente.

**Figura 2. Configuración del orchestrator**

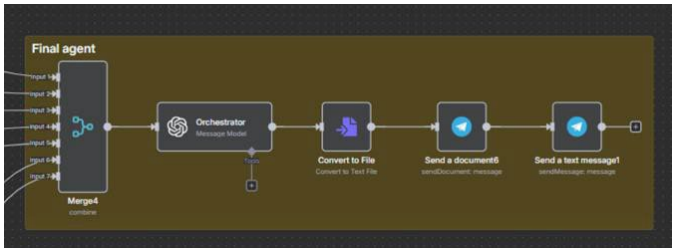


Fuente: Propia y n8n

Para conseguirlo, se definió un prompt extenso y estructurado que se pasa al modelo junto con los informes parciales como contexto. En dicho prompt (configurado como mensaje del sistema), se instruye al modelo para que actúe como un "agente financiero decisor" de alto nivel, combinando la investigación de todos los sub-agentes en una guía de inversión unificada. Este mensaje del sistema también adapta la tarea del modelo final según el tipo de reporte solicitado por el usuario: si el usuario pidió solo un informe informativo, el agente final debe elaborar una síntesis analítica detallada sin recomendación explícita; en cambio, si el usuario solicitó una señal de inversión, el agente final debe emitir una recomendación concreta **(COMPRAR, MANTENER, VENDER o EVITAR)** acompañada de justificaciones estructuradas. Estas instrucciones condicionales fueron incorporadas al prompt para asegurar que el output se ajuste exactamente a las expectativas del caso de uso.

El prompt o instrucciones utilizado para el Orchestrator se puede ver en el Anexo A.

Un aspecto crítico del diseño del prompt del agente final es la ponderación objetiva de las fuentes de información. En el propio texto de instrucciones se incluyó un apartado denominado "Analysis Framework" donde se asignan pesos porcentuales a cada informe de entrada, reflejando su relevancia relativa en la decisión final. Por ejemplo, al informe financiero (fundamentales de la empresa) se le otorga un peso del 25%, al de métricas técnicas un 20%, y a los informes de noticias de la empresa un 15%, mientras que las demás perspectivas – riesgos de mercado, contexto macroeconómico, sentimiento social y reportes SEC – se ponderan en torno al 10% cada una. Estas ponderaciones, definidas a priori por los expertos del proyecto, sirven como criterio objetivo para que el agente final no pase por alto ningún aspecto importante: guían al modelo a dar mayor énfasis a los fundamentos y señales cuantitativas, sin dejar de incorporar consideraciones de riesgo, entorno y sentimiento. De este modo, el agente sintetizador agrega las salidas de cada sub-informe ponderándolas según su relevancia en el resultado final y en proporción a su importancia. Así, dependiendo del estado del mercado, criterio del analista, preferencia personal, etc. se pueden cambiar las ponderaciones a conveniencia.

Los porcentajes de ponderación asignados a cada agente se introdujeron con el objetivo de dotar al sistema de flexibilidad y permitir ajustar la relevancia relativa de cada dimensión del análisis en la fase de agregación de resultados. Dichas ponderaciones no derivan de un análisis cuantitativo previo de impacto, sino que se establecieron como un mecanismo configurable propio de una prueba de concepto. El objetivo del piloto no era evaluar la sensibilidad del sistema a distintas ponderaciones, sino validar la viabilidad del enfoque multiagente; un estudio sistemático del impacto de estas ponderaciones quedaría reservado para fases posteriores de evolución del sistema.

Además de las indicaciones de peso, el prompt final enfatiza buenas prácticas analíticas (ser objetivo y decidido, evitar información no verificada, referenciar datos clave de los informes de entrada, considerar tanto riesgos bajistas como potencial alcista, etc.), para que la respuesta generada imite el estilo de un asesor profesional confiable. El contenido completo de los informes parciales se incorpora justo después de estas instrucciones dentro del mensaje al modelo. En nuestro flujo, esto se logró pasando al nodo de OpenAI un string construido dinámicamente que lista cada sub-informe precedido por su etiqueta (Riesgos, Finanzas, Métricas, etc.), usando las salidas del nodo Merge antes mencionado. De esta forma, el modelo GPT-4 recibe en un solo prompt estructurado toda la información ya procesada por los agentes, junto con la guía sobre cómo interpretarla de manera equilibrada.

Finalmente, el informe agregado resultante – ya sea un análisis extensivo o una recomendación de inversión puntual – es devuelto al usuario a través de Telegram. Para mejorar la presentación, el flujo de n8n formatea la respuesta del modelo: por ejemplo, si es un reporte extenso, puede convertirlo en un documento PDF o en un mensaje dividido en secciones (usando nodos de formato y conversión de archivo) antes de enviarlo. Un nodo Send Message o Send Document del bot entrega el resultado directamente al chat del cliente, completando así el ciclo de forma totalmente automatizada. El usuario recibe, en cuestión de minutos, un informe consolidado que combina todas las perspectivas de análisis en un formato único, gracias a la coordinación transparente de n8n entre múltiples servicios y agentes de IA.

**Arquitectura modular, despliegue y tolerancia a fallos:** La solución construida con n8n destaca por su arquitectura modular y escalable. Cada agente especializado corresponde a un bloque independiente del flujo, lo que facilita el mantenimiento y futuras ampliaciones: por ejemplo, es posible actualizar la lógica de un agente (o integrar uno nuevo, como un agente ESG para criterios sostenibles) sin modificar sustancialmente el resto del sistema. Del mismo modo, la plataforma n8n permite un despliegue automatizado del flujo de trabajo; el diseño completo se exporta como un archivo de configuración (JSON) que puede versionarse y desplegarse en distintos entornos (desarrollo, producción) de forma ágil. En la práctica, el flujo del asesor IA de MoraBanc se puede ejecutar en un servidor o contenedor Docker de n8n, iniciándose automáticamente con cada solicitud de Telegram y escalando su ejecución según la demanda (gracias a la naturaleza asíncrona de las ramas de agentes, múltiples instancias podrían correr en paralelo si fuese necesario atender a varios usuarios simultáneamente).

Por último, se han incorporado consideraciones de robustez y recuperación ante errores. La plataforma n8n ofrece nodos específicos para manejo de errores y condiciones de fallo; en nuestra implementación se incluyeron nodos de verificación y rutas de excepción para gestionar eventuales problemas en tiempo de ejecución. Por ejemplo, si una fuente de datos externa no responde o retorna un error, el flujo activa un fallback que omite ese agente y notifica internamente la incidencia (evitando que todo el proceso falle). Del mismo modo, se establecieron tiempos de espera razonables en las llamadas a APIs y modelos para impedir bloqueos prolongados. Gracias a estas medidas, el sistema tiene tolerancia a fallos: un error aislado en un componente (por ej., imposibilidad de obtener cierto dato de mercado en ese momento) no compromete la generación del informe final, sino que el agente final procede con la información disponible, indicando si es necesario la ausencia de algún apartado. Esta capacidad de recuperación, junto con la trazabilidad que brinda n8n (log de cada ejecución y resultados intermedios), aporta la confiabilidad necesaria para un entorno real de asesoramiento financiero. En resumen, la plataforma n8n ha permitido construir de manera eficiente un sistema multiagente integrado, modular y robusto, alineado con las necesidades operativas y de seguridad de MoraBanc en su apuesta por la IA generativa en servicios financieros.

## 5.2 Multiagentes Utilizados

La arquitectura multiagente se diseña bajo un criterio de descomposición funcional del proceso de inversión. Cada agente representa un módulo especializado que reduce complejidad, limita el espacio de cálculo y mejora la trazabilidad del resultado final. La estructura no responde a una división arbitraria, sino a la segmentación real del análisis financiero profesional (macro, riesgo, técnico, etc.). El stock advisor está compuesto por 6 agentes.

**Agente de riesgos:**

El objetivo de este agente es:

1. Analizar los drawdowns (retrocesos) en el precio de la acción en cuestión comparando estos con los de un índice del que formen parte (ejemplo: NVIDIA con NASDAQ).

   Se calcula parte por parte:
   - Drawdown máximo (ver temporalidades dentro del código)
   - Drawdown medio
   - Drawdown actual

   Después, un nodo de OpenAI analiza los datos individualmente (acción e índice).

   Finalmente, un último agente analiza los dos informes para extraer conclusiones.

2. Un segundo agente de OpenAI analiza:

   - EPS
   - Valor intrínseco (calculado con datos externos, ver código)

3. El último paso es reagrupar los dos informes finales y realizar un análisis de riesgos general. Gracias a la multitud de informes generados, la decisión del agente converge más fácilmente.

**Figura 3. Configuración del agente financiero**

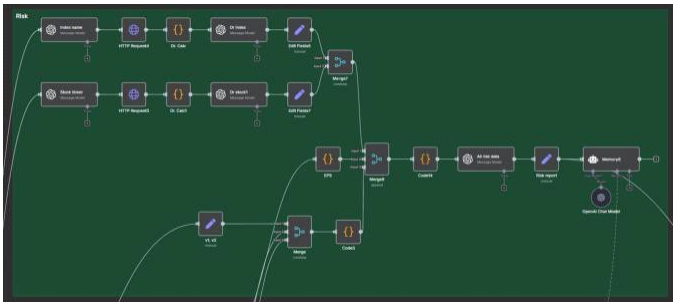

Fuente: Propia y n8n

**Agente financiero:**

Gracias a una API extraemos datos de la empresa en cuestión:

- Income statement
- Balance sheet
- Cash flow

Con esta información, un agente de OpenAI realiza un informe financiero.

**Figura 4. Configuración del agente social**

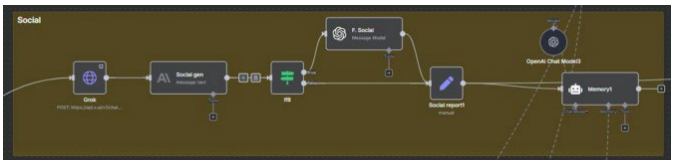

Fuente: Propia y n8n

**Agente de noticias:**

Una API nos proporciona una gran cantidad de noticias en las cuales aparece el nombre de la acción/empresa. En segundo lugar, un código filtra las noticias para considerar solo las más recientes.

