



DOCENTES DE ADMINISTRACIÓN FINANCIERA

**45 Jornadas Nacionales de Administración Financiera**  
Septiembre 18 y 19, 2025

# **Análisis financiero y agentes IA**

## **Transformando la gestión empresarial**

**Ariel Eduardo Verón**

*Universidad de Buenos Aires*

### SUMARIO

1. Introducción
2. Marco teórico
3. Metodología del estudio
4. Desarrollo: casos de uso y análisis
5. Reflexiones y conclusión

Para comentarios:  
[ariel.veron@gmail.com](mailto:ariel.veron@gmail.com)

## Resumen

Se explora la viabilidad técnica y organizacional de implementar agentes de inteligencia artificial (IA) basados en *large language models* (LLM) para transformar procesos financieros empresariales críticos. A través de un diseño metodológico de casos múltiples se analizaron tres aplicaciones fundamentales: la automatización del análisis multi-período de ratios financieros, la detección proactiva de fraudes en contextos inflacionarios y la predicción temprana del riesgo crediticio. Los resultados evidencian que los agentes LLM permiten superar las limitaciones de los enfoques tradicionales al proporcionar análisis contextualizados, detección de patrones complejos y capacidad predictiva, con impactos significativos en eficiencia operativa, reducción de pérdidas y optimización de la toma de decisiones. Además, se identifican implicaciones organizacionales y profesionales relevantes, incluyendo la transición hacia modelos de gestión proactivos, la democratización del acceso a capacidades analíticas avanzadas y la redefinición de competencias requeridas en el rol financiero. Si bien las conclusiones deben interpretarse considerando limitaciones como el uso de datos simulados y la rápida evolución tecnológica de los LLM, los hallazgos sugieren un potencial transformador de la IA generativa en el ámbito financiero y delimitan líneas de investigación futuras en tesorería, gestión de activos, cumplimiento regulatorio y finanzas sostenibles.

## 1. Introducción

### 1.1 Contextualización del problema

El análisis financiero empresarial enfrenta en la actualidad una paradoja fundamental: mientras que el volumen de datos disponibles para la toma de decisiones ha crecido exponencialmente, la capacidad de los profesionales para procesarlos y extraer insights accionables sigue limitada por las herramientas tradicionales y los enfoques analíticos convencionales. Esta brecha entre la abundancia de información y la efectividad del análisis constituye uno de los principales desafíos que enfrentan las organizaciones en el contexto económico contemporáneo.

Las herramientas tradicionales de análisis financiero (principalmente hojas de cálculo como Microsoft Excel, sistemas ERP (*enterprise resource planning*) y soluciones de *business intelligence*) fueron diseñadas para un entorno empresarial menos complejo y con volúmenes de datos significativamente menores. Según estudios recientes de McKinsey & Company (2023), los profesionales financieros dedican aproximadamente 70 % de su tiempo a actividades de recopilación, limpieza y formateo de datos, dejando apenas 30 % para el análisis estratégico y la generación de insights que agreguen valor real al proceso de toma de decisiones.

Esta ineficiencia se manifiesta particularmente en tres áreas críticas: el análisis de ratios financieros de múltiples periodos, donde la interpretación contextual de tendencias requiere horas de trabajo manual para identificar patrones significativos; la detección de fraudes y ano-

malías, donde los sistemas basados en reglas tradicionales generan altos índices de falsos positivos y fallan en detectar esquemas maliciosos sofisticados; y la gestión de riesgo crediticio, donde el análisis de aging convencional proporciona una visión retrospectiva que limita la capacidad predictiva necesaria para una gestión proactiva.

El costo de estas ineficiencias es considerable. Un estudio de la Association of Certified Fraud Examiners (2024) estima que las organizaciones pierden en promedio 5 % de sus ingresos anuales debido a fraudes no detectados oportunamente, mientras que PwC (2023) reporta que las decisiones de crédito basadas exclusivamente en análisis histórico resultan en tasas de default 40 % superiores comparadas con enfoques predictivos más sofisticados.

## 1.2 Motivación y justificación

La evolución reciente de la inteligencia artificial generativa, particularmente el desarrollo de modelos extensos de lenguaje (*large language models*, LLM) como GPT-5, Claude 4, y Gemini Ultra, ha creado una oportunidad sin precedentes para transformar radicalmente los procesos de análisis financiero. Estos modelos han demostrado capacidades emergentes en razonamiento complejo, análisis de patrones temporales y generación de insights contextualizados que van más allá de las limitaciones de los sistemas de análisis tradicionales.

La transición de chatbots conversacionales simples hacia agentes autónomos capaces de ejecutar tareas complejas representa un cambio de paradigma fundamental. Mientras que los chatbots se limitan a responder preguntas específicas, los agentes basados en LLM pueden planificar secuencias de acciones, utilizar herramientas especializadas, mantener contexto temporal y generar análisis multidimensionales que tradicionalmente requerían intervención humana experta.

Sin embargo, existe una brecha significativa entre la capacidad tecnológica disponible y su adopción efectiva en el sector financiero empresarial. Según el Global AI Survey de BCG (2024), mientras que 85 % de las organizaciones considera la IA como una prioridad estratégica, solo 23 % ha implementado exitosamente soluciones de IA generativa en procesos financieros críticos. Esta brecha se debe principalmente a la falta de marcos metodológicos claros, casos de uso demostrados y métricas confiables de retorno de inversión.

El momento para abordar esta brecha es particularmente oportuno. El contexto económico actual, caracterizado por volatilidad inflacionaria, incertidumbre geopolítica y presiones competitivas intensificadas, demanda capacidades analíticas más sofisticadas y respuestas más ágiles. Las organizaciones que logren implementar efectivamente agentes de IA para procesos financieros obtendrán ventajas competitivas sostenibles en términos de velocidad de decisión, precisión analítica y eficiencia operacional.

## 1.3 Objetivos del estudio

El objetivo principal de este trabajo es demostrar la viabilidad técnica de implementar agentes de inteligencia artificial basados en Large Language Models para la automatización y optimización de procesos financieros empresariales críticos.

Los objetivos específicos que guían este estudio son:

Objetivo 1: Evaluación de un agente especializado para automatización inteligente de análisis de ratios financieros multi-periodo. Este objetivo busca demostrar cómo un agente LLM puede procesar automáticamente estados financieros históricos de 15 años (45 períodos trimestrales), identificar patrones temporales significativos y generar análisis que tradicionalmente requiere horas de trabajo profesional especializado.

Objetivo 2: Evaluación de un sistema de detección proactiva de fraudes y anomalías basado en análisis contextual avanzado. Este componente del estudio evalúa la capacidad de agentes LLM para superar las limitaciones de sistemas basados en reglas tradicionales, reduciendo falsos positivos mientras incrementa la detección de esquemas fraudulentos sofisticados, particularmente en contextos inflacionarios complejos.

Objetivo 3: Validación de un modelo predictivo de riesgo crediticio que transforme la gestión reactiva tradicional en un enfoque proactivo basado en análisis temporal multivariable. Este objetivo busca demostrar cómo los agentes pueden generar predicciones de riesgo crediticio con 3-6 meses de anticipación, optimizando políticas de crédito y capital de trabajo.

#### 1.4 Estructura del estudio

La Sección 2 establece el marco teórico necesario, revisando la evolución de *large language models*, la transición hacia agentes autónomos, el estado del arte en aplicaciones de IA financiera y las consideraciones regulatorias y éticas pertinentes.

La Sección 3 detalla la metodología de investigación empleada, justificando el diseño de estudio de casos múltiples, describiendo la arquitectura técnica propuesta y estableciendo las métricas de evaluación que permiten comparar objetivamente el rendimiento de los agentes desarrollados versus enfoques tradicionales.

