



# MÁSTER EN TECNOLOGÍAS FINANCIERAS, PAGOS Y BANCA DIGITAL

## TRABAJO FIN DE MÁSTER APIS INTELIGENTES PARA OPEN BANKING

Autor: Marcos Antonio Martínez Gil  
Director: Barbara Fernandes de Oliveira  
Madrid  
Julio de 2025





Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título  
APIs Inteligentes para Open Banking  
en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el  
curso académico 2024/25 es de mi autoría, original e inédito y  
no ha sido presentado con anterioridad a otros efectos.

El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido  
tomada de otros documentos está debidamente referenciada.

Fdo.: Marcos Antonio Martínez Gil

Fecha: 15/ 07/2025

Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO



Fdo.: Barbara Fernandes de Oliveira

Fecha: 24/ 07/ 2025

## **APIS INTELIGENTES PARA OPEN BANKING**

**Autor:** Martínez Gil, Marcos Antonio

**Director:** Fernandes de Oliveira, Barbara

**Entidad Colaboradora:** ICAI – Universidad Pontificia Comillas

### **RESUMEN DEL PROYECTO**

Este Trabajo Fin de Máster investiga la integración de Inteligencia Artificial Generativa (GenAI) en las APIs de Open Banking, proponiendo "APIs Inteligentes" que superan las limitaciones de las APIs tradicionales en interoperabilidad, personalización y generación de valor añadido. La investigación surge del reconocimiento de que las APIs actuales, aunque fundamentales para el ecosistema Open Banking, presentan restricciones estructurales que frenan la materialización plena de servicios financieros verdaderamente inteligentes y proactivos.

La metodología se basa en investigación aplicada con análisis conceptual y evaluación de viabilidad técnica, riesgos y cumplimiento normativo. Se examina el estado del arte de tecnologías GenAI aplicables al sector financiero, incluyendo Grandes Modelos de Lenguaje (LLMs), arquitecturas de Generación Aumentada por Recuperación (RAG) y plataformas cloud especializadas. El marco regulatorio europeo, particularmente PSD2, PSD3/PSR, GDPR y el AI Act, proporciona el contexto normativo para evaluar la viabilidad de estas propuestas.

Se desarrollan tres propuestas conceptuales específicas: un Copilot de Integración de APIs Open Banking que acelera el desarrollo de TPPs mediante asistencia inteligente; una API de personalización financiera que genera narrativas y recomendaciones contextualizadas basadas en datos transaccionales; y una API de cumplimiento automatizado que optimiza procesos AML, generación de SARs y auditoría continua. Cada propuesta se fundamenta en arquitecturas RAG para contextualización, LLMAaaS para escalabilidad empresarial, y middleware de GenAI como orquestador y "cortafuegos de cumplimiento".

Los resultados demuestran que las APIs inteligentes pueden transformar el sector financiero hacia servicios proactivos y personalizados, democratizando el asesoramiento financiero y optimizando procesos operativos. Sin embargo, su éxito está condicionado a una implementación progresiva centrada en gobernanza robusta, explicabilidad algorítmica y cumplimiento "por diseño", considerando desafíos críticos como latencia, costes, sesgos algorítmicos y nuevos vectores de seguridad específicos de GenAI.

**Palabras clave:** Open Banking, Open Finance, Inteligencia Artificial Generativa, APIs Inteligentes, RAG, FinTech, LLMaaS, Middleware de IA, XAI, Personalización financiera, Automatización de cumplimiento, Seguridad en APIs, Evaluación de riesgo crediticio, Bases de datos vectoriales, FinTech, Chatbots financieros.

## 1. Introducción

El sector financiero enfrenta una transformación hacia Open Finance, donde las APIs tradicionales revelan limitaciones estructurales en flexibilidad, interoperabilidad e inteligencia contextual. La irrupción de la Inteligencia Artificial Generativa (GenAI) presenta una oportunidad disruptiva para redefinir estas interfaces, creando "APIs Inteligentes" capaces de procesar lenguaje natural, generar insights contextuales y adaptarse dinámicamente a las necesidades del ecosistema financiero.

Este TFM aborda la convergencia entre GenAI y Open Banking, analizando cómo arquitecturas como RAG (Retrieval-Augmented Generation) y LLMaaS (LLM-as-a-Service) pueden materializar el potencial de servicios financieros verdaderamente inteligentes, manteniendo los estándares de seguridad, cumplimiento y transparencia requeridos por el sector.

## 2. Definición del Proyecto

El proyecto se centra en investigar y proponer soluciones conceptuales para integrar capacidades de GenAI en APIs de Open Banking, superando las limitaciones funcionales actuales. Se definen tres ejes de investigación: evaluación de tecnologías GenAI aplicables al sector financiero, diseño de patrones arquitectónicos seguros y escalables, y desarrollo de propuestas de valor concretas que demuestren el potencial transformador de estas tecnologías.

## 3. Descripción del modelo

La investigación propone un framework arquitectónico basado en tres componentes clave: patrones RAG para contextualización financiera, arquitecturas LLMaaS para escalabilidad empresarial, y middleware de GenAI como orquestador y "compliance firewall". Este middleware actúa como capa de abstracción entre las APIs tradicionales y las capacidades generativas, garantizando gobernanza, explicabilidad y cumplimiento normativo.

El diseño integra bases de datos vectoriales para gestión del conocimiento, modelos LLM especializados en finanzas, y frameworks de explicabilidad (XAI) para transparencia algorítmica, cumpliendo con requisitos regulatorios específicos del sector financiero.

## 4. Resultados

**Tres propuestas de APIs Inteligentes conceptualizadas:** Copilot de Integración de APIs Open Banking, API de personalización financiera y API de cumplimiento automatizado

**Framework FAIDA (Feedback-Aware Intelligent Development Assistant):** Sistema auto-adaptativo que aprende de interacciones developer-API para optimizar continuamente la experiencia de integración.

**Hoja de ruta de adopción:** Framework progresivo desde pilotos de bajo riesgo hasta implementaciones estratégicas, con énfasis en gobernanza y gestión del cambio organizacional.

## 5. Conclusiones

Las APIs Inteligentes representan un salto paradigmático hacia servicios financieros proactivos y personalizados, con potencial para transformar la experiencia del cliente y optimizar procesos operativos. Sin embargo, su éxito depende críticamente de la implementación de marcos robustos de gobernanza, explicabilidad y cumplimiento "by design".

El middleware de GenAI emerge como componente arquitectónico esencial, actuando como orquestador inteligente y guardián de cumplimiento. La adopción debe seguir una estrategia progresiva, comenzando con casos de uso de bajo riesgo como el Copilot de Integración de APIs Open Banking, avanzando hacia aplicaciones de mayor impacto estratégico en personalización y cumplimiento automatizado.

## 6. Referencias

- [1] Cohere. (2025). Generative AI in Finance | Use Cases, Benefits & The Future. Obtenido de Cohere: <https://cohere.com/blog/generative-ai-in-finance>
- [2] Larry Lerner, V. C. (abril de 2025). How banks can turn AI's promise into real impact. Obtenido de McKinsey & Company: <https://www.mckinsey.com/industries/financial-services/our-insights/banking-matters/how-banks-can-turn-ais-promise-into-real-impact>
- [3] Shijie Wu, O. I. (2023). BloombergGPT: A Large Language Model for Finance. Obtenido de arXiv: <https://arxiv.org/html/2303.17564v3>
- [4] Amazon Web Services. (s.f.). Amazon Bedrock FAQs. Obtenido de AWS: <https://aws.amazon.com/bedrock/faqs/>
- [5] CloudOptimo. (s.f.). Amazon Bedrock vs Azure OpenAI vs Google Vertex AI: An In-Depth Analysis. Obtenido de CloudOptimo:



**UNIVERSIDAD PONTIFICIA COMILLAS**  
ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)  
MÁSTER EN TECNOLOGÍAS FINANCIERAS, PAGOS Y BANCA  
DIGITAL

<https://www.cloudoptimo.com/blog/amazon-bedrock-vs-azure-openai-vs-google-vertex-ai-an-in-depth-analysis/>

## **INTELLIGENT APIS FOR OPEN BANKING**

**Author:** Martínez Gil, Marcos Antonio

**Supervisor:** Fernandes Oliveira, Barbara

**Collaborating Entity:** ICAI – Comillas Pontifical University

### **PROJECT ABSTRACT**

This Master's Thesis explores the integration of Generative Artificial Intelligence (GenAI) into Open Banking APIs, proposing the concept of "Intelligent APIs" that transcend the limitations of traditional APIs in terms of interoperability, personalization, and added value generation. The research stems from the recognition that current APIs, while foundational to the Open Banking ecosystem, exhibit structural constraints that hinder the full realization of truly intelligent and proactive financial services.

The methodology is based on applied research, incorporating conceptual analysis and an assessment of technical feasibility, risks, and regulatory compliance. The study examines the state of the art in GenAI technologies applicable to the financial sector, including Large Language Models (LLMs), Retrieval-Augmented Generation (RAG) architectures, and specialized cloud platforms. The European regulatory framework—particularly PSD2, PSD3/PSR, GDPR, and the AI Act—provides the normative context for evaluating the viability of these proposals.

Three specific conceptual proposals are developed: an Open Banking API Integration Copilot that accelerates the development of Third Party Providers (TPPs) through intelligent assistance; a financial personalization API that generates contextualized narratives and recommendations based on transactional data; and an automated compliance API that optimizes AML processes, SAR generation, and continuous auditing. Each proposal is grounded in RAG architectures for contextualization, LLM-as-a-Service for enterprise scalability, and GenAI middleware functioning as both orchestrator and "compliance firewall."

The findings demonstrate that Intelligent APIs can transform the financial sector toward proactive and personalized services, democratizing financial advice and optimizing operational processes. However, their success depends on a gradual implementation centered on robust governance, algorithmic explainability, and "compliance by design," taking into account critical challenges such as latency, costs, algorithmic bias, and new GenAI-specific security vectors.

**Keywords:** Open Banking, Open Finance, Generative Artificial Intelligence, Intelligent APIs, RAG, FinTech, LLMAaaS, AI Middleware, XAI, Financial Personalization, Compliance Automation, API Security, Credit Risk Assessment, Vector Databases, Financial Chatbots.

## **1. Introduction**

The financial sector is undergoing a transformation towards Open Finance, where traditional APIs reveal structural limitations in flexibility, interoperability, and contextual intelligence. The emergence of Generative Artificial Intelligence (GenAI) presents a disruptive opportunity to redefine these interfaces, creating "Intelligent APIs" capable of processing natural language, generating contextual insights, and dynamically adapting to the needs of the financial ecosystem.

This thesis addresses the convergence of GenAI and Open Banking, analyzing how architectures like RAG (Retrieval-Augmented Generation) and LLMAaaS (LLM-as-a-Service) can realize the potential of truly intelligent financial services while upholding the security, compliance, and transparency standards required by the sector.

## **2. Project Definition**

The project focuses on investigating and proposing conceptual solutions for integrating GenAI capabilities into Open Banking APIs, overcoming current functional limitations. Three research pillars are defined: evaluating GenAI technologies applicable to the financial sector, designing secure and scalable architectural patterns, and developing concrete value propositions that demonstrate the transformative potential of these technologies.

## **3. Model Description**

The research proposes an architectural framework based on three key components: RAG patterns for financial contextualization, LLMAaaS architectures for enterprise scalability, and GenAI middleware as an orchestrator and "compliance firewall." This middleware acts as an abstraction layer between traditional APIs and generative capabilities, ensuring governance, explainability, and regulatory compliance.

The design integrates vector databases for knowledge management, LLM models specialized in finance, and eXplainable AI (XAI) frameworks for algorithmic transparency, complying with specific regulatory requirements of the financial sector.

## **4. Results**

Three conceptualized Intelligent API proposals: An Open Banking API Integration Copilot, a financial personalization API, and an automated compliance API.

FAIDA (Feedback-Aware Intelligent Development Assistant) Framework: A self-adaptive system that learns from developer-API interactions to continuously optimize the integration experience.

Adoption Roadmap: A progressive framework from low-risk pilots to strategic implementations, with an emphasis on governance and organizational change management.

## **5. Conclusions**

Intelligent APIs represent a paradigm shift towards proactive and personalized financial services, with the potential to transform the customer experience and optimize operational processes. However, their success critically depends on the implementation of robust governance, explainability, and "by design" compliance frameworks.

GenAI middleware emerges as an essential architectural component, acting as an intelligent orchestrator and compliance guardian. Adoption should follow a progressive strategy, starting with low-risk use cases like the Open Banking API Integration Copilot, and advancing towards higher-impact strategic applications in personalization and automated compliance.

## **6. References**

Cohere. (2025). Generative AI in Finance | Use Cases, Benefits & The Future. Retrieved from Cohere: <https://cohere.com/blog/generative-ai-in-finance>

Larry Lerner, V. C. (April 2025). How banks can turn AI's promise into real impact. Retrieved from McKinsey & Company: <https://www.mckinsey.com/industries/financial-services/our-insights/banking-matters/how-banks-can-turn-ais-promise-into-real-impact>

Shijie Wu, O. I. (2023). BloombergGPT: A Large Language Model for Finance. Retrieved from arXiv: <https://arxiv.org/html/2303.17564v3>

Amazon Web Services. (n.d.). Amazon Bedrock FAQs. Retrieved from AWS: <https://aws.amazon.com/bedrock/faqs/>

CloudOptimo. (n.d.). Amazon Bedrock vs Azure OpenAI vs Google Vertex AI: An In-Depth Analysis. Retrieved from CloudOptimo: <https://www.cloudoptimo.com/blog/amazon-bedrock-vs-azure-openai-vs-google-vertex-ai-an-in-depth-analysis/>



**UNIVERSIDAD PONTIFICIA COMILLAS**  
ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI)  
MÁSTER EN TECNOLOGÍAS FINANCIERAS, PAGOS Y BANCA  
DIGITAL

|   |           |
|---|-----------|
| <b>CAPÍTULO 1. INTRODUCCIÓN .....</b>   | <b>15</b> |
| 1.1. LA PROMESA Y LOS RETOS DE LAS APIS EN LA BANCA ABIERTA.....  | 15        |
| <i>(Machine, s.f.) (Nagarro, s.f.) (Ralston, s.f.) (Reco Security Experts, 2025) (Plaid, s.f.)</i> .....            | 17        |
| 1.2. PROBLEMÁTICA: LIMITACIONES DE LAS APIS TRADICIONALES Y LA OPORTUNIDAD DE GENAI .....                           | 17        |
| 1.3. JUSTIFICACIÓN E IMPORTANCIA DEL ESTUDIO .....  | 18        |
| 1.4. PREGUNTAS DE INVESTIGACIÓN Y OBJETIVOS .....   | 19        |
| 1.4.1. Preguntas de Investigación .....   | 19        |
| 1.4.2. Objetivo General .....   | 20        |
| 1.4.3. Objetivos Específicos .....  | 20        |
| 1.5. ENFOQUE METODOLÓGICO, ALCANCE Y LIMITACIONES .....   | 21        |
| <b>CAPÍTULO 2. MARCO REGULATORIO, TECNOLÓGICO Y ESTADO DEL ARTE .....</b>   | <b>23</b> |
| 2.1. MARCO REGULATORIO: PSD2, EVOLUCIÓN HACIA PSD3/PSR Y ESTÁNDARES EUROPEOS (EBA, BERLIN GROUP) .....              | 23        |
| 2.2. PILAR TECNOLÓGICO: ARQUITECTURAS Y ESTÁNDARES DE APIS EN OPEN BANKING (REST, OAUTH2, NEXTGENPSD2).....         | 24        |
| 2.3. INTELIGENCIA ARTIFICIAL GENERATIVA: FUNDAMENTOS Y HERRAMIENTAS APLICABLES (LLMS, RAG, PLATAFORMAS CLOUD) ..... | 25        |
| 2.4. ESTADO DEL ARTE: CONVERGENCIA DE GENAI Y APIS EN SERVICIOS FINANCIEROS.....                                    | 28        |
| 2.4.1. Casos de Uso Actuales y Emergentes .....   | 28        |
| 2.4.2. Definición y Características Diferenciales de las APIS Inteligentes .....                                    | 29        |
| 2.4.3. Identificación de Brechas de Investigación y Oportunidades Clave .....                                       | 31        |
| <b>CAPÍTULO 3. ANÁLISIS DE VIABILIDAD DE GENAI EN APIS FINANCIERAS.....</b>   | <b>33</b> |
| 3.1. EVALUACIÓN COMPARATIVA DE PLATAFORMAS Y HERRAMIENTAS GENAI .....   | 33        |
| 3.1.1. Proveedores Cloud: Amazon Bedrock, Azure OpenAI, Google Vertex AI .....                                      | 33        |
| 3.1.2. Modelos Especializados: OpenAI, Anthropic, Cohere y Otros .....  | 35        |
| 3.1.3. Criterios de Selección para el Contexto Financiero .....   | 36        |
| 3.2. PATRONES ARQUITECTÓNICOS PARA LA INTEGRACIÓN DE GENAI EN APIS .....  | 40        |
| 3.2.1. Retrieval-Augmented Generation (RAG) en Finanzas .....   | 40        |
| 3.2.2. LLM-as-a-Service (LLMaaS) para APIS Bancarias .....  | 42        |
| 3.2.3. Middleware de GenAI para Orquestación y Gobernanza .....   | 45        |
| 3.2.4. El Middleware como Orquestador de Agentes de IA Colaborativos .....  | 49        |
| 3.3. ANÁLISIS DE LIMITACIONES TÉCNICAS Y DESAFÍOS REALES .....  | 52        |
| 3.3.1. Latencia y Rendimiento en Casos de Uso Financiero.....   | 52        |
| 3.3.2. Costes de Implementación y Operación .....   | 53        |
| 3.3.3. Explicabilidad (XAI) y Transparencia en Modelos Financieros .....  | 54        |
| 3.3.4. Seguridad, Privacidad y Cumplimiento Normativo (PSD2/3, GDPR, AI Act).....                                   | 56        |
| 3.3.5. Calidad y Disponibilidad de Datos Financieros para GenAI .....   | 57        |
| <b>CAPÍTULO 4. PROPUESTAS DE VALOR: DISEÑO CONCEPTUAL DE APIS INTELIGENTES .....</b>                                | <b>59</b> |
| 4.1. API ASISTENTE PARA DESARROLLADORES (COPILOT DE INTEGRACIÓN DE APIS OPEN BANKING) .....                         | 59        |
| 4.1.1. Caso de Uso: Aceleración de la Integración TPP y Reducción de Errores.....                                   | 59        |
| 4.1.2. Arquitectura de Alto Nivel .....   | 60        |
| 4.1.3. Beneficios Clave y Entidades Beneficiadas .....  | 63        |

|  |           |
|--|-----------|
| 4.1.4. Viabilidad, Consideraciones Específicas y Escenarios de Estrés .....  | 64        |
| 4.2. API CON ANÁLISIS PREDICTIVO PARA PERSONALIZACIÓN FINANCIERA .....   | 66        |
| 4.2.1. Caso de Uso: Recomendaciones Proactivas de Productos y Asesoramiento Financiero Personalizado.....                      | 66        |
| 4.2.2. Arquitectura de Alto Nivel .....  | 67        |
| 4.2.3. Beneficios Clave y Entidades Beneficiadas .....   | 69        |
| 4.3. API DE CUMPLIMIENTO Y AUDITORÍA AUTOMATIZADA .....  | 72        |
| 4.3.1. Caso de Uso: Monitorización de Transacciones (AML), Generación de Informes Regulatorios (SARs), Auditoría de APIs ..... | 72        |
| 4.3.2. Arquitectura de Alto Nivel .....  | 73        |
| 4.3.3. Beneficios Clave y Entidades Beneficiadas .....   | 76        |
| 4.3.4. Viabilidad, Requisitos de Explicabilidad y Seguridad, y Escenarios de Estrés.....                                       | 77        |
| <b>CAPÍTULO 5. DISCUSIÓN ESTRATÉGICA Y HOJA DE RUTA .....</b>  | <b>79</b> |
| 5.1. COMPARATIVA ESTRATÉGICA DE LAS PROPUESTAS DE APIS INTELIGENTES .....  | 79        |
| 5.1.1. Impacto Potencial en el Ecosistema Open Finance .....   | 79        |
| 5.1.2. Madurez Tecnológica y Complejidad de Implementación.....  | 79        |
| 5.1.3. Factibilidad de Adopción por el Mercado .....   | 80        |
| 5.2. IMPACTO EN LOS STAKEHOLDERS DEL ECOSISTEMA .....  | 81        |
| 5.3. BARRERAS PARA LA ADOPCIÓN Y ESTRATEGIAS DE MITIGACIÓN .....   | 82        |
| 5.3.1. Costes de Inversión y ROI .....   | 82        |
| 5.3.2. Cumplimiento Normativo y Regulatorio (PSD2, PSD3, PSR, AI Act) .....  | 83        |
| 5.3.3. Consideraciones Éticas y de Privacidad (sesgos, transparencia, control del cliente) ..                                  | 84        |
| 5.3.4. Gestión del Talento y Cambio Organizacional .....   | 85        |
| 5.3.5. Riesgos y Costes de la No Adopción o Adopción Lenta .....   | 86        |
| 5.4. HOJA DE RUTA CONCEPTUAL PARA LA ADOPCIÓN DE APIS INTELIGENTES .....   | 86        |
| 5.5. TENDENCIAS FUTURAS EN GENAL Y APIS FINANCIERAS Y CONEXIÓN CON LA INVESTIGACIÓN.....                                       | 87        |
| <b>CAPÍTULO 6. CONCLUSIONES Y LÍNEAS FUTURAS DE TRABAJO.....</b>   | <b>89</b> |
| 6.1. SÍNTESIS DE HALLAZGOS SOBRE APIS INTELIGENTES .....   | 89        |
| 6.2. RESPUESTA A LAS PREGUNTAS DE INVESTIGACIÓN SOBRE APIS INTELIGENTES .....  | 90        |
| 6.3. LÍNEAS FUTURAS ESPECÍFICAS PARA APIS INTELIGENTES .....   | 90        |
| 6.4. RECOMENDACIONES ESPECÍFICAS PARA APIS INTELIGENTES .....  | 91        |
| <b>CAPÍTULO 7. BIBLIOGRAFÍA.....</b>   | <b>92</b> |
| <b>ANEXO I.....</b>  | <b>99</b> |
| APENDICE: GLOSARIO DE TERMINOS Y SIGLAS.....   | 99        |
| APENDICE: GLOSARIO DE INSTITUCIONES, BANCOS, CORPORACIONES, ORGANIZACIONES Y ENTIDADES .....                                   | 104       |

## Capítulo 1. Introducción

El sector financiero se encuentra inmerso en una profunda transformación, evolucionando desde el paradigma del Open Banking (impulsado por regulaciones como PSD2 y centrado en el acceso a datos de pago) hacia la visión más ambiciosa del Open Finance. Este nuevo horizonte, que busca ofrecer una visión financiera 360° al cliente abarcando seguros, inversiones y pensiones, pone de manifiesto una tensión crítica: las Interfaces de Programación de Aplicaciones (APIs), pilar tecnológico de esta apertura, presentan limitaciones funcionales que restringen su potencial. Frente a este desafío, la Inteligencia Artificial Generativa (GenAI) emerge como una oportunidad disruptiva para redefinir estas interfaces, dando lugar al concepto de "APIs Inteligentes". El presente Trabajo de Fin de Máster investiga esta integración, analizando cómo la GenAI puede superar las barreras tradicionales y qué nuevos desafíos, arquitecturas y propuestas de valor surgen de esta convergencia tecnológica. Para abordar esta investigación de manera lógica y progresiva, este documento se estructura en seis capítulos principales.