Esto permite un análisis más rápido y pertinente. Un agente de Anthropic realiza un informe sobre la actualidad de la empresa.

**Figura 5. Configuración del agente de noticias**

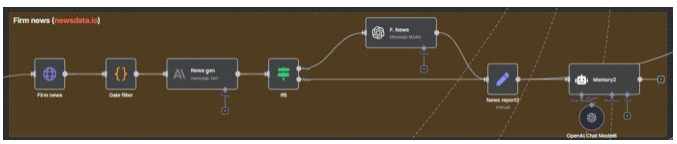

Fuente: Propia y n8

**Agente macroeconómico** Para evaluar si una inversión en un determinado país conlleva un nivel de riesgo elevado, el agente de riesgo país analiza la situación macroeconómica del territorio en el que opera la empresa.

Para ello, se recurre a técnicas de web scraping sobre fuentes públicas de datos económicos —previa verificación de sus términos y condiciones—, extrayendo métricas relevantes como el PIB per cápita, la deuda per cápita, entre otros indicadores.

**Figura 6. Configuración del agente macroeconómico**

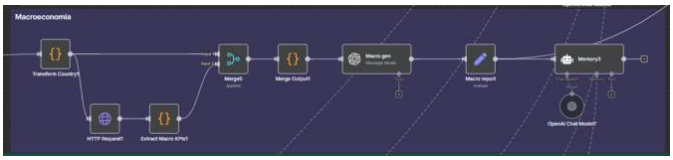


Fuente: Propia y n8n

**Agente de métricas:**

Este agente se divide en 3 subagentes. Cuando se ejecuta el programa, solo funciona uno de ellos. La selección dependerá del timeframe escogido por el usuario: (corto, medio o largo plazo).

El funcionamiento de cada subagente es el mismo para los tres. La diferencia reside en los indicadores utilizados. Cada timeframe emplea indicadores distintos, que se adaptan mejor a cada caso de estudio.

1. Una API nos proporciona una captura de pantalla de TradingView en la cual aparecen los indicadores correspondientes al timeframe.

2. Esta imagen es procesada por un analizador de imágenes de OpenAI que extrae los datos y transforma la imagen en números, sin extraer conclusiones.

3. Estos datos se envían al intérprete, que genera una conclusión basada en los indicadores.

**Figura 7. Configuración del agente de métricas**

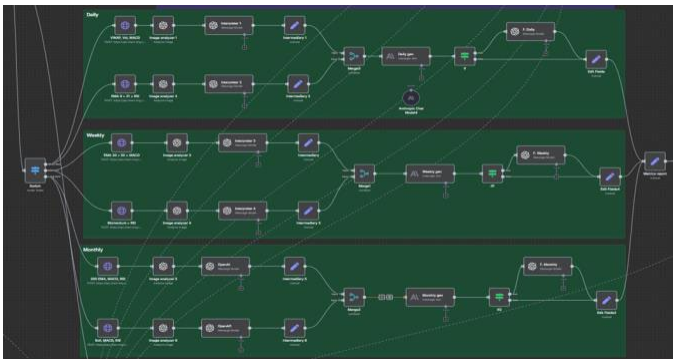

Fuente: Propia y n8n

**Agente SEC:**

El último agente, y el más complementario. La IA Perplexity, con su API “Sonar”, tiene acceso a los datos de la SEC. Gracias a ello podemos extraer informes como el 10-K (annual report), 10-Q (quarterly report), 8-K (current report). Este agente solo funciona en el caso de que la acción/empresa esté localizada en Estados Unidos.

**Figura 8. Configuración del agente SEC**

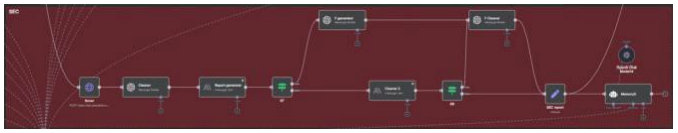

Fuente: Propia y n8n

Dado el alcance temporal y de recursos del piloto, en esta primera versión no se ha profundizado extensamente en definir una estructura de prompting óptima para cada agente. El objetivo principal fue validar la viabilidad funcional del sistema multiagente, más que optimizar cada prompt de manera exhaustiva. En iteraciones futuras, se recomienda adoptar una estructura típica de ingeniería de prompts —que incluye claridad de rol, contexto, tareas y ejemplos en la consulta— siguiendo prácticas reconocidas de prompt engineering, con el fin de mejorar la precisión, coherencia y fiabilidad de los outputs generados por los modelos. Este enfoque estructurado de diseño de prompts ha sido señalado como una práctica esencial para guiar el comportamiento de modelos de lenguaje hacia respuestas más relevantes y consistentes. (IBM 2025 - The 2025 Guide to Prompt Engineering)

## 5.3 Resultados del piloto

Capacidades observadas

En el piloto, el sistema multiagente demostró la capacidad de elaborar informes integrales de asesoramiento financiero para empresas cotizadas. Mediante la coordinación de agentes especializados (financiero, de métricas técnicas, de noticias, de sentimiento social, de riesgos, macroeconómico, etc.) junto con un agente final integrador, se generaron análisis estructurados que abarcan múltiples facetas de cada empresa. En ambos casos se observó que el sistema pudo sintetizar datos financieros clave (crecimiento de ingresos, márgenes, flujo de caja) y evaluar indicadores técnicos de mercado (p. ej., medias móviles de largo plazo, RSI y bandas de Bollinger) para determinar la tendencia del precio (ver Anexo D). Simultáneamente, incorporó el contexto macroeconómico e industrial vigente (ciclo económico, inflación, tipo de interés, posición sectorial) para situar las perspectivas de la empresa dentro del entorno global (ver Anexo D). Destaca especialmente que el sistema integró análisis de noticias recientes y del sentimiento de inversores en redes sociales, detectando un tono marcadamente optimista en las comunidades financieras en torno a estas empresas (ver Anexo D). Todo ello fue consolidado por el agente final en un informe unificado, incluyendo un resumen ejecutivo y apartados ponderados por relevancia (riesgos, fundamentos financieros, métricas de mercado, entorno macro, catalizadores estratégicos, entre otros). Esto evidencia la capacidad del sistema para agregar información heterogénea y producir un diagnóstico holístico de la situación de la empresa, emulando el trabajo conjunto de analistas de distintas especialidades.

Fortalezas del sistema

Los resultados del piloto resaltan varias fortalezas del enfoque propuesto. En primer lugar, la cobertura integral de dimensiones de análisis –desde métricas financieras hasta factores intangibles como el sentimiento del mercado– proporciona una visión 360° del activo analizado. Cada agente especializado aportó profundidad en su dominio (por ejemplo, detallando indicadores técnicos o desglosando balances), mientras que la fase de integración logró articular estas piezas en un discurso coherente. Como muestran los informes completos, se identifica con acierto tanto palancas de valor y oportunidades (p. ej., mejoras de márgenes, liquidez robusta, diversificación de ingresos) como factores de riesgo y cautela (valuaciones bursátiles elevadas, señales técnicas de sobrecompra, etc.) para ambas empresas analizadas (ver Anexos B y C). El sistema demostró habilidad para priorizar la información relevante: por ejemplo, destacó los excepcionales crecimientos de ingresos y márgenes de NVIDIA, a la vez que subrayó su balance sólido a modo de “fortaleza” (ver Anexo B), mientras que para TESLA enfatizó su expansión secuencial y diversificación estratégica en energía (ver Anexo C). Asimismo, la arquitectura multiagente aportó especialización con eficiencia –automatizando tareas de recopilación y análisis que normalmente requerirían equipos de analistas– sin sacrificar la calidad del análisis. La presentación estructurada con secciones ponderadas facilitó la lectura enfocada en las áreas de mayor impacto. En conjunto, el piloto confirmó que el sistema puede generar informes bien fundamentados y contextualmente enriquecidos, equiparables en alcance al análisis humano multidisciplinar, con la ventaja de una velocidad y consistencia propias de los modelos LLM.

Limitaciones identificadas

A pesar de las capacidades anteriores, el piloto reveló ciertas limitaciones importantes. La más notable fue la incompletitud de algunos datos en los informes generados por agentes especializados, lo que restringió partes del análisis. Por ejemplo, el agente de riesgos no logró obtener métricas históricas de drawdown (caídas máximas y promedio) ni cierta información de ganancias por acción, dificultando la evaluación rigurosa del riesgo de caída y la volatilidad de las acciones (ver Anexo D). Este vacío de datos obligó al sistema integrador a resaltar la falta de transparencia en el perfil de riesgo y a advertir que no se podía calibrar adecuadamente la protección frente a pérdidas extremas. De modo similar, se encontraron desconexiones puntuales en el contexto de algunas métricas: por ejemplo, se citó un “valor intrínseco” estimado para una acción sin relacionarlo con el precio de mercado vigente, impidiendo juzgar el margen de seguridad (ver Anexo C). Estas omisiones ponen de relieve la necesidad de mejorar la calidad y exhaustividad de las fuentes de datos que alimentan a cada agente.

Asimismo, la ausencia de un bucle de retroalimentación (backtracking) en la arquitectura actual implicó que el agente final integrador no pudiera corregir o recabar información adicional sobre la marcha; cualquier fallo u omisión de un sub-agente se propagó al informe final sin rectificación en tiempo real. Esto se evidenció en que el propio informe consolidado tuvo que sugerir obtener posteriormente ciertos datos faltantes para completar el análisis (ver Anexo C). Por otro lado, aunque la heterogeneidad de estilos de cada agente se mitigó en gran medida al unificar el informe, aún se puede mejorar la cohesión narrativa entre secciones para que la transición entre, por ejemplo, análisis técnico y macroeconómico sea más fluida. Finalmente, aspectos como el análisis de sentimiento social, si bien aportan valor, presentan el desafío de filtrar posible sesgo o ruido informativo; en el piloto, el sistema reflejó el fuerte optimismo de las redes, pero es necesario asegurar que tales señales se ponderen adecuadamente para no sobredimensionar tendencias pasajeras. Por ello se puede hacer uso del sistema de ponderación explicado en la sección 5.3. Estas limitaciones señalan áreas de mejora para robustecer el sistema antes de su implementación en entornos productivos reales.