La Sección 4 es el núcleo del estudio y se desarrollan en profundidad los tres casos de uso seleccionados: automatización de análisis de ratios financieros, detección proactiva de fraudes, y análisis predictivo de riesgo crediticio. Cada caso incluye descripción del problema, diseño del agente, implementación, resultados y análisis de valor agregado.

La Sección 5 consolida los resultados obtenidos, proporciona análisis comparativo cuantitativo y cualitativo, discute implicaciones teóricas y prácticas, identifica limitaciones del estudio y propone direcciones futuras de investigación.

Este enfoque estructurado permite que el estudio contribuya simultáneamente al avance del conocimiento académico en el campo de IA aplicada a finanzas y proporcione herramientas prácticas para profesionales y organizaciones interesadas en implementar estas soluciones innovadoras.

## 2. Marco teórico

### 2.1 Fundamentos de los *large language models* (LLM)

1) *Arquitectura transformer y el mecanismo de atención.* Los *large language models* (LLM), o modelos extensos de lenguaje, representan un cambio paradigmático en el procesamiento del lenguaje natural, fundamentado en la arquitectura *transformer* introducida por Vaswani *et al.* (2017) en su trabajo *Attention is all you need*. Esta arquitectura permite un salto cuantitativo en las capacidades de las redes neuronales que se utilizaban hasta la fecha, basándose en mecanismos de atención para procesar secuencias de datos.

El modelo *transformer* supera las limitaciones fundamentales de las redes neuronales recurrentes (RNN), particularmente su procesamiento secuencial y la pérdida de información en secuencias largas (DataCamp, 2024), abriendo la puerta a la interpretación de estructuras complejas expresadas sobre largas secuencias de datos como las que se presentan en las formas gramaticales y de contenidos de los lenguajes.

2) *Evolución de los LLM.* La evolución de los LLM ha sido meteórica desde la introducción del *transformer* original. BERT (*bidirectional encoder representations from transformers*), introducido por Google en 2019, estableció un hito importante y permanece como la base de la mayoría de aplicaciones modernas de word embedding (Stryker & Bergmann, 2024). Posteriormente, la serie GPT (*generative pre-trained transformer*) de OpenAI demostró las capacidades generativas de los modelos autorregresivos diseñados para generación de texto (Stryker & Bergmann, 2024).

La transición del *transformer* de 2017 a las arquitecturas modernas de 2025, como las utilizadas en Llama 4, Deepseek y otros, ha introducido mejoras sustanciales que abordan desafíos relacionados con la estabilidad del entrenamiento y eficiencia computacional.

3) *Capacidades emergentes y razonamiento.* Los LLM modernos exhiben capacidades emergentes que van más allá de la simple predicción de palabras. En el paradigma actual de pre-entrenamiento, los modelos dominantes para casi todas las tareas de procesamiento de lenguaje natural se basan en la arquitectura *transformer*, con modelos como BERT, ELECTRA, RoBERTa y Longformer (Zhang *et al.*, 2024).

Estas capacidades emergentes incluyen razonamiento complejo, resolución de problemas matemáticos, generación de código, y comprensión contextual profunda. La capacidad de los LLM para mantener coherencia en textos largos y realizar inferencias complejas los posiciona como herramientas poderosas para aplicaciones empresariales críticas.

4) *Limitaciones conocidas y mitigaciones.* A pesar de sus capacidades impresionantes, los LLM enfrentan limitaciones significativas que deben ser consideradas en aplicaciones financieras. El entrenamiento de modelos con grandes conjuntos de datos puede conducir a violaciones de privacidad y sesgos, especialmente si los datos de entrenamiento no son representativos o están sesgados (Patil, 2024). Además, la opacidad de *caja negra* de la IA puede dificultar que los stakeholders comprendan o cuestionen las decisiones automatizadas (Patil, 2024).

Además una tendencia natural de los LLM es a “alucinar”, otorgar respuestas que pueden parecer coherentes con lo requerido, pero que realmente son inexactas, erróneas o directamente inventadas.

Para mitigar estas limitaciones, se han desarrollado técnicas como el *fine-tuning* específico del dominio, la implementación de mecanismos de validación cruzada, y el uso de técnicas de interpretabilidad para hacer más transparentes las decisiones del modelo.

## 2.2 De chatbots a agentes autónomos

1) *Taxonomía de sistemas de IA conversacional*. La evolución desde chatbots simples hacia agentes autónomos representa una transformación fundamental en las capacidades de la IA. En un sistema de agente autónomo alimentado por LLM, el LLM funciona como el cerebro del agente, complementado por varios componentes clave: planificación (descomposición de subobjetivos), reflexión y refinamiento, memoria a corto y largo plazo (Weng, 2023).

Los chatbots tradicionales operan con capacidades limitadas de respuesta a consultas específicas, mientras que los agentes autónomos pueden planificar secuencias complejas de acciones, utilizar herramientas especializadas y mantener contexto temporal extenso para análisis multidimensionales.

2) *Características distintivas de agentes*. A diferencia de los sistemas tradicionales de IA, los agentes de IA no separan la toma de decisiones de la ejecución de tareas (Bergmann, 2024). Esta integración permite a los agentes adaptar dinámicamente sus estrategias basándose en retroalimentación del entorno y resultados intermedios.

Los agentes de IA resuelven tareas complejas en aplicaciones empresariales, incluyendo diseño de software, automatización IT, generación de código y asistencia conversacional, utilizando las técnicas avanzadas de procesamiento de lenguaje natural de los LLM (Gutowska, 2024).

### 3) Arquitecturas de agentes: ReAct, Chain-of-Thought, Tool Use

*ReAct (Reasoning and Acting)*. ReAct impulsa a los LLM a generar trazas de razonamiento verbal y acciones para una tarea, permitiendo al sistema realizar razonamiento dinámico para crear, mantener y ajustar planes mientras también permite la interacción con entornos externos (Prompt Engineering Guide, 2024a). El paradigma ReAct sincroniza razonamiento y acción, permitiendo mayor sinergia entre ambos: el razonamiento ayuda al modelo a inducir, rastrear y actualizar planes de acción (Yao *et al.*, 2023).

*Chain-of-Thought (CoT)*. *Chain of thought* se ha convertido en una técnica de *prompting* (consulta a los modelos de lenguaje) estándar para mejorar el rendimiento del modelo en tareas complejas, instruyendo al modelo a “pensar paso a paso” para descomponer tareas difíciles en pasos más pequeños y simples (Weng, 2023). Esta aproximación transforma tareas grandes en múltiples tareas manejables y proporciona interpretación del proceso de pensamiento del modelo.

*Tool Use y orquestación*. Los agentes modernos pueden utilizar herramientas bien definidas para ejecutar tareas, desde recuperación de información hasta cálculos complejos y acceso a bases de datos especializadas (Prompt Engineering Guide,

2024b). La capacidad de orquestar múltiples herramientas permite a los agentes abordar problemas que requieren diversos tipos de procesamiento y fuentes de datos.

4) *Sistemas multi agente*. Los frameworks multi agente tienden a superar a los agentes individuales porque mientras más planes de acción estén disponibles para un agente, se pueden beneficiar de más aprendizaje y reflexión (Gutowska, 2024). Estos sistemas permiten la especialización de agentes individuales y la colaboración para resolver problemas complejos que requieren múltiples dominios de expertise.

## 2.3 Aplicaciones de IA en finanzas

1) *Detección de fraudes y anomalías*. La detección de fraudes representa una de las aplicaciones más maduras y exitosas de la IA en el sector financiero. El Departamento del Tesoro de Estados Unidos anunció que sus últimos esfuerzos en adoptar un enfoque basado en tecnología y datos para la prevención de fraudes permitieron la prevención y recuperación de más de \$4 mil millones en fraudes y pagos incorrectos en el año fiscal 2024 (U.S. Department of the Treasury, 2024).