### ***1.1. La Promesa y los Retos de las APIs en la Banca Abierta***

Las APIs constituyen la columna vertebral tecnológica del Open Banking y su proyección hacia Open Finance, actuando como el mecanismo que materializa la promesa de un ecosistema financiero verdaderamente interconectado. Sin embargo, la realidad de su implementación revela una tensión fundamental entre el potencial transformador que representan y los obstáculos prácticos que enfrentan.

Esta dualidad se manifiesta de manera particularmente aguda en el contexto europeo, donde la regulación PSD2 ha catalizado una explosión de innovación, pero también ha expuesto las limitaciones inherentes de las aproximaciones técnicas actuales. La fragmentación del mercado, lejos de ser un problema meramente técnico, refleja desafíos más profundos relacionados con la gobernanza, la seguridad y la sostenibilidad económica de los modelos basados en APIs.

La Tabla 1.2 sintetiza esta compleja realidad, contrastando las aspiraciones del ecosistema con los retos que determinan su viabilidad práctica. Lo que emerge de este análisis no es simplemente una lista de pros y contras, sino un mapa de las tensiones estructurales que definen el futuro del Open Banking.

**Tabla 1.2: Promesas y Retos de las APIs en la Banca Abierta**

| Aspecto           | Descripción Detallada  |
|-------------------|--|
| <b>Promesas</b>   |  |
| Innovación        | Habilitan a TPPs para crear nuevos servicios financieros sobre infraestructura existente.  |
| Personalización   | Facilitan experiencias de cliente más integradas, convenientes y adaptadas a necesidades individuales (Plaid, s.f.).               |
| Eficiencia        | Potencial para automatizar procesos, reducir tareas manuales y proveer datos en tiempo real.                                       |
| Nuevos Modelos    | Fomentan ecosistemas de colaboración/competencia y modelos como BaaS.  |
| Monetización      | Oportunidad para bancos de generar ingresos por acceso consentido a datos/servicios.   |
| <b>Retos</b>      |  |
| Seguridad         | Son vectores de ataque; protegerlas es crucial pero complejo. Aumento de ataques (Ralston, s.f.) (Reco Security Experts, 2025).    |
| Estandarización   | Falta de estándares universales dificulta integración, interoperabilidad y escala (Machine, s.f.) (Nagarro, s.f.).                 |
| Costo/Complejidad | Desarrollo, mantenimiento y gestión de APIs seguras y escalables requiere inversión significativa (Miquido, s.f.) (Miquido, 2025). |
| Interoperabilidad | Asegurar funcionamiento fluido entre APIs de distintas entidades es un desafío persistente (Machine, s.f.).                        |
| Privacidad        | Necesidad de cumplir normativas (GDPR) y mantener la confianza del usuario en el manejo de datos sensibles.                        |

|                        |   |
|------------------------|---|
| Integración Legacy     | Conectar APIs modernas con sistemas bancarios antiguos es complejo y puede limitar rendimiento. |
| Rendimiento/Fiabilidad | Interrupciones o lentitud impactan negativamente la experiencia de usuario y la operatividad.   |
| Cumplimiento Reg.      | Navegar requisitos regulatorios cambiantes y complejos (PSD2/3, GDPR).                          |

(Machine, s.f.) (Nagarro, s.f.) (Ralston, s.f.) (Reco Security Experts, 2025) (Plaid, s.f.)

## 1.2. Problemática: Limitaciones de las APIs Tradicionales y la Oportunidad de GenAI

El paradigma actual de APIs en Open Banking opera bajo un modelo fundamentalmente transaccional y reactivo, diseñado para facilitar el intercambio de datos estructurados mediante endpoints predefinidos. Esta arquitectura, aunque efectiva para los objetivos iniciales de PSD2, revela limitaciones críticas cuando se enfrenta a las ambiciones más amplias de Open Finance.

### Limitaciones Fundamentales Identificadas:

Las APIs tradicionales exhiben tres restricciones estructurales que frenan la evolución hacia servicios financieros verdaderamente inteligentes. Su rigidez inherente las confina a responder únicamente a comandos predefinidos, requiriendo modificaciones costosas ante nuevas necesidades o fuentes de datos no estructuradas. La fragmentación del ecosistema de desarrollo se ve agravada por la heterogeneidad de estándares y documentación inconsistente, incrementando significativamente los costes de integración para TPPs. Finalmente, la ausencia de inteligencia integrada delega cualquier análisis o personalización a sistemas externos, limitando la capacidad de generar insights contextuales en tiempo real.

### La Oportunidad Disruptiva de GenAI:

La Inteligencia Artificial Generativa emerge como catalizador para superar estas limitaciones estructurales. Los LLMs y arquitecturas como RAG posibilitan la creación de interfaces verdaderamente adaptativas, capaces de interpretar intenciones expresadas en lenguaje natural, procesar información no estructurada y generar respuestas contextualizadas que trascienden la simple recuperación de datos.

Esta transformación promete desplazar el valor de la conectividad básica hacia la inteligencia integrada, habilitando capacidades de hiperpersonalización a escala, automatización avanzada de procesos complejos y detección proactiva de patrones que permanecen ocultos para sistemas tradicionales (Coher, 2025) (Macro Global, s.f.).

### **Imperativo Estratégico:**

La convergencia de estas limitaciones con las capacidades emergentes de GenAI no representa meramente una oportunidad de optimización incremental, sino un punto de inflexión que podría redefinir las ventajas competitivas en el sector financiero. Las instituciones que logren integrar efectivamente estas tecnologías en sus APIs podrían establecer diferenciaciones sustanciales en experiencia del cliente, eficiencia operativa y capacidad de innovación.

Sin embargo, esta transformación introduce riesgos inherentes a la IA generativa (incluyendo alucinaciones, sesgos algorítmicos y nuevos vectores de ataque) que demandan aproximaciones arquitectónicas y de gobernanza fundamentalmente diferentes a las empleadas en sistemas tradicionales. La materialización exitosa de esta oportunidad requiere, por tanto, un equilibrio cuidadoso entre ambición tecnológica y gestión prudente del riesgo.

### **1.3. Justificación e Importancia del Estudio**

La presente investigación se justifica por la necesidad imperante de alinear las capacidades tecnológicas de las APIs financieras con las crecientes ambiciones del ecosistema Open Finance. Esta necesidad surge de varios factores convergentes:

**Relevancia del Problema:** Las APIs de Open Banking, aunque fundamentales, exhiben limitaciones funcionales -en interoperabilidad, flexibilidad e inteligencia contextual- que frenan la materialización plena de los servicios personalizados y proactivos que Open Finance promete.

**Potencial Transformador de la Solución:** La integración de Inteligencia Artificial Generativa (GenAI) en las APIs ofrece una vía disruptiva para superar estas limitaciones. Dotar a las APIs de capacidades de comprensión, análisis y generación puede desbloquear un valor sustancial para consumidores, bancos y fintechs, mejorando experiencias, eficiencia y la capacidad de innovación (Larry Lerner, 2025) (Surovtseva, 2025).

**Imperativo Tecnológico y Competitivo:** En un sector financiero en rápida digitalización, la adopción de tecnologías como GenAI es una necesidad estratégica (Accenture, s.f.). Las instituciones buscan innovar para mantener la competitividad, optimizar costes (FinOps, s.f.) y satisfacer las expectativas de clientes digitales, demandando aplicaciones prácticas y con ROI tangible para sus inversiones en IA,

**Contribución Académica y Práctica:** Aunque la literatura sobre Open Finance y GenAI es extensa por separado, su convergencia en el diseño de APIs financieras es un campo emergente. Este TFM busca abordar esta brecha, proponiendo soluciones conceptuales de "APIs Inteligentes" con implicaciones prácticas, y analizando rigurosamente los desafíos de su implementación (técnicos, de seguridad y éticos) más allá del entusiasmo inicial

**Potencial Impacto Social:** Aunque con cautela ante los riesgos, APIs más inteligentes podrían fomentar la inclusión y resiliencia financiera mediante servicios mejor adaptados y asesoramiento accesible, condicionado a una gestión ética y responsable.

En síntesis, este estudio responde a la evolución hacia Open Finance, las deficiencias de las APIs actuales para capitalizar esta apertura, el potencial disruptivo de GenAI y las presiones competitivas del sector. Se busca así cerrar la brecha entre la promesa de GenAI y la necesidad de investigar su implementación práctica, segura y ética en el núcleo de la infraestructura de Open Banking/Finance: sus APIs.

## **1.4. Preguntas de Investigación y Objetivos**

Para abordar la problemática descrita y alcanzar los fines justificados en la sección anterior, la presente investigación se guiará por las siguientes preguntas de investigación y objetivos:

### **1.4.1. Preguntas de Investigación**

- P1: ¿Cómo pueden las capacidades específicas de la Inteligencia Artificial Generativa (GenAI), tales como el procesamiento del lenguaje natural, la generación de código y el análisis contextual, ser integradas arquitectónicamente en las APIs de Open Banking para superar las limitaciones funcionales de las APIs tradicionales en términos de interoperabilidad semántica, análisis de datos en tiempo real y generación de valor añadido?
- P2: ¿Qué arquitecturas de software y patrones de diseño específicos (ej. microservicios, API gateways inteligentes, integración de modelos LLM/RAG) son más viables y adecuados para desarrollar "APIs Inteligentes" que incorporen funcionalidades de GenAI de forma segura, eficiente, escalable y mantenible dentro del complejo ecosistema técnico y regulatorio de Open Banking/Finance?
- P3: ¿Cuáles son los principales desafíos técnicos (latencia, coste computacional, gestión de modelos), operativos (monitorización, gobernanza), de seguridad (nuevos vectores de ataque, privacidad de datos), éticos (sesgos, transparencia, explicabilidad) y regulatorios (cumplimiento GDPR, responsabilidad) asociados a la implementación y despliegue de estas APIs Inteligentes basadas en GenAI, y qué estrategias conceptuales de mitigación podrían aplicarse?

- P4: ¿Qué propuestas de valor concretas y diferenciadoras pueden ofrecer estas APIs Inteligentes a los distintos actores del ecosistema financiero incluyendo bancos incumbentes, empresas fintech innovadoras, desarrolladores de TPPs y clientes finales (particulares y empresas) - en comparación con las APIs de Open Banking existentes?

#### ***1.4.2. Objetivo General***

- OG: Investigar y proponer soluciones conceptuales para la creación de APIs Inteligentes que integren capacidades de Inteligencia Artificial Generativa (GenAI) con el fin de mejorar la interoperabilidad semántica, las funcionalidades analíticas y las propuestas de valor dentro del ecosistema de Open Banking/Finance, evaluando su viabilidad conceptual y los desafíos inherentes a su implementación.

#### ***1.4.3. Objetivos Específicos***

- OE1: Identificar y evaluar las capacidades fundamentales de las herramientas y técnicas de GenAI (con énfasis en LLMs y arquitecturas RAG) que resultan más aplicables y prometedoras para la mejora sustancial de las APIs en el contexto de los servicios financieros.
- OE2: Investigar y proponer patrones arquitectónicos y principios de diseño conceptuales para la integración segura, eficiente y responsable de modelos y capacidades de GenAI dentro de la estructura y el flujo de operación de las APIs de Open Banking.
- OE3: Diseñar conceptualmente al menos un ejemplo concretos y detallados de APIs Inteligentes que demuestren propuestas de valor específicas y novedosas habilitadas por GenAI (por ejemplo, un asistente cognitivo para desarrolladores de APIs, una API con capacidades predictivas y de personalización contextual integradas (Sarthak Pande, 2025), o un sistema inteligente de validación de conformidad y seguridad.
- OE4: Analizar la viabilidad conceptual (técnica y operativa) de las soluciones propuestas y evaluar los principales riesgos asociados a su desarrollo y despliegue, incluyendo aspectos críticos de seguridad, privacidad de datos, consideraciones éticas (sesgo, explicabilidad) y cumplimiento normativo (particularmente GDPR y AI Act).

Es fundamental que tanto las preguntas de investigación como los objetivos reflejen un equilibrio necesario. Por un lado, deben explorar activamente el potencial innovador y transformador que GenAI puede aportar a las APIs financieras (P1, P4, OE1, OE2, OE4). Por otro lado, deben abordar de manera crítica y rigurosa los desafíos prácticos, los riesgos inherentes y las consideraciones éticas y de seguridad que conlleva la implementación de una tecnología tan potente y novedosa en un sector altamente regulado y sensible como el financiero (P2, P3, OE3, OE5). Este enfoque dual es esencial para garantizar que la investigación no sea meramente especulativa ni excesivamente

cautelosa, sino que ofrezca una perspectiva fundamentada, equilibrada y responsable sobre el futuro de las APIs Inteligentes en Open Banking/Finance.

### **1.5. Enfoque metodológico, alcance y limitaciones**

Este TFM adopta un enfoque de Investigación Aplicada, centrado en idear soluciones prácticas para integrar GenAI y APIs en Open Finance. El estudio se estructura en:

- Análisis del marco regulatorio, tecnológico y estado del arte (Capítulo 2).
- Identificación de desafíos y oportunidades para APIs inteligentes.
- Ideación y descripción conceptual de propuestas de APIs inteligentes, explorando tecnologías GenAI y patrones de integración (Capítulos 4 y 5).
- Discusión estratégica y evaluación de dichas propuestas (Capítulo 6).

La evaluación se basará en viabilidad técnica conceptual, innovación, valor potencial, seguridad y cumplimiento normativo.

#### **Alcance del Estudio:**

- Ideación y Conceptualización: Se centra en el análisis teórico y la descripción de conceptos para APIs Inteligentes. No se implementan prototipos ni se realizan pruebas empíricas. Las soluciones son constructos teóricos basados en la literatura y el estado del arte.
- Tecnologías GenAI: Se enfoca en LLMs y patrones como RAG, relevantes para APIs financieras.
- Contexto Regulatorio: Se toma como referencia el marco europeo (PSD2, PSD3/PSR, GDPR), considerando también tendencias de otras regiones.
- Casos de Uso Ilustrativos: Se conceptualizan casos de uso relevantes en Open Banking/Finance, sin cobertura exhaustiva.
- Fuentes de Información: Se basa en fuentes secundarias, incluyendo literatura académica, informes técnicos y estándares tecnológicos.

#### **Limitaciones del Estudio:**

- Naturaleza Conceptual: Las ideas y estrategias de mitigación no se validan empíricamente; se evalúan teóricamente.
- Evolución Rápida del Campo: El estudio captura una instantánea del estado del arte, pero no puede prever futuros desarrollos tecnológicos o regulatorios.
- Disponibilidad y Calidad de Datos: Dependencia de información pública; acceso limitado a datos propietarios.

- Riesgos Inherentes a GenAI: Limitaciones intrínsecas de GenAI (sesgo, explicabilidad, alucinaciones) son desafíos activos de investigación.
- Generalidad: El enfoque en el contexto europeo puede limitar la aplicabilidad directa en otras jurisdicciones.

Estas limitaciones contextualizan los hallazgos y sugieren áreas para futuras investigaciones.

## Capítulo 2. Marco Regulatorio, Tecnológico y Estado del Arte

### 2.1. Marco Regulatorio: PSD2, Evolución hacia PSD3/PSR y Estándares Europeos (EBA, Berlin Group)

#### PSD2 como catalizador del Open Banking

La PSD2 (2018) reconfiguró el mercado de pagos europeo, fomentando la competencia y la innovación mediante el mandato de Acceso a la Cuenta (XS2A) y la Autenticación Reforzada de Cliente (SCA). Aunque efectiva, su implementación enfrentó desafíos como la fragmentación de APIs y la fricción en la experiencia de usuario, mitigados parcialmente por exenciones.

#### Desafíos en la implementación de PSD2

La fragmentación de APIs (Machine, s.f.) y la variabilidad en la calidad de las interfaces aumentaron los costes de integración para los TPPs. La EBA señaló problemas como la inconsistencia en la calidad de las APIs (Machine, s.f.) y la aplicación dispar de exenciones SCA (Ilyin, s.f.), lo que complicó la interoperabilidad. Estos desafíos resaltan la oportunidad para APIs inteligentes con GenAI, que podrían ofrecer soluciones innovadoras para la integración y la gestión del consentimiento.

#### Evolución hacia PSD3 y PSR

La experiencia con PSD2 ha impulsado la propuesta de PSD3 y PSR, que buscan mejorar la protección al consumidor y optimizar el Open Banking. Los cambios propuestos incluyen:

- **Mejora de APIs:** Requisitos más estrictos sobre funcionalidad y rendimiento, con posible eliminación de interfaces de contingencia.
- **Dashboards de Permisos:** Paneles centralizados para la gestión de permisos, potencialmente mejorados con interfaces conversacionales basadas en GenAI.
- **Prevención de Fraude:** Medidas como la verificación obligatoria IBAN/nombre y el intercambio seguro de información sobre fraude, lo que crea oportunidades para análisis predictivo de fraude en tiempo real.
- **Hacia Open Finance:** PSD3/PSR son un paso hacia el acceso a datos financieros más amplios, donde las APIs inteligentes serán cruciales para interpretar y generar valor (Stripe, s.f.).

## El papel de los Estándares Europeos

El Berlin Group, con su framework NextGenPSD2, ha promovido la interoperabilidad, logrando una amplia adopción (Nagarro, s.f.). Sin embargo, persisten desafíos como variaciones en las implementaciones y la coexistencia de múltiples estándares regionales, lo que fragmenta el mercado paneuropeo. Las APIs inteligentes con GenAI podrían actuar como "traductores semánticos" o facilitar la generación de adaptadores de código, influyendo en futuros estándares para integrar capacidades de IA de forma nativa.

## 2.2. Pilar Tecnológico: Arquitecturas y Estándares de APIs en Open Banking (REST, OAuth2, NextGenPSD2)

### Principios de diseño de APIs RESTful en Open Banking

Las APIs de Open Banking, basadas en REST, son valoradas por su simplicidad y escalabilidad. Adherirse a principios como la orientación a recursos, la comunicación stateless, el versionado y la paginación garantiza interoperabilidad básica. Sin embargo, la rigidez de REST limita la flexibilidad y la capacidad de comprensión contextual, lo que abre oportunidades para APIs inteligentes con GenAI.

### Estándares de Autorización y Seguridad

La seguridad en Open Banking pivota sobre OAuth 2.0 y OpenID Connect, con flujos específicos para escenarios variados. El estándar FAPI, con mecanismos avanzados como PAR y mTLS, es crucial para proteger contra amenazas sofisticadas. Las APIs inteligentes deben operar dentro de estos marcos y no introducir nuevas vulnerabilidades, aunque pueden contribuir a la detección de anomalías.

### Desafíos y Alternativas: REST vs. GraphQL

REST, aunque dominante, presenta limitaciones para datos financieros complejos y casos de uso en tiempo real. GraphQL, con sus ventajas en eficiencia de datos, manejo de estructuras complejas y actualizaciones en tiempo real, emerge como alternativa. Sin embargo, también presenta desafíos en términos de curva de aprendizaje, caching y seguridad del endpoint único.

### Comparativa de Arquitecturas API: REST vs. GraphQL

| Característica        | REST                   | GraphQL  | Idoneidad en Open Finance                                  |
|-----------------------|------------------------|--|--|
| Recuperación de Datos | Simple pero propenso a | Eficiente, cliente solicita exactamente lo necesario | APIs estándar vs. APIs inteligentes para dashboards y LLMs |

|                                |   |   |   |
|--------------------------------|---|---|---|
|                                | over/under-fetching                       |   |   |
| Manejo de Datos Anidados       | Requiere múltiples llamadas               | Maneja relaciones complejas en una sola consulta                    | Visualización de carteras, análisis de relaciones financieras                               |
| Actualizaciones en Tiempo Real | No nativo, requiere polling o WebSockets  | Soporte nativo para "subscriptions"                                 | Notificaciones de transacciones, alertas de mercado   |
| Versionado                     | Estrategias múltiples, puede ser complejo | Evolución del esquema sin romper clientes existentes                | Entornos con evolución rápida de productos y requisitos de datos                            |
| Caching                        | Aprovecha caching HTTP estándar           | Más complejo, requiere estrategias de caching a nivel de aplicación | Datos que cambian con poca frecuencia vs. datos dinámicos                                   |
| Curva de Aprendizaje           | Ampliamente conocido                      | Requiere aprender el lenguaje de consulta y el esquema              | Proyectos con necesidad de implementación rápida vs. proyectos con inversión en aprendizaje |
| Seguridad                      | Políticas de seguridad granulares         | Requiere validación robusta de consultas                            | Ambos requieren implementación de seguridad robusta (OAuth2, FAPI)                          |

La elección entre REST y GraphQL, o un enfoque híbrido, será crucial a medida que los casos de uso de Open Finance se vuelvan más complejos y orientados a datos en tiempo real (Machine, s.f.).

### **2.3. Inteligencia Artificial Generativa: Fundamentos y Herramientas Aplicables (LLMs, RAG, Plataformas Cloud)**

La irrupción de la Inteligencia Artificial Generativa en el panorama financiero representa más que una simple evolución tecnológica; constituye un cambio paradigmático en cómo las instituciones pueden procesar, interpretar y generar valor a partir de información compleja. En el núcleo de esta transformación se encuentran dos conceptos fundamentales que redefinen las posibilidades de las APIs financieras.

Los **Grandes Modelos de Lenguaje (LLMs)** han emergido como la piedra angular de esta revolución, ofreciendo capacidades de comprensión y generación de texto que trascienden las limitaciones de los sistemas tradicionales basados en reglas. Su arquitectura Transformer les permite no solo procesar lenguaje natural con una sofisticación sin precedentes, sino también generar código, analizar documentos

financieros complejos y mantener conversaciones contextuales que resultan indistinguibles de las interacciones humanas.

La **Generación Aumentada por Recuperación (RAG)** surge como respuesta a una limitación crítica de los LLMs: su tendencia a "alucinar" información y su dependencia de datos de entrenamiento que pueden volverse obsoletos. RAG representa una arquitectura híbrida que combina la capacidad generativa de los LLMs con acceso dinámico a bases de conocimiento actualizadas, creando sistemas que pueden ofrecer respuestas precisas basadas en información verificable y contextualmente relevante.

La convergencia de estos elementos con las plataformas cloud especializadas ha democratizado el acceso a capacidades de IA que antes estaban reservadas para gigantes tecnológicos, permitiendo que instituciones financieras de diversos tamaños puedan experimentar e implementar soluciones generativas avanzadas.

La Tabla 2.3.1 desglosa sistemáticamente estos componentes tecnológicos, detallando no solo sus características fundamentales, sino también las herramientas específicas disponibles para el sector financiero y los desafíos particulares que presenta su implementación en entornos altamente regulados.