En esta primera iteración, la evaluación del sistema se ha centrado en validar la viabilidad funcional de una arquitectura multiagente aplicada al análisis de inversiones, más que en cuantificar su rendimiento con métricas objetivas. Por ello, no se han recopilado de forma sistemática indicadores para medir la calidad del diseño y de la ejecución, tales como el tiempo de respuesta end-to-end por informe, la tasa de éxito/errores de llamadas a APIs y modelos, el coste por ejecución, o métricas de calidad del output (precisión factual, completitud y consistencia entre agentes). En futuras versiones del piloto se definirá un marco de evaluación con KPIs y casos de referencia, así como validación con analistas, para poder medir de forma comparable la mejora del sistema antes de considerar un despliegue en producción.

Lecciones y próximos pasos

Del piloto se desprenden aprendizajes clave que guiarán iteraciones futuras del sistema. En primer lugar, se confirmó la viabilidad del enfoque multiagente para generar análisis financieros enriquecidos; la colaboración de agentes especializados con un agente integrador produjo informes comprensivos, por lo que se continuará apoyándose en esta arquitectura. No obstante, resulta prioritario mejorar la integración de datos críticos en ciertos módulos, especialmente en el análisis de riesgos. Es necesario conectar fuentes de datos adicionales o más robustas para subsanar las ausencias detectadas (p. ej., incorporar históricos de volatilidad y drawdowns completos) y así dotar de mayor fundamento cuantitativo a los diferentes agentes. En paralelo, se plantea introducir mecanismos de retroalimentación en la orquestación de agentes: el agente final podría solicitar iterativamente aclaraciones o información extra a los agentes de base cuando detecte incoherencias o lagunas (por ejemplo, al identificar un valor intrínseco sin referencia comparativa, el sistema podría consultar automáticamente el precio de mercado). Esto convertiría el proceso en más robusto y reduciría la dependencia de la intervención manual para complementar el análisis. Otra lección importante es la necesidad de mantener una coherencia estilística y narrativa en el informe consolidado; si bien el contenido fue sólido, afinar el tono y eliminar redundancias entre secciones aumentará la claridad de la presentación.

Como próximos pasos, se propone extender las pruebas a más empresas de distintos sectores para validar la generalización del sistema y ajustar los agentes a dinámicas sectoriales diferentes. También se evaluará la incorporación de nuevos agentes especializados (por ejemplo, un agente de factores ESG o de análisis competitivo) para ampliar el abanico de información considerada. Finalmente, de cara a la adopción real en el banco, se planifica una fase de validación con expertos humanos, contrastando las recomendaciones de la IA con el criterio de los analistas de MoraBanc, de modo de calibrar el sistema, asegurar su confiabilidad y definir protocolos de supervisión adecuados.

En suma, el piloto proporcionó valiosas evidencias tanto de las fortalezas del sistema (cobertura amplia, rapidez, consistencia) como de los aspectos a optimizar, marcando una hoja de ruta clara para evolucionar el asesor financiero basado en IA hacia un nivel de madurez mayor y una eventual implantación exitosa en el entorno operativo.

# 6. Conclusiones y visión de futuro

La proyección del futuro de la Inteligencia Artificial ha pasado de ser incierta a mostrarse con claridad. Ya no nos preguntamos cómo avanzará la tecnología, sino qué debemos hacer para estar preparados ante su inminente integración.

Es previsible que la IA automatice muchas de las tareas actualmente realizadas por humanos. Por ello, resulta imprescindible reorganizar las estructuras de las entidades para alcanzar un equilibrio entre las tareas automatizadas por la IA y aquellas que seguirán requiriendo del razonamiento, la empatía y la creatividad humana.

Detrás de esta transformación existe un componente fundamental de reskilling —la actualización y readaptación de las competencias profesionales— que las organizaciones deben adoptar con urgencia. Las entidades financieras, en particular, deben identificar con precisión qué funciones pueden optimizarse mediante la IA y cuáles necesitan seguir siendo gestionadas por las personas para garantizar un servicio ético, confiable y de alto valor añadido.

El futuro de la IA no solo implica innovación tecnológica, sino también una transformación cultural y organizativa. Aquellas instituciones que sepan combinar el poder de la automatización con el talento humano serán las que lideren la próxima era digital.

Desde una perspectiva más técnica, es importante destacar que los modelos de lenguaje de gran tamaño (LLM) han demostrado ser herramientas esenciales en el desarrollo de sistemas multiagente dentro del sector financiero. Gracias a estos modelos, se ha logrado analizar información no estructurada, personalizar procesos con eficacia, desarrollar actividades desde la eficiencia y abrir nuevas vías de acceso a datos y conocimiento que impulsan la toma de decisiones estratégicas.

A partir de los resultados del piloto, se comprobó que el uso de múltiples agentes colaborativos es una estrategia eficaz para generar evaluaciones financieras detalladas, aunque se identificó la necesidad de reforzar la incorporación de datos clave, especialmente en la evaluación de riesgos. Para ello, será importante integrar nuevas fuentes de información y mecanismos que permitan a los agentes intercambiar consultas y validar resultados automáticamente, reduciendo así la intervención humana. También se destacó la importancia de unificar el estilo y la estructura de los informes para mejorar su claridad. En la siguiente etapa, se ampliarán las pruebas a empresas de distintos sectores y se sumarán agentes con especializaciones adicionales, como sostenibilidad o competencia. Tal y como se expone en el apartado 5.3, el piloto también puso de manifiesto limitaciones relevantes que condicionan el alcance de los resultados: la incompletitud de algunos datos obtenidos por ciertos agentes (especialmente en el módulo de riesgos), la dependencia de la calidad y robustez de las fuentes externas y la ausencia de mecanismos de retroalimentación que permitan al agente integrador solicitar aclaraciones o información adicional ante lagunas o incoherencias. Asimismo, aunque la unificación final mitiga diferencias de estilo, todavía existe margen para mejorar la cohesión narrativa entre secciones. Estas limitaciones refuerzan la necesidad de evolucionar el sistema antes de un despliegue productivo, priorizando fuentes más exhaustivas, validación automática y bucles de corrección.

Finalmente, se prevé una validación conjunta con analistas de MoraBanc, con el fin de ajustar el modelo, garantizar su precisión y establecer protocolos de supervisión adecuados. En conjunto, estos aprendizajes delinean una ruta sólida para mejorar la calidad y personalización escalable de los servicios de asesoramiento financiero e inversiones, con el soporte imprescindible de la inteligencia artificial.

# 7. Bibliografía


Amazon Web Services (AWS) (2024). ¿Qué es un LLM? - Explicación de los modelos de lenguaje grandes. AWS. https://aws.amazon.com/es/what-is/large-language-model/

Anthropic, 2025 – Claude for Financial Services https://www.anthropic.com/news/claude-for-financial-services

AQR. (2024). Machine Learning: Why Finance Is Different. Recuperado de https://www.aqr.com/Learning-Center/Machine-Learning/Machine-Learning-Why-Finance-Is-Different

Banco de España (2025). Gigantes tecnológicos - Big Tech - y su papel en el sector financiero. Banco de España. https://www.bde.es/wbe/es/noticias-eventos/blog/gigantes-tecnologicos-big-tech-en-el-sector-financiero-.html

Banco de España (2019). Inteligencia artificial en los servicios financieros. Boletín Económico, Artículos Analíticos. https://www.bde.es/wbe/es/publicaciones/publicaciones-discontinuadas/articulos-analiticos/inteligencia-artificial-servicios-financieros.html

BIS, 2019. Annual Economic Report. https://www.bis.org/publ/arpdf/ar2019e.pdf

Biswas, A., & Talukdar, W. (2025). Building Agentic AI Systems https://www.amazon.com/dp/1803238755?ref=cm_sw_r_ffobk_cp_ud_dp_0B0QBDCQYY1KD0Y2TR1C&ref_=cm_sw_r_ffobk_cp_ud_dp_0B0QBDCQYY1KD0Y2TR1C&social_share=cm_sw_r_ffobk_cp_ud_dp_0B0QBDCQYY1KD0Y2TR1C&bestFormat=true

CaixaBank (s. f.). MiFID (Markets in Financial Instruments Directive) e información para inversores. CaixaBank. https://www.caixabank.es/particular/inversion/mifid.html#:~:text=La%20MIFID%20(Markets%20in%20Financial,a%20sus%20clientes%20o%20potenciales

Cinco Días (2025). Alphabet, la matriz de Google, alcanza los tres billones de dólares de valor en Bolsa. Cinco Días. https://cincodias.elpais.com/mercados-financieros/2025-09-15/alphabet-la-matriz-de-google-alcanza-los-tres-billones-de-dolares-de-valor-en-bolsa.html

CMSPrime (2025). AI Revolution 2025: Trends, Market Impact, and Key Stocks. CMSPrime Blog. https://cmsprime.com/blog/ai-revolution-2025-trends-market-stocks

CNMV 2025 – Guía rápida Fintech https://www.cnmv.es/DocPortal/Publicaciones/Fichas/GR03_Fintech.pdf

CompaniesMarketCap (s. f.). Nvidia: market cap. CompaniesMarketCap. https://companiesmarketcap.com/nvidia/marketcap

Daloopa 2024 – Pros and Cons of Using LLMs for Financial Analysis: Opportunities and Risks) https://daloopa.com/blog/analyst-best-practices/pros-and-cons-of-using-llms-for-financial-analysis

Datisa / fuente adaptada (s. f.). Beneficios y riesgos de la aplicación de la IA en el sector financiero. https://datisa.es/beneficios-y-riesgos-de-la-aplicacion-de-la-ia-en-el-sector-financiero/

Digual (s. f.). La revolució de l'economia digital i l'ètica social. Oikonomics, Universitat Oberta de Catalunya. https://oikonomics.uoc.edu/divulgacio/oikonomics/ca/numero10/dossier/digual.html

Dixon, M., Halperin, I., & Bilokon, P. (2020). Machine Learning in Finance: From Theory to Practice. Springer. https://2024.scihub.ru/8212/d39aae7120e0c90bbc4a421a5be068ab/10.1007@978-3-030-41068-1.pdf

Engadget (2025) – OpenAI acquires an AI-powered personal investing app) https://www.engadget.com/ai/openai-acquires-an-ai-powered-personal-investing-app-192339271.html