Los motores de IA pueden ayudar con la detección de fraudes en grandes conjuntos de datos buscando correlaciones y tendencias, ayudando a las instituciones financieras a prevenir actividad fraudulenta antes de que se convierta en un problema mayor (Markiewicz, 2024). Las técnicas de machine learning permiten el monitoreo en tiempo real y la prevención proactiva del fraude.

*Evolución de las técnicas de detección*. Casi tres cuartos (73 %) de las organizaciones actualmente utilizan IA para la detección de fraudes (Biocatch, 2024). Sin embargo, todos los encuestados esperan que tanto el crimen financiero como la actividad fraudulenta aumenten en 2024, gracias en parte a la IA, los criminales están innovando más rápido de lo que los bancos pueden seguir el ritmo (Biocatch, 2024).

La IA permite no sólo el desarrollo de patrones técnicos cada vez más sofisticados para llevar adelante fraudes, sino que también permite el desarrollo de técnicas como ingeniería social, entre los que se encuentran los deep fakes para modificación de voz y video, los cuales se espera que proliferen en los años venideros, mientras los actores maliciosos encuentran y despliegan IA generativa cada vez más sofisticada pero asequible para defraudar a bancos y sus clientes (Deloitte, 2024).

2) *Gestión de riesgo crediticio*. La evaluación del riesgo crediticio ha sido transformada por las capacidades predictivas de la IA. Los modelos de machine learning construidos sobre datos ponderados pueden asignar probabilidades a acciones potenciales y evaluar su decisión más precisa, haciéndolos muy adecuados para determinar riesgo (Flinders *et al*, 2024).

Los modelos de IA pueden procesar grandes conjuntos de datos rápidamente e identificar patrones que indican la probabilidad de default de un prestatario, analizando datos históricos de préstamos, comportamiento del cliente e incluso indicadores macroeconómicos (Mustafa & Schaffer, 2024). Esto no solo mejora el proceso de toma de decisiones para los prestamistas sino que también reduce el riesgo de préstamos incobrables.

3) *Problemas identificados y oportunidades*. A pesar de los avances significativos, persisten brechas importantes. Dos de cada cinco (41 %) tomadores de decisiones antifraude dicen que el fraude y el crimen financiero se manejan en unidades separadas sin colaboración cruzada (Biocatch, 2024). Esta operación en “departamentalizada”, con falta de comunicación representa un problema mayor para la capacidad de una organización de rastrear y combatir exitosamente tanto el crimen financiero como el fraude.

De aquí detectamos nuevas oportunidades:

- Integración de fuentes de datos alternativas para evaluación crediticia
- Implementación de sistemas de detección en tiempo real más sofisticados
- Desarrollo de modelos explicables para cumplimiento regulatorio
- Creación de sistemas adaptativos que evolucionen con nuevas amenazas

## 2.4 Contexto regulatorio y ético

1) *Marcos regulatorios globales*. El panorama regulatorio para la IA en servicios financieros está evolucionando rápidamente. En 2023, la Unión Europea anunció el EU AI Act, la primera regulación mundial sobre IA. El Acta reconoció los beneficios de la IA mientras delineaba los riesgos asociados con su uso y creando un marco regulatorio (ABA Banking Journal, 2024).

El Departamento de Servicios Financieros de Nueva York emitió avisos durante 2024, proporcionando orientación sobre los riesgos planteados por la IA, ilustrando cómo el marco regulatorio de ciberseguridad existente debe usarse para evaluar y abordar los riesgos de ciberseguridad presentados por la IA (Welle *et al*, 2025).

2) *Consideraciones de privacidad y seguridad de datos*. Las instituciones financieras tienen acceso único a una abundancia de información personalmente identificable, por lo que es crítico que quienes los manejan consideren todas las leyes de privacidad y protección de datos. Dado que los sistemas alimentados por IA manejan grandes cantidades de datos sensibles, estos se vuelven objetivos atractivos para ciberataques. (ABA Banking Journal, 2024).

3) *Gestión de sesgos algorítmicos*. El sesgo a menudo es implícito con la IA ya que todo, desde la entrada de datos hasta los algoritmos de entrenamiento y el aprendizaje continuo, puede conducir hacia la discriminación (ABA Banking Journal, 2024). Para mitigar esto, las organizaciones deben priorizar la transparencia y asegurar que las tecnologías de IA sean auditadas y validadas para la equidad (NAVEX, 2025).

Las evaluaciones deben completarse para todos los tipos de usuarios, y se alienta a los implementadores a prestar especial atención al impacto en comunidades marginadas y/o vulnerables (Ridzuan *et al*, 2024).

4) *Gobernanza y cumplimiento*. La gobernanza efectiva de IA involucra establecer mecanismos para monitorear y evaluar continuamente los sistemas de IA, asegurando que cumplan con las normas éticas establecidas y las regulaciones legales (Mucci & Stryker, 2024). Solo 18 % de las organizaciones tienen un consejo a nivel empresarial autorizado para tomar decisiones sobre

gobernanza responsable de IA, destacando la necesidad urgente de supervisión estructurada (NAVEX, 2025).

La gobernanza de IA comienza desde arriba. Involucrar a líderes senior que defenderán el uso ético y responsable de la IA en toda la institución financiera. Establecer un comité de ética de IA dedicado, donde líderes de TI, cumplimiento, legal y otros departamentos puedan revisar regularmente proyectos (Wright, 2024).

Las instituciones financieras deben desarrollar marcos de gobernanza integral que incluyan:

- Políticas claras sobre el despliegue de IA
- Comités de supervisión con representación multidisciplinaria
- Mecanismos de monitoreo continuo
- Protocolos de auditoría y validación regular
- Procedimientos de gestión de incidentes y respuesta

### 3. Metodología del estudio

#### 3.1 Diseño del estudio

*1) Enfoque metodológico: estudio de casos múltiples.* El presente trabajo adopta un enfoque metodológico basado en el estudio de casos múltiples, un diseño particularmente adecuado para la exploración de fenómenos contemporáneos dentro de su contexto real, especialmente cuando las fronteras entre el fenómeno y el contexto no son claramente evidentes (Yin, 2018). Esta metodología permite examinar en profundidad cómo los agentes de IA basados en LLM pueden transformar procesos financieros específicos, capturando tanto los aspectos técnicos como organizacionales de estas implementaciones.

El diseño de casos múltiples sigue un enfoque de “replicación teórica”, donde cada caso es seleccionado para predecir resultados contrastantes pero por razones teóricamente anticipables (Eisenhardt & Graebner, 2007). Los tres casos de estudio seleccionados –análisis de ratios financieros, detección de fraudes, y evaluación de riesgo crediticio– representan procesos financieros fundamentalmente diferentes que permiten explorar un espectro amplio de aplicaciones de agentes de IA.

Para cada caso, se implementó un proceso sistemático de recolección y análisis de datos que incluyó:

- Observación directa de procesos antes y después de la implementación
- Entrevistas semiestructuradas con stakeholders clave (analistas financieros, oficiales de riesgo, desarrolladores)
- Análisis cuantitativo de métricas de performance pre y post-implementación
- Evaluación cualitativa de factores organizacionales y culturales

Este enfoque multimétodo facilita la triangulación de datos, incrementando la validez interna del estudio al capturar el fenómeno desde múltiples perspectivas (Patton, 2015).

2) *Justificación del diseño elegido.* La selección del estudio de casos múltiples como metodología primaria responde a tres consideraciones fundamentales que lo hacen particularmente apropiado lo que queremos estudiar.

En primer lugar, la implementación de agentes de IA en procesos financieros representa un fenómeno emergente con escasos precedentes documentados en la literatura académica. Como señalan Dubois y Gadde (2002), los estudios de caso son especialmente valiosos para investigaciones de carácter exploratorio donde los constructos teóricos están en desarrollo. La naturaleza novedosa de la aplicación de arquitecturas ReAct y Chain-of-Thought en contextos financieros requiere un enfoque que permita la elaboración teórica inductiva.