**Tabla 2.3.1: Componentes Clave de la IA Generativa para Servicios Financieros Inteligentes**

| Componente                            | Descripción Fundamental   | Tecnologías/Herramientas Específicas Relevantes para Finanzas   | Rol en la Creación de APIs/Servicios Inteligentes   | Desafíos de Implementación en Finanzas   |
|---------------------------------------|---|---|---|--|
| <b>LLM - Arquitectura Transformer</b> | Modelos de lenguaje basados en autoatención, entrenados en grandes corpus para comprender y generar texto/código. | GPT-4, Claude 3, Gemini, Llama; Modelos afinados/especializados como BloombergGPT, FinGPT (Shijie Wu, 2023).            | Motor de comprensión de lenguaje natural para interpretar consultas API, generar respuestas contextuales, crear contenido financiero, y asistir en la generación de código API. | Alucinaciones, conocimiento desactualizado, sesgos, coste computacional, necesidad de interpretabilidad (XAI). |
| <b>RAG - Recuperación (Retrieval)</b> | Proceso de encontrar y extraer información relevante de   | Modelos de embedding (ej. BERT financiero, Sentence Transformers), algoritmos de búsqueda por similitud (ej. KNN, ANN). | Proporciona contexto actualizado y específico del dominio (ej.  | Calidad y actualidad de la base de conocimiento, relevancia de la  |

|                                       |  |  |   |  |
|---------------------------------------|--|--|---|--|
|                                       | una base de conocimiento externa basada en una consulta de usuario.  |  | regulaciones, datos de mercado, documentación API) al LLM para mejorar la precisión de las respuestas de la API inteligente.  | recuperación, escalabilidad de la búsqueda, gestión de datos sensibles (Pruralsight, s.f.).  |
| <b>RAG - Aumentación y Generación</b> | Combinación de la consulta original con la información recuperada para formar un prompt enriquecido que se pasa al LLM para la generación de la respuesta final. | Frameworks como LangChain, LlamaIndex para orquestar el flujo RAG. Técnicas de prompting.                                      | Permite a la API inteligente generar respuestas más precisas, contextualizadas y basadas en hechos, reduciendo alucinaciones y utilizando información propietaria o en tiempo real. | Diseño de prompts efectivos, manejo de grandes volúmenes de contexto recuperado, asegurar la coherencia entre la información recuperada y el conocimiento del LLM. |
| <b>Bases de Datos Vectoriales</b>     | Bases de datos especializadas para almacenar y realizar búsquedas de similitud eficientes sobre embeddings vectoriales.  | Pinecone, Weaviate, Milvus, FAISS, ChromaDB, Azure AI Search, Amazon Kendra, Elasticsearch (con capacidades vectoriales) [64]. | Almacenan y sirven los embeddings de la documentación de APIs, regulaciones financieras, catálogos de productos, etc., para el componente de recuperación de RAG.                   | Coste, escalabilidad, gestión de la indexación, seguridad de los datos almacenados, integración con el resto de la infraestructura.                                |
| <b>Plataformas Cloud GenAI</b>        | Suites de servicios ofrecidos por proveedores cloud para construir, desplegar y gestionar aplicaciones GenAI.  | AWS Bedrock, Azure OpenAI Service, Google Vertex AI, NVIDIA NeMo (CloudOptimo, s.f.).  | Proveen la infraestructura escalable, los modelos fundacionales, las herramientas de MLOps y los servicios de datos necesarios para operar APIs inteligentes a                      | Dependencia del proveedor (vendor lock-in), costes de uso, seguridad y cumplimiento en la nube, integración con sistemas on-premise, concentración de riesgos.     |

|  |  |  |                       |  |
|--|--|--|-----------------------|--|
|  |  |  | nivel<br>empresarial. |  |
|--|--|--|-----------------------|--|

(Shijie Wu, 2023) (Cohere, 2025) (CloudOptimo, s.f.) (Cohere, 2025)

La maduración de este ecosistema tecnológico sugiere que el futuro de las APIs financieras no residirá en la adopción de una única solución monolítica, sino en la orquestación inteligente de múltiples componentes especializados. Esta tendencia hacia la modularidad presenta tanto oportunidades como desafíos: mientras que permite mayor flexibilidad y optimización de costes, también introduce complejidades de integración y gobernanza que las instituciones financieras deberán navegar cuidadosamente.

La proliferación de modelos específicos para el dominio financiero, como BloombergGPT, señala hacia una especialización creciente que podría redefinir las ventajas competitivas en el sector. Las instituciones que logren combinar efectivamente modelos generales con conocimiento propietario a través de arquitecturas RAG sofisticadas podrían establecer diferenciaciones significativas en la calidad y relevancia de sus servicios automatizados.

## 2.4. Estado del Arte: Convergencia de GenAI y APIs en Servicios Financieros

La confluencia de la Inteligencia Artificial Generativa (GenAI) y las Interfaces de Programación de Aplicaciones (APIs) está marcando un punto de inflexión en la industria de servicios financieros (Accenture, 2025). Esta convergencia no solo optimiza procesos existentes, sino que también habilita la creación de servicios financieros fundamentalmente nuevos, más inteligentes, personalizados y proactivos. A medida que las APIs de Open Banking y, progresivamente, de Open Finance, proporcionan un acceso más amplio y estandarizado a los datos financieros, la GenAI ofrece las herramientas para transformar estos datos en valor tangible para clientes e instituciones (Cohere, 2025).

### 2.4.1. Casos de Uso Actuales y Emergentes

Instituciones financieras y fintechs están implementando soluciones que combinan GenAI y APIs para mejorar la eficiencia, la personalización y la innovación de productos. Los principales casos de uso incluyen:

- **Personalización Avanzada:** GenAI procesa datos de Open Banking para ofrecer recomendaciones de productos financieros y asesoramiento personalizado, como en Morgan Stanley (Macro Global, s.f.).

- **Detección de Fraude:** GenAI analiza patrones en datos de transacciones en tiempo real para detectar fraudes sutiles, mejorando la prevención de fraude por ingeniería social (Plaid, s.f.).
- **Asistentes Financieros y Chatbots:** LLMs con RAG acceden a información de cuentas para ofrecer respuestas personalizadas y guiar procesos financieros.
- **Automatización de Procesos:** GenAI automatiza tareas intensivas en conocimiento y optimiza flujos de trabajo complejos (89).
- **Análisis de Documentos y Generación de Informes:** GenAI extrae información clave de documentos financieros y genera resúmenes estructurados.
- **Evaluación de Riesgos y Cumplimiento Normativo:** GenAI mejora la precisión en la evaluación de riesgos crediticios y automatiza el cumplimiento normativo.
- **Procesamiento de Préstamos:** GenAI reduce el tiempo de procesamiento y la tasa de rechazo de solicitudes de préstamo, como en Metro Credit Union (AWS, s.f.).
- **Generación de Código y Desarrollo de APIs:** GenAI facilita la generación de código, el mantenimiento de sistemas heredados y la creación de documentación técnica.
- **Retorno de la Inversión (ROI):** Empresas financieras reportan mejoras en productividad y un ROI positivo gracias a GenAI. La inversión en GenAI representó el 12% del gasto tecnológico (Accenture, s.f.) en el Reino Unido en 2024, con una previsión de aumento al 16% para 2025.

Estos casos de uso demuestran que la integración de GenAI y APIs ofrece un amplio espectro de oportunidades para transformar los servicios financieros, haciéndolos más inteligentes, eficientes y seguros.

#### ***2.4.2. Definición y Características Diferenciales de las APIs Inteligentes***

A medida que la Inteligencia Artificial Generativa (GenAI) se integra más profundamente con las infraestructuras de API en los servicios financieros, emerge el concepto de "APIs Inteligentes". Estas representan una evolución arquitectónica fundamental que trasciende la función tradicional de las APIs como meros conductos de datos.

##### **Definición Operativa:**

Una **API Inteligente** se define como una interfaz de programación de aplicaciones que integra modelos de IA Generativa (como LLMs, frecuentemente potenciados por arquitecturas RAG) para procesar, interpretar y generar información o iniciar acciones de

manera contextual, personalizada y potencialmente proactiva, basándose en los datos a los que accede y en la interacción con el usuario o sistema solicitante.

Desde una perspectiva arquitectónica, constituye un **patrón de diseño híbrido** que combina:

- Interfaces API estándar (REST/GraphQL) como capa de acceso
- Middleware de orquestación de GenAI como núcleo procesador
- Sistemas RAG para contextualización de datos
- Modelos LLM especializados para generación y análisis

#### **Características Diferenciales Clave:**

- **Procesamiento Avanzado de Lenguaje Natural:** Interpretan intención en lenguaje natural, superando la rigidez de endpoints tradicionales, esencial para asistentes financieros contextuales.
- **Personalización Dinámica:** Trascienden la personalización basada en reglas, facilitando experiencias financieras altamente individualizadas que se ajustan en tiempo real al perfil completo del usuario.
- **Capacidad de Inferencia y Predicción:** Realizan inferencias lógicas, identifican patrones ocultos y generan observaciones proactivas, transformando datos históricos en recomendaciones predictivas.
- **Automatización de Flujos Complejos:** Orquestan workflows multi-paso que involucran consultas a diversas fuentes de datos y toma de decisiones basada en IA, incluyendo generación de informes personalizados y evaluación de riesgos crediticios automatizada.
- **Adaptabilidad Continua:** Mediante sistemas RAG y retroalimentación supervisada, pueden mejorar su rendimiento y relevancia temporal, incorporando nueva información de bases de conocimiento actualizadas.

#### **Transformación Paradigmática:**

Las APIs Inteligentes configuran una evolución sustancial que redefine las interfaces de meros puntos de integración técnica hacia nodos de acceso a capacidades de inteligencia aplicada. Esta metamorfosis convierte las APIs tradicionales (anteriormente "tuberías" de datos) en interfaces cognitivas capaces de comprender, razonar y actuar de manera alineada con las necesidades contextuales complejas de usuarios y organizaciones del sector financiero.

Este cambio paradigmático habilita una nueva generación de servicios financieros caracterizados por su naturaleza proactiva, personalización profunda y eficiencia operativa optimizada, marcando un punto de inflexión en la evolución del Open Banking hacia ecosistemas verdaderamente inteligentes.

### ***2.4.3. Identificación de Brechas de Investigación y Oportunidades Clave***

Pese al potencial, la integración de GenAI en APIs financieras es incipiente, presentando brechas de investigación y oportunidades clave que este TFM busca explorar:

#### **Brechas de Investigación:**

1. **Explicabilidad y Fiabilidad (XAI):** Garantizar la fiabilidad y ofrecer explicaciones comprensibles para las decisiones de APIs inteligentes en contextos financieros críticos (ej. evaluación de crédito, asesoramiento) (Grady, s.f.).
2. **Seguridad Específica:** Abordar nuevos vectores de ataque en APIs con LLMs (ej. inyección de prompts, embedding de datos RAG) y desarrollar marcos de prueba adaptados.
3. **Gobernanza de Datos para RAG:** Asegurar privacidad (GDPR), exactitud y ausencia de sesgos en las bases de conocimiento RAG financieras, y gestionar su ciclo de vida.
4. **Escalabilidad, Latencia y Coste:** Optimizar arquitecturas y modelos para equilibrar la sofisticación de GenAI con los requisitos de rendimiento y coste del sector financiero.
5. **Ética y Regulación de la Autonomía:** Investigar la responsabilidad, auditabilidad y equidad de APIs inteligentes con capacidades decisorias autónomas.
- 6.

#### **Oportunidades Clave (que este TFM abordará mediante el diseño conceptual de APIs Inteligentes):**

6. **Democratización del Asesoramiento Financiero:** Ofrecer asesoramiento personalizado y proactivo a gran escala.
7. **Nuevos Modelos de Negocio Basados en APIs de Valor Agregado:** Monetizar insights derivados de IA y servicios automatizados (BaaS, Insights-as-a-Service).
8. **Mejora Radical de la Eficiencia Operativa:** Automatizar tareas complejas de conocimiento (análisis de documentos, cumplimiento).
9. **Innovación Acelerada en Productos y Servicios:** Facilitar la creación de ofertas hiperpersonalizadas y proactivas.
10. **Fortalecimiento de la Resiliencia y Gestión de Riesgos:** Mejorar la detección predictiva y adaptativa de fraudes y otros riesgos.

Este TFM se centrará en el diseño conceptual de APIs que comiencen a materializar estas oportunidades, considerando estrategias para mitigar las brechas identificadas. El objetivo es avanzar hacia 'Finanzas Aumentadas', donde las APIs inteligentes integren la IA de forma fluida y responsable en los servicios financieros.

## Capítulo 3. Análisis de Viabilidad de GenAI en APIs Financieras

La viabilidad técnica de las APIs Inteligentes se define en la intersección entre ambición tecnológica y restricciones operativas reales. Este capítulo evalúa críticamente tres dimensiones fundamentales: las plataformas y herramientas GenAI disponibles en el mercado, los patrones arquitectónicos necesarios para su integración segura en entornos financieros, y las limitaciones técnicas que determinarán el éxito o fracaso de estas implementaciones.

El análisis trasciende la evaluación superficial de capacidades para adentrarse en consideraciones prácticas de costes, latencia, seguridad y cumplimiento normativo que las instituciones financieras enfrentarán en implementaciones reales.

### 3.1. Evaluación Comparativa de Plataformas y Herramientas GenAI

La selección de la plataforma y los modelos de GenAI subyacentes es una directamente en las capacidades, el coste, la seguridad y el cumplimiento normativo de las futuras "APIs Inteligentes" (CloudOptimo, s.f.). No se trata simplemente de identificar el modelo "más potente", sino de discernir cuál es el más adecuado y seguro para el contexto financiero, un sector caracterizado por su rigurosa regulación y la sensibilidad de los datos que maneja.

#### 3.1.1. Proveedores Cloud: Amazon Bedrock, Azure OpenAI, Google Vertex AI

Los principales proveedores cloud compiten intensamente por dominar el espacio GenAI, desplegando servicios que requieren evaluación cuidadosa por parte de instituciones financieras.

**Amazon Bedrock** ofrece acceso unificado a modelos fundacionales de terceros (Claude de Anthropic, Jurassic de AI21, Command de Cohere) y propios modelos Titan, con reciente incorporación de Llama 3.1 y capacidades de fine-tuning. Su ventaja reside en la integración nativa con AWS (SageMaker, Lambda, S3) y modelo pay-as-you-go. Garantiza que los prompts no entrenan modelos base y cumple estándares ISO 27001, SOC, HIPAA y GDPR, desarrollando capacidades para AI Act (CloudOptimo, s.f.) (AWS, s.f.) (AWS Static, s.f.).

**Azure OpenAI Service** proporciona acceso directo a modelos OpenAI avanzados (GPT-4 Turbo, GPT-4o, DALL-E) integrados en infraestructura Azure. Su diferenciación principal es la profunda integración con el ecosistema Microsoft (365 Copilot, Power Platform, DevOps). Utiliza precios basados en tokens con opciones de capacidad reservada, asegurando que interacciones de clientes no reentrenan modelos. Posee certificaciones HIPAA, GDPR, ISO 27001 y herramientas específicas para AI Act con evaluación automatizada de riesgos (Microsoft Learn, s.f.) (Microsoft Learn, s.f.).

**Google Vertex AI** combina modelos GenAI propios (Gemini 1.5 Pro/Flash, PaLM 2) con extenso Model Garden de terceros. Se distingue por orientación robusta hacia MLOps, capacidades avanzadas de fine-tuning y nuevo Vertex AI Agent Builder. Su modelo de precios modular se integra con BigQuery y herramientas de datos. Implementa arquitectura zero-trust con controles IAM, CMEK y residencia de datos, cumpliendo PCI DSS, ISO 27001, HIPAA y GDPR, con herramientas específicas para AI Act incluyendo Model Cards automatizadas (Google Cloud, s.f.) (Google Cloud, s.f.)

### **Implicaciones Estratégicas para el Sector Financiero:**

La competencia feroz entre estos gigantes tecnológicos genera una evolución acelerada de sus plataformas GenAI, particularmente en respuesta a los requisitos regulatorios emergentes del AI Act. Para las entidades financieras, esta dinámica implica que la selección de proveedor no puede considerarse una decisión estática. La observación de las fortalezas distintivas, Vertex AI en MLOps y herramientas de cumplimiento AI Act, Azure OpenAI en integración ecosistémica Microsoft y soporte empresarial, y Bedrock en diversidad de modelos y flexibilidad arquitectónica, sugiere que ninguna plataforma mantendrá superioridad absoluta en todos los aspectos indefinidamente.

Considerando la naturaleza inherentemente aversa al riesgo del sector financiero y su búsqueda continua de optimización de costes y acceso a tecnología de vanguardia, las instituciones requerirán desarrollar agilidad estratégica. Esto podría manifestarse en la preparación para ecosistemas multi-cloud o, mínimamente, en la institucionalización de procesos de reevaluación periódica de proveedores. La dependencia de un único proveedor cloud podría constituir un riesgo estratégico a largo plazo, limitando la capacidad de adaptación a diferenciadores cambiantes de coste, rendimiento o cumplimiento para casos de uso específicos.

Por consiguiente, la arquitectura de futuras APIs Inteligentes debería, en la medida de lo posible, ser agnóstica al proveedor del LLM subyacente, permitiendo mayor flexibilidad y resiliencia estratégica ante la evolución continua del panorama tecnológico y regulatorio.

### ***3.1.2. Modelos Especializados: OpenAI, Anthropic, Cohere y Otros***

Más allá de las grandes plataformas cloud, diversos proveedores ofrecen acceso directo a sus LLMs mediante APIs o despliegues privados, opción particularmente atractiva para el sector financiero.

- **OpenAI** destaca por sus modelos GPT-4 y variantes, ampliamente reconocidos por sus capacidades avanzadas en comprensión y generación de lenguaje natural. Sin embargo, su uso financiero debe considerar estrictamente las políticas de uso, especialmente para asesoramiento financiero (que requiere revisión profesional cualificada y divulgación del uso de IA) y decisiones automatizadas de alto riesgo como crédito o seguros. OpenAI garantiza cifrado en tránsito y reposo, asegurando que los datos empresariales no se utilizan para entrenar modelos públicos (Milvus, s.f.).
- **Anthropic** ofrece modelos Claude, accesibles también vía Amazon Bedrock y Google Vertex AI (Services, s.f.), que han demostrado efectividad particular en contextos financieros. Casos como IG Group evidencian la capacidad de Claude para razonamiento complejo y comprensión de matices financieros, logrando incrementos significativos de productividad. nCino utiliza Claude (AWS, s.f.) en Amazon Bedrock para automatizar la creación de memorandos de crédito complejos. Anthropic enfatiza seguridad y cumplimiento, ofreciendo opciones FedRAMP (Federal Risk and Authorization Management Program) High a través de Google Cloud.
- **Cohere** se enfoca en soluciones empresariales con fuerte orientación a seguridad y soberanía de datos, ofreciendo despliegues privados en VPC del cliente o entornos on-premise. Sus modelos están diseñados para gestión del conocimiento, automatización administrativa y análisis de datos de clientes para innovación de productos financieros (Cohere, 2025).
- **BloombergGPT** representa un ejemplo notable de LLM específicamente entrenado para el dominio financiero. Entrenado con datos financieros propietarios de Bloomberg (FinPile) y datos públicos, este modelo de 50 mil millones de parámetros demuestra rendimiento superior en tareas financieras específicas (análisis de sentimiento, reconocimiento de entidades nombradas, respuesta a preguntas financieras) comparado con LLMs generales de tamaño similar, sin sacrificar significativamente el rendimiento en benchmarks generales (Shijie Wu, 2023).

#### **Tendencia hacia Especialización:**

La emergencia de modelos como BloombergGPT y la creciente capacidad de personalización apuntan hacia una tendencia significativa: la relevancia de modelos más pequeños y especializados o aquellos extensivamente afinados con datos propietarios. Esta preferencia deriva de la necesidad imperante en finanzas de control granular sobre modelos, exigencia de explicabilidad, optimización de costes operativos y mitigación de riesgos como las "alucinaciones", especialmente con datos sensibles.

Los modelos generalistas de gran escala, aunque potentes, pueden resultar costosos y presentar limitaciones en dominios altamente especializados. El sector financiero, por su naturaleza confidencial y escrutinio regulatorio, demanda precisión y auditabilidad. Consecuentemente, las entidades financieras tenderán a favorecer modelos sobre los cuales ejercer control más directo, mediante fine-tuning exhaustivo en infraestructura propia o utilizando modelos compactos entrenados específicamente para tareas financieras concretas (11, s.f.).

Esto sugiere que las futuras APIs Inteligentes probablemente no dependerán de un único LLM monolítico "talla única", sino que orquestrarán el acceso a una diversidad de modelos: algunos grandes y generalistas para comprensión del lenguaje natural en la interfaz API, y otros más pequeños y especializados para ejecutar lógicas de negocio específicas, como análisis de riesgo crediticio basado en datos internos o interpretación de documentos regulatorios.

### *3.1.3. Criterios de Selección para el Contexto Financiero*

Las instituciones financieras deben evaluar herramientas y plataformas GenAI considerando criterios críticos específicos del sector:

- **Seguridad:** Constituye un criterio no negociable que abarca evaluación del cifrado de datos en tránsito y reposo, robustez de gestión de identidades y accesos (IAM), prevención de fugas de datos (DLP), seguridad de prompts y respuestas generadas, y capacidad de despliegue en entornos seguros como VPCs. Proveedores como OpenAI, Anthropic (vía Google Cloud) y Cohere ofrecen diversas garantías y opciones de despliegue privado, mientras que Amazon Bedrock y Google Vertex AI heredan las infraestructuras de seguridad robustas de AWS y GCP respectivamente.
- **Cumplimiento Normativo:** La adherencia a regulaciones como PSD2/PSD3, GDPR, el Reglamento (UE) 2024/1689 (AI Act) y otras normativas financieras específicas es fundamental (94, s.f.). Debe considerarse las capacidades de auditoría, gobernanza del modelo, residencia de datos y certificaciones de cumplimiento que ofrecen las plataformas (ISO 27001, SOC 2, HIPAA). OpenAI

y Google Cloud (16, s.f.) proporcionan opciones de residencia de datos y acuerdos de procesamiento de datos (DPA).

- **Coste:** Requiere análisis detallado de modelos de precios (por token de entrada/salida, por hora de cómputo para entrenamiento o inferencia), costes asociados al fine-tuning, almacenamiento de datos y modelos, e infraestructura necesaria. La optimización de costes (FinOps for GenAI) emerge como disciplina crítica, considerando que los precios de tokens varían considerablemente entre modelos y proveedores.
- **Escalabilidad:** Las soluciones deben manejar grandes volúmenes de solicitudes API y picos de demanda característicos de aplicaciones financieras sin degradación del rendimiento. Las plataformas cloud típicamente ofrecen escalabilidad gestionada.
- **Explicabilidad (XAI):** La capacidad de entender y justificar cómo un modelo GenAI alcanza sus conclusiones es vital en finanzas, no solo para cumplimiento regulatorio sino para generar confianza entre usuarios y gestores (66, s.f.). La opacidad de muchos LLMs ("cajas negras") representa un desafío significativo, requiriendo evaluación de herramientas y técnicas XAI disponibles, como LIME y SHAP (Grady, s.f.), y su aplicabilidad a los modelos seleccionados.