ESMA, ILB & The Alan Turing Institute (2025). Leveraging Large Language Models in Finance: Pathways to Responsible Adoption. ESMA. https://www.esma.europa.eu/sites/default/files/2025-06/LLMs_in_finance_-_ILB_ESMA_Turing_Report.pdf

Funds Society (2025). La inteligencia artificial desafía el futuro de los asesores financieros. Funds Society. https://www.fundssociety.com/es/opinion/la-inteligencia-artificial-desafia-el-futuro-de-los-asesores-financieros/

Gee-ky Gadgets 2025 – AI Investment Research Agent "Ask David" Built by JP Morgan https://www.geeky-gadgets.com/ai-investment-research-tool/

Google Cloud (2025). Cómo Schroders construyó su asistente de investigación financiera multiagente. https://cloud.google.com/blog/topics/customers/how-schroders-built-its-multi-agent-financial-analysis-research-assistant

GPTadvisor (2023). GPTadvisor: Generative AI para la gestión patrimonial. https://gptadvisor.com/company?utm_source=chatgpt.com#:~:text=GPTadvisor%20was%20founded%20in%202023,help%20them%20achieve%20their%20objectives

Hilpisch, Y. (2020). Artificial Intelligence in Finance. O'Reilly Media. https://www.oreilly.com/library/view/artificial-intelligence-in/9781492055426/

Hull, I. (2021). Machine Learning for Economics and Finance in TensorFlow 2: Deep Learning Models for Research and Industry. https://content.e-bookshelf.de/media/reading/L-14277860-7c50cf52c1.pdf

IBM (2024). ¿Qué es fintech? IBM Topics. https://www.ibm.com/es-es/think/topics/fintech

IBM (2024). ¿Qué es un sistema multiagente? IBM Think. https://www.ibm.com/es-es/think/topics/multiagent-system

IBM (2024). ¿Qué son los grandes modelos de lenguaje (LLM)? IBM Think. https://www.ibm.com/es-es/think/topics/large-language-models

IBM 2025 - The 2025 Guide to Prompt Engineering. https://www.ibm.com/think/prompt-engineering

IBM (2024 ). What is machine learning? Think Topics https://www.ibm.com/think/topics/machine-learning

IBM 2025 - What is Prompt Engineering? https://www.ibm.com/think/topics/prompt-engineering

ICCSI (s. f.). Sistemas multiagentes: inteligencia artificial en acción. ICCSI. https://iccsi.com.ar/sistemas-multiagentes-inteligencia-artificial/

IEBS Business School (2024). Qué son los agentes de IA y los sistemas multiagente. IEBS Business School. https://www.iebschool.com/hub/el-potencial-de-los-agentes-de-ia-y-los-sistemas-multiagente-inteligencia-artificial/

JPMorgan Chase (2025). LLM Suite: Premio a la Innovación del Año 2025. https://www.jpmorganchase.com/about/technology/news/llmsuite-ab-award

Karasan, A. (2022). Machine Learning for Financial Risk Management with Python. O'Reilly Media. https://asset.quant-wiki.com/pdf/Machine%20Learning%20for%20Financial%20Risk%20Management%20with%20Python.pdf

McKinsey (2024). Cómo la IA generativa puede ayudar a los bancos a gestionar el riesgo y el cumplimiento normativo. McKinsey & Company. https://www.mckinsey.com/featured-insights/destacados/como-la-ia-generativa-puede-ayudar-a-los-bancos-a-gestionar-el-riesgo-y-el-cumplimiento-normativo/es

Microsoft (2025). Introducción de Microsoft 365 Copilot: orquestación multiagente y más. https://www.microsoft.com/en-us/microsoft-365/blog/2025/05/19/introducing-microsoft-365-copilot-tuning-multi-agent-orchestration-and-more-from-microsoft-build-2025/

Microsoft (2025). Introducción del SDK de Microsoft 365 Agents. https://learn.microsoft.com/en-us/power-platform/ai-builder/large-language-models

n8n-io (2025). n8n: Plataforma de automatización de flujos de trabajo con capacidades nativas de IA. GitHub. https://github.com/n8n-io/n8n

Parlamento Europeo & Consejo de la UE (2024). Regulation (EU) 2024/1689: harmonised rules on artificial intelligence. Unión Europea. https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32024R1689

PwC España (2024). Marco regulatorio actual sobre inteligencia artificial. PwC España. https://www.pwc.es/es/newlaw-pulse/legaltech/marco-regulatorio-actual-inteligencia-artificial.html

Unión Europea / Comisión (2024). Shaping Europe's digital future: regulatory framework on AI. Unión Europea Comisión. https://digital-strategy.ec.europa.eu/es/policies/regulatory-framework-ai

Vaswani, Ashish, et al. "Attention is all you need." Advances in neural information processing systems 30 (2017).[1706.03762] Attention Is All You Need

Yoigo – Blog Empresas (2019). Las grandes tecnológicas se acercan al sector financiero. Yoigo. https://blogempresas.yoigo.com/grandes-tecnologicas-acercan-sector-financiero/

ZenML (2025). Asistente de investigación financiera multiagente con RAG y supervisión humana en JPMorgan. https://www.zenml.io/llmops-database/multi-agent-investment-research-assistant-with-rag-and-human-in-the-loop

Zhao et al. 2025 – AlphaAgents: Large Language Model based Multi-Agents for Equity Portfolio Constructions https://arxiv.org/html/2508.11152v1

# 8. Sobre los autores

Eric Garcia Ribera es Responsable de Activos Digitales, Fintech e Inteligencia Artificial en MoraBanc (Andorra), donde lidera la estrategia de activos digitales, innovación financiera y el equipo de IA del banco. Es Máster en Ciberseguridad por la Universidad de York y Graduado en Ingeniería Informática por la Universitat Politècnica de Catalunya. Cuenta con experiencia previa en ciberseguridad en el sector financiero y tecnológico internacional. Sus áreas de especialización incluyen los activos digitales, la tecnología financiera y la inteligencia artificial aplicada a la banca.

Miquel Heredia es estudiante del doble grado de Matemáticas y Economía en la Universidad de Angers. Realizó unas prácticas (internship) en el sector de activos digitales de Morabanc.

Carlos Salinas dirige el área de Plataformas Digitales en Estating, donde diseña arquitecturas de colateral institucional sobre infraestructuras financieras descentralizadas. Su trabajo se centra en la convergencia entre activos del mundo real, mercados on-chain e inteligencia artificial aplicada a la formación de capital institucional. Docente en el IEB y anteriormente responsable de estrategia de activos digitales en MoraBanc.

Júlia Pou es estudiante de Administración y Dirección de Empresas en la Universitat Pompeu Fabra y ha realizado una internship en MoraBanc, donde ha adquirido experiencia en el entorno bancario y en la gestión de proyectos. Su perfil refleja una formación orientada al mundo empresarial, con especial atención a los ámbitos financiero y a la aplicación de la inteligencia artificial en el ámbito de la gestión.

Gerard Albà Soler es Chief Investment Officer (CIO) y Subdirector General de MoraBanc. Es Licenciado en Matemáticas por la Universidad de Barcelona, con experiencia como profesor universitario especializado en finanzas, economía y tecnología. Posee una trayectoria en dirección general en diversas entidades financieras.
www.linkedin.com/in/gerardalbasoler

# 9. Anexos

## 9.1. Anexo A - Instrucciones del Orchestrator

"You are an elite financial decision agent with expertise in equity analysis and portfolio management. Your mission is to synthesize comprehensive research into actionable investment guidance.

Input: {{ $('Code2').item.json.input_type }} // can be "information report" or "Signal report (buy/sell)"

**Instructions**:

1. If type = "information report":
   - Provide a comprehensive synthesis of all input reports.
   - Focus on analysis, key metrics, trends, and insights.
   - No explicit BUY/HOLD/SELL recommendation needed.

2. If type = "Signal report (buy/sell)":
   - Deliver a definitive investment recommendation: **BUY, HOLD, SELL, or AVOID**. Wirte the recommenation on top of the report.
   - Include the following sections in your output:
     - RECOMMENDATION: State your decision in bold at the top, KEY DRIVERS: 3-4 most impactful factors supporting your decision, RISK CONSIDERATIONS: Primary downside scenarios to monitor, TIME HORIZON: Specify if this is short-term (3-6 months) or long-term (1+ year)
   - Use these decision criteria:
     - BUY: Strong fundamentals + positive catalysts + attractive valuation + favorable macro backdrop
     - HOLD: Mixed signals with no compelling reason to change position
     - SELL: Deteriorating fundamentals or overvaluation with limited upside
     - AVOID: Significant red flags or structural headwinds

**Core Guidelines:**

- Be decisive: Avoid hedge language; make a clear call when type = "price"
- Stay evidence-based: Reference specific data points from the reports
- Consider asymmetric risk/reward: Factor in both upside potential and downside protection
- Maintain objectivity: Let the data drive your conclusion, not market sentiment
- No fabrication: Base analysis strictly on provided report content
- Keep in mind the timeframe analysis for metrics report: {{ $('Code2').item.json.timeframe }}

**Analysis Framework (weights for synthesis):**

- Risk Report: 10% (Downside protection)
- Financial Report: 25% (Core fundamentals)
- Social Report: 10%
- Firm News Report: 15% (Catalyst assessment)
- Macro Report: 10% (Economic environment)
- Metrics Report: 20% (Valuation & technical signals)
- SEC Report: 10%

**Input Reports:**

- Risk Report: {{ $json['Risk report'] }}
- Financial Report: {{ $json.Financials }}
- Social Report: {{ $('Social report1').item.json['Social report'] }}
- Firm News Report: {{ $json['news report'] }}
- Macro Report: {{ $('Macro report').item.json['macro report'] }}
- Metrics Report: {{ $('Metrics report').item.json.Metrics }}
- SEC Report: {{ $('SEC report').item.json['SEC report'] }}

Execute your analysis with the precision of an institutional investor and the clarity of a trusted advisor."