En segundo lugar, la complejidad inherente a la integración de agentes de IA en sistemas financieros demanda un análisis contextualizado que capture las interdependencias entre factores tecnológicos, organizacionales y regulatorios. Como argumenta Flyvbjerg (2006), los estudios de caso permiten la observación de interacciones complejas que serían difícilmente capturables mediante métodos cuantitativos descontextualizados. Esto resulta particularmente relevante considerando que la efectividad de los agentes de IA está condicionada no sólo por su arquitectura técnica sino también por factores organizacionales como cultura, expertise disponible y procesos de governance.

Finalmente, el objetivo dual de la investigación (contribuir tanto al conocimiento académico como a la práctica profesional) encuentra en el estudio de casos una metodología ideal para generar *insights* con validez práctica. Según Van de Ven (2007), los estudios de caso facilitan el *engaged scholarship*, permitiendo el desarrollo de conocimiento que es simultáneamente riguroso y relevante. Esta consideración resulta especialmente pertinente dado el carácter aplicado de la investigación.

3) *Alcance y delimitaciones.* El estudio se enfoca específicamente en agentes de IA basados en LLM con arquitecturas ReAct y Chain-of-Thought. Otras arquitecturas de IA como machine learning, redes neuronales, o quedan fuera del alcance directo, aunque se consideran como tecnologías complementarias en sistemas híbridos.

Es importante señalar que estas delimitaciones, si bien necesarias para la factibilidad del estudio, introducen limitaciones a la generalización de resultados que son reconocidas y discutidas en la sección de limitaciones del estudio.

### 3.2 Selección de casos de uso

1) *Criterios de selección.* La selección de casos de uso siguió un proceso basado en criterios definidos para asegurar relevancia teórica y práctica. Se establecieron los siguientes criterios principales:

*Representatividad funcional:* Los casos debían representar funciones financieras core presentes en la mayoría de organizaciones financieras.

*Complejidad analítica:* Los casos debían involucrar procesos con complejidad analítica suficiente para poner a prueba las capacidades avanzadas de razonamiento de LLM, particularmente aquellas que implican análisis temporal, contextual y causal.

*Impacto económico potencial:* Se priorizaron casos con alto impacto económico potencial, medido en términos de eficiencia operacional, reducción de riesgos y/o oportunidades de generación de valor.

*Diversidad de desafíos:* Los casos seleccionados debían presentar desafíos diversificados que permitieran explorar diferentes capacidades de los agentes de IA y examinar la generalización de hallazgos a través de diferentes contextos.

2) *Descripción de los tres casos seleccionados.* Los tres casos seleccionados para este estudio, ordenados por complejidad creciente, son:

*Caso 1: Automatización inteligente de análisis de ratios financieros*

Este caso aborda la transformación del proceso de análisis de ratios financieros multi-período, tradicionalmente intensivo en tiempo y propenso a errores. Específicamente, se desarrolló un agente especializado en ratios al cual se le proveyó de una muestra a analizar de 15 años de datos históricos (45 períodos trimestrales), sobre los cuales debía identificar patrones temporales significativos y generar análisis contextualizado que tradicionalmente requiere horas de trabajo profesional especializado.

*Caso 2: Detección proactiva de fraudes y anomalías*

Este caso explora la aplicación de agentes LLM para superar las limitaciones de sistemas rule-based tradicionales en la detección de fraudes, particularmente en contextos inflacionarios complejos. Se desarrolló un agente especializado en fraudes que integra análisis multivariable y contextual para la detección temprana de esquemas fraudulentos sofisticados y se le proveyó de datos con simulaciones de patrones fraudulentos de facturación de proveedores.

*Caso 3: Análisis predictivo de riesgo crediticio*

Este caso examina la transformación de la gestión reactiva tradicional de riesgo crediticio hacia un enfoque proactivo basado en análisis temporal multivariable. Se implementó un agente especializado capaz de generar predicciones de riesgo crediticio con 3-6 meses de anticipación, optimizando políticas de crédito y capital de trabajo.

La selección de estos tres casos proporciona una exploración amplia del potencial de agentes LLM en procesos financieros fundamentales que representan desafíos universales para las organizaciones.

## 4. Desarrollo: casos de uso y análisis

### 4.1 Caso 1: Automatización inteligente de análisis de ratios financieros

#### 1) Descripción del problema

Complejidad del análisis manual multi-periodo. El análisis de ratios financieros multi-periodo representa uno de los procesos más intensivos en tiempo y propensos a errores dentro de las operaciones financieras empresariales. En el contexto específico de este estudio, se simuló el análisis de una organización que requería el procesamiento sistemático de 15 años de datos históricos, equivalentes a 45 períodos trimestrales, para evaluar tendencias de rendimiento, identificar patrones cíclicos y generar proyecciones estratégicas.

El proceso tradicional involucra múltiples etapas secuenciales que consumen recursos significativos. La recopilación de datos financieros desde sistemas ERP heterogéneos requiere aproximadamente horas de trabajo especializado por período analizado, considerando la extracción desde módulos de contabilidad general, cuentas por cobrar, inventarios y activos fijos. La normalización y limpieza de estos datos, necesaria debido a cambios en criterios contables y estructuras organizacionales a lo largo del período de 15 años, demanda tiempo adicional.

La fase de cálculo de ratios, aunque aparentemente mecánica, presenta complejidades sustanciales cuando se considera que los requerimientos gerenciales suelen revestir ajustes y cambios, lo que suele impactar en esta fase. Más crítico aún, la interpretación contextual de tendencias temporales requiere que los analistas identifiquen manualmente patrones significativos, correlaciones entre ratios diferentes, y anomalías que podrían indicar cambios fundamentales en el negocio.

La demora inherente en el proceso de análisis tradicional crea una brecha temporal crítica entre la disponibilidad de datos y la generación de insights accionables. Esta demora se traduce en costos de oportunidad significativos que pueden presentar impactos económicos sustanciales.

#### 2) Diseño del agente especializado

a) *Arquitectura técnica del agente.* El desarrollo del agente especializado en ratios, se fundamenta en la arquitectura ReAct (*Reasoning and Acting*) adaptada específicamente para análisis financiero temporal. La arquitectura integra tres componentes principales: un motor de razonamiento financiero, un sistema de orquestación de herramientas especializadas, y un módulo de síntesis contextual.

*Motor de razonamiento financiero.* Utiliza GPT-4 como modelo base con prompts especializados que incorporan principios de análisis financiero, metodologías de evaluación de ratios, y técnicas de análisis temporal. El motor está entrenado para reconocer patrones financieros estándar y anomalías típicas que pueden requerir investigación adicional.

*Sistema de orquestación de herramientas.* Integra herramientas especializadas mediante APIs:

- DataExtractor: Conexión directa con APIs de sistemas ERP (SAP, Oracle, Microsoft Dynamics)
- RatioCalculator: Motor de cálculo optimizado para ratios financieros estándar con validación cruzada
- TrendAnalyzer: Algoritmos de análisis temporal basados en descomposición estacional y detección de puntos de cambio

b) *Proceso de extracción y procesamiento de datos.* El flujo de procesamiento implementa un pipeline diseñado para automatizar completamente el proceso manual tradicional:

*Etapas 1: Ingesta inteligente de datos.* El agente ejecuta consultas SQL dinámicas contra múltiples sistemas fuente, adaptando automáticamente las consultas según la estructura específica de cada sistema ERP. Utiliza mapeo semántico para identificar campos equivalentes en diferentes sistemas y aplica reglas de transformación para normalizar formatos de fecha, moneda y unidades de medida.

*Etapas 2: Validación y limpieza contextual.* Implementa reglas de validación financiera que verifican consistencia en el tiempo y coherencia contable.