### **Imperativo Regulatorio de la Explicabilidad:**

La explicabilidad trasciende la característica técnica deseable para convertirse en imperativo regulatorio y de negocio en el ámbito financiero. Regulaciones como el AI Act de la UE y las crecientes expectativas de supervisores financieros exigen transparencia en decisiones algorítmicas, especialmente aquellas con impacto significativo en consumidores o estabilidad del mercado. Dado que los modelos GenAI, particularmente LLMs de gran escala, operan frecuentemente como "cajas negras", su adopción en casos de uso de alto riesgo (concesión automatizada de crédito o detección de fraude con implicaciones legales podría verse bloqueada sin explicaciones claras y auditables de su funcionamiento).

Esta necesidad impulsará la demanda de APIs Inteligentes que no solo entreguen respuestas, sino que también ofrezcan "trazas de explicación" o metadatos que justifiquen la salida del modelo GenAI. Esta traza podría incluir fragmentos de información más influyentes (en sistemas RAG), importancia de características consideradas, o incluso narrativas generadas por otro LLM especializado en explicar las decisiones del primero. Aunque esto añada complejidad arquitectónica a la API, constituye un componente esencial para su adopción responsable y sostenible en el sector financiero.

A continuación, se presenta una tabla comparativa de las principales plataformas GenAI considerando estos criterios:

**Tabla 3.1: Comparativa de Plataformas GenAI para APIs Financieras Inteligentes**

| Característica / Plataforma     | Amazon Bedrock  | Azure OpenAI Service  | Google Vertex AI   | Modelos Directos (OpenAI, Anthropic, Cohere API)   |
|---------------------------------|---|---|--|--|
| <b>Modelos Clave (Finanzas)</b> | Anthropic Claude (razonamiento, contexto), Amazon Titan, Cohere Command | OpenAI GPT-4/Turbo (capacidades generales avanzadas), DALL-E (multimodalidad)       | Google Gemini (multimodalidad nativa, razonamiento), PaLM 2, Model Garden (variedad) | OpenAI GPT-4/Turbo, Anthropic Claude (diversas versiones como Opus, Sonnet, Haiku), Cohere Command R/R+ (específicos para empresa). Bloomberg GPT como ejemplo de especialización. |
| <b>Modelo de Precios</b>        | Pay-as-you-go por token (varía por modelo/proveedor)                    | Basado en tokens + costes de infraestructura Azure, opciones de capacidad reservada | Modular (cómputo, tokens, endpoints), granularidad en costes                         | Generalmente por token, con diferentes tiers según el modelo y volumen. Algunos ofrecen opciones de fine-tuning con coste adicional.   |
| <b>Fortalezas (Finanzas)</b>    | Variedad de modelos de proveedores líderes, integración                 | Acceso a modelos OpenAI de vanguardia, integración                                  | Robustas MLOps, amplias opciones de fine-tuning, integración                         | Flexibilidad, acceso directo a las últimas innovaciones del proveedor, potencial para  |

|                                    |  |  |   |  |
|------------------------------------|--|--|---|--|
|                                    | AWS, seguridad   | ecosistema Microsoft   | con BigQuery, seguridad Google Cloud  | despliegues privados (Cohere, Anthropic).  |
| <b>Debilidades/Consideraciones</b> | Fine-tuning limitado directamente en Bedrock para modelos de terceros  | Dependencia de modelos OpenAI, costes pueden escalar   | Curva de aprendizaje para MLOps completas, precios modulares pueden ser complejos de predecir inicialmente  | Gestión de infraestructura si es auto-alojado, (OpenAI, 2025) (e.g., OpenAI y asesoramiento financiero).   |
| <b>Seguridad y Cumplimiento</b>    | AI Act: Soporte Anexo III (alto riesgo). Metadatos: Parciales via SageMaker. Trazabilidad: Completa (CloudTrail). CE: Req. implementación externa. Seguridad: AWS IAM, KMS, no entrenamiento con prompts. ISO, SOC, HIPAA, GDPR. | AI Act: Soporte Anexo III limitado. Metadatos: Básicos (Azure ML). Trazabilidad: Completa (Monitor). CE : Req. implementación externa. Seguridad: Azure RBAC, Customer Lockbox, no entrenamiento con datos. HIPAA, GDPR, FedRAMP High. | AI Act: Soporte Anexo III avanzado. Metadatos: Detallados (Model Garden). Trazabilidad: Completa (Cloud Logging). CE: Req. implementación externa. Seguridad: IAM, CMEK, residencia datos, VPC Controls. PCI DSS, ISO, HIPAA, GDPR. | AI Act: Variable según proveedor. Metadatos: Proveedor-dependiente. Trazabilidad: Limitada. CE: Req. caso por caso. Seguridad: OpenAI: cifrado, SOC2, GDPR. Anthropic: FedRAMP High. Cohere: despliegues privados. |
| <b>Fine-Tuning / RAG</b>           | RAG con Knowledge Bases. Fine-tuning externo vía SageMaker   | Fine-tuning directo para GPT-3.5 (GPT-4 esperado). Soporte RAG   | Amplia gama: prompt tuning, adapter tuning (LoRA), full model retraining.   | OpenAI: fine-tuning API. Anthropic y Cohere también soportan personalización   |

|  |  |                     |                                       |                                      |
|--|--|---------------------|---------------------------------------|--------------------------------------|
|  |  | vía Azure AI Search | RAG con Vertex AI Search/Conversation | n. RAG es un patrón común aplicable. |
|--|--|---------------------|---------------------------------------|--------------------------------------|

(OpenAI, 2025) (Services, s.f.) (AWS, s.f.) (Google Cloud, s.f.)

## 3.2. Patrones Arquitectónicos para la Integración de GenAI en APIs

La transformación de APIs tradicionales en "APIs Inteligentes" requiere más que simples llamadas a un endpoint de un LLM. Es necesario considerar patrones arquitectónicos que permitan integrar de manera robusta, escalable y gobernable las capacidades de GenAI en el flujo de las APIs financieras. Estos patrones deben abordar cómo los modelos acceden a datos relevantes, cómo se orquestan las interacciones y como se gestionan aspectos críticos como la seguridad y el cumplimiento. Es fundamental que estos patrones sienten las bases técnicas que fundamentarán las propuestas conceptuales específicas que se detallarán en el Capítulo 4, anticipando cómo la arquitectura habilita dichas soluciones.

### 3.2.1. Retrieval-Augmented Generation (RAG) en Finanzas

El patrón de Generación Aumentada por Recuperación (RAG, por sus siglas en inglés) se ha convertido en una técnica fundamental para mejorar la fiabilidad y relevancia de las respuestas generadas por LLMs, especialmente en dominios especializados como el financiero (Cohere, 2025). RAG ancla las respuestas del LLM en un corpus de información específico y actualizado, mitigando el riesgo de "alucinaciones" (respuestas incorrectas pero plausibles) y asegurando que la información proporcionada sea contextualmente pertinente.

En el sector financiero, RAG permite a las APIs Inteligentes acceder y utilizar dinámicamente fuentes de datos controladas, tales como:

- Políticas internas del banco y procedimientos operativos.
- Documentación regulatoria extensa y en constante cambio (e.g., IFRS, Basel III, GDPR).
- Datos de mercado en tiempo real o históricos.
- Perfiles de clientes y su historial transaccional (obtenidos con consentimiento a través de APIs AISP de Open Banking).
- Bases de conocimiento sobre productos y servicios financieros.

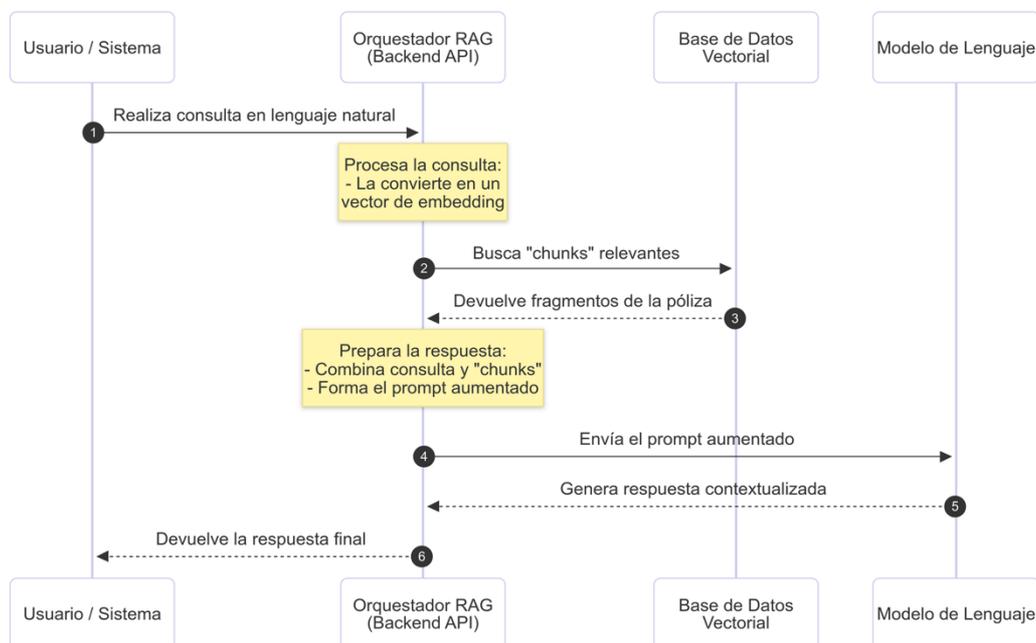
Casos de uso típicos incluyen el procesamiento automatizado de documentos financieros (Ivan Iaroshev, 2024), la creación de asistentes de conocimiento para empleados, la

personalización de recomendaciones financieras y la respuesta a consultas complejas de clientes sobre productos o regulaciones. Por ejemplo, (AWS, s.f.) implementa RAG para permitir que las aplicaciones financieras accedan a datos propietarios de forma segura.

### **Diagrama Conceptual Propuesto: Arquitectura RAG para Consulta de Pólizas de Seguros vía API Inteligente.**

Un diagrama conceptual para este caso ilustraría el siguiente flujo:

1. Un usuario (o sistema) realiza una consulta en lenguaje natural a través de una API Inteligente (e.g., "¿Mi póliza de seguro de hogar cubre daños por inundación hasta qué importe?").
2. La API recibe la consulta y la envía a un componente Orquestador RAG.
3. El Orquestador convierte la consulta en un vector de embedding utilizando un modelo de embedding.
4. Este vector se utiliza para realizar una búsqueda de similitud en una Base de Datos Vectorial.
5. Esta base de datos contiene "chunks" (fragmentos) preprocesados y vectorizados de todas las pólizas de seguros relevantes y documentos asociados.
6. Se recuperan los "chunks" más relevantes de la póliza del cliente específico (y posiblemente cláusulas generales aplicables).
7. Estos fragmentos relevantes, junto con la consulta original, se combinan para formar un prompt aumentado.
8. El prompt aumentado se envía a un LLM.
9. El LLM genera una respuesta precisa y contextualizada, basada en la información recuperada (e.g., "Sí, su póliza número XXXXX cubre daños por inundación hasta un importe de Y EUR, según la cláusula Z.1. Consulte la página W de su contrato para más detalles.>").
10. Esta respuesta es devuelta a través de la API al solicitante.



El diagrama también podría mostrar una conexión opcional a un sistema de Open Banking (AISP) que proporcione datos contextuales adicionales sobre el cliente (e.g., si tiene otras pólizas o productos con la entidad) para enriquecer aún más la interacción, siempre con el debido consentimiento.

La efectividad de RAG en el ámbito financiero depende de manera crítica de la calidad y granularidad del proceso de "chunking" (división de documentos en fragmentos) y "embedding" (creación de representaciones vectoriales) de los documentos financieros y regulatorios. Estos documentos suelen ser densos, complejos y con interdependencias significativas entre sus partes; un chunking inadecuado puede llevar a la pérdida de contexto crucial, mientras que modelos de embedding de baja calidad pueden resultar en la recuperación de información irrelevante o incorrecta para la consulta del usuario. Por lo tanto, el preprocesamiento de los datos para RAG -incluyendo la estrategia de chunking, la elección del modelo de embedding y el versionado de estos embeddings a medida que los documentos originales cambian- es tan importante como el propio LLM generador (Explainable AI in finance, 2025). Las instituciones financieras necesitarán invertir en estrategias sofisticadas de preparación y gestión del ciclo de vida de estos datos vectorizados para asegurar la fiabilidad de sus APIs Inteligentes basadas en RAG.

### 3.2.2. LLM-as-a-Service (LLMaaS) para APIs Bancarias

El patrón LLM-as-a-Service (LLMaaS) se refiere a una arquitectura donde uno o varios LLMs son gestionados como un servicio centralizado, al cual acceden múltiples APIs

Inteligentes y otras aplicaciones dentro de la organización (Google Cloud Blog, s.f.). Este servicio puede ser provisto por una plataforma cloud (como las mencionadas anteriormente) o ser una instancia gestionada internamente por la propia institución financiera, especialmente si se utilizan modelos propietarios o afinados con datos sensibles.

Las ventajas de este patrón incluyen:

- **Gestión centralizada:** Simplifica la administración, el versionado, la monitorización y la actualización de los LLMs.
- **Reutilización:** Permite que múltiples APIs y aplicaciones compartan la misma infraestructura de LLM, optimizando costes y recursos.
- **Consistencia:** Asegura que diferentes partes de la organización utilicen los mismos modelos base (o versiones aprobadas), lo que puede ser importante para la coherencia de las respuestas y el cumplimiento.

Sin embargo, también presenta desafíos:

- **Posible factor limitante:** Si no se diseña adecuadamente, el servicio centralizado de LLM podría convertirse en una limitación para el rendimiento.
- **Acoplamiento:** Un alto grado de dependencia de un servicio LLMAaaS central podría generar un fuerte acoplamiento, dificultando la adopción de nuevos modelos o proveedores si el servicio central no evoluciona con la agilidad necesaria.
- **Gestión de prioridades:** Diferentes APIs pueden tener distintos requisitos de latencia, coste y capacidad del LLM, lo que requiere una gestión sofisticada de las prioridades y el enrutamiento dentro del servicio LLMAaaS.

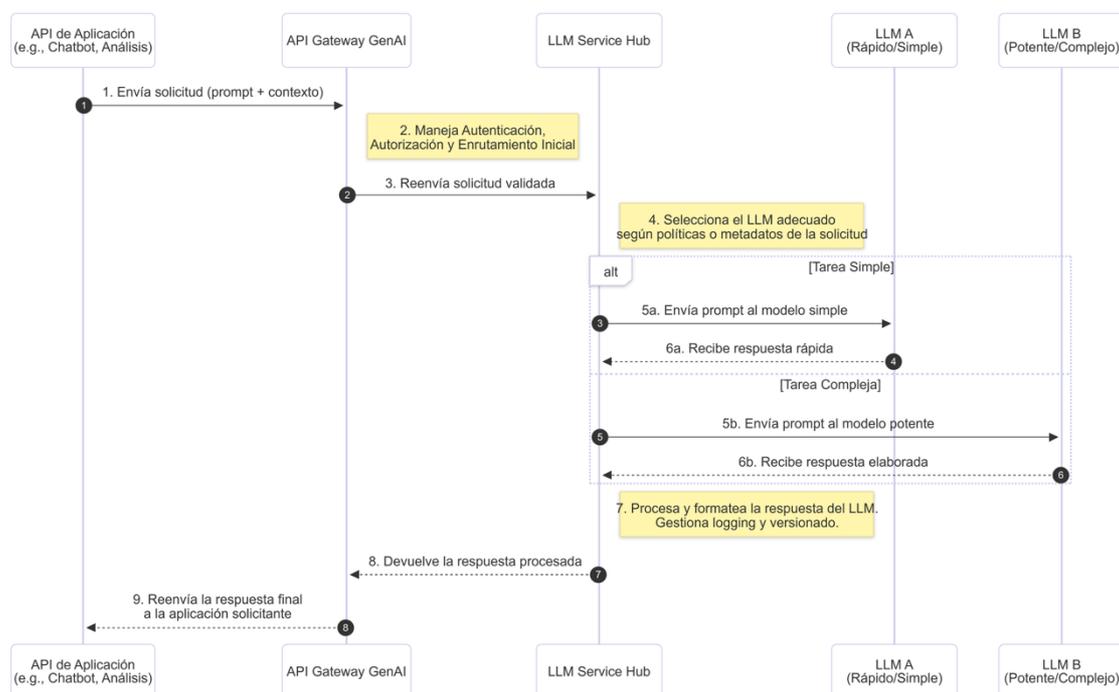
### **Diagrama Conceptual Propuesto: Arquitectura LLMAaaS en un Banco para Múltiples APIs Inteligentes.**

Este diagrama mostraría diversas APIs de aplicación (e.g., API de Chatbot de Soporte, API de Análisis de Sentimiento de Noticias Financieras, API de Resumen de Documentos Regulatorios) interactuando con un componente central denominado "API Gateway de GenAI" o "LLM Service Hub".

1. Las APIs de aplicación envían solicitudes (prompts y datos de contexto) al API Gateway de GenAI.
2. El API Gateway de GenAI maneja la autenticación, autorización, y posiblemente el enrutamiento inicial de la solicitud.
3. El LLM Service Hub recibe la solicitud y, basándose en metadatos o políticas, selecciona el LLM o la configuración de LLM más adecuada (e.g., un modelo más

pequeño y rápido para tareas simples, un modelo más potente para análisis complejos).

4. El LLM Service Hub gestiona la interacción con el/los LLM(s) subyacentes, incluyendo el manejo de tokens, el versionado de modelos y el logging de la interacción.
5. La respuesta del LLM es procesada por el LLM Service Hub (e.g., para formateo o validación básica) y devuelta al API Gateway de GenAI.
6. El API Gateway de GenAI reenvía la respuesta a la API de aplicación solicitante.



Este hub centralizado también podría conectarse a sistemas de monitorización y MLOps para el seguimiento del rendimiento y los costes de los LLMs.

El patrón LLMAaaS (Google Cloud, s.f.) en el sector financiero probablemente evolucionará más allá de un simple servicio que expone un único LLM. Dada la diversidad de tareas que las APIs Inteligentes deberán realizar y las variaciones en los perfiles de coste, capacidad, especialización y cumplimiento de los diferentes LLMs disponibles, una aproximación más sofisticada será necesaria. Se anticipa la emergencia de un "bróker de LLMs" o un "plano de orquestación de GenAI" (Joshi, 2025). Esta capa inteligente no se limitaría a servir a un único modelo, sino que enrutaría dinámicamente las solicitudes de las APIs al LLM más adecuado para cada tarea particular. Por ejemplo, una solicitud de resumen de un documento interno podría dirigirse a un modelo afinado localmente y optimizado para costes, mientras que una consulta compleja que requiera razonamiento avanzado sobre datos de mercado podría ser enviada a un modelo de

vanguardia más potente (y potencialmente más caro) ofrecido por un proveedor cloud. Esta orquestación inteligente, posiblemente gestionada por un "GenAI middleware" (discutido en la siguiente sección), se volverá crucial para optimizar el equilibrio entre rendimiento, coste y cumplimiento en el uso de GenAI a escala empresarial, preparando el terreno para los casos de uso que se detallarán en el Capítulo 4 (Google Cloud Blog, s.f.).

### ***3.2.3. Middleware de GenAI para Orquestación y Gobernanza***

Para abordar la complejidad inherente a la integración de GenAI en múltiples APIs y asegurar una gobernanza efectiva, se propone la implementación de una capa de middleware de GenAI (Tech, Vamsi Talks, s.f.; DATA, NTT, s.f.). Este middleware actuaría como un intermediario inteligente y un punto de control entre las APIs de negocio (tanto las tradicionales como las nuevas APIs Inteligentes) y los diversos servicios y modelos de GenAI subyacentes.

Las funciones clave de este middleware incluirían:

- **Orquestación de Prompts y Flujos:** Gestión de la construcción de prompts complejos, encadenamiento de llamadas a LLMs (prompt chaining), y coordinación de interacciones con sistemas RAG y otras fuentes de datos.
- **Gestión de Contexto:** Mantenimiento del contexto conversacional o transaccional a lo largo de múltiples interacciones de API, crucial para muchos casos de uso de GenAI.
- **Selección y Versionado Dinámico de Modelos:** Implementación de la lógica del "broker de LLMs" mencionado anteriormente, seleccionando el modelo más apropiado para cada solicitud y gestionando diferentes versiones de modelos.
- **Logging y Auditoría Centralizados:** Registro detallado de todas las interacciones con los LLMs (prompts, respuestas, metadatos) para fines de auditoría, depuración, análisis de rendimiento y cumplimiento normativo.
- **Aplicación de Políticas de Seguridad y Cumplimiento:** Imposición de políticas de seguridad (e.g., enmascaramiento de datos sensibles antes de enviar a un LLM externo), controles de acceso, y validaciones de cumplimiento antes y después de la interacción con el LLM.
- **Integración con Herramientas XAI:** Facilitación de la conexión con servicios de explicabilidad para generar o recuperar justificaciones de las respuestas de los LLMs.
- **Monitorización y FinOps:** Seguimiento del uso de tokens, costes de inferencia, latencia y otros KPIs para optimizar el gasto en GenAI.

Este enfoque de middleware se alinea bien con arquitecturas de referencia como la Banking Industry Architecture Network (BIAN), que promueve la modularidad y la estandarización de los servicios bancarios. Un middleware de GenAI podría considerarse una capacidad de servicio transversal dentro del marco BIAN (DATA, NTT, s.f.), facilitando la infusión de inteligencia en múltiples dominios de servicio. De manera similar, las arquitecturas de gateway de GenAI, como las propuestas por Microsoft utilizando API Management (APIM), pueden considerarse una forma de este middleware, centralizando el acceso y la aplicación de políticas a los servicios de GenAI (Microsoft Learn, s.f.).