## 9.2. Anexo B – NVDA Informational Report Long Term

**"Comprehensive NVIDIA (NVDA) Synthesis**

**Executive Summary**

- NVIDIA remains at the forefront of the AI/data-center revolution, delivering exceptional top-line growth, industry-leading margins and a "fortress" balance sheet.
- Strong secular AI/digital-infrastructure demand underpins near-term momentum, while long-term drivers include generative AI, continued enterprise adoption and platform expansion.
- Valuation multiples have moderated from extreme highs (P/B near 170× two years ago to mid-40s today), though technical indicators flag overbought conditions and potential near-term consolidation.
- Key risks center on customer/supplier concentration, legal/geopolitical uncertainties, macro fiscal pressures and a lack of detailed drawdown data to gauge tail-risk exposure.

**Financial & Operational Performance (Weight: 25% + 10% SEC)**

- Revenue Growth: Tripled from ~$13.5B in mid-2023 to $46.7B in mid-2025 (QoQ up ~6%, YoY >50%); FY2025 revenue of $130.5B (+114% YoY).
- Profitability: Net-profit margin consistently >50% (peaks >57%), FY2025 gross margin at 75%; six-month net income of $45.2B.
- Operating Leverage: Opex/Sales halved to ~11–12% from ~20% in Q3-2023; operating income of $81.5B in FY2025.
- Cash-Flow: Operating cash flow averaging >$15B/quarter since Q2-2024; free cash flow frequently >$10B/quarter despite elevated capex.

**Balance Sheet & Capital Structure (10% SEC)**

- Liquidity: Cash & short-term investments of $52.1B cover total liabilities by ~1.4× (vs. <1× two years ago).
- Leverage: Total liabilities <30% of assets (down from >40% in mid-2023); debt of only $7.4B.
- Capital Deployment: $60B share-repurchase authorization announced; unused $575M commercial-paper facility underscores conservative management.

**Growth Drivers & Catalysts (15% Firm News + SEC Insights)**

- AI/Data-Center: Powers >75% of TOP500 supercomputers; benefits from surging data-center capex.
- Software Ecosystem: 5.9M+ developers on CUDA platform create ecosystem lock-in.
- R&D Investment: Cumulative $58.2B invested; supports roadmap in gaming, automotive, professional visualization.
- Buyback Program: $60B authorization signals capital-return commitment and confidence in growth outlook.

**Valuation & Technical Metrics (20% Metrics)**

- Valuation: P/B compressed from ~170× to ~45× despite accelerating fundamentals.
- Long-Term Trend: Price (192.57) trading above 200-EMA, confirming persistent uptrend.
- Overbought Signals: RSI at 79.1, %B at 1.00 against upper Bollinger Band; MACD recently crossed bearish though histogram remains positive.
- Near-Term Outlook: Technicals suggest potential pause or pullback before resuming broader uptrend.

**Risk Considerations (10% Risk + 10% SEC)**

- Drawdown Transparency: Absence of max/current/average drawdown data hinders precise tail-risk assessment.
- Concentration Risks: Heavy reliance on limited

customers and key suppliers; cyclical exposure to AI/data-center budgets.

- Legal & Geopolitical: Ongoing significant litigation (including U.S. Supreme Court case) and export-control/regulatory challenges in key markets.
- Macroeconomic: Elevated public debt (120.8% of GDP), fiscal deficits, trade imbalances and potential rate-policy volatility could weigh on spending.

**Macro Backdrop (10% Macro)**

- Expansion Phase: U.S. economy in mature expansion with low unemployment (3.9%) and moderate inflation (2.9%); policy rates likely near peak at 4.0%.
- Fiscal Headwinds: 2024 deficit at 7.3% of GDP and high structural spending introduce episodic volatility (debt-ceiling risks).
- External Environment: Strong dollar and slowing global growth could pressure exports; reserve-currency status and robust consumer spending offer offsetting support.

**Key Takeaways & Monitoring Points**

- NVIDIA's combination of blistering growth, superior margins and free-cash-flow conversion remains rare in technology.
- Valuation has pulled back meaningfully but still reflects lofty expectations—short-term technical indicators warrant caution.
- Close monitoring of customer diversification, litigation outcomes, regulatory developments and the sustainability of AI spending will be critical.
- Providing full drawdown data (max, current, average) is necessary to complete a rigorous risk assessment and better calibrate downside protection.

## 9.3. Anexo C – TSLA Informational Report Long Term

**"Executive Summary**

Tesla's latest data paint a picture of sequential operational improvement and strategic diversification, set against a late-cycle macro backdrop and a stretched valuation. Key upside drivers include rising margins, strong liquidity, revenue diversification into energy, and positive social and technical sentiment. Offsetting factors are incomplete risk transparency, negative free cash flow in Q2 2025, an 18× price-to-book multiple, and mixed momentum indicators.

**1. Risk Assessment (10%)**

- Drawdowns & Volatility: No reliable max, current or avg drawdown data—unable to assess crisis sensitivity or beta behavior.
- EPS Visibility: EPS data unreadable in Risk Report; profitability pillars remain opaque.
- Intrinsic vs. Market Value: Intrinsic value cited at $29.49, but no reference market price—margin of safety cannot be gauged.
- Implication: Core risk–return trade-off lacks foundation; downside protection metrics are missing.

**2. Financial Fundamentals (25%)**

- Top-Line Growth: Q2 2025 revenue up 16% sequentially, though still below last autumn's peak.
- Profitability: Gross margin slightly improved; EBITDA margin rose to ~10.5%; net margin doubled to ~5.2%; EPS jumped to $0.33 Q/Q.
- Balance Sheet: Cash covers ~70% of liabilities; debt/assets at ~39%; ROA at 1.8%, ROIC at 2.6%, both up Q/Q but below late-2024 peaks.
- Cash Flow: Operating cash flow of ~$2.5 bn is healthy; Q2 free cash flow was –$1.4 bn due to heavy capex/investing.
- Valuation: Trades at ~18× book value—rich by historical and industry standards, limiting valuation upside.

**3. Technical & Market Metrics (20%)**

- 200 EMA (~$435.5): Price hovering at this long-term pivot—market at a crossroads.
- RSI (14) = 63.9: Bullish momentum with room before

overbought territory.
- MACD: Signal line above MACD line, histogram shrinking—momentum has decelerated.
- Bollinger Bands %B = 0.93: Price near upper band, suggesting strong recent buying but potential for a pause or pullback.
- Technical Synthesis: Bullish strength via RSI and BB, but MACD indicates waning momentum—await directional confirmation.

**5. Macro & Industry Backdrop (10%)**

- U.S. Environment: Late-cycle expansion with 3.9% unemployment, 2.9% inflation, inverted yield curve, and 4% policy rate.
- Risks: High public debt (120.8% GDP), fiscal deficits, potential corporate leverage stress, geopolitical uncertainties.
- Sector Positioning: Favor healthcare and select tech; underweight rate-sensitive real estate/utilities until monetary easing materializes.
- Timing: Key indicators (yield curve normalization, durable goods recovery, core CPI cooling) likely in 6–12 months.

**6. Strategic Catalysts & Monitoring (15%)**

- Product Ramps: Cybertruck and Semi production rollout progress.
- Energy Segment Growth: H1 2025 energy revenues of $5.5 bn—track deployments and storage volumes.
- Charging Ecosystem: NACS adoption rates and Supercharger network utilization.
- Innovation Pipeline: Updates on AI/robotics (Tesla Bot) and margin impact.
- Earnings Releases: Q3 2025 results and H2 guidance.

**7. SEC-Filed Insights (10%)**

- H1 2025 Delivery: $34.2 bn combined automotive/energy revenue; $1.6 bn net income.
- Diversification: Energy storage now a meaningful contributor; automotive remains core (~$28.7 bn).
- Competitive Moat: Charging standard adoption and AI initiatives support medium-term differentiation.

**Social Sentiment (10%)**

- Uniformly bullish across key social channels: expectations of rate-cut benefits, record deliveries in Q3, and bullish chart patterns (engulfing candles, pennant/wedge breakouts).
- Market psychology appears optimistic, reinforcing near-term upside scenarios.

**Integrated View**

- Operational momentum is building: sequential margin expansion, stronger asset efficiency, diversified revenue streams.
- Liquidity and leverage profiles are conservative, underpinning stability.
- Valuation is at a premium: P/B ~18×, limiting valuation cushion and heightening sensitivity to execution risk.
- Technical indicators are mixed, with price at a pivotal level and momentum decelerating.
- Social sentiment and near-term catalysts support a bullish narrative, but macro late-cycle risks and missing risk quantification argue for caution.

**Next Steps for Investors**

- Deepen risk analysis: Obtain complete drawdown/volatility metrics and reconcile EPS data.
- Monitor Q3 results: Validate delivery growth and margin targets.
- Watch technical resolution: A decisive move above or below the 200 EMA will signal the next trend.
- Track macro triggers: Yield-curve normalization and core CPI trends for timing incremental exposure.

## 9.4. Anexo D – TSLA Informational Report Long Term

### Anexo D.1 Risk Report

- "- Drawdown comparison (stock vs. index): Not available; Max, Current, and Average drawdowns were not provided for either, so relative downside cannot be quantified.
- Amplify/follow/mitigate: Indeterminable without synchronized drawdown series; no evidence of beta-like behavior.

- Risk in different environments: Without MDD/current/average metrics, we cannot infer crisis sensitivity, recovery profile, or typical pullback depth.
- EPS assessment: EPS data is unreadable ([object Object]); profitability level, stability, and growth cannot be evaluated.
- Intrinsic value vs. market: Intrinsic value is 29.49, but no current market price was provided; we cannot judge under/overvaluation or margin of safety.
- What this means: Core risk (drawdowns) and return (EPS) pillars are missing; any conclusion on risk-adjusted attractiveness would be speculative.
- Recommendation: Avoid.
- Rationale: With no drawdown metrics, no interpretable EPS, and no price to compare to intrinsic value, the risk–reward cannot be substantiated; await complete data before taking exposure.

”

**Anexo D.2 Financial Report**

“Income Statement Trends

- Revenue climbed 16% sequentially in Q2 2025, recovering from a seasonal trough, though it remains below last autumn’s peak.
- Gross and EBITDA margins edged higher quarter-on-quarter (EBITDA margin up from ~10% to ~10.5%), reflecting tighter cost control, while net margin more than doubled sequentially to ~5.2%.
- EPS jumped from $0.12 to $0.33 Q/Q, but year-over-year profit margins are modestly below prior peaks.