*Etapas 3: Cálculo de ratios.* Ejecuta cálculos de ratios utilizando tanto fórmulas estándar como variaciones específicas del sector.

*Etapas 4: Síntesis contextual y generación de insights.* El motor de razonamiento analiza los resultados numéricos en contexto, identificando patrones significativos, correlaciones entre ratios diferentes, y anomalías que requieren atención. Genera explicaciones en lenguaje natural que conectan los hallazgos cuantitativos con implicaciones estratégicas.

c) *Interfaz de interacción y personalización.* Para este estudio se ha preparado una interfaz conversacional para interactuar con el sistema de agentes. Esta permite consultas en lenguaje natural como “¿Cuál ha sido la evolución del ROE en los últimos 5 años comparado con el promedio sectorial?” El agente interpreta la consulta, ejecuta el análisis necesario y proporciona respuestas contextualizadas.

3) *Análisis de valor agregado.* La implementación del agente especialista en ratios habilita capacidades analíticas que podrían ser inaccesibles debido a limitaciones de recursos:

*Análisis predictivo continuo:* El sistema permite ejecutar modelos predictivos que requieren actualización de ratios financieros en tiempo real. Entre otros beneficios es posible destacar:

- Modelos de alerta temprana para deterioro crediticio de clientes corporativos
- Predicción de flujos de caja con precisión mejorada
- Simulación de escenarios “what-if” con múltiples variables simultáneas

*Benchmarking dinámico:* La automatización permite comparación continua con benchmarks sectoriales actualizados mensualmente, versus la comparación anual tradicional. Esto habilita a que una empresa pueda:

- Identificar métricas que posicionen a la organización con respecto a su sector

- Medir áreas de con rendimientos que requieran atención estratégica
- Desarrollar KPIs propietarios basados en patrones únicos identificados

*Democratización del análisis:* La interfaz conversacional permite que:

- Usuarios no técnicos accedan a análisis financiero sofisticado
- Incremento en consultas analíticas realizadas, permitiendo explorar más escenarios
- Reducción del tiempo de respuesta a consultas de management

## 4.2 Caso 2: Detección proactiva de fraudes y anomalías

1) *Caracterización del desafío.* La detección de fraudes y anomalías en contextos financieros representa uno de los desafíos más complejos que enfrentan las organizaciones hoy en día. Esta complejidad se magnifica particularmente en entornos económicos caracterizados por alta volatilidad inflacionaria, donde la distinción entre ajustes legítimos de precios y comportamientos fraudulentos se torna extremadamente difícil.

El caso específico abordado en este estudio examina una problemática común pero raramente tratada con suficiente sofisticación analítica: la detección de esquemas fraudulentos de proveedores en contextos de alta inflación. Las empresas argentinas enfrentaron durante el período 2022-2023 tasas inflacionarias de 95 % y 65 % respectivamente, creando un entorno donde los aumentos significativos de precios resultaban esperables y justificables, pero simultáneamente proporcionaban una “cobertura perfecta” para comportamientos fraudulentos sofisticados.

Los enfoques tradicionales para la detección de fraudes en este contexto presentan limitaciones fundamentales:

1. *Sistemas estáticos basados en reglas:* Los métodos convencionales basados en umbrales y reglas predefinidas (como alertas por incrementos superiores al X%) resultan ineficaces en contextos inflacionarios donde variaciones sustanciales son esperables. Esto genera excesivos falsos positivos o, al elevar los umbrales, permite que comportamientos fraudulentos sofisticados pasen desapercibidos.
2. *Análisis retrospectivo:* La detección convencional opera fundamentalmente a posteriori, identificando fraudes meses después de su ocurrencia, típicamente durante auditorías anuales.
3. *Incapacidad para analizar patrones complejos:* Los métodos tradicionales analizan montos absolutos o variaciones porcentuales, pero carecen de capacidad para evaluar patrones comportamentales sofisticados como secuencias temporales, correlaciones entre diversos factores, o intencionalidad implícita en las variaciones.
4. *Limitaciones en la evaluación contextual:* La imposibilidad de considerar simultáneamente múltiples variables contextuales (tipo de servicio, comportamiento histórico, justificaciones textuales, comparaciones sectoriales) impide distinguir efectivamente entre ajustes legítimos y fraudulentos.

El desafío central radica, por tanto, no en detectar simplemente aumentos de precios, sino en identificar patrones específicos que revelen intencionalidad fraudulenta en un contexto donde ciertos aumentos significativos resultan completamente justificables.

2) *Modelo de detección basado en LLM*. Para explorar las posibilidades de los agentes IA para hacer frente a estos desafíos se configuró un agente que implementa una arquitectura híbrida que combina las capacidades de procesamiento de lenguaje natural y razonamiento contextual de los LLM con componentes especializados para análisis financiero forense.

*Arquitectura del modelo*. El agente implementa una arquitectura ReAct (Reasoning and Acting) extendida, adaptada específicamente para detección de fraudes financieros. La arquitectura se estructura en los siguientes componentes fundamentales:

- Núcleo LLM: Este componente proporciona las capacidades fundamentales de razonamiento, comprensión contextual y evaluación de causalidad.
- Módulo de contextualización económica: Componente especializado que integra variables macroeconómicas (índices de inflación sectorial, eventos económicos relevantes) y permite evaluar la razonabilidad de variaciones de precios en el contexto específico.
- Sistema de análisis temporal: Implementa algoritmos especializados para detección de patrones secuenciales complejos, cambios de tendencia, ciclos y anomalías temporales. Este componente es crucial para identificar comportamientos como “testing de límites” y “retrocesos tácticos”.

La interacción entre estos componentes sigue un flujo iterativo inspirado en el paradigma ReAct, donde el razonamiento del LLM guía las acciones de los componentes especializados, cuyos resultados alimentan nuevamente el proceso de razonamiento en ciclos sucesivos de refinamiento.

*Sistema de scoring y priorización*. El agente construye un sistema de scoring multifactorial que asigna niveles de riesgo (1-10) a cada proveedor basándose en la convergencia de múltiples indicadores. Este sistema considera:

1. Magnitud de desviaciones: Evaluada no en términos absolutos sino relativos al contexto económico específico.
2. Consistencia de patrones: Persistencia y recurrencia de comportamientos potencialmente problemáticos.
3. Sofisticación de comportamientos: Complejidad y evolución de las estrategias detectadas.
4. Impacto potencial: Cuantificación del riesgo financiero estimado para la organización.

5. Evidencia acumulada: Convergencia de múltiples indicadores independientes que refuerzan la evaluación.

Este enfoque permite priorizar investigaciones y acciones correctivas basadas en niveles de riesgo objetivamente establecidos, optimizando recursos de supervisión.

3) *Análisis de valor agregado*. La implementación de sistemas de detección proactiva de fraudes basados con agentes IA genera impacto significativo en múltiples dimensiones:

*a) Reducción de pérdidas directas*

*Detección temprana de sobrefacturación*: La implementación de agentes especializados permiten identificar y actuar sobre comportamientos fraudulentos antes que los métodos tradicionales por la velocidad, flexibilidad y continuidad de los análisis.

*Minimización de falsos positivos*: La reducción de falsos positivos podría generar ahorros por eliminación de investigaciones innecesarias y preservación de relaciones comerciales valiosas.

*Optimización de recursos de auditoría*: La capacidad de priorización inteligente basada en scores de riesgo permiten la reasignación eficiente de recursos limitados de auditoría.

*b) Impacto en negociación y relaciones comerciales*. Más allá del ahorro directo por prevención de fraudes, la implementación del sistema puede generar beneficios sustanciales en otras dimensiones estratégicas:

*Poder de negociación mejorado*: La disponibilidad de evidencia específica y cuantificable sobre comportamientos problemáticos tienen la capacidad de transformar fundamentalmente las dinámicas de negociación con proveedores.