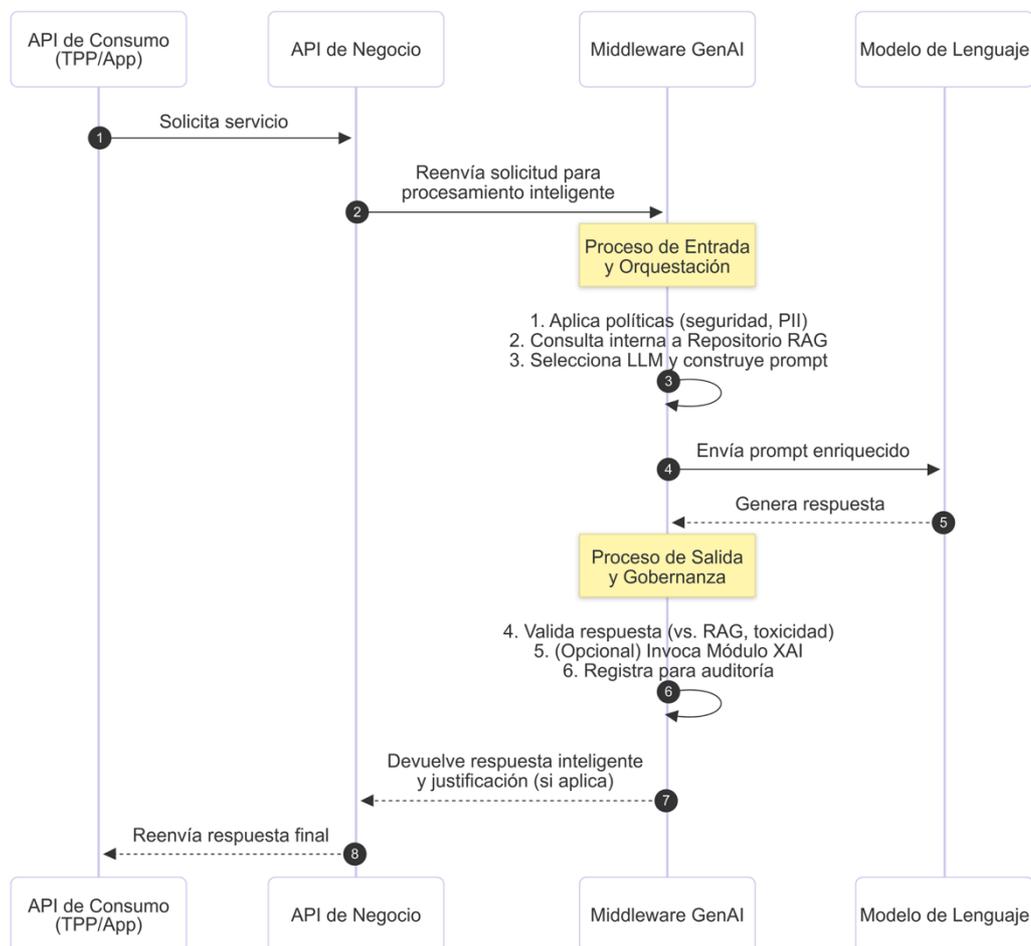
Profundizando en los desafíos prácticos de la construcción de este middleware de GenAI, surgen varias consideraciones críticas:

- **Interoperabilidad con LLMs y Sistemas RAG Heterogéneos:** El middleware debe ser capaz de interactuar fluidamente con una diversidad de LLMs (tanto modelos comerciales como de código abierto, cada uno con sus propias APIs y formatos de respuesta) y con diferentes implementaciones de sistemas RAG (que pueden variar en sus bases de datos vectoriales, modelos de embedding y mecanismos de recuperación). Esto requiere un diseño modular y adaptable, posiblemente utilizando patrones de adaptador y estrategias de normalización de datos.
- **Gestión de la Latencia Adicional:** Cada capa de abstracción, como un middleware, introduce inherentemente una latencia adicional. En el contexto de GenAI, donde la inferencia de los LLMs ya puede ser latente, minimizar este overhead es crucial. El middleware debe estar optimizado para un procesamiento eficiente, con mecanismos de caching inteligente, enrutamiento optimizado y, posiblemente, la capacidad de ejecutar ciertas funciones (como validaciones simples) de manera asíncrona o en paralelo.
- **Modelo de Desarrollo y Propiedad:** El desarrollo de un middleware de GenAI tan sofisticado podría seguir diferentes modelos. Podría ser una capacidad interna estratégica para grandes bancos con recursos significativos de ingeniería, permitiéndoles un control total y una personalización profunda. Alternativamente, podría emerger como una solución de mercado ofrecida por proveedores especializados (existentes o nuevos), quienes se enfocarían en la complejidad de la integración de GenAI, ofreciendo una plataforma robusta y gobernable a múltiples instituciones financieras. Esta última opción podría democratizar el acceso a capacidades avanzadas de orquestación de GenAI.

### **Diagrama Conceptual Propuesto: Middleware de GenAI en el Ecosistema de APIs de Open Finance.**

Este diagrama ilustraría un ecosistema de Open Finance donde las APIs de Consumo (e.g., aplicaciones de TPPs, frontends bancarios) interactúan con APIs de Negocio del banco.

1. Una API de Negocio (e.g., API de Asesoramiento Personalizado) recibe una solicitud.
2. En lugar de llamar directamente a un LLM, esta API de Negocio (o un API Gateway que la precede) reenvía la solicitud al "Financial GenAI Middleware".
3. El Middleware de GenAI procesa la solicitud:
  - Aplica políticas de seguridad y cumplimiento (e.g., anonimización de PII).
  - Orquesta la interacción con los componentes GenAI necesarios:
    - Puede consultar un Repositorio RAG (con datos de clientes, productos, regulaciones).
    - Selecciona dinámicamente el LLM más adecuado (interno/externo, grande/pequeño).
    - Construye el prompt final.
  - Envía el prompt al LLM seleccionado.
4. El LLM genera una respuesta.
5. El Middleware de GenAI recibe la respuesta del LLM:
  - Aplica políticas de validación y seguridad a la respuesta (e.g., detección de toxicidad, verificación de hechos contra el RAG).
  - Puede invocar un Módulo XAI para generar una explicación.
  - Registra la interacción para auditoría.
6. El Middleware devuelve la respuesta "inteligente" (y posiblemente la explicación) a la API de Negocio, que a su vez la reenvía al consumidor original.



La introducción de una capa de middleware de GenAI robusta y especializada podría convertirse en un elemento diferenciador y un producto o servicio clave por derecho propio dentro del stack tecnológico financiero. Su valor no residiría únicamente en simplificar la compleja tarea de integrar las capacidades de GenAI, sino, de forma crucial, en actuar como un "Compliance Firewall" (Cortafuegos de Cumplimiento) para todas las interacciones con los LLMs.

Este "Compliance Firewall" integrado en el middleware tendría un rol técnico específico y aplicaría políticas concretas (Reco Security Experts, 2025). Su interacción se daría tanto en el flujo de entrada (antes de que los datos lleguen al LLM) como en el de salida (antes de que la respuesta del LLM se entregue). Algunos ejemplos de políticas que podría aplicar este firewall incluyen:

- Política de no transmisión de datos personales identificables (PII) a modelos de GenAI externos que no cuenten con certificación de seguridad X o acuerdo de procesamiento de datos Y. Esto implicaría técnicas de anonimización,

pseudonimización o enmascaramiento de datos sensibles en el prompt antes de su envío a un LLM fuera del control directo de la entidad.

- Política de validación de respuestas generadas por LLMs contra una base de conocimiento de hechos aprobados (RAG) antes de su entrega al usuario, especialmente en contextos de asesoramiento o información crítica. Si la respuesta del LLM contradice o no se alinea con la información verificada en el RAG interno, el firewall podría bloquear la respuesta, solicitar una regeneración o escalar a un supervisor humano.
- Política de registro y auditoría inmutable de todas las interacciones (prompts, respuestas, decisiones de enrutamiento del middleware) que pasen por el firewall. Este registro detallado sería fundamental para la trazabilidad, la investigación de incidentes y la demostración de cumplimiento ante los reguladores.

Esta función de cortafuegos aseguraría que las políticas de uso de datos, privacidad, seguridad y ética se apliquen rigurosamente antes de que cualquier dato sensible del cliente o de la institución llegue a los modelos de GenAI (especialmente aquellos operados por terceros) y, de igual manera, antes de que las respuestas generadas por estos modelos lleguen a los usuarios finales o se propaguen a otros sistemas internos. Dada la complejidad de la integración de GenAI y los significativos riesgos asociados, especialmente en un sector tan regulado, y la creciente prioridad de la gobernanza de la IA, una capa de middleware que abstraiga la complejidad intrínseca de los LLMs y centralice la gobernanza y el cumplimiento normativo sería de un valor incalculable. Esto podría impulsar la aparición de soluciones de mercado como "GenAI Firewalls" o "Compliance Orchestrators for LLMs" diseñadas específicamente para las necesidades del sector financiero, que se integrarían de forma nativa con las APIs Inteligentes para garantizar un uso seguro, ético y regulado de la Inteligencia Artificial Generativa. Estas soluciones fundamentan arquitectónicamente la viabilidad de las propuestas que se explorarán en el Capítulo 4.

### ***3.2.4. El Middleware como Orquestador de Agentes de IA Colaborativos***

En los apartados anteriores se ha argumentado que la orquestación inteligente añade valor transformador a las APIs; sin embargo, tal inteligencia sigue siendo mayoritariamente estática. Resulta particularmente relevante, por tanto, explorar un marco que no solo consuma modelos de IA para responder, sino que reconfigure su propia topología y su lógica interna a medida que el entorno operacional evoluciona.

En este sentido, proponemos un Framework de API Inteligente Dinámica y Auto-Adaptativa (FAIDA), inspirado en las teorías de arquitecturas software capaces de alterarse en tiempo de ejecución y en los principios de evolución incremental del software. A grandes rasgos, FAIDA incorpora un bucle MAPE-K ampliado (Monitor, Analyse, Plan, Execute, Knowledge) donde la fase «K» se enriquece continuamente con señales inferidas por GenAI. El resultado es una plataforma que “aprende” las interacciones reales de consumidores y productores de APIs y ajusta, sin intervención

humana, políticas de rate-limiting, estrategias de balanceo semántico e, incluso, introduce nuevos endpoints generados sobre demanda. (78)

Por otra parte, la resiliencia se materializa a través de componentes self-healing que detectan fallos o degradaciones y aplican remedios automáticos, desde la regeneración de contratos OpenAPI hasta el redireccionamiento de flujo, siguiendo prácticas ya validadas en entornos SaaS auto-sanadores. Cabe destacar que el motor de aprendizaje no opera únicamente a nivel de datos de negocio; observa también métricas de gobernanza (latencia, coste de tokens, cumplimiento de SLA) y, cuando detecta tendencias adversas, refactoriza la malla de microservicios para preservar la eficiencia.

### **Estructura conceptual del FAIDA**

1. Capa de Observación Multidimensional: captura telemetría, trazas semánticas y feedback de usuarios finales.
2. Agente de Análisis Evolutivo: combina detección estadística de anomalías con un modelo GenAI que interpreta patrones emergentes y genera hipótesis de mejora.
3. Planner Político-Predictivo: traduce hipótesis en un plan de reconfiguración. Si la fiabilidad estimada supera un umbral adaptativo, activa la fase de ejecución.
4. Ejecutor de Reconfiguración Segura: aplica cambios de contrato, escala servicios o introduce un nuevo conector, utilizando técnicas de blue-green y feature flags para minimizar riesgos.
5. Repositorio de Conocimiento Vivo: persiste decisiones y métricas; alimenta de vuelta el lazo MAPE-K cerrando el ciclo.

### **Procesos de gobernanza:**

Merece especial atención la gobernanza de cambios: cada decisión del Planner se somete a un «gate» de política explicable. Si la justificación generada por el agente no supera las reglas de auditoría (ej., trazabilidad de datos sensibles), la acción queda en suspenso y se solicita revisión humana. Esta estrategia minimiza los riesgos regulatorios y alinea el framework con la tendencia de auditorías formales sobre patrones de arquitectura dinámica.

### **Escenario ilustrativo:**

Imaginemos un banco digital que lanza, de forma súbita, una campaña de microcréditos. El tráfico a la API de scoring se triplica durante la primera semana. Bajo FAIDA, la capa de observación detecta la anomalía y el agente sugiere clonar el microservicio de scoring con un modelo ML simplificado, ajeno a las peticiones de alta precisión. La clonación se despliega en un cluster efímero, se actualiza el gateway y, si la latencia promedio vuelve a valores nominales, el cambio se consolida. Caso contrario, se revierte automáticamente.

### **Riesgos y mitigaciones:**

Aunque el potencial disruptivo de FAIDA es evidente, su adopción comporta retos serios: la complejidad cognitiva del sistema, el coste de pruebas de regresión sobre configuraciones emergentes y la posibilidad de «deriva de políticas». Parte de estos riesgos se atenúan mediante la inclusión de salvaguardas XAI que permiten auditar cada decisión y mediante umbrales de confianza variables según la criticidad del endpoint.

En síntesis, el FAIDA representa un avance sustantivo respecto al middleware estático. No solo integra inteligencia; también se reinventa a sí mismo continuamente, reduciendo tiempos de respuesta ante eventos exógenos y optimizando los recursos de forma evolutiva y verificable. (79)

### **Diagrama Conceptual Propuesto: Arquitectura FAIDA en Evolución Dinámica**

Este diagrama ilustraría la naturaleza auto-adaptativa del Framework FAIDA, mostrando cómo evoluciona su topología en respuesta a cambios del entorno operacional.

#### **Flujo de Operación y Evolución del FAIDA:**

1. **Entrada de Solicitudes Diversas:** Múltiples APIs de negocio (e.g., API de Scoring Crediticio, API de Detección de Fraude, API de Recomendaciones Personalizadas) envían solicitudes al núcleo FAIDA.
2. **Capa de Observación Multidimensional** monitoriza continuamente:
  - Patrones de tráfico y latencias por endpoint
  - Métricas de calidad de respuestas GenAI
  - Señales de degradación o sobrecarga
  - Feedback semántico de usuarios finales
3. **Agente de Análisis Evolutivo** procesa las señales capturadas:
  - Detecta anomalías estadísticas en el comportamiento del sistema
  - Emplea un modelo GenAI especializado para interpretar patrones emergentes
  - Genera hipótesis de mejora arquitectónica ("necesidad de agente especializado en criptomonedas")
4. **Planner Político-Predictivo:** evalúa las hipótesis:
  - Simula el impacto de posibles reconfiguraciones
  - Calcula métricas de fiabilidad y riesgo
  - Si supera umbrales adaptativos, autoriza la reconfiguración
5. **Ejecutor de Reconfiguración Segura** implementa cambios dinámicos:
  - **Escenario A:** Clona microservicios bajo demanda (como en el ejemplo de microcréditos)
  - **Escenario B:** Genera automáticamente nuevos agentes especializados
  - **Escenario C:** Rebalancea cargas entre LLMs según patrones de uso
  - **Escenario D:** Actualiza contratos OpenAPI para reflejar nuevos endpoints
6. **Repositorio de Conocimiento Vivo** mantiene la memoria organizacional:
  - Registra decisiones evolutivas exitosas y fallidas

- Alimenta el bucle MAPE-K con aprendizajes históricos
- Permite rollback inteligente ante configuraciones problemáticas

El diagrama siguiente materializa visualmente la arquitectura FAIDA, destacando su naturaleza evolutiva mediante la representación de flujos bidireccionales y bucles de retroalimentación que caracterizan a los sistemas auto-adaptativos. La representación gráfica enfatiza tres aspectos fundamentales: primero, la entrada diversificada desde múltiples APIs de negocio hacia el núcleo FAIDA; segundo, el procesamiento secuencial a través de los cinco componentes principales (observación, análisis, planificación, ejecución y conocimiento) que conforman el bucle MAPE-K ampliado; y tercero, la gestión dinámica de recursos que permite la creación y destrucción automática de componentes según la demanda.

La evolución desde middleware estático hacia frameworks auto-adaptativos como FAIDA representa un salto paradigmático en la concepción de las APIs financieras. Mientras que los patrones RAG, LLMaaS y middleware tradicional proporcionan la base tecnológica necesaria, FAIDA introduce la capacidad de evolución autónoma que será fundamental para las APIs Inteligentes que se explorarán en el siguiente capítulo. Esta capacidad de auto-reconfiguración no solo optimiza el rendimiento operativo, sino que sienta las bases arquitectónicas para que las APIs trasciendan su rol de simples interfaces hacia convertirse en ecosistemas cognitivos adaptativos.

### ***3.3. Análisis de Limitaciones Técnicas y Desafíos Reales***

Si bien el potencial de GenAI para transformar las APIs financieras es considerable, su implementación práctica se enfrenta a una serie de limitaciones técnicas y desafíos reales que deben ser abordados con pragmatismo (Analyst Prep, s.f.). Estos desafíos no son meramente teóricos, sino que tienen implicaciones directas en la viabilidad, el coste y la aceptación de las APIs Inteligentes en el entorno financiero.

#### ***3.3.1. Latencia y Rendimiento en Casos de Uso Financiero***

La latencia de los LLMs representa una preocupación crítica para aplicaciones financieras que operan en tiempo real o cuasi-real. Casos de uso como validación instantánea de pagos PISP, detección de fraude transaccional, o asistentes conversacionales que requieren interacciones fluidas, pueden ver comprometida su viabilidad si la latencia del LLM subyacente es excesiva. Investigaciones (Dao, Fu, Ermon, Rudra, & Ré) identifican la latencia de inferencia como desafío clave, mientras que análisis de Deepchecks (Deepchecks, s.f.) y Nexgencloud (NextGent Cloud, s.f.) detallan los diferentes tipos de latencia y factores que la afectan.

### **Estrategias de Mitigación de Latencia:**

Las estrategias para mitigar latencia incluyen el uso de modelos más pequeños o destilados (model distillation), optimización de prompts para generar respuestas más concisas, empleo de hardware especializado (GPUs/TPUs), procesamiento por lotes donde sea aplicable, y técnicas de inferencia más eficientes como inferencia simultánea o caching semántico.

### **Métricas de Latencia Diferenciadas:**

Es crucial distinguir entre métricas de latencia, ya que tienen implicaciones distintas para diversas APIs financieras. La "latencia hasta el primer token" (TTFT) se refiere al tiempo que tarda el modelo en iniciar la generación de respuesta, mientras que la "latencia de la respuesta completa" (TTLT) representa el tiempo total hasta generar toda la salida.

Una API de chatbot interactivo puede percibirse como responsiva si el TTFT es bajo, incluso con TTLT algo mayor, ya que el usuario observa que el sistema está "pensando" y comenzando a responder. Contrariamente, una API de validación de transacciones o detección de fraude en tiempo real necesita un TTLT extremadamente bajo, pues la decisión completa debe tomarse en milisegundos.

### **Implicaciones Arquitectónicas:**

Este matiz implica que el diseño de APIs Inteligentes debe considerar qué perfil de latencia es crítico para su caso de uso específico. Consecuentemente, las arquitecturas de GenAI, posiblemente gestionadas a través del "GenAI Middleware" discutido anteriormente, podrían necesitar emplear diferentes modelos de LLM o aplicar distintas técnicas de optimización de inferencia según los requisitos de latencia específicos de cada API consumidora.

Esta diferenciación permite optimizar recursos computacionales y costes, asignando modelos más potentes pero lentos para casos de uso que toleran mayor latencia, mientras reserva modelos optimizados para velocidad en aplicaciones críticas en tiempo real.

### **3.3.2. Costes de Implementación y Operación**

La adopción de GenAI conlleva una estructura de costes multifacética que trasciende la simple adquisición tecnológicas (Miquido, s.f.). Los costes directos incluyen licencias de modelos/plataformas, costes de inferencia (tarifados por tokens procesados con variaciones significativas entre proveedores), costes de fine-tuning para adaptar modelos preentrenados, e infraestructura para auto-alojamiento o sistemas RAG robustos (hardware GPUs/TPUs, almacenamiento, redes).

Los costes indirectos y operativos resultan igualmente significativos: talento especializado (ingenieros de IA, científicos de datos con experiencia en LLMs, expertos MLOps) con salarios elevados debido a la escasez de oferta; integración con sistemas core bancarios; preparación y gestión de datos, especialmente para RAG (curación, limpieza, chunking, embedding y actualización continua); cumplimiento y gobernanza continua para detectar sesgos y asegurar cumplimiento normativo; formación y gestión del cambio organizacional; y sostenibilidad energética, factor emergente de coste operativo y reputacional dado el considerable consumo energético de LLMs que influye en la selección de modelos eficientes y proveedores cloud con credenciales de sostenibilidad.

### **FinOps para GenAI y TCO Extendido:**

La optimización de estos costes ha propiciado la aparición de FinOps para GenAI, disciplina especializada que armoniza rendimiento de modelos, impacto empresarial e inversión económica requerida. La implementación de GenAI representa un desembolso de capital sustancial, no solo por despliegue tecnológico sino por el gasto operativo recurrente de equipos altamente especializados, erigiendo la gobernanza financiera proactiva como pilar fundamental para la viabilidad (FinOps, s.f.).

El "coste total de propiedad" (TCO) de una API Inteligente se extiende mucho más allá del coste por token de un LLM. Los costes asociados a preparación de datos (especialmente sistemas RAG), fine-tuning continuo, monitorización de calidad y detección de sesgos, gestión de seguridad específica de GenAI (protección contra prompt injection), cumplimiento normativo y desarrollo de mecanismos XAI pueden superar significativamente los costes directos de inferencia. Estos "costes ocultos" son frecuentemente subestimados en fases iniciales de proyectos GenAI.

Las instituciones financieras, caracterizadas por aversión al riesgo y necesidad de control riguroso, deben reconocer que la implementación de GenAI no es un proyecto de "desplegar y olvidar". Requiere inversión continua en mantenimiento, supervisión y gobernanza. Esta realidad podría llevar a las entidades a favorecer soluciones GenAI con capacidades robustas de MLOps y herramientas de gobernanza integradas, incluso si el coste por token inicial parece comparativamente más alto, ya que un TCO más bajo a largo plazo y mejor gestión del riesgo podrían justificar la inversión inicial.

### ***3.3.3. Explicabilidad (XAI) y Transparencia en Modelos Financieros***

El sector financiero opera bajo estricta supervisión regulatoria y fuertes expectativas de confianza del cliente, convirtiendo la explicabilidad de decisiones de IA en requisito

fundamental (Iván Balsategui, 2024), no opcional. Los LLMs, por su complejidad y entrenamiento en vastos conjuntos de datos, funcionan frecuentemente como "cajas negras" (Philip Mavrepis, 2024) donde el razonamiento exacto detrás de respuestas específicas resulta difícil de desentrañar. Esta opacidad representa un desafío significativo para su adopción en casos críticos como denegación de crédito, asignación de perfiles de riesgo o generación de alertas de fraude, donde se requiere justificación auditable.

### **Técnicas XAI y Limitaciones:**

Técnicas como LIME (Local Interpretable Model-agnostic Explanations) y SHAP (SHapley Additive exPlanations) han surgido para iluminar el comportamiento de modelos ML. LIME crea aproximaciones locales interpretables alrededor de predicciones específicas, mientras SHAP utiliza teoría de juegos para asignar valores de contribución a cada característica de entrada. Aunque valiosas, su aplicación directa y en tiempo real a LLMs dentro del flujo API puede ser compleja y computacionalmente costosa. Además, la interpretabilidad de explicaciones generadas para usuarios no técnicos sigue siendo área de investigación activa, con algunos trabajos sugiriendo el uso de LLMs para traducir salidas técnicas XAI en explicaciones comprensibles en lenguaje natural.

### **Arquitecturas de Explicabilidad para APIs:**

La necesidad de explicabilidad en APIs GenAI financieras podría impulsar arquitecturas donde la respuesta de la API principal venga acompañada o seguida por una solicitud a una "API de explicación" paralela (Ralston, s.f.). Esta API de explicación podría tomar un identificador de transacción o decisión original y devolver justificación detallada, utilizando combinación de técnicas XAI y generación de lenguaje natural. Alternativamente, la API principal podría incluir metadatos de explicación directamente en su respuesta, como resumen de factores más influyentes o puntero a documentación relevante utilizada por sistemas RAG.

Esta aproximación, aunque añade complejidad arquitectónica, desacopla la generación de respuesta de la generación de explicación, permitiendo diferentes niveles de detalle y modalidades de explicación según las necesidades del consumidor API (sistema, auditor o cliente final).