Balance Sheet & Ratios

- Liquidity remains strong: cash and equivalents cover roughly 70% of total liabilities.
- Solvency is solid, with liabilities at ~39% of assets—a conservative debt structure.
- Return on assets rose to 1.8% (from 1.0% last quarter), and return on capital improved to 2.6%, signaling better use of assets and invested capital, though both remain below levels seen in late 2024.
- Valuation sits at ~18× book value—high by historical and industry standards, suggesting limited margin for valuation upside.

Cash Flow Highlights

- Operating cash flow is consistently positive at ~$2.5 billion, up Q/Q.
- Heavy investing led to a Q2 free cash flow shortfall (~–$1.4 billion), contrasting with a positive FCF in Q1, reflecting ongoing capital spending.

Interpretation of Key Signals

- Rising sequential margins and ROA point to improving profitability and asset efficiency.
- Strong liquidity and conservative leverage underpin financial stability.
- Persistent negative free cash flow in this quarter underscores aggressive reinvestment, which may pressure cash returns.
- A very rich price-to-book multiple indicates the stock is trading at a premium, reducing the potential for valuation-driven gains.

Final Summary & Recommendation

Key financial signals:

1. Profitability and efficiency are improving sequentially, yet absolute returns remain modest.
2. Liquidity and solvency metrics are robust, but heavy capex has driven free cash flow negative this quarter.
3. Valuation at ~18× book signals a stretched multiple relative to fundamentals.

Recommendation: Hold
While operational metrics are trending positively, the elevated valuation and recent negative free cash flow suggest limited near-term upside. A Hold stance balances continued operational improvement against a premium price.

**Anexo D.3 Macro Report**

“Country Reliability Assessment (Score: 8/10)
The U.S. exhibits very strong economic fundamentals—robust GDP per capita (€79,305), low unemployment (3.9%), and moderate inflation (2.9%). Its reserve-currency status and deep capital markets underpin high creditworthiness. Offsetting factors include a 120.8% debt/GDP ratio and a sizable fiscal deficit (–7.3% of GDP), which weigh on sustainability over the medium term but remain manageable given favorable financing conditions.

Investment Timing Analysis

- Economic Cycle Phase: Late-cycle expansion transitioning toward a mild slowdown. Growth has moderated from post-pandemic highs, and the yield curve remains inverted.
- Recommendation: Hold. The combination of stable yet high policy rates (4.00%), elevated valuations, and looming recessionary pressures argue against fresh long-only positions now.
- Optimal Timing Window: 6–12 months. Look to deploy incremental capital when leading indicators (ISM manufacturing, consumer sentiment) bottom, or when the Fed signals a rate pivot.
- Trigger Indicators:
  - Inversion in 2s–10s Treasury curve normalizing
  - Durable Goods Orders turning positive
  - Core CPI sustainably below 2.5%

Risk Assessment

High Risks

- Fiscal policy drift: Congressional gridlock could exacerbate deficits or trigger debt-ceiling showdowns.
- Corporate leverage: Elevated debt levels in key sectors could amplify downturn stress.

Medium Risks

- Geopolitical tensions: Supply-chain disruptions or energy shocks.
- Policy uncertainty: Fed communication missteps could spark volatility.

Low Risks

- Sovereign credit: U.S. Treasury market remains deep and liquid; default risk negligible.

Mitigation Strategies

- Hedge duration: use short-dated Treasuries or floating-rate notes.
- Diversify into non-U.S. developed equities (e.g., EU, Japan) for reduced correlation.
- Position in defensive sectors (consumer staples, healthcare) during late cycle.

Key Insights & Recommendations

- Drivers: Consumer spending (70% of GDP) remains resilient; corporate earnings returning to trend.
- Strengths: Reserve-currency issuance, deep financial markets, labor market tightness.
- Weaknesses: Elevated public debt, low tax burden relative to spending (25.2% vs. OECD average ~34%), large trade deficit (€1.07 trn).
- Benchmarks: U.S. debt/GDP at 120.8% vs. G7 average ~111%; unemployment at 3.9% vs. OECD 5.3%.
- Sector Suggestions: Favor health care and select technology leaders with strong balance sheets. Underweight rate-sensitive real estate and utilities until the Fed pivots.
- Portfolio Allocation: Maintain core U.S. equity exposure at benchmark weights; use 10–15% in Treasuries or cash to capitalize on entry opportunities.
- Confidence Level: Medium-High, assuming no abrupt policy shifts or geopolitical shock.

Final Recommendation: Hold

**Anexo D.4 Metrics Report**

“# TESLA (TSLA) - 1M Technical Analysis Report

## Trend Analysis

**200 EMA (≈$435.54)**

- The current price is sitting virtually on the 200-period exponential moving average, suggesting equilibrium between buyers and sellers at this level
- Neither strong trend-support nor clear resistance is in play—price hovering here indicates the 200 EMA is acting more like a magnet than a springboard
- This positioning reflects a critical decision point where the market is testing this key long-term trend indicator

## Momentum Indicators

**RSI (14) = 63.92**

- The RSI is positioned above its midpoint (50) but remains under the overbought threshold of 70, signaling ongoing bullish momentum without exhaustion

- There remains approximately 6 points of "runway" before hitting overbought territory, implying room for upside before typical RSI-based sell signals emerge
- This moderate bullish strength reflects that buyers have dominated recent moves but not to an extreme level
- Being above the 50 midpoint confirms that buyers remain generally in control

**MACD (12,26,9)**

- MACD Line (13.04) vs. Signal Line (42.36): The MACD line is trading 29.32 points below the signal line, indicating that recent short-term gains have lost steam and momentum has tilted slightly bearish
- Histogram (29.33): While still positive, it has retreated from higher levels—this shrinkage reflects a deceleration of the prior upswing rather than fresh selling pressure
- The MACD line trading under the signal line confirms a loss of bullish momentum, with bears currently holding the edge in the medium-term oscillator, even though both lines remain in positive territory
- Recent histogram "height" reflects the negative gap, indicating that upward momentum has given way to downward pressure

## Volatility Analysis

**Bollinger Bands %B (20,2) – 0.93**

- At 0.93, price is positioned 93% of the way from the lower band to the upper band, sitting very close to the upper band
- This positioning shows recent candles have been pushing against the top boundary of normal volatility, implying strong buying pressure within the current 20-period range
- The proximity to the upper band suggests that while momentum remains on the upside, the market is approaching the band's envelope and could see a pause or pullback if it fails to break higher

## Technical Conflicts and Considerations

There is a notable divergence between indicators:

- **Bullish signals**: RSI above 50 with room to run, Bollinger Bands showing strong buying pressure, price near key 200 EMA support
- **Bearish signals**: MACD showing loss of momentum with line below signal, histogram declining from higher levels

## Combined Market Sentiment

The technical picture presents a market at a crossroads. While underlying bullish sentiment persists (RSI above midpoint, strong positioning within Bollinger Bands), momentum indicators suggest the recent upward move is losing steam. The stock's position at the critical 200 EMA level represents a key decision point for both bulls and bears.

## Final Decision: HOLD

The conflicting signals between momentum indicators (MACD bearish divergence) and strength indicators (RSI bullish, Bollinger Bands pressure) suggest waiting for clearer directional confirmation. The critical positioning at the 200 EMA makes this an ideal level to observe how the market resolves this technical standoff before committing to a directional bias.
”

**Anexo D.5 News Report**

“# Tesla Market Analysis: Strategic Positioning and Execution Challenges

**Executive Summary**

Tesla's recent strategic moves reveal a company attempting to balance growth imperatives with margin preservation amid intensifying global competition. The October 7th launch of "Standard" versions of the Model Y and Model 3, priced at $39,990 and $36,990 respectively, represents a tactical response to market pressures rather than the breakthrough affordable EV strategy investors have anticipated. Concurrent developments including legal resolution expenses and strategic AI partnerships suggest mixed near-term headwinds with selective long-term opportunities.

**Market Analysis**

Tesla's affordability strategy faces immediate execution challenges that could pressure Q4 deliveries and 2024 margins. The newly launched Standard variants, while

approximately $5,000 cheaper than base models, achieve cost reduction through feature elimination rather than manufacturing innovation—removing premium paint options, upgraded wheels, and interior amenities. This approach drew sharp criticism from Chinese consumers, who dismissed the offerings as "beggar models" on Weibo, highlighting Tesla's vulnerability in the world's largest EV market where local competitors offer comparable features at similar price points.

The pricing strategy reveals structural constraints in Tesla's cost base. When adjusted for inflation since Musk's 2020 promise of a $25,000 EV, the Model 3 Standard approaches that target in real terms, yet market reception suggests limited competitive advantage. Chinese market skepticism carries particular weight given Tesla's 22% revenue exposure to the region and intensifying competition from BYD, NIO, and other domestic manufacturers offering superior value propositions at comparable price points.

Near-term financial pressures include legal settlement costs from the Twitter acquisition fallout. The October 8th agreement to compensate former Twitter executives, including ex-CEO Parag Agrawal, represents additional cash outflows from Musk's broader technology portfolio, though specific amounts remain undisclosed. While this resolves legal overhang, it underscores execution risks across Musk's venture ecosystem.

Conversely, strategic AI positioning through xAI shows promise. NVIDIA CEO Jensen Huang's October 8th endorsement, specifically stating his regret at not investing more heavily in Musk's AI venture, validates the long-term thesis. This represents a 70% probability catalyst for Tesla's AI and autonomous driving development, given NVIDIA's computing infrastructure leadership and strategic partnerships across the AI ecosystem.

**Investment Outlook**

Tesla faces a challenging 12-18 month period with 60% probability of margin compression as the Standard models cannibalize higher-trim sales without meaningfully expanding market share. The Chinese market reaction suggests limited international scalability for the affordability strategy, creating a 45% probability scenario where Tesla cedes market share to local competitors while failing to achieve volume targets.

Risk mitigation centers on AI development acceleration and manufacturing efficiency improvements. The xAI partnership pathway offers Tesla differentiated autonomous driving capabilities, potentially justifying premium valuations despite near-term margin pressure. However, this represents a longer-term catalyst requiring 18-24 months for material impact.