*Preservación de relaciones valiosas*: La capacidad para distinguir efectivamente entre aumentos legítimos y fraudulentos permite mantener relaciones comerciales con proveedores que implementen ajustes razonables, evitando confrontaciones innecesarias y preservando relaciones estratégicamente valiosas.

### 4.3 Caso 3: Análisis predictivo de riesgo crediticio

1) *Problemática de gestión de crédito*. La gestión tradicional de riesgo crediticio en el sector financiero empresarial se caracteriza por un enfoque fundamentalmente reactivo, basado en análisis de antigüedad de saldos que proporcionan únicamente una visión retrospectiva del comportamiento de pago de los clientes. Esta aproximación convencional presenta limitaciones críticas que se magnifican en contextos económicos volátiles como el argentino, donde la capacidad predictiva se torna esencial para la supervivencia organizacional.

La problemática central radica en que los sistemas tradicionales de análisis crediticio operan como “espejos retrovisores” financieros: pueden describir con precisión lo que ya ocurrió, pero carecen de capacidad para anticipar lo que está por suceder (McKinsey & Company, 2024).

Durante el período 2022-2023, las empresas argentinas enfrentaron un contexto económico caracterizado por tasas inflacionarias de 95 % y 65 % respectivamente, combinadas con restricciones cambiarias y volatilidad macroeconómica persistente (Banco Central de la República Argentina, 2023). En este entorno, la capacidad para distinguir entre problemas de pago coyunturales (derivados de condiciones económicas temporales) y estructurales (indicativos de deterioro fundamental de la capacidad de pago) se convierte en una competencia crítica para la preservación del capital de trabajo y la continuidad operativa.

El análisis de *aging* tradicional presenta tres limitaciones fundamentales que este caso busca superar:

*Limitación temporal:* Los reportes de antigüedad de saldos proporcionan fotografías estáticas del estado actual, sin capacidad para identificar trayectorias o velocidades de cambio.

*Limitación contextual:* Los sistemas convencionales carecen de capacidad para incorporar variables contextuales complejas como estacionalidades sectoriales, ciclos económicos, o patrones comportamentales específicos del cliente.

*Limitación predictiva:* La ausencia de capacidades predictivas impide la implementación de estrategias proactivas de gestión de riesgo, relegando a las organizaciones a posiciones reactivas donde las opciones de mitigación se limitan a acciones correctivas posteriores al deterioro crediticio.

El costo de estas limitaciones es considerable y en el contexto específico de empresas industriales argentinas, donde las relaciones comerciales de largo plazo constituyen activos estratégicos críticos, la capacidad para anticipar y prevenir deterioro crediticio antes de su materialización representa una ventaja competitiva fundamental.

2) *Arquitectura predictiva del agente.* Para comprobar las habilidades de un agente IA, se trabajó con un agente especializado en análisis predictivo de riesgo crediticio basado, con extensiones específicas para el dominio financiero y adaptaciones para el contexto económico argentino.

#### *Componentes fundamentales de la arquitectura*

*Motor de análisis temporal multivariable:* El componente central del agente implementa algoritmos de análisis de series temporales específicamente diseñados para identificar patrones comportamentales en datos de pago. A diferencia de los sistemas convencionales que analizan únicamente montos y fechas, este motor evalúa simultáneamente variables como: días de atraso promedio, evolución de montos facturados versus pagados, utilización porcentual de límites crediticios, etc.

*Motor de proyección probabilística:* El agente puede implementar modelos de proyección de escenarios probabilísticos para horizontes temporales específicos. Estos modelos no solamente considerarían tendencias históricas, sino también factores contextuales como estacionalidades conocidas, eventos macroeconómicos proyectados, y capacidad histórica de recuperación del cliente específico.

*Sistema de contextualización sectorial:* Reconociendo que diferentes sectores económicos presentan patrones crediticios distintivos, el agente incorpora un módulo especializado en análisis sectorial que considera características específicas de cada industria. Por ejemplo, las empresas del sector turístico naturalmente experimentan variaciones estacionales predecibles (diciembre-febrero en Argentina), mientras que empresas metalúrgicas deberían mantener patrones más estables a lo largo del año.

3) *Detección de patrones de riesgo.* Para verificar las capacidades del agente IA se utilizaron datos simulados de comportamiento crediticio de 15 clientes principales de una empresa industrial argentina durante el período enero 2022 - junio 2023, proporcionando 18 meses de historial completo.

El sistema identificó exitosamente cinco categorías distintas de comportamiento crediticio:

1. *Deterioro gradual predecible:* Representado por casos como “Metalúrgica Progreso”, donde el modelo detectó deterioro lineal de atraso de pagos por mes, proyectando alcanzar niveles críticos en septiembre 2023.
2. *Problemas estacionales recurrentes:* Ejemplificado por “Turismo Vacaciones Felices”, donde el sistema identificó patrones consistentes de dificultades durante diciembre-enero-febrero, permitiendo planificación proactiva.
3. *Default súbito por eventos externos:* Como “Gastronómico Central”, donde cambios abruptos en el comportamiento crediticio señalaron eventos disruptivos específicos requiriendo evaluación inmediata.
4. *Fluctuaciones temporales normales:* Clientes cuyas variaciones permanecían dentro de rangos esperables para su sector y características específicas.
5. *Mejora sostenida:* Casos donde el modelo detectó trayectorias de recuperación genuina versus mejoras temporales superficiales.

4) *Valor estratégico.* La implementación de agentes IA optimizados para riesgo crediticio genera valor estratégico que trasciende la simple mejora en precisión predictiva, transformando fundamentalmente el paradigma de gestión crediticia desde enfoques reactivos hacia capacidades proactivas que redefinen las posibilidades estratégicas organizacionales.

a) *Transformación de gestión reactiva a proactiva.* El valor más significativo de los agentes IA radica en su capacidad para transformar la gestión crediticia de fundamentalmente reactiva (respondiendo a problemas después de su materialización) hacia genuinamente proactiva (anticipando y previniendo problemas antes de su ocurrencia).

Esta transformación se manifiesta en tres dimensiones críticas:

*Intervención preventiva:* La capacidad para identificar deterioro crediticio 3-6 meses antes de su materialización permite implementar estrategias de intervención cuando las opciones disponibles son máximas y los costos de intervención mínimos. En lugar de esperar hasta que un cliente alcance 90+ días de atraso para iniciar acciones correctivas, las organizaciones pueden ajustar términos comerciales, reestructurar pagos, o incluso modificar estrategias de producto cuando el cliente aún mantiene solvencia operativa.

*Optimización de capital de trabajo:* Al anticipar períodos de dificultad específicos, las organizaciones pueden ajustar proactivamente políticas de inventario, programación de producción, y planificación de flujo de caja. El caso de “Turismo Vacaciones Felices” ilustra este valor: conociendo con certeza que el cliente experimentará dificultades durante diciembre-febrero, la empresa puede planificar inventarios reducidos para esos meses y acelerar cobranzas antes del período crítico.

*Preservación de relaciones comerciales:* La intervención temprana permite preservar relaciones comerciales valiosas mediante soluciones colaborativas implementadas antes de que el deterioro crediticio genere tensiones irreversibles.

b) *Optimización de políticas crediticias.* Los agentes de IA permiten la optimización granular de políticas crediticias mediante diferenciación sofisticada entre tipos de riesgo. En lugar de aplicar políticas uniformes a todos los clientes, el sistema permite personalización basada en patrones específicos:

*Políticas diferenciadas por tipo de riesgo:* Clientes con problemas estacionales predecibles pueden recibir líneas de crédito estacionales automáticas, mientras que clientes con deterioro gradual pueden ser gestionados mediante ajustes progresivos de términos. Esta diferenciación optimiza simultáneamente exposición al riesgo y preservación de relaciones comerciales.