### ***3.3.4. Seguridad, Privacidad y Cumplimiento Normativo (PSD2/3, GDPR, AI Act)***

Las APIs financieras manejan datos extremadamente sensibles, y la integración de GenAI introduce nuevas dimensiones de riesgo (Ralston, s.f.) que requieren gestión proactiva. Los riesgos específicos incluyen:

- **Prompt Injection:** Actores maliciosos diseñan prompts para engañar al LLM y hacer que revele información confidencial, ejecute acciones no deseadas o genere contenido inapropiado (Manor-Liechtman, s.f.).
- **Fuga de Datos:** Los LLMs, especialmente si son entrenados con datos sensibles, pueden "memorizar" y revelar inadvertidamente esta información en sus respuestas.
- **Envenenamiento de Modelos:** Si los datos de entrenamiento o fuentes RAG son comprometidos con datos maliciosos, el comportamiento del modelo puede corromperse (Pruralsight, s.f.).
- **Generación de Contenido Nocivo:** Los LLMs pueden generar desinformación, contenido sesgado o instrucciones perjudiciales sin controles adecuados.

Estos riesgos se magnifican en Open Finance, donde las APIs exponen funcionalidades a un ecosistema más amplio. El cumplimiento de regulaciones como PSD2/PSD3 (autenticación fuerte del cliente y consentimiento explícito), GDPR (reglas estrictas para procesamiento de datos personales), y el Reglamento (UE) 2024/1689 (AI Act) es crucial para el diseño y operación de APIs Inteligentes.

#### **Medidas de Seguridad y Cumplimiento:**

Los proveedores implementan diversas medidas de seguridad. OpenAI detalla políticas que restringen asesoramiento financiero no supervisado y decisiones de alto riesgo, ofreciendo cifrado y controles de retención de datos. Anthropic y Cohere enfatizan seguridad y opciones de despliegue que permiten mayor control sobre datos. Las plataformas cloud como AWS Bedrock, Azure OpenAI y Google Vertex AI proporcionan herramientas de seguridad heredadas de sus infraestructuras respectivas.

#### **Compliance by Design y AI Act:**

El cumplimiento del AI Act (vigente desde agosto 2024) exige que las APIs Inteligentes implementen "compliance by design" mediante exposición obligatoria de metadatos específicos: clasificación de riesgo según Anexo III, características del modelo GenAI subyacente, medidas anti-sesgo documentadas y grado de explicabilidad técnica

disponible. Para sistemas de credit scoring, requiere certificación CE previa a comercialización.

Esto implica que las APIs necesiten exponer metadatos describiendo características del modelo GenAI subyacente: nivel de riesgo según clasificación de la Ley de IA, tipo de datos de entrenamiento, medidas de mitigación de sesgos implementadas, y grado de explicabilidad ofrecible. Los TPPs y bancos que consuman estas APIs Inteligentes necesitarán esta información para evaluaciones de riesgo y cumplimiento de obligaciones regulatorias.

Esta necesidad podría impulsar la evolución de especificaciones API (Open Banking UK, Berlin Group) para incluir campos estandarizados relacionados con gobernanza de IA, fomentando el desarrollo de herramientas de "auditoría de IA para APIs" capaces de verificar afirmaciones de cumplimiento y seguridad de proveedores de APIs Inteligentes.

### ***3.3.5. Calidad y Disponibilidad de Datos Financieros para GenAI***

La máxima "basura entra, basura sale" es especialmente cierta para sistemas GenAI. Su efectividad, particularmente con técnicas como RAG o fine-tuning, depende intrínsecamente de la calidad, actualidad, relevancia y accesibilidad de los datos financieros. El sector financiero enfrenta desafíos particulares:

- **Silos de Datos:** Muchos bancos luchan con silos internos donde información del cliente y transaccional está fragmentada en múltiples sistemas heredados, dificultando la creación de vistas unificadas necesarias para entrenar modelos GenAI efectivos. La superación de estos silos representa frecuentemente el principal obstáculo práctico y puede exigir modernización fundamental de la infraestructura de datos subyacente.
- **Privacidad de Datos del Cliente:** Los datos financieros son extremadamente sensibles. Las restricciones de privacidad (GDPR) y la necesidad de consentimiento explícito limitan la cantidad y tipo de información disponible para entrenamiento de modelos, especialmente para proveedores externos de GenAI.
- **Actualidad de los Datos:** Los mercados financieros y circunstancias de clientes cambian rápidamente. Los modelos GenAI deben alimentarse con datos actualizados para generar observaciones relevantes, desafío para modelos preentrenados con "corte de conocimiento" en el pasado.
- **Escasez de Datasets Públicos:** Existe escasez relativa de datasets financieros públicos de alta calidad para entrenar modelos GenAI, debido a la naturaleza propietaria y sensible de la mayoría de datos financieros.

### **Datos Sintéticos como Mitigación:**

El uso de datos sintéticos se explora como mitigación. Estos datos generados artificialmente imitan propiedades estadísticas de datos reales sin contener información personal identificable, útiles para aumentar conjuntos de entrenamiento o probar modelos en escenarios raros. Sin embargo, la generación de datos sintéticos financieros de alta fidelidad presenta desafíos: dificultad para capturar correlaciones no lineales complejas, dinámica de eventos de cola ("cisnes negros") anómalos, pero de alto impacto, y cambios de régimen en mercados. Existe riesgo de que modelos GenAI aprendan artefactos del proceso de generación sintética, llevando a conclusiones erróneas cuando se enfrentan a datos reales.

### **Paradoja Open Banking-GenAI:**

Se presenta una paradoja interesante: Open Banking busca liberar datos financieros (con consentimiento) para fomentar innovación, permitiendo a TPPs acceder a información antes confinada en bancos. Contrariamente, la capacidad de GenAI para extraer valor profundo de grandes conjuntos de datos, especialmente mediante fine-tuning con datos propietarios, puede ser fuente crucial de ventaja competitiva. Los datos transaccionales y de comportamiento son activos valiosos para entrenar modelos de personalización, evaluación de riesgos, detección de fraude.

Esta dinámica podría generar tensión: los bancos podrían volverse reacios a compartir datos que, procesados por GenAI, podrían revelar estrategias competitivas o erosionar su ventaja diferencial. Esto podría llevar a APIs Inteligentes diseñadas para ofrecer insights derivados de GenAI sin exponer datos brutos o modelos subyacentes, convirtiéndose en "cajas negras inteligentes" que proporcionan resultados útiles, pero protegen la propiedad intelectual.

Esta emergencia plantea implicaciones significativas para la confianza del consumidor y capacidad de auditoría de TPPs. Si las APIs operan con razonamiento interno deliberadamente opaco, surge la pregunta: ¿Cómo verificar equidad, ausencia de manipulación o cumplimiento normativo sin transparencia en procesos de decisión? La opacidad podría erosionar la confianza del consumidor y dificultar la debida diligencia de TPPs, requiriendo equilibrio delicado entre protección de IP y necesidad de supervisión adecuada.

## Capítulo 4. Propuestas de Valor: Diseño Conceptual de APIs Inteligentes

Tres propuestas conceptuales de APIs Inteligentes materializan el potencial transformador de GenAI en contextos financieros específicos. Cada diseño aborda un caso de uso diferenciado: aceleración del desarrollo de integraciones, personalización financiera proactiva, y automatización de procesos de cumplimiento.

Estas propuestas no constituyen especificaciones de implementación, sino demostraciones conceptuales del valor estratégico y técnico que las APIs Inteligentes pueden aportar al ecosistema Open Finance, incluyendo análisis de viabilidad y consideraciones críticas para su adopción.

### ***4.1. API Asistente para Desarrolladores (Copilot de Integración de APIs Open Banking)***

#### ***4.1.1. Caso de Uso: Aceleración de la Integración TPP y Reducción de Errores***

La integración con APIs de Open Banking, aunque estandarizada parcialmente (Berlin Group Standard, UK Open Banking Standard, FDX en Norteamérica), mantiene complejidad considerable para desarrolladores de TPPs y bancos que consumen o exponen estas APIs. Esta complejidad radica en la necesidad de comprender especificaciones técnicas detalladas, implementar correctamente flujos de autenticación y autorización seguros (OAuth2 y FAPI), gestionar consentimiento del usuario según PSD2/3 y GDPR, manejar códigos de error variados y asegurar resiliencia de integración.

Una API "Copilot de Integración de APIs Open Banking" o "Copilot para Desarrolladores", impulsada por GenAI, abordaría estos desafíos actuando como experto virtual para equipos de desarrollo. Sus funcionalidades incluirían:

- **Comprensión de Especificaciones:** Interpretar y explicar en lenguaje natural la documentación técnica de APIs Open Banking, incluyendo matices de diferentes estándares o implementaciones específicas de cada banco.
- **Generación de Código:** Producir fragmentos de código para integración en diversos lenguajes (Python, Java, JavaScript), cubriendo tareas comunes como autenticación, llamadas a endpoints específicos (obtener saldos, iniciar pagos), y manejo de respuestas.

- **Configuración de Flujos de Seguridad:** Asistir en configuración correcta de flujos OAuth2, incluyendo gestión de tokens, manejo de scopes de consentimiento, e implementación de medidas de seguridad como PKCE.
- **Guía de Cumplimiento:** Proporcionar orientación sobre requisitos de manejo de errores, gestión del consentimiento del usuario según normativa aplicable, y mejores prácticas de seguridad.
- **Depuración y Resolución de Problemas:** Ayudar a diagnosticar problemas comunes de integración, sugiriendo posibles causas y soluciones basadas en mensajes de error o comportamiento observado.

Este asistente se inspira en el éxito de herramientas como GitHub Copilot (Tech, Vamsi Talks, s.f.) y la arquitectura de copilots (Microsoft Learn, s.f.) empresariales emergentes. Google Cloud también menciona el uso de IA para síntesis de documentos, aplicable a la vasta documentación de APIs.

### **Valor Estratégico:**

Un Copilot de Integración de APIs Open Banking no solo acelera significativamente los ciclos de desarrollo para TPPs, sino que también mejora la calidad y seguridad de las integraciones. Al guiar a desarrolladores a través de complejidades de estándares y flujos de seguridad, promoviendo mejores prácticas de codificación, este asistente inteligente reduce la probabilidad de errores comunes que podrían llevar a vulnerabilidades de seguridad, incumplimientos normativos o experiencias de usuario deficientes.

Desde la perspectiva de bancos que exponen APIs, esto se traduce en menor carga de soporte técnico para desarrolladores de TPPs y, crucialmente, en un ecosistema de integraciones más robusto y seguro, mitigando riesgos asociados a implementaciones defectuosas por terceros. Los bancos podrían incluso considerar ofrecer activamente estos copilots como parte de sus portales para desarrolladores, mejorando la experiencia de integración, fomentando la innovación en su plataforma y, en última instancia, reduciendo sus propios costes operativos y de riesgo (Machine, s.f.).

### ***4.1.2. Arquitectura de Alto Nivel***

La arquitectura de esta API Asistente para Desarrolladores se fundamenta en el patrón RAG (Cohere, 2025) para acceder a una base de conocimiento actualizada y específica de APIs de Open Banking, y en un modelo LLMAaaS (Google Cloud Blog, s.f.) para capacidades de generación de código y comprensión del lenguaje natural. El middleware de GenAI orquestaría las interacciones entre componentes y aplicaría políticas de uso,

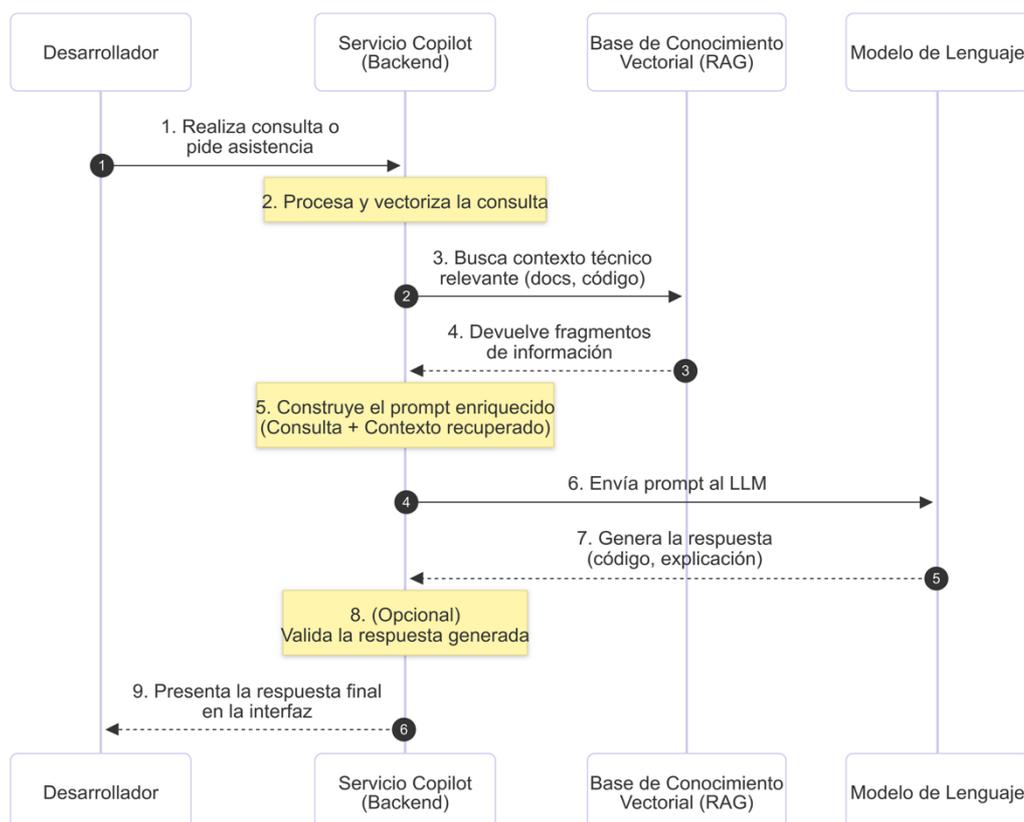
considerando las limitaciones de latencia o coste analizadas en el Capítulo 3 (Tech, Vamsi Talks, s.f.).

### **Componentes Principales:**

- **Interfaz de Usuario/API de Acceso:** Podría manifestarse como plugin para IDEs populares (VS Code, IntelliJ), aplicación web interactiva dentro del portal de desarrolladores del banco, o API REST/GraphQL que otras herramientas de desarrollo puedan consumir.
- **Orquestador de Copilot:** Componente central que recibe consultas del desarrollador (e.g., "Genera código en Python para obtener lista de cuentas de cliente usando API de BBVA bajo estándar Berlin Group, incluyendo manejo del token de acceso").
- **Módulo RAG Especializado:** Componente crucial que accede a una base de conocimiento vectorializada, construida utilizando técnicas de chunking y embedding (Cohere, 2025). Esta base contendría:
  - Especificaciones oficiales de estándares Open Banking (Open Banking UK, Berlin Group NextGenPSD2, FDX)
  - Documentación detallada de APIs específicas de bancos (guías para desarrolladores de BBVA, JPMorgan, NatWest)
  - Manuales de implementación, FAQs, discusiones de foros de desarrolladores y artículos técnicos
  - Ejemplos de código fuente que demuestren implementaciones seguras y conformes a estándares
  - Guías sobre requisitos regulatorios (PSD2/3, GDPR) aplicables a integración de APIs
  - Corpus curado de vulnerabilidades comunes en integraciones financieras y patrones de código seguro
- **Modelo de Lenguaje Grande (LLM):** LLM con fuertes capacidades de comprensión del lenguaje natural, razonamiento y generación de código en múltiples lenguajes. Este modelo utilizaría el contexto recuperado por el módulo RAG para generar explicaciones precisas, fragmentos de código funcionales o configuraciones de seguridad, pudiendo ser instruido para cruzar referencias con el corpus de vulnerabilidades.
- **Módulo de Validación de Salida (Opcional pero Recomendado):** Podría incluir herramientas básicas de análisis estático de código (linters) o validadores de esquemas (OpenAPI Schema validators) para verificar corrección sintáctica y conformidad básica del código generado antes de presentarlo al desarrollador.

### **Flujo de Interacción:**

1. El desarrollador realiza una consulta o solicita asistencia a través de la interfaz.
2. El Orquestador de Copilot procesa la consulta.
3. El Orquestador invoca al Módulo RAG, que convierte la consulta en un embedding y busca en la base de conocimiento vectorial los documentos, especificaciones y ejemplos de código más relevantes.
4. Los fragmentos de información recuperados se combinan con la consulta original para formar un prompt enriquecido.
5. Este prompt se envía al LLM.
6. El LLM procesa el prompt y genera la respuesta, que puede ser una explicación textual, un fragmento de código, una secuencia de pasos de configuración, o una combinación de estos.
7. La respuesta es opcionalmente validada por el Módulo de Validación.
8. La respuesta final se presenta al desarrollador a través de la interfaz.



La arquitectura RAG es fundamental aquí para asegurar que el LLM se base en la documentación técnica correcta y actualizada, minimizando el riesgo de generar código

obsoleto o incorrecto. Las arquitecturas generales de copilots proporcionan el marco conceptual para la interacción y la orquestación.

### ***4.1.3. Beneficios Clave y Entidades Beneficiadas***

#### **Beneficios Clave:**

- **Reducción drástica del tiempo de desarrollo:** Automatización de búsqueda de información y generación de código boilerplate, eliminando tareas repetitivas que consumen tiempo significativo.
- **Menor curva de aprendizaje:** Facilita la comprensión de estándares y APIs complejas de Open Banking, democratizando el acceso a desarrolladores con diferentes niveles de experiencia.
- **Mejora de la calidad y seguridad del código:** Promueve patrones de codificación seguros y conformes, ayudando a evitar errores comunes en implementación de flujos de autenticación y consentimiento.
- **Mayor consistencia en implementaciones:** Ayuda a que diferentes TPPs implementen APIs de manera más uniforme, reduciendo la fragmentación del ecosistema.
- **Reducción de la carga de soporte:** Los bancos que exponen APIs podrían experimentar disminución significativa en consultas de soporte de desarrolladores de TPPs.
- **Fomento de la innovación:** Al facilitar la integración, reduce la barrera de entrada para nuevos TPPs y la creación de nuevos servicios (84, s.f.).

El impacto de esta API podría medirse conceptualmente a través de métricas como reducción porcentual en tiempo de integración de TPPs, disminución en número de tickets de soporte de desarrolladores y mejora en puntuación de conformidad y seguridad de las integraciones.

#### **Entidades Beneficiadas:**

- **Desarrolladores de TPPs (Fintechs):** Principalmente beneficiados al aumentar su productividad y reducir la complejidad técnica, permitiéndoles enfocarse en la lógica de negocio diferenciadora.
- **Desarrolladores internos de bancos:** Que también necesitan integrar o construir sobre APIs de Open Banking, beneficiándose de la misma eficiencia y reducción de errores.
- **Bancos (Proveedores de APIs):** Experimentan menores costes de soporte, ecosistema de TPPs más saludable, integraciones más seguras y robustas, y potencialmente mayor adopción de sus APIs.

- **Reguladores (indirectamente):** Al mejorar la conformidad y seguridad de las integraciones, facilitando un ecosistema más estable y confiable.
- **Clientes Finales (indirectamente):** Al permitir que TPPs ofrezcan servicios innovadores de manera más rápida y segura, mejorando la disponibilidad y calidad de productos financieros.

Esta distribución de beneficios crea un ciclo virtuoso donde la mejora en la experiencia del desarrollador se traduce en un ecosistema más robusto y innovador para todos los participantes.

#### *4.1.4. Viabilidad, Consideraciones Específicas y Escenarios de Estrés*

**Viabilidad:** La viabilidad de esta API es alta. Las tecnologías subyacentes, como RAG y LLMs con capacidades de generación de código (modelos de la familia Codex de OpenAI, Gemini de Google, evaluados en la sección 3.1), ya existen y están madurando rápidamente (15, s.f.). El principal desafío no es tanto la tecnología GenAI en sí, sino la curación, estructuración y mantenimiento continuo de la base de conocimiento que alimentará al sistema RAG.

##### **Consideraciones Específicas:**

**Actualización Constante de la Base de Conocimiento:** Las especificaciones de APIs de Open Banking, implementaciones bancarias y mejores prácticas de seguridad están en constante evolución. Se requiere un proceso robusto y posiblemente automatizado para mantener actualizada la documentación, ejemplos de código, corpus de vulnerabilidades y embeddings en la base de conocimiento vectorial. Este esfuerzo no debe subestimarse y podría requerir un equipo dedicado especializado en curación de contenido técnico y gestión de sistemas RAG. Alternativamente, para proyectos con enfoque más abierto, se podrían explorar modelos de colaboración con la comunidad de desarrolladores, aunque esto plantearía desafíos de gobernanza y calidad. La sostenibilidad a largo plazo debe ser cuestionada y planificada explícitamente, considerando los costes de mantenimiento discutidos en la sección 3.3.2.

**Precisión y Fiabilidad del Código Generado:** Aunque los LLMs pueden generar código funcional, este siempre debe considerarse como "primer borrador" y debe ser minuciosamente revisado y probado por desarrolladores humanos, especialmente en lógica de negocio crítica y aspectos de seguridad. El Copilot debe educar a los usuarios sobre esta necesidad.

**Manejo de la Ambigüedad y la Variedad:** El sistema debe ser capaz de manejar la ambigüedad en consultas de desarrolladores y la variedad de estándares de Open Banking (UK Open Banking, Berlin Group, FDX) y lenguajes de programación.

**Seguridad del Propio Copilot:** Si el Copilot tiene acceso a información sensible (claves de API de sandbox del desarrollador para pruebas), debe ser diseñado con fuertes medidas de seguridad.

**Propiedad Intelectual:** Consideraciones sobre la propiedad del código generado y el uso de ejemplos de código de diversas fuentes.

#### **Escenarios de Estrés Hipotéticos:**

**Especificación de API Ambigua o Errónea:** ¿Cómo manejaría el sistema una especificación de API oficial que es ambigua, contradictoria o está mal redactada?

**Respuesta Conceptual:** El sistema RAG, a través de su "Módulo RAG Especializado", debería estar diseñado para recuperar múltiples fragmentos relevantes. El LLM, al procesar estos fragmentos, podría identificar inconsistencias o ambigüedades, presentando al desarrollador las posibles interpretaciones o señalando secciones problemáticas de la documentación. Podría sugerir enfoques conservadores o patrones comunes ante la ambigüedad y recomendar consulta directa con el proveedor de la API. No obstante, la calidad de la salida dependerá directamente de la calidad y claridad de la base de conocimiento ingerida.

**Código Generado con Vulnerabilidad Sutil:** ¿Qué salvaguardas existirían si el código generado contiene una vulnerabilidad sutil no detectada por validadores básicos?

**Respuesta Conceptual:** El sistema debería enfatizar explícitamente que el código generado es una ayuda y no una solución final de producción, recomendando revisiones de seguridad manuales y uso de herramientas de análisis de seguridad estático (SAST) y dinámico (DAST) más avanzadas. El "Módulo de Validación de Salida" podría integrarse con herramientas SAST básicas para una primera capa de detección. Adicionalmente, el "Módulo RAG Especializado", al incluir un corpus curado de vulnerabilidades comunes en APIs financieras y patrones de código seguro, permitiría al LLM ser instruido para cruzar referencias con este corpus durante la generación de código y advertir proactivamente sobre patrones de riesgo conocidos (54, s.f.). La implementación de este aprendizaje proactivo sobre vulnerabilidades presenta desafíos técnicos en cuanto a la curación y actualización constante del corpus de vulnerabilidades y la capacidad del LLM para aplicar este conocimiento de manera fiable sin generar excesivos falsos positivos.