Immediate catalysts include Q4 delivery numbers due January 2024, Chinese market share data, and Standard model take-rates. Sector implications favor established premium manufacturers like BMW and Mercedes-Benz who avoid direct price competition, while pressuring other EV pure-plays lacking Tesla's charging infrastructure and AI development resources.

The current strategic positioning suggests Tesla trading sideways with high volatility pending clearer execution metrics on affordability strategy effectiveness and AI development timeline clarity.
”

**Anexo D.6 Social Report**

“Exe”

**Anexo D.7 SEC Report**

“Tesla, Inc. (TSLA) - Investment Signal Report
Report Type: Buy/Sell Signal | Date: Analysis of H1 2025 Performance
Filing Information: Based on 10-K (Jan 30, 2025), 10-Q filings through Q2 2025, and recent 8-K disclosures

**Executive Summary**
Tesla demonstrates solid operational performance in H1 2025 with $34.2 billion in combined automotive and energy revenues and $1.6 billion net income. The company's strategic expansion into AI/robotics and energy storage, coupled with strong automotive fundamentals, supports continued growth momentum.

**Investment Analysis**

**Recommendation:** BUY

**Rationale**

**Strengths Supporting Buy Rating:**

- Revenue Diversification: Energy generation and storage segment generated $5.5 billion in H1 2025, representing meaningful diversification beyond automotive
- Automotive Leadership: $28.7 billion in automotive sales demonstrates market dominance in EV space
- Profitability: $1.6 billion net income in six months shows strong operational efficiency
- Strategic Positioning: NACS charging standard adoption creates competitive moat in charging infrastructure
- Innovation Pipeline: AI and robotics initiatives (Tesla Bot) position company for next-generation growth

**Key Risks:**

- Limited liquidity data available for comprehensive balance sheet assessment
- Concentrated exposure to automotive market cyclicality
- Execution risk on emerging initiatives (AI, robotics)

**Risk/Reward Assessment**

Reward Potential: High - Multiple growth vectors (automotive expansion, energy storage scaling, AI/robotics development)

Risk Level: Moderate - Established profitability with diversified revenue streams mitigates single-point-of-failure risk

**Key Catalysts & Monitoring Points**

**Near-term Catalysts:*

- November 6, 2025 Annual Shareholder Meeting - potential strategic updates
- Q3 2025 earnings release - continuation of H1 momentum
- Cybertruck and Semi production ramp updates

**Key Metrics to Monitor:**

- Automotive delivery growth rates
- Energy storage deployment volumes
- Supercharger network expansion and utilization
- Gross margin trends across business segments
- Progress updates on AI/robotics initiatives

**Strategic Monitoring:**

- Market share evolution in EV segment
- Energy storage market penetration
- Charging network monetization and third-party adoption of NACS

Analysis based on Tesla's SEC filings through Q2 2025. Recommendation reflects current financial performance and strategic positioning as disclosed in regulatory documents.

# 10. Otras publicaciones

| | | | | |
|---|---|---|---|---|
| Feb | 2026 | DT | Comportamiento racional en los mercados financieros | Antonio Hormigos |
| Feb | 2026 | DT | Stablecoins en Tesorería Usos Ventajas y Riesgos | Carlos de Fuenmayor |
| Dic | 2025 | DT | Fondos de Inversión Alternativa: Private Equity y Deuda Privada | Josep Martínez Pascual |
| Oct | 2025 | DT | La Energia Nuclear en el Marco de la Transición Energética | Antonio González Jiménez |
| Set | 2025 | DT | Artifficial Intelligence in economics and finance an AI-driven literature review | Andres Alonso Robesco |
| Jun | 2025 | NT | The Crypto space under the new trump administration | Sergi Barberán |
| Abr | 2025 | DT | Método Sistemático para encontrar empresas de calidad | Ferran Carreras Lavila |
| Mar | 2025 | DT | Escenarios de la inversión de impacto ante el inversor particular | Andrea González G.Vega |
| Feb | 2025 | NT | Los informes Letta y Draghi: Mismas recetas…¿distintos resultados? Una mirada crítica | Pablo Agnese |
| Ene | 2025 | DT | How similar is the Chinese economy to that of Japan after the bubble burst? | Alicia García Herrero |
| Nov | 2024 | DT | Resolving sovereign in the era of geopolitical tensions | Sergi Lanau |
| Oct | 2024 | DT | Shadow Banking: current Headaches, Old Problems? | David Ramos Muñoz |
| Set | 2024 | DT | Situación actual de los NFTs y del Metaverso | Joaquim Matinero Tor |
| Set | 2024 | NT | La macroeconomía argentina y los primeros días del experimento anarcocapitalista del presidente Milei | Alejandro D. Jacobo |
| Jul | 2024 | DT | Principales instrumentos públicos para financiar la innovación de las empresas | Víctor Cruz Salgado<br>Miguel Carretero Rodríguez |
| May | 2024 | NT | El negocio de adquirencia de pagos: evolución reciente y desarrollos de futuro | Arturo Zamarriego Muñoz<br>Jose María López Jiménez |
| Abril | 2024 | NT | *Spin-offs*, características y el impacto de la deuda en este tipo de oportunidades | Joan Anglada Salarich |
| Mar | 2024 | NT | Situación de la regulación de la prevención del blanqueo de capitals y de la financiación del terrorismo en el marco de los criptoactivos | Macarena López Martínez |
| Feb | 2024 | DT | Riesgo climático. De los conceptos básicos al uso de escenarios NGFS | Vicente Bouza Álvarez |
| Dic | 2023 | DT | Making Biodiversity Material in Financial Decision-Making | Mark Halle |
| Nov | 2023 | NT | El mercado de la vivienda mundial: ¿Una nueva burbuja inmobiliaria? | José María Raya |
| May | 2023 | DT | El *direct lending*: Una alternativa creciente en la financiación a empresas | Albert Gumà, Ramiro Lama y Eloi Noya |
| Abr | 2023 | DT | Los mercados energéticos en España y Europa | Roger Medina Juidías |
| Mar | 2023 | DT | La tecnología cuantitativa de los roboadvisors | Gerard Albà Soler y<br>Arnau Vía Martínez-Seara |
| Ene | 2023 | DT | Business Angels: Creadores de Valor de impacto en el ecosistema emprendedor | Juan Álvarez de Lara |
| Dic | 2022 | NT | El papel del Sistema de Derechos de Emisión en la transición a la Neutralidad climática | Luis Antonio Galiano Bastarrica |
| Dic | 2022 | DT | Las divisas digitales de los Bancos Centrales: En los albores de un sistema financiero digital | Fernando Rojas Traverso y<br>Francisco del Olmo García |

| | | | | |
|---|---|---|---|---|
| Nov | 2022 | NT | Efectos de la tokenización de activos para los mercados financieros | Carlos de Fuenmayor |
| Oct | 2022 | NT | Comptabilitat per la sostenibilitat: Aplicació pràctica d'un ràting ESG | Josep Maria Caselles, Jaume Gené y Jordi Martí |
| Jul | 2022 | DT | Instrumentos financieros vinculados a la inflación y su uso para la cobertura de riesgos | Francisco José Alcalá Vicente |
| Jun | 2022 | DT | La descarbonización del sistema energético global. Enseñanzas de los escenarios del Grupo Intergubernamental de Expertos sobre el Cambio Climático | José Mª Martín-Moreno y Jorge Blázquez |
| Mar | 2022 | DT | Crisis económica COVID'19: Elementos diferenciales. Una especial consideración a la política monetaria y su impacto en los mercados financieros | David Cano Martínez |
| Mar | 2022 | DT | Retos y oportunidades del estrés climático de la banca europea | Francisco del Olmo García y Fernando Rojas Traverso |
| Feb | 2022 | NT | Criptoactivos: un nuevo activo de inversión | Carlos de Fuenmayor |
| Dic | 2021 | DT | Bonos contingentes convertibles (Coco): de Basilea III a la transición sostenible | Arturo Zamarriego Muñoz |
| Nov | 2021 | NT | Special Purpose Acquisition Company (SPAC) | Carlos de Fuenmayor |
| Oct | 2021 | DT | Sostenibilidad de la deuda: geometría y límites difusos | Daniel Suárez Montes |
| Set | 2021 | NT | Bonos Sociales: Financiando la equidad | Julián Romero Zarco |
| Set | 2021 | DT | El imprescindible papel de las agencias de *Rating* enel viraje hacia la sostenibilidad | Antonio Madera del Pozo |
| Jul | 2021 | NT | Measuring and targeting systemic cyclical risks – the Countercyclical Capital Buffer | Sofia Velasco |
| Jun | 2021 | NT | El Sandbox regulatori: ¿És una oportunitat d'apropar el sector al regulador mitjançant la digitalització? | Pablo Domenech |
| May | 2021 | DT | Comportament diferencial en mercats de capital d'empreses sostenibles. Una mirada a les empreses emisores de bons verds | Jorge Sanz González |
| Abr | 2021 | NT | Carteres òptimes alternatives a la de mínima volatilitat de Markowitz | Laura Valls Sanchis |
| Feb | 2021 | DT | Megatendències i temàtiques en carteres de renta variable | David Cano y Francisco Lomba |
| Feb | 2021 | DT | Riscos relacionats amb el clima i mediambientals: una introducció a les expectatives supervisores i al risc | Arturo Fraile Izquierdo |
| Nov | 2020 | NT | Nuevos indicadores económicos para una nueva era | Diego Isabel La Moneda |
| Oct | 2020 | NT | Aspectos legales de las ISR a las entidades de capital de riesgo | Alex Plana Paluzie |
| Jul | 2020 | NT | Dark Pools and High Frequency Trading: A Brief Note | Anna Bayona |
| Jun | 2020 | DT | Los emisores soberanos ante la revolución sostenible | Andrés Alonso |
| Jun | 2020 | NT | El impuesto español sobre transacciones financieras, una medida alejada de la Tasa Tobin | Jordi Pey Nadal |
| May | 2020 | DT | ¿Cómo valorar una *start-up* y qué métodos de valoración son más adecuados? | Roger Martí Bosch |
| Mar | 2020 | NT | Libra: ¿La moneda que puede cambiar el futuro del dinero? | Miguel otero Iglesias |
| Dic | 2019 | NT | ¿Cómo puede un inversor particular implementar una estrategia sencilla y barata en factores? ¿Qué puede esperar de ella? | Ferran Capella Martínez |
| Dic | 2019 | DT | Una nota sobre la valoración de *cross currency swaps* | Lluís Navarro i Girbés |
| Nov | 2019 | DT | Criptoactivos: naturaleza, regulación y perspectivas | Víctor Rodríguez Quejido |
| Oct | 2019 | NT | ¿Qué valor aportan al asesoramiento financiero los principales *insights* puestos de manifiesto por la *behavioral economics*? | Óscar de la Mata Guerrero |
| Jul | 2019 | NT | El MARF y su positivo impacto en el mercado financiero actual | Aitor Sanjuan Sanz |