*Límites dinámicos:* El sistema permite la implementación de límites crediticios dinámicos que se ajustan automáticamente basándose en trayectorias predictivas. Clientes en deterioro acelerado pueden experimentar reducción gradual de límites, mientras que clientes en recuperación pueden acceder a límites expandidos.

## 5. Reflexiones y conclusión

### 5.1 Implicaciones organizacionales

*Más allá del ahorro: transformación organizacional.* El impacto más profundo, aunque menos directamente cuantificable, se podría dar en la transformación cualitativa de la función de control financiero:

1. *Evolución de reactiva a proactiva:* La capacidad de detección temprana transforma fundamentalmente el paradigma de control, permitiendo intervenciones preventivas antes de la materialización de pérdidas significativas.

2. *Democratización del expertise forense*: La codificación de conocimiento experto en el sistema permite que personal financiero sin especialización forense acceda a capacidades analíticas avanzadas, expandiendo el alcance del control interno.
3. *Aprendizaje organizacional acelerado*: La documentación sistemática de patrones, justificaciones y estrategias fraudulentas genera una base de conocimiento institucional que evoluciona continuamente, creando una “memoria organizacional” que trasciende la dependencia de expertise individual.

Estos casos demuestran cómo la implementación de agentes IA para finanzas trascienden la mera automatización, creando capacidades analíticas organizacionales nuevas, que transforman fundamentalmente la función de control financiero y generan impacto económico significativo y sostenible.

## 5.2. Implicaciones profesionales

1) *Transformación del rol del profesional financiero*. Los resultados de este estudio sugieren que la implementación de agentes IA está catalizando una transformación profunda en el rol del profesional financiero. Esta transformación no representa simplemente una automatización de tareas existentes, sino una redefinición fundamental del valor que estos profesionales aportan a sus organizaciones.

Como señala Deloitte (2024), “la automatización inteligente está liberando a los profesionales financieros de tareas transaccionales repetitivas, permitiéndoles enfocarse en análisis estratégico y toma de decisiones de alto valor”.

Sin embargo, esta liberación de tiempo va acompañada de expectativas más altas sobre el valor agregado por los profesionales. Tavakoli *et al*, de McKinsey & Co (2024) identifican que “las organizaciones líderes están redefiniendo los roles financieros para enfatizar capacidades de interpretación, contextualización y colaboración interdepartamental”.

Este cambio coincide con lo que el Bin Hendi (2025) ha identificado como el “aumento de roles híbridos en finanzas”, donde la expertise técnica financiera se combina con capacidades de gestión de tecnología avanzada.

2) *Nuevas competencias requeridas*. La implementación exitosa de agentes de IA en procesos financieros demanda un conjunto de competencias emergentes que difieren significativamente del perfil tradicional de profesionales financieros. A partir de nuestros hallazgos, identificamos cuatro categorías críticas de competencias requeridas para maximizar el valor de esta tecnología:

*Competencias de interfaz tecnológica*: La capacidad para interactuar efectivamente con agentes de IA representa una nueva alfabetización fundamental. Los profesionales financieros deben desarrollar proficiencia en prompt engineering, evaluación crítica de outputs de IA, y supervisión efectiva de sistemas autónomos. Como señala KPMG (2024), “la habilidad para orquestar sistemas de IA, más que programarlos, será una competencia core para profesionales financieros”.

*Competencias de contextualización avanzada:* La capacidad para proporcionar contexto crítico que los sistemas de IA no pueden derivar independientemente. Según Bergmann (2024), “la expertise humana en identificar factores contextuales únicos y trasladarlos a parámetros comprensibles por IA será indispensable”.

*Competencias de síntesis interdisciplinaria:* La habilidad para integrar insights de múltiples dominios. PwC (2024) ha identificado que “los profesionales financieros del futuro serán traductores entre el mundo técnico de IA y las necesidades prácticas del negocio”.

*Competencias de juicio ético:* La capacidad para supervisar sistemas de IA desde una perspectiva ética y de gobernanza. Como documenta EY (2024), “la supervisión humana informada será esencial para mantener alineación entre sistemas de IA financiera y valores organizacionales y sociales”.

Será el profesional humano el que deberá evaluar e incorporar el contexto ético adecuado cuando la IA comience a tomar decisiones que ya no solamente afectarán a procesos sino también, a personas.

### 5.3 Limitaciones del estudio

*Generalización de resultados.* La generalización de los resultados obtenidos debe considerar varias dimensiones de especificidad contextual. En primer lugar, los tres casos de estudio se desarrollaron con datos simulados, corriendo en entornos controlados y con información que no tiene el caos típico de los sistemas en producción alimentados por usuarios reales.

Además, las implementaciones estudiadas utilizaron modelos LLM de última generación con acceso a recursos computacionales sustanciales. Como señala Mukherjee (2025), “la arquitectura y capacidades de los LLM evolucionan rápidamente, lo que dificulta la generalización de resultados entre diferentes generaciones de modelos”. Esta dependencia de modelos específicos plantea interrogantes sobre la replicabilidad de resultados con modelos diferentes o en contextos con restricciones de recursos computacionales.

El perfil demográfico y tecnológico de los equipos involucrados también puede limitar la generalización. El estudio está asumiendo un equipo de trabajo que puede dar soporte los sistemas que alimentan los agentes de IA, así como a los entornos que permiten la comunicación entre estos y los usuarios y a la implementación o tuning de las herramientas que utiliza el agente así como la elección de los modelos de lenguaje adecuados para cada tarea.

Según KPMG (2024), “la alfabetización en IA varía significativamente entre diferentes regiones e industrias, lo que puede afectar dramáticamente los resultados de implementaciones similares”. Esta variabilidad sugiere que organizaciones con diferentes perfiles de talento pueden experimentar curvas de adopción y resultados distintos.

Finalmente, es importante considerar que el estudio se realizó durante un período específico del ciclo económico (2023-2025) caracterizado por inflación moderada y recuperación post-pandémica. El rendimiento de los sistemas predictivos de riesgo podría variar significativamente en diferentes condiciones macroeconómicas, como sugiere el Federal Reserve Bank of St. Louis (2024) al señalar que “los modelos de riesgo crediticio típicamente muestran degradación durante transiciones abruptas entre regímenes económicos”.

## 5.4 Consideraciones éticas y sociales

### *Impacto en empleo y roles profesionales*

La implementación de agentes de IA en procesos financieros plantea interrogantes significativos sobre el futuro del empleo en el sector. Durante la preparación del estudio encontré un impacto complejo que no se alinea con narrativas simplistas de “sustitución laboral”. Después de haber implementado el Caso 1, la automatización de análisis de ratios financieros no eliminó la necesidad de analistas financieros, sino que transformó su rol hacia actividades de mayor valor agregado. Este hallazgo se alinea con la investigación de Accenture (2024), que encontró que “la implementación de IA en finanzas típicamente resulta en redistribución más que eliminación de empleo, con reducción de 27 % en tareas rutinarias compensada por incremento de 16 % en roles analíticos avanzados”.

Es importante considerar también las dimensiones demográficas de este impacto. Como señala Bin Hendi (2025), “la transición hacia roles aumentados por IA presenta desafíos particularmente agudos para trabajadores en etapas avanzadas de carrera, creando riesgos de inequidad generacional en oportunidades laborales futuras”.

## 5.5. Direcciones futuras de investigación

*Extensión a otros dominios financieros.* Aunque este estudio ha explorado tres casos de uso fundamentales en procesos financieros empresariales, existen múltiples dominios financieros adicionales que representan oportunidades prometedoras para investigación futura. Un área particularmente fértil es la aplicación de agentes de IA en gestión de tesorería y optimización de capital de trabajo. Como señala McKinsey (2024), “la optimización dinámica de capital de trabajo representa una oportunidad de \$2 trillones globalmente que permanece largamente sin explotar debido a limitaciones de herramientas analíticas tradicionales”.