## ***4.2. API con Análisis Predictivo para Personalización Financiera***

### ***4.2.1. Caso de Uso: Recomendaciones Proactivas de Productos y Asesoramiento Financiero Personalizado***

El Santo Grial de la banca moderna es la hiper-personalización (Surovtseva, 2025): ofrecer a cada cliente el producto adecuado, el consejo oportuno y la experiencia relevante en el momento preciso. Las APIs de Open Banking, a través de los Account Information Service Providers (AISPs), proporcionan acceso (con consentimiento explícito del cliente) a una rica fuente de datos transaccionales y de cuentas. Una API con Análisis Predictivo, potenciada por GenAI, podría consumir estos datos para ofrecer insights profundos y recomendaciones financieras proactivas y altamente personalizadas.

#### **Funcionalidades Clave:**

- **Predicción de Flujo de Caja y Alertas Tempranas:** Analizar patrones de ingresos y gastos para predecir futuras dificultades de flujo de caja, alertando al cliente y sugiriendo acciones correctivas (posponer gastos no esenciales, considerar crédito puente).
- **Optimización de Ahorros e Inversiones:** Basándose en objetivos financieros declarados, perfil de riesgo y patrones de gasto/ahorro, la API podría sugerir cuentas de ahorro con mayor rendimiento, contribución a planes de pensiones, o diversificación de inversiones hacia productos adecuados.
- **Recomendaciones Contextuales:** Identificar momentos de vida o necesidades financieras emergentes (compra de vivienda, nacimiento de hijo, planificación de viaje) y proponer productos relevantes (hipotecas, seguros, préstamos personales).
- **Asesoramiento sobre Gestión de Deuda:** Analizar deudas existentes del cliente y sugerir estrategias de consolidación o refinanciación para reducir costes o mejorar plazos.
- **Resúmenes Financieros Inteligentes:** Crear resúmenes periódicos del estado financiero, explicando tendencias, destacando logros y señalando áreas de mejora en lenguaje claro y motivador.

#### **Valor Diferencial: Narrativas Financieras Personalizadas**

Esta API no se limitaría a ofrecer simples recomendaciones de "siguiente mejor oferta". Su verdadero valor diferencial radicaría en la capacidad de generar "narrativas financieras" **personalizadas**. Utilizando las fortalezas de GenAI en generación de lenguaje natural, la API podría explicar el "porqué" detrás de cada recomendación de manera empática, educativa y comprensible.

Muchos consumidores encuentran la jerga financiera intimidante y no comprenden completamente las implicaciones de productos financieros tradicionales. Una API que pueda "contar una historia" sobre la situación financiera particular del cliente, cómo ciertas acciones pueden ayudarle a alcanzar sus metas específicas, y cuáles son los riesgos y beneficios asociados, sería mucho más efectiva para fomentar la educación financiera, la confianza y la toma de decisiones informadas. Esto trasciende la simple optimización de ventas para convertirse en un verdadero "asesor financiero virtual", accesible a través de la API e integrable en múltiples puntos de contacto (aplicación móvil del banco, plataformas PFM de terceros, asistentes de voz).

Empresas como Plaid y Envestnet (Plaid, s.f.) (Evestnet - Yodlee, s.f.) ya ofrecen APIs que proporcionan insights financieros a partir de datos agregados, pudiendo ser base para una capa GenAI más avanzada. Un desafío clave reside en la "última milla": asegurar que el cliente actúe de manera informada sobre esa información. Las aplicaciones que consuman esta API podrían considerar la integración ética de principios de economía del comportamiento (nudges) o elementos de gamificación para facilitar la adopción de hábitos financieros saludables, siempre con total transparencia y control por parte del usuario.

#### *4.2.2. Arquitectura de Alto Nivel*

La arquitectura de esta API de Personalización Financiera se apoya fuertemente en el patrón RAG (Cohere, 2025) para acceder y procesar datos transaccionales AISP y contextualizar las respuestas del LLM con información de productos financieros y conocimiento de mercado. La gestión centralizada de LLMs se realizaría a través de un esquema LLMAaaS, (Google Cloud Blog, s.f.) y la orquestación general, incluyendo gestión del consentimiento y aplicación de políticas de privacidad, sería manejada por un middleware de GenAI (Microsoft Learn, s.f.) que también integraría las herramientas de XAI (Grady, s.f.) necesarias. Es importante considerar que las limitaciones de estos patrones (latencia del middleware, coste de LLMAaaS) podrían impactar el rendimiento y coste de esta API.

#### **Componentes Principales:**

- **Conector Open Banking (AISP):** Módulo seguro y conforme para conectarse a las APIs AISP de los bancos del cliente (con consentimiento explícito y autenticación robusta) para obtener datos de cuentas, saldos y transacciones.
- **Módulo de Ingestión y Enriquecimiento de Datos:** Incluye ingestión y almacenamiento seguro de datos obtenidos; limpieza y estandarización para asegurar calidad y consistencia; categorización inteligente (Plaid, s.f.) usando

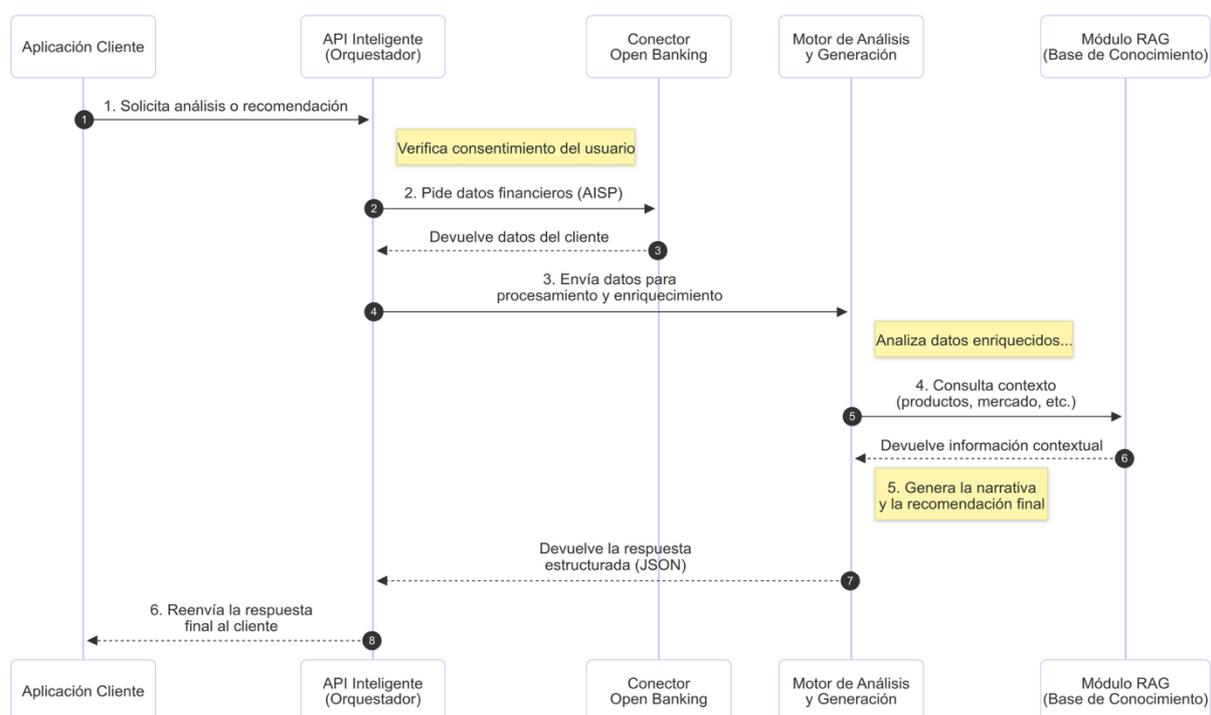
técnicas ML/GenAI (inspiradas en soluciones como Ntropy) para categorizar transacciones precisamente (alimentación, transporte, ocio, suministros); y generación de embeddings para crear representaciones vectoriales de datos financieros del cliente (perfiles de gasto, metas) facilitando el análisis por modelos predictivos.

- **Motor de Inferencia Predictiva y Personalización (GenAI/ML):** Contiene modelos predictivos (uno o varios LLMs o combinación con modelos ML tradicionales) entrenados para identificar patrones y tendencias en datos financieros del cliente, predecir necesidades futuras (probabilidad de necesitar préstamo, capacidad de ahorro futuro), y evaluar idoneidad de productos financieros para el perfil del cliente. Incluye módulo RAG para acceder a información contextual relevante: catálogo de productos y servicios financieros con características, términos y condiciones; información de mercado actualizada (tasas de interés, rendimiento de inversiones); perfiles de riesgo y políticas de idoneidad del banco; conocimiento financiero general y mejores prácticas.
- **Módulo de Generación de Recomendaciones y Narrativas:** El LLM seleccionado utiliza insights del motor predictivo e información del RAG para generar recomendaciones de productos o acciones específicas, y explicaciones claras y personalizadas (narrativas financieras) en lenguaje natural, adaptadas al nivel de conocimiento financiero del cliente.
- **Módulo de Gestión de Consentimiento y Preferencias del Usuario:** Interactúa con el API Endpoint para permitir que aplicaciones cliente (y usuarios a través de ellas) consulten y actualicen granularmente las preferencias sobre qué tipo de datos pueden usarse, para qué categorías de predicciones o recomendaciones, y con qué frecuencia o nivel de detalle desean recibir narrativas financieras o alertas. Facilita el cumplimiento de principios GDPR y el control efectivo del usuario.
- **API Endpoint (Interfaz de la API Inteligente):** Expone la funcionalidad para ser consumida por aplicaciones cliente (app bancaria, PFM de TPP). La API podría ofrecer diferentes endpoints para obtener insights, predicciones, recomendaciones completas con narrativas, y para gestionar consentimientos.

### **Flujo de Interacción:**

1. solicita un análisis o recomendación para el Cliente X a través de la API Inteligente.
2. La API invoca al Conector Open Banking para obtener los datos financieros actualizados del Cliente X (con el debido consentimiento y autenticación gestionados a través del Módulo de Gestión de Consentimiento).
3. Los datos son procesados por el Módulo de Enriquecimiento.

4. El Motor de Inferencia Predictiva analiza los datos enriquecidos, utilizando el Módulo RAG para obtener información sobre productos financieros disponibles, condiciones de mercado, etc., conforme a las preferencias del usuario.
5. El Módulo de Generación de Recomendaciones y Narrativas utiliza los outputs del motor predictivo para construir la recomendación y la explicación personalizada.
6. La respuesta (e.g., en formato JSON, conteniendo la recomendación, la narrativa, y posiblemente datos de soporte) se devuelve a través de la API a la aplicación solicitante.



La arquitectura RAG es esencial para asegurar que las recomendaciones se basen en información de productos precisa y actualizada, y que el LLM pueda justificar sus sugerencias. El uso de datos AISP es la base para la personalización (Evestnet - Yodlee, s.f.).

### 4.2.3. Beneficios Clave y Entidades Beneficiadas

#### Beneficios Clave:

- **Mejora de la salud financiera del cliente:** Proporciona herramientas y consejos para una mejor toma de decisiones, fomentando hábitos financieros saludables y planificación a largo plazo.

- **Mayor engagement y fidelización:** Ofrece valor proactivo y relevante, fortaleciendo la relación con la entidad financiera mediante experiencias personalizadas y anticipatorias.
- **Aumento de la venta cruzada y adopción de productos:** Las recomendaciones personalizadas y oportunas tienen mayor probabilidad de conversión al estar contextualizadas en las necesidades reales del cliente.
- **Democratización del asesoramiento financiero:** Pone a disposición de un público más amplio un nivel de asesoramiento que antes estaba reservado a clientes de banca privada, reduciendo la brecha de acceso a servicios financieros sofisticados.
- **Eficiencia para asesores humanos:** Puede servir como herramienta para que los asesores financieros humanos preparen recomendaciones y dediquen más tiempo a la relación con el cliente, optimizando su productividad.

El impacto de esta API podría medirse conceptualmente a través de métricas como incremento en la adopción de productos recomendados, mejora en indicadores de salud financiera de usuarios (ratio de ahorro, reducción de deuda), y aumento en satisfacción y retención de clientes.

#### **Entidades Beneficiadas:**

- **Clientes Finales:** Obtienen mayor control y comprensión de sus finanzas, acceso a asesoramiento personalizado y herramientas para mejorar su bienestar financiero.
- **Bancos y Entidades Financieras:** Mejoran la satisfacción del cliente, aumentan ingresos por ventas de productos, reducen el churn, y pueden optimizar costes de servicios de asesoramiento (4, 2025).
- **Fintechs de Gestión Financiera Personal (PFM):** Pueden consumir esta API para enriquecer sus aplicaciones y ofrecer valor diferencial a sus usuarios sin desarrollar capacidades de GenAI internamente.
- **Asesores Financieros Humanos:** Pueden utilizar los insights de la API para complementar su juicio y mejorar la eficiencia de su trabajo, enfocándose en aspectos relacionales de mayor valor.

Esta distribución de beneficios crea un ecosistema donde la tecnología potencia las capacidades humanas mientras democratiza el acceso a servicios financieros inteligentes, generando valor para todos los participantes del ecosistema Open Finance.

#### **4.2.4. Viabilidad, Consideraciones Éticas y Escenarios de Estrés**

**Viabilidad:** La viabilidad conceptual es alta, pero enfrenta desafíos significativos en implementación responsable. Ya existen APIs de agregación de datos y categorización de transacciones (Plaid, Yodlee, sección 3.1). El principal desafío reside en la capa predictiva y generación de narrativas con GenAI, asegurando calidad, imparcialidad y relevancia de recomendaciones financieras (85, s.f.).

Es crucial reiterar los límites actuales de la IA en "asesoramiento" financiero directo. La transición de una IA que "sugiere" a una que "asesora" de forma fiable es un salto considerable, con profundos desafíos éticos, regulatorios y de responsabilidad. Las políticas de OpenAI prohíben explícitamente el uso de sus modelos para asesoramiento financiero sin revisión profesional cualificada y divulgación del uso de IA (31, s.f.). El riesgo de que usuarios interpreten cualquier output como consejo validado es alto debido a la naturaleza persuasiva del lenguaje generado por LLMs.

#### **Consideraciones Éticas y de Privacidad:**

- **Privacidad de Datos:** El manejo de datos transaccionales extremadamente sensibles requiere cumplimiento estricto de GDPR, CCPA y mecanismos robustos de gestión del consentimiento facilitados por el "Módulo de Gestión de Consentimiento y Preferencias del Usuario".
- **Sesgos en Modelos:** Los LLMs pueden aprender y perpetuar sesgos de datos históricos, llevando a recomendaciones financieras injustas o discriminatorias (3, s.f.). Se necesita gobernanza robusta de modelos, auditorías de sesgos periódicas y técnicas de mitigación.
- **Calidad y Responsabilidad:** Las recomendaciones deben ser sólidas, adecuadas al perfil del cliente y en su mejor interés. Existe riesgo de "negligencia algorítmica" si la API proporciona consejos perjudiciales.
- **Explicabilidad y Transparencia:** Los clientes necesitarán entender por qué se hizo una recomendación específica (67, 2024). La API debe proporcionar justificaciones claras y comprensibles.
- **Control del Cliente:** Los clientes deben tener control sobre sus datos, tipo de recomendaciones deseadas, y capacidad de desactivar el servicio o revocar consentimiento.
- **Diseño de Interfaz:** Las aplicaciones deben presentar narrativas financieras con indicadores claros de que es una sugerencia generada por IA, comunicando nivel de confianza, base de la recomendación y vías para validación humana.

#### **Escenarios de Estrés Hipotéticos:**

**Datos Transaccionales Incompletos o Erróneos:** El "Módulo de Ingestión y Enriquecimiento de Datos" debería incorporar mecanismos robustos de validación y detección de anomalías. Ante datos significativamente incompletos o erróneos, la API

debería abstenerse de generar recomendaciones o advertir explícitamente sobre la baja fiabilidad. Para patrones sospechosos de fraude, debería priorizar alertas de seguridad en lugar de recomendaciones personalizadas.

**Sobreajuste a Datos Ruidosos:** El "Motor de Inferencia Predictiva" debería favorecer generalización y estabilidad, ponderando más las tendencias a largo plazo y objetivos financieros declarados. Las recomendaciones significativas deberían evitar reacciones automáticas a fluctuaciones recientes que contradicen patrones históricos consistentes. La supervisión humana para recomendaciones de mayor impacto sigue siendo esencial.

### **4.3. API de Cumplimiento y Auditoría Automatizada**

#### **4.3.1. Caso de Uso: Monitorización de Transacciones (AML), Generación de Informes Regulatorios (SARs), Auditoría de APIs**

El cumplimiento normativo es una de las áreas más costosas y complejas para las instituciones financieras. Una API de Cumplimiento y Auditoría Automatizada, impulsada por GenAI, podría ofrecer mejoras significativas en eficiencia y efectividad en varias áreas críticas:

**Monitorización Anti-Blanqueo de Capitales (AML) Mejorada:** Los (Google Cloud, s.f.) basados en reglas predefinidas generan alto volumen de falsos positivos y pasan por alto patrones sofisticados de blanqueo. GenAI puede analizar flujos de transacciones (obtenidos a través de APIs PISP/AISP o logs internos) y datos contextuales (perfiles de clientes, noticias adversas) para detectar patrones anómalos y comportamientos sospechosos que los sistemas basados en reglas no identifican. Incluye la capacidad de entender narrativas complejas y relaciones no obvias entre entidades.

**Generación Automatizada de Informes de Actividad Sospechosa (SARs):** Una vez identificada actividad potencialmente sospechosa, la API podría utilizar GenAI para generar automáticamente un borrador narrativo del SAR. Este borrador incluiría detalles relevantes de la transacción, cliente, motivos de sospecha y referencias normativas, listo para revisión, complemento y validación por un analista de cumplimiento humano antes de presentación a autoridades regulatorias. Esto podría reducir drásticamente el tiempo y esfuerzo manual dedicado a la redacción de SARs (Reuters, s.f.).

**Auditoría Continua de APIs:** En un ecosistema de Open Finance cada vez más interconectado, asegurar la integridad y uso adecuado de las APIs es crucial. Esta API Inteligente podría analizar continuamente los logs de uso de APIs (tanto expuestas por el banco como consumidas de terceros) para detectar anomalías, intentos de acceso no

autorizado, patrones de uso que indiquen posibles brechas de seguridad, o incumplimientos de políticas de acceso y SLAs.

**Automatización de Controles de Cumplimiento:** La API podría ayudar a automatizar la verificación de ciertos controles de cumplimiento (comprobaciones KYC/CDD periódicas, adherencia a límites de exposición) y generar documentación de evidencia necesaria para auditorías internas y externas. Soluciones RegTech ya están explorando el uso de GenAI para estos fines (A-Team insight, 2025).

### **Valor Estratégico:**

Esta API de Cumplimiento y Auditoría Automatizada podría evolucionar hasta convertirse en un "auditor de IA en tiempo real" para el ecosistema de Open Finance, yendo más allá de comprobaciones estáticas y retrospectivas para proporcionar supervisión inteligente y continua. La capacidad de GenAI para procesar grandes volúmenes de datos dispares (transacciones, logs, noticias, documentos regulatorios) y detectar patrones complejos que escapan a sistemas basados en reglas ofrece una oportunidad significativa.

En el contexto de Open Finance, donde el volumen y velocidad de transacciones e interacciones de datos se incrementan exponencialmente, la supervisión manual o mediante reglas simples se vuelve ineficaz. Una API que pueda monitorizar continuamente la actividad del ecosistema, generar alertas inteligentes sobre riesgos emergentes y automatizar parcialmente la generación de informes de cumplimiento sería invaluable para mantener la integridad y confianza en el sistema. Esto podría dar lugar a nuevos modelos de "RegTech-as-a-Service", donde esta funcionalidad es ofrecida por proveedores especializados, o convertirse en una capacidad central desarrollada por los propios bancos para auto-supervisarse y supervisar la actividad de TPPs conectados a sus sistemas.

### **4.3.2. Arquitectura de Alto Nivel**

La arquitectura de esta API de Cumplimiento y Auditoría Automatizada emplea intensivamente el patrón RAG (Cohere, 2025) para contextualizar el análisis de transacciones y logs con normativas actualizadas y políticas internas. Los LLMs, gestionados bajo un modelo LLMAaaS se encargan del análisis de patrones y generación de borradores de informes. Un middleware de GenAI es crucial para la orquestación de flujos de datos, integración con diversas fuentes y aplicación de políticas de seguridad a través de su funcionalidad de "Compliance Firewall". Las limitaciones de estos patrones (latencia, coste, complejidad de gobernanza del RAG) deben considerarse en su diseño e

implementación. La arquitectura es modular, integrando diferentes capacidades de GenAI y ML (18, s.f.).

### **Componentes Principales:**

**Colectores de Datos y Conectores API:** Proporcionan acceso a flujos de transacciones en tiempo real (desde sistemas core, APIs PISP/AISP), ingestión de logs de uso de APIs (desde API Gateways, servidores de aplicaciones), y conexión a fuentes de datos externas (listas de sanciones actualizadas, feeds de noticias adversas, bases de datos de perfiles de riesgo).

**Motor de Detección de Anomalías y Riesgos (GenAI/ML):** Incluye modelos de detección de patrones (LLMs o modelos ML especializados como redes neuronales, árboles de decisión) entrenados para identificar patrones anómalos en transacciones (indicativos de AML o fraude) o en uso de APIs (indicativos de abuso o brechas de seguridad). Debería diseñarse con capacidades de aprendizaje online o incremental para adaptarse rápidamente a nuevos patrones validados por humanos. Contiene un módulo RAG para contexto regulatorio y de políticas que permite al motor consultar en tiempo real normativas AML/CFT actualizadas, políticas internas de seguridad y cumplimiento del banco, y perfiles de riesgo de clientes y contrapartes. También incluye análisis de lenguaje natural (NLP) para procesar información no estructurada como narrativas de transacciones, artículos de noticias adversas, o descripciones en logs de API.