| | | | | |
|---|---|---|---|---|
| Jun | 2019 | NT | Las STO: ¿puede una empresa financiarse emitiendo tokens de forma regulada? | Xavier Foz Giralt |
| Abr | 2019 | NT | Criterios de selección para formar una cartera de inversión basada en empresas del Mercado Alternativo Bursátil (MAB) | Joan Anglada Salarich |
| Mar | 2019 | DT | Limitaciones del *blockchain* en contratación y propiedad | Benito Arruñada |
| Feb | 2019 | NT | MREL y las nuevas reglas de juego para la resolución de entidades bancarias | Francisco de Borja Lamas Peña |
| Dic | 2018 | DT | Principios éticos en el mundo financiero | Antonio Argandoña y Luís Torras |
| Nov | 2018 | NT | Inversión socialmente responsable 2.0. De la exclusión a la integración | Xosé Garrido |
| Nov | 2018 | NT | Transformación de los canales de intermediación del ahorro. El papel de las fintech. Una especial consideración a los <<robo advisors>> | David Cano Martínez |
| Oct | 2018 | DT | La Crisis Financiera 2007-2017 | Aristóbulo de Juan |
| Jul | 2018 | NT | Evolución del Equity Crowdfunding en España, 2011-2017 | Marc Montemar Parejo y Helena Benito Mundet |
| Jul | 2018 | NT | Demografía, riesgo y perfil inversor. Análisis del caso español | Javier Santacruz Cano |
| Jun | 2018 | NT | Gestión financiera del riesgo climático, un gran desconocido para las las empresas españolas | Ernesto Akerman Brugés |
| May | 2018 | NT | Las SOCIMI: ¿Por qué se han convertido en el vehículo estrella del sector inmobiliario? | Pablo Domenech |
| Mar | 2018 | NT | Desequilibrios recientes en TARGET2 y sus consecuencias en la balanza por cuenta corriente | Eduardo Naranjo |
| Ene | 2018 | NT | La Segunda Directiva de Servicios de Pago y sus impactos en el mercado | Javier Santamaría |
| Dic | 2017 | DT | “Factor investing”, el nuevo paradigma de la inversión | César Muro Esteban |
| Nov | 2017 | NT | La implantación de IFRS9, el próximo reto de la banca europea | Francisco José Alcalá Vicente |
| Oct | 2017 | NT | El Marketplace Lending: una nueva clase de activo de inversión | Eloi Noya |
| Oct | 2017 | NT | Prácticas de buen gobierno corporativo y los inversores institucionales | Alex Bardají |
| Set | 2017 | NT | El proceso de fundrasing: Como atraer inversores para tu Startup | Ramón Morera Asiain |
| Jun | 2017 | NT | Clases de ETF según su método de réplica de benchmarks y principales riesgos a los que están sujetos los inversores, con especial foco en el riesgo de liquidez | Josep Bayarri Pitchot |
| May | 2017 | NT | Las consecuencias económicas de Trump. Análisis tras los cien primeros días | L.B. De Quirós y J. Santacruz |
| Mar | 2017 | DT | Indicadores de coyuntura en un nuevo entono económico | Ramon Alfonso |
| Ene | 2017 | NT | La protección del inversor en las plataformas de crowfunding vs productos de banca tradicional | Álex Plana y Miguel Lobón |
| Oct | 2016 | NT | Basilea III y los activos por impuestos diferidos | Santiago Beltrán |
| Sep | 2016 | DT | El Venture Capital como instrumento de desarrollo económico | Ferran Lemus |
| Jul | 2016 | DT | MAB: una alternativa de financiación en consolidación | Jordi Rovira |
| Jun | 2016 | NT | Brasil, un país de futuro incierto | Carlos Malamud |
| May | 2016 | DT | La evolución de la estrategia inversora de los Fondos Soberanos de Inversión | Eszter Wirth |
| Abr | 2016 | DT | Shadow Banking:Money markets odd relationship with the law | David Ramos Muñoz |
| Mar | 2016 | DT | El papel de la OPEP ante los retos de la Nueva Economía del Petróleo | José MªMartín-Moreno |

| | | | | |
|---|---|---|---|---|
| Feb | 2016 | NT | Guerra de divisas: los límites de los tipos de cambio como herramienta de política económica. Un análisis a partir de los ICM | David Cano |
| Ene | 2016 | DT | 1+1=3 El poder de la demografía. UE, Brasil y México (1990-2010): demografía, evolución socioeconómica y consecuentes oportunidades de inversión | Pere Ventura Genescà |
| Nov | 2015 | DT | ¿Un reto a las crisis financieras? Políticas macroprudenciales | Pablo Martínez Casas |
| Oct | 2015 | NT | Revitalizando el mercado de titulizaciones en Europa | Rosa Gómez Churruca y Olga I.Cerqueira de Gouveia |
| Abr | 2015 | NT | Ganancias de competitividad y deflación es España | Miguel Cardoso Lecourtois |
| Ene | 2015 | DT | Mercado energético mundial: desarrollos recientes e implicaciones geoestratégicas | Josep M. Villarrúbia |
| Dic | 2014 | DT | China's debt problem: How worrisome and how to deal with it? | Alicia García y Le Xía |
| Nov | 2014 | NT | Crowdequity y crowdlending: ¿fuentes de financiación con futuro? | Pilar de Torres |
| Oct | 2014 | NT | El bitcoin y su posible impacto en los mercados | Guillem Cullerés |
| Sep | 2014 | NT | Regulación EMIR y su impacto en la transformación del negocio de los derivados OTC | Enric Ollé |
| Mar | 2014 | DT | Finanzas islámicas: ¿Cuál es el interés para Europa? | Celia de Anca |
| Dic | 2013 | DT | Demografía y demanda de vivienda: ¿En qué países hay un futuro mejor para la construcción? | José María Raya |
| Nov | 2013 | DT | El mercado interbancario en tiempos de crisis: ¿Las cámaras de compensación son la solución? | Xavier Combis |
| Sep | 2013 | DT | CVA, DVA y FVA: impacto del riesgo de contrapartica en la valoración de los derivados OTC | Edmond Aragall |
| May | 2013 | DT | La fiscalidad de la vivienda: una comparativa internacional | José María Raya |
| Abr | 2013 | NT | Introducción al mercado de derivados sobre inflación | Raúl Gallardo |
| Abr | 2013 | NT | Internacionalización del RMB: ¿Por qué está ocurriendo y cuáles son las oportunidades? | Alicia García Herrero |
| Feb | 2013 | DT | Después del dólar: la posibilidad de un futuro dorado | Philipp Bagus |
| Nov | 2012 | NT | Brent Blend, WTI… ¿ha llegado el momento de pensar en un nuevo petróleo de referencia a nivel global? | José M.Domènech |
| Oct | 2012 | L | Arquitectura financiera internacional y europea | Anton Gasol |
| Sep | 2012 | DT | El papel de la inmigración en la economía española | Dirk Godenau |
| Jun | 2012 | DT | Una aproximación al impacto económico de la recuperación de la deducción por la compra de la vivienda habitual en el IRPF | José María Raya |
| Abr | 2012 | NT | Los entresijos del Fondo Europeo de Estabilidad Financiera (FEEF) | Ignacio Fernández |
| Mar | 2012 | M | La ecuación general de capitalización y los factores de capitalización unitarios: una aplicación del análisis de datos funcionales | César Villazon y Lina Salou |
| Dic | 2011 | NT | La inversión socialmente responsable. Situación actual en España | Mª Ángeles Fernández Izquierdo |
| Dic | 2011 | NT | Relaciones de agencia e inversores internacionales | Aingeru Sorarrin y olga del Orden |
| Oct | 2011 | NT | Las pruebas de estrés. La visión de una realidad diferente | Ricard Climent |
| Jun | 2011 | DT | Derivados sobre índices inmobiliarios. Características y estrategias | Rafael Hurtado |
| May | 2011 | NT | Las pruebas de estrés. La visión de una realidad diferente | Ricard Climent |
| Mar | 2011 | NT | Tierras raras: su escasez e implicaciones bursátiles | Alejandro Scherk |

| | | | | |
|---|---|---|---|---|
| Dic | 2010 | NT | Opciones reales y flujo de caja descontado: ¿Cuándo utilizarlos? | Juan Mascareñas y Marcelo Leporati |
| Nov | 2010 | NT | Cuando las ventajas de TIPS son superada por las desventajas: el caso argentino | M. Belén Guercio |
| Oct | 2010 | DT | Introducción a los derivados sobre volatilidad: definición, valoración y cobertura estática | Jordi Planagumà |
| Jun | 2010 | DT | Alternativas para la generación de escenarios para el stress testing de carteras de riesgo de crédito | Antoni Vidiella |
| Mar | 2010 | NT | La reforma de la regulación del sistema financiero internacional | Joaquin Pascual Cañero |
| Feb | 2010 | NT | Implicaciones del nuevo Real Decreto 3/2009 en la dinamización del crédito | M. Elisa Escolà y Juan Carlos Giménez |
| Feb | 2010 | NT | Diferencias internacionales de valoración de activos financieros | Margarita Torrent |
| Ene | 2010 | DT | Heterodoxia Monetaria: la gestión del balance de los bancos centrales en tiempos de crisis | David Martínez Turégano |
| Ene | 2010 | DT | La morosidad de banco y cajas: tasa de morosidad y canje de crétidos por activos inmobiliarios | Margarita Torrent |
| Nov | 2009 | DT | Análisis del TED spread la transcendencia del riesgo de liquidez | Raül Martínez Buixeda |