Otra dirección prometedora es la aplicación de estos agentes a la gestión de activos y wealth management. Khandani et al. (2023) han demostrado que “modelos predictivos avanzados pueden generar alpha significativo cuando integran análisis de patrones temporales complejos con contextualización de tendencias macroeconómicas”, capacidades que los agentes basados en LLM podrían potencialmente proporcionar.

El dominio de cumplimiento regulatorio (RegTech) representa otra frontera importante. Como documenta Ayodeji (2024), “la complejidad regulatoria global ha crecido exponencialmente, con instituciones financieras enfrentando aproximadamente 217 cambios regulatorios diarios en 2023”. Esta complejidad creciente crea una oportunidad significativa para agentes especializados en interpretación, monitoreo e implementación de requerimientos regulatorios.

Finalmente, el área de finanzas sostenibles merece atención dedicada. Boston Consulting Group (2024) proyecta que “inversiones alineadas con criterios ESG alcanzarán \$50 trillones para 2025, creando demanda sin precedentes para análisis sofisticado de métricas de sostenibilidad”. Agentes especializados en análisis de datos ESG podrían jugar un rol crucial en la transición hacia modelos financieros más sostenibles.

## 5.6 Conclusión y mensaje final

Este estudio proporciona evidencia empírica y un marco metodológico para que organizaciones y profesionales naveguen esta transformación con confianza, maximizando beneficios mientras gestionan riesgos y consideraciones éticas.

La inteligencia artificial basada en LLM no es una promesa a futuro sino una realidad presente que está redefiniendo los límites de lo posible en análisis financiero. La pregunta para las organizaciones no es si adoptar estas tecnologías, sino qué tan rápidamente pueden hacerlo para mantener relevancia competitiva.

Para los profesionales financieros, representa una oportunidad única de evolucionar hacia roles de mayor valor estratégico, liberados de las limitaciones del procesamiento manual de datos a la vez que nos recuerda que como profesionales de un área tan dinámica como las finanzas es un requisito fundamental la capacitación continua, mantener la curiosidad y asumir riesgos.

El futuro del análisis financiero será una colaboración sinérgica entre inteligencia humana y artificial, donde cada una aporta sus fortalezas únicas para crear capacidades que ninguna podría lograr independientemente.

## REFERENCIAS

- ABA Banking Journal (2024, April 3). *AI compliance and regulation: What financial institutions need to know*. En sitio web [bankingjournal.aba.com](https://bankingjournal.aba.com)
- Apotheker, J., Duranton, S., Lukic, V., Bellefonds, N., Iyer, S., Bouffault, O. & Laubier, R. (2024). *From potential to profit with GenAI*. BCG Publications. En sitio web [bcg.com](https://bcg.com)
- Ayodeji, A. (2024). *Artificial intelligence in enhancing regulatory compliance and risk management*. Working paper.
- Bergmann, D. (2024). *What is a ReAct agent?* En sitio web [ibm.com](https://ibm.com).
- Bin Hendi, T. (2025). *AI: Rewriting the future of finance and financial inclusion*. World Economic Forum, en sitio web [weforum.org](https://weforum.org).
- Biocatch (2024). *2024 AI fraud financial crime survey*.
- Boston Consulting Group (BCG) (2024). *AI adoption in 2024: 74% of companies struggle to achieve and scale value*. BCG Publications. En sitio web [bcg.com](https://bcg.com)
- Brown, T., Mann, B., Ryder, N. et al. (2020). *Language models are few-shot learners*. Advances in Neural Information Processing Systems, 33: 1877-1901.
- Cloud Security Alliance (2025). *AI and privacy: Shifting from 2024 to 2025*.
- DataCamp (2024, January 9). *How transformers work: A detailed exploration of transformer architecture*.
- Deloitte (2024). *Generative AI is expected to magnify the risk of deepfakes and other fraud in banking*.
- Devlin, J., Chang, M. W., Lee, K. & Toutanova, K. (2018). *BERT: Pre-training of deep bidirectional transformers for language understanding*. arXiv preprint arXiv:1810.04805.
- European Parliament (2023). *EU AI Act: First regulation on artificial intelligence*.
- Flinders, M., Schneider, J. & Smalley, I. (2024). *AI fraud detection in banking*. En sitio web [ibm.com](https://ibm.com).

- Floridi, L., Cows, J., Beltrametti, M. et al. (2018). *AI4People An ethical framework for a good AI society: Opportunities, risks, principles, and recommendations*. *Minds and Machines*, 28 (4): 689-707.
- Flyvbjerg, B. (2006). *Five misunderstandings about case-study research*. *Qualitative Inquiry*, 12 (2): 219-245.
- GDPR (2018). *General Data Protection Regulation*.
- Gutowska, A. (2024). *What are AI agents?* En sitio web ibm.com.
- KPMG (2023). *Repetitive tasks and finance staff productivity study*. KPMG Financial Services.
- McKinsey & Company (2024). *Financial data and markets infrastructure: Positioning for the future*. McKinsey Financial Services.
- Mucci, T. & Stryker, C. (2024). *What is AI governance?* En sitio web ibm.com
- Mukherjee, A. (2025). *The evolution of transformer architecture: From 2017 to 2024*. Medium, February 9, 2025.
- NAVEX (2025). *Artificial intelligence and compliance: Preparing for the future of AI governance, risk, and compliance*.
- Markiewicz, M. (2024). *Risk reducing AI use cases for financial institutions*. En sitio web netguru.com, November 22, 2024.
- Mustafa, F. & Schaffer, A. (2024). *AI integration in financial services: A comprehensive approach to fraud detection and risk assessment*. Working paper.
- Patil, D. (2024). *Artificial intelligence in financial risk assessment and fraud detection: Opportunities and ethical concerns*. Working paper.
- Poloclub (2024). *Transformer explainer: LLM transformer model visually explained*.
- Prompt Engineering Guide (2024). *ReAct prompting*. En sitio web promptingguide.ai.
- Prompt Engineering Guide (2024b). *LLM agents*. En sitio web promptingguide.ai.
- Ridzuan, N.N., Masri, M., Anshari, M., Fitriyani, N.L. & Syafrudin, M. (2024). *AI in the financial sector: The line between innovation, regulation and ethical responsibility*. *Information*, 15 (8), 432.
- Stryker, C. & Bergmann, D. (2024). *What is a transformer model?* En sitio web ibm.com
- Tavakoli, A., Harreis, H., Rowshankish, K. & Bogobowicz, M. (2024). *Charting a path to the data- and AI-driven enterprise of 2030*. McKinsey Digital.
- U.S. Department of the Treasury. (2024, October 17). *Treasury announces enhanced fraud detection processes, including machine learning AI, prevented and recovered over \$4 billion in fiscal year 2024*. Press Release JY2650.
- Van de Ven, A.H. (2007). *Engaged scholarship*.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L. & Polosukhin, I. (2017). *Attention is all you need*. *Advances in Neural Information Processing Systems*, 30: 5998-6008.
- Welle, L.J., Betancourt, K., Tayman, W.K., Schoenthal, A., Funk, A. M. & Yu, P. (2025). *The evolving landscape of AI regulation in financial services*. En sitio web goodwininlaw.com
- Weng, L. (2023, June 23). *LLM powered autonomous agents*. Lil'Log.
- Wright, C. (2024). *4 keys to AI governance driving compliance and accountability*. En sitio web jackhenry.com, December 2, 2024
- Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K. & Cao, Y. (2023). *ReAct: Synergizing reasoning and acting in language models*. arXiv preprint arXiv:2210.03629.
- Zhang, A., Lipton, Z., Li, M. & Smola, A. (2024). *Dive into deep learning. Ch 11: Attention mechanisms and transformers*.