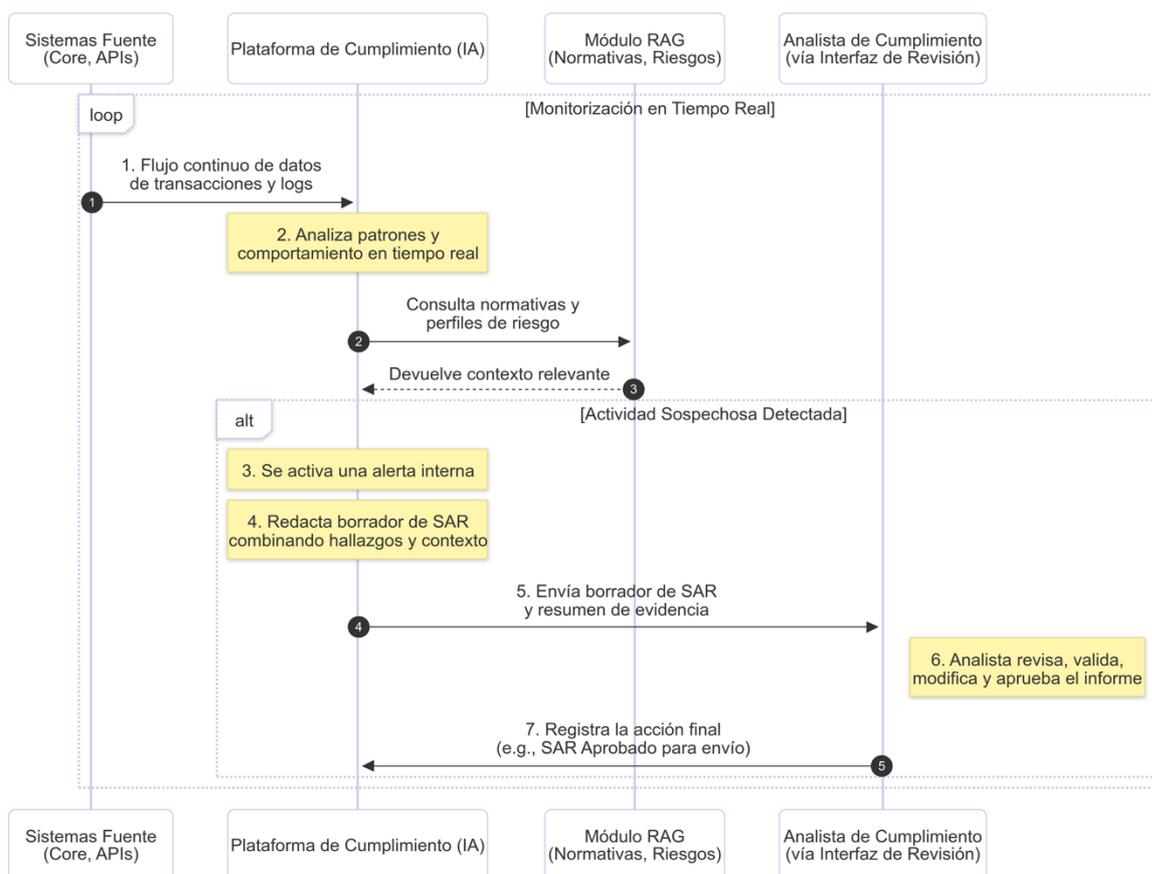
**Módulo de Generación de Informes y Alertas (GenAI):** Un LLM entrenado o afinado para redactar borradores de informes (SARs, informes de incidentes de seguridad, sumarios de auditoría). Este LLM toma los hallazgos del motor de detección (transacciones sospechosas, logs de API anómalos) y la información contextual del RAG (regulación específica que podría haberse infringido) para generar texto coherente, preciso y que cite evidencia relevante.

**Interfaz de Revisión y Validación Humana:** Portal o sistema de workflow donde analistas de cumplimiento, oficiales de seguridad o auditores pueden revisar borradores generados por la IA [93]. La IA proporciona al analista: resumen de evidencia que destaque los datos/transacciones/logs específicos que activaron la alerta; reglas o patrones (si son explícitos) o características contextuales que el sistema consideró más relevantes; y referencias directas a secciones de normativa o políticas internas aplicables recuperadas por el módulo RAG. Esto permite añadir juicio propio, solicitar más información y finalmente aprobar o modificar informes antes de su envío.

**API Endpoint (Interfaz de la API Inteligente):** Para recibir solicitudes de análisis ("monitorizar transacciones para el cliente Y", "auditar el uso de la API Z durante el último mes"), enviar alertas proactivas, o permitir que aplicaciones de workflow de cumplimiento recuperen borradores de informes.

### Flujo de Interacción (Ejemplo AML/SAR):

1. Los datos de transacciones fluyen continuamente hacia el Motor de Detección.
2. El Motor de Detección analiza las transacciones en tiempo real, utilizando el Módulo RAG para consultar normativas AML y perfiles de riesgo si es necesario.
3. Si se detecta una actividad o conjunto de transacciones que excede un umbral de sospecha, se activa una alerta.
4. El Módulo de Generación de Informes toma los detalles de la alerta y la información contextual relevante, y redacta un borrador de SAR.
5. El borrador del SAR se envía a la Interfaz de Revisión Humana, junto con el resumen de evidencia y referencias contextuales.
6. Un analista de cumplimiento revisa el borrador, lo valida, lo modifica si es necesario, y lo aprueba para su presentación.
7. La API puede registrar el estado final del SAR y la acción tomada.



Las arquitecturas de AML (Google Cloud, s.f.) con IA y los sistemas de generación de SARs proporcionan una base para este diseño (Reuters, s.f.). El uso de RAG para acceder a normativas es similar al patrón RAG para acceder a documentación de APIs, pero con un corpus documental diferente.

### ***4.3.3. Beneficios Clave y Entidades Beneficiadas***

#### **Beneficios Clave:**

- **Reducción de falsos positivos en monitorización AML:** GenAI puede entender mejor el contexto y reducir alertas irrelevantes que consumen tiempo de analistas.
- **Aceleración de investigación y presentación de SARs:** La generación automática de borradores puede reducir significativamente los plazos de procesamiento.
- **Mejora de calidad y consistencia de informes regulatorios:** Los LLMs aseguran que los informes sigan plantillas estándar y usen lenguaje preciso.
- **Detección proactiva de brechas de seguridad:** El análisis continuo de logs puede revelar problemas antes de que se conviertan en incidentes mayores.
- **Reducción de costes de cumplimiento:** A través de automatización de tareas manuales y optimización del tiempo de analistas [83].
- Mejora de capacidad de auditoría: Proporciona una traza más detallada y fácilmente analizable de las actividades.

El impacto podría medirse a través de métricas como reducción porcentual de falsos positivos en AML, disminución en tiempo promedio de redacción y validación de SARs, y aumento en cobertura y frecuencia de auditoría automatizada de APIs.

#### **Entidades Beneficiadas:**

- **Bancos e Instituciones Financieras:** Principalmente sus departamentos de cumplimiento, riesgo, seguridad y auditoría interna, experimentando mayor eficiencia operativa.
- **Reguladores y Unidades de Inteligencia Financiera (UIFs):** Podrían recibir SARs de mayor calidad y más consistentes, facilitando su propio análisis y supervisión.
- **Ecosistema Financiero en General:** Al mejorar la integridad y reducir el riesgo de delitos financieros y abusos, creando un entorno más seguro.
- **Audidores Externos:** Podrían utilizar los outputs de esta API para realizar auditorías de manera más eficiente y con mayor cobertura.

Esta distribución de beneficios fortalece la integridad del sistema financiero mientras optimiza los recursos dedicados al cumplimiento normativo.

#### *4.3.4. Viabilidad, Requisitos de Explicabilidad y Seguridad, y Escenarios de Estrés*

**Viabilidad:** La viabilidad es media a alta, con componentes de diferente madurez. La detección de anomalías y análisis de patrones con ML ya son prácticas comunes en AML y fraude. La generación de narrativas de SARs con GenAI es más novedosa pero tecnológicamente factible, como demuestran las pruebas de concepto (91, s.f.). El principal desafío radica en la fiabilidad, minimización de errores (falsos positivos y negativos) en contextos complejos y dinámicos, e integración fluida con procesos de revisión humana. Su efectividad dependerá críticamente de la calidad, granularidad y estandarización de los logs de entrada y datos transaccionales, lo cual puede requerir inversiones previas significativas en mejora de infraestructura de captura y gobernanza de datos.

#### **Consideraciones Críticas:**

- **Explicabilidad Absolutamente Crítica:** Los reguladores exigirán saber por qué el sistema consideró una actividad como sospechosa y cómo se generó un SAR. La "caja negra" no es una opción. Se necesitarán mecanismos robustos de XAI para trazar decisiones hasta datos y reglas subyacentes.
- **Seguridad y Confidencialidad:** Los datos de transacciones, perfiles de clientes, detalles de investigaciones e informes de auditoría son extremadamente sensibles. La API debe cumplir con los más altos estándares de seguridad de datos y control de acceso.
- **Adaptabilidad Regulatoria Continua:** El panorama de regulaciones financieras y tácticas de delincuentes financieros están en constante cambio. El sistema debe poder actualizarse fácil y rápidamente.
- **Supervisión Humana Indispensable:** Las decisiones críticas de cumplimiento siempre requerirán validación y juicio de un profesional humano. La API automatiza preparación y análisis preliminar, pero no reemplaza la responsabilidad final del experto.
- **Riesgo de "Sobre-confianza":** Existe riesgo de que analistas humanos se vuelvan demasiado dependientes de recomendaciones generadas por IA y reduzcan su escrutinio crítico. Se necesitan programas de formación y protocolos que aseguren colaboración efectiva humano-IA.

#### **Escenarios de Estrés Hipotéticos:**

- **Nuevo Tipo de Transacción Fraudulenta Desconocida:** El "Motor de Detección de Anomalías y Riesgos" debería incorporar, además de modelos supervisados basados en patrones conocidos, un componente de detección de anomalías no supervisado para identificar desviaciones significativas del comportamiento transaccional normal, incluso si no coinciden con firmas de fraude previamente catalogadas. Estas "anomalías desconocidas" tendrían alta prioridad para revisión humana por analistas expertos.
- **Ataque Coordinado con Volumen Masivo:** La arquitectura debe prever mecanismos de priorización y correlación de alertas. El Motor de Detección podría utilizar IA para identificar patrones de ataques coordinados y agregar alertas individuales en "incidentes" de mayor nivel. La "Interfaz de Revisión y Validación Humana" presentaría estos incidentes de forma priorizada, destacando magnitud y características comunes del ataque. El sistema podría tener umbrales para escalar automáticamente la notificación o activar protocolos de respuesta predefinidos si la magnitud supera ciertos parámetros, siempre bajo supervisión.

## Capítulo 5. Discusión Estratégica y Hoja de Ruta

La viabilidad técnica no garantiza el éxito comercial. Este capítulo adopta una perspectiva pragmática sobre las fuerzas del mercado, intereses contradictorios y barreras institucionales que determinarán qué APIs Inteligentes prosperarán en el ecosistema financiero real.

El análisis evalúa comparativamente las tres propuestas, examina su impacto en diferentes stakeholders, identifica obstáculos críticos para la adopción, y propone una hoja de ruta estratégica que reconoce las limitaciones presupuestarias y la aversión al riesgo característica del sector financiero.

### 5.1. Comparativa Estratégica de las Propuestas de APIs Inteligentes

Las tres APIs propuestas presentan perfiles de riesgo-recompensa marcadamente diferentes. Analicemos cada una bajo tres lentes críticos: impacto potencial, madurez tecnológica y factibilidad de adopción (Scalefocus, s.f.).

#### 5.1.1. Impacto Potencial en el Ecosistema Open Finance

El **API Asistente para Desarrolladores** ofrece un impacto alto con efecto multiplicador. Aunque se dirige a un nicho específico, acelerar las integraciones de TPPs y mejorar su calidad podría desbloquear innovación en todo el ecosistema. Un desarrollador más productivo significa servicios financieros más rápidos al mercado.

La **API de Personalización Financiera** presenta el impacto más alto. Transformar la relación cliente-banco de reactiva a proactiva mediante "narrativas financieras" personalizadas podría redefinir la lealtad del cliente y los modelos de negocio bancarios. Es la promesa central de Open Finance materializada.

La **API de Cumplimiento** tiene impacto alto pero menos visible. Automatizar AML, SARs y auditorías libera recursos significativos y reduce riesgos regulatorios. Su eficiencia podría, indirectamente, reducir costes para consumidores.

#### 5.1.2. Madurez Tecnológica y Complejidad de Implementación

El Copilot de Integración de APIs Open Banking goza de madurez tecnológica alta. RAG y LLMs para código están bastante desarrollados. Su complejidad es media, centrada en

curar y mantener una base de conocimiento actualizada y validar la seguridad del código generado.

La **API de Personalización** muestra madurez media. Aunque ML predictivo existe, generar narrativas empáticas y explicables es más reciente. Su complejidad es alta: maneja datos personales sensibles, requiere gobernanza robusta contra sesgos y debe cumplir estrictas regulaciones de asesoramiento.

La **API de Cumplimiento** tiene madurez media-alta para detección de anomalías, pero media para generación de informes. Su complejidad es muy alta: los errores tienen consecuencias severas, requiere fiabilidad extrema y explicabilidad robusta para reguladores.

### *5.1.3. Factibilidad de Adopción por el Mercado*

El **Copilot** presenta adopción potencialmente rápida. Con ROI claro en eficiencia de desarrollo y menor riesgo percibido, tanto TPPs como bancos podrían adoptarlo. Sin embargo, una mala primera experiencia podría generar escepticismo duradero.

La **API de Personalización** enfrenta adopción gradual. Aunque existe demanda de personalización, las preocupaciones sobre privacidad, ética y confianza en "asesoramiento IA" frenarán la adopción masiva inicial.

La **API de Cumplimiento** será impulsada por necesidad pero cautelosa. La presión regulatoria motiva, pero la aversión al riesgo en áreas críticas hará que la adopción sea medida, comenzando con tareas de bajo riesgo.

### **Conclusión Estratégica**

Paradójicamente, aunque la API de Personalización tiene mayor potencial transformador, el Copilot de Integración de APIs de Open Banking presenta el perfil de adopción más ágil. Su menor riesgo y ROI cuantificable lo convierten en el candidato ideal para ser el "caballo de Troya" que introduzca GenAI en las organizaciones financieras, generando confianza para casos de uso más complejos posteriormente.

**Tabla 5.1: Comparativa Estratégica de APIs Inteligentes**

| API                        | Impacto       | Madurez | Adopción | Stakeholders               | Barreras                              |
|----------------------------|---------------|---------|----------|----------------------------|---------------------------------------|
| Copilot<br>Desarrolladores | Alto<br>(4/5) | Alta    | Rápida   | Desarrolladores,<br>Bancos | Mantenimiento<br>base<br>conocimiento |

|                 |                |            |           |                           |                                       |
|-----------------|----------------|------------|-----------|---------------------------|---------------------------------------|
| Personalización | Muy Alto (5/5) | Media      | Gradual   | Cientes, Bancos, Fintechs | Privacidad, sesgos, explicabilidad    |
| Cumplimiento    | Alto (4/5)     | Media-Alta | Cautelosa | Bancos, Reguladores       | Fiabilidad extrema, validación humana |

## 5.2. Impacto en los Stakeholders del Ecosistema

La adopción de APIs Inteligentes impulsadas por GenAI representa más que una evolución tecnológica: redistribuye poder, oportunidades y riesgos entre todos los actores del ecosistema financiero.

### **Bancos: Transformación del Modelo de Negocio**

Los bancos enfrentan la mayor transformación. Las APIs Inteligentes les ofrecen tres vectores de valor:

El **Copilot de Integración de APIs Open Banking** reduce costes de soporte técnico y mejora la calidad del ecosistema TPP, creando integraciones más seguras que reducen riesgos indirectos. La **API de Personalización** habilita nuevos modelos de ingresos basados en insights premium y asesoramiento proactivo, pero incrementa la responsabilidad sobre la calidad del "asesoramiento" generado. La **API de Cumplimiento** optimiza masivamente procesos AML/SARs, liberando analistas para tareas de mayor valor y reduciendo riesgos regulatorios.

Numerosos bancos ya exploran GenAI: BBVA con ChatGPT (BBVA, s.f.) Enterprise, JPMorgan con COIN e IndexGPT, NatWest mejorando asistentes virtuales. McKinsey estima (Larry Lerner, 2025) que GenAI podría aportar entre \$200-340 mil millones anuales a la banca global.

### **TPPs: Democratización de la Inteligencia**

Para los TPPs, estas APIs representan acceso a capacidades que serían prohibitivamente costosas de desarrollar internamente. El Copilot acelera su time-to-market, la API de Personalización les permite ofrecer insights sofisticados sin inversión en GenAI compleja, y la API de Cumplimiento abre oportunidades RegTech para servir a instituciones más pequeñas.

### **Cientes Finales: Experiencias Transformadas**

Los clientes se benefician indirectamente del Copilot (servicios más rápidos al mercado), directamente de la Personalización (asesoramiento proactivo, narrativas financieras educativas), y de mayor seguridad gracias a mejores herramientas de detección de fraude.

## **Reguladores: Nuevos Desafíos y Oportunidades**

Los reguladores enfrentan dilemas complejos: ¿cómo supervisar algoritmos opacos? ¿Cómo asegurar explicabilidad y auditabilidad? ¿Cómo prevenir sesgos algorítmicos? ¿Cómo gestionar el riesgo sistémico por "concentración de inteligencia"?

### **El Riesgo de Concentración**

Surge una preocupación crítica: el desarrollo de modelos GenAI robustos es costoso y complejo. TPPs pequeños y bancos regionales podrían volverse dependientes de unas pocas APIs Inteligentes dominantes, creando un nuevo tipo de riesgo sistémico. Una falla en una API ampliamente utilizada podría tener efectos en cascada.

Las medidas de mitigación incluyen promover estándares abiertos, requisitos de interoperabilidad y supervisión específica de proveedores sistémicamente importantes. Los reguladores necesitarán monitorizar estas dinámicas de dependencia para asegurar la resiliencia del mercado.

## **5.3. Barreras para la Adopción y Estrategias de Mitigación**

A pesar del enorme potencial, la adopción generalizada de APIs Inteligentes en el sector financiero enfrenta una serie de barreras significativas (Scalefocus, s.f.). Identificar estas barreras y proponer estrategias prácticas para su mitigación es crucial para materializar la promesa de GenAI.

### **5.3.1. Costes de Inversión y ROI**

La implementación de GenAI en APIs financieras enfrenta una realidad incómoda: los costes iniciales son sustanciales y el ROI puede ser esquivo, especialmente en casos exploratorios.

#### **La Barrera del Coste**

Los costes abarcan tecnología (licencias, hardware especializado GPUs/TPUs), talento escaso (ingenieros de IA, científicos de datos) y transformación de procesos internos. Cuantificar el ROI resulta particularmente desafiante para beneficios indirectos o a largo plazo.

#### **Costes Específicos por API**

El **Copilot de Integración de APIs Open Banking** requiere inversión inicial alta en curación de bases de conocimiento RAG, mantenimiento continuo considerable, costes de inferencia LLM y talento MLOps especializado.

La **API de Personalización** demanda costes elevados en preparación de datos transaccionales (cumpliendo GDPR), desarrollo de modelos predictivos, infraestructura RAG, gobernanza robusta de modelos y gestión de consentimiento.

La **API de Cumplimiento** necesita inversión en estandarización de datos de alta calidad, modelos de detección de anomalías, curación de bases RAG normativas, generación de borradores SAR y interfaces de revisión humana.

### **Estrategias de Mitigación**

**Enfoque incremental:** Comenzar con pilotos de alto impacto y riesgo controlado, como el **Copilot de Integración de APIs Open Banking**, para demostrar valor rápidamente.

**FinOps para GenAI:** Implementar prácticas específicas de optimización de costes, incluyendo selección inteligente de modelos y optimización de prompts (FinOps, s.f.).

**Modelos colaborativos:** Explorar consorcios industriales para compartir costes de infraestructuras no competitivas, como bases de conocimiento regulatorias.

**Priorizar ROI tangible:** Enfocarse inicialmente en aplicaciones con retorno claro, como mejoras de productividad de desarrolladores o automatización de tareas repetitivas de cumplimiento.

### **5.3.2. Cumplimiento Normativo y Regulatorio (PSD2, PSD3, PSR, AI Act)**

La entrada en vigor del AI Act en agosto 2024 (Pareek, 2025) ha complicado significativamente el panorama regulatorio para APIs Inteligentes. Las instituciones deben navegar simultáneamente marcos normativos convergentes: PSD2 y su evolución hacia PSD3/PSR, GDPR, normativas AML/CFT y los nuevos requisitos del AI Act.

#### **La Complejidad Regulatoria Convergente**

PSD3 y PSR prometen requisitos más estrictos sobre funcionalidad y rendimiento de APIs, con posible eliminación de interfaces de contingencia y dashboards centralizados de permisos. Paralelamente, el AI Act exige arquitecturas de compliance (Lasso Security, s.f.) diferenciadas según clasificación de riesgo. Los sistemas de alto riesgo requieren marcado CE, documentación técnica detallada y registro en base de datos europea. Para sistemas de credit scoring, la certificación CE es obligatoria antes de comercialización.

Esta convergencia PSD3/PSR-AI Act es particularmente desafiante: mientras PSD3 busca APIs más robustas y dashboards inteligentes de gestión de permisos, el AI Act impone requisitos de transparencia y explicabilidad que pueden chocar con la eficiencia operativa.

El cronograma de plena aplicación del AI Act (agosto 2026) presiona los tiempos de implementación.

### **Estrategias de Mitigación**

**Cumplimiento por diseño:** Integrar consideraciones regulatorias desde el inicio. La API de Personalización debe incorporar gestión de consentimiento compatible con futuros dashboards PSD3 y narrativas con descargos claros para el AI Act. La API de Cumplimiento requiere un "Compliance Firewall" en el middleware y explicabilidad de alertas. El Copilot debe generar código que promueva prácticas conformes tanto a estándares PSD como a requisitos de IA.

**Colaboración proactiva:** Mantener diálogo abierto con reguladores europeos y participar en sandboxes regulatorios para probar APIs en entornos controlados, anticipando la transición PSD2-PSD3.

**Plataformas con gobernanza:** Priorizar herramientas GenAI que ofrezcan capacidades robustas de auditoría, explicabilidad y gestión de riesgos, preparadas para múltiples marcos normativos.

La convergencia regulatoria genera costes considerables, pero el enfoque de "cumplimiento por diseño" puede transformar esta barrera en ventaja competitiva.

### **5.3.3. Consideraciones Éticas y de Privacidad (sesgos, transparencia, control del cliente)**

GenAI introduce dilemas éticos complejos: los modelos pueden amplificar sesgos históricos, llevando a decisiones discriminatorias, mientras que la opacidad de los LLMs erosiona la confianza del cliente.

**Riesgos Específicos:** Los sesgos algorítmicos (BBVA, s.f.) son particularmente peligrosos en la API de Personalización (discriminación en recomendaciones financieras) y en la API de Cumplimiento (perfiles discriminatorios). Incluso el Copilot podría generar código sesgado.

### **Estrategias de Mitigación:**

**Marcos de IA responsable:** Implementar frameworks internos con métricas específicas de equidad y transparencia para las tres APIs.

**Detección activa de sesgos:** Utilizar técnicas algorítmicas para identificar sesgos, complementadas con equipos de desarrollo diversificados.

**Privacidad por diseño:** Incorporar minimización de datos, anonimización y técnicas como aprendizaje federado. La API de Personalización debe implementar pseudonimización y computación confidencial.

**Transparencia y explicabilidad:** Desarrollar capacidades XAI que generen explicaciones en lenguaje natural, especialmente críticas para las APIs de Personalización y Cumplimiento (Bhattacharya, 2024).

**Control granular del cliente:** Otorgar control detallado sobre uso de datos, tipos de recomendaciones y capacidad de revocación sencilla del consentimiento.

La ética no es obstáculo para la innovación, sino requisito para la sostenibilidad a largo plazo.

#### *5.3.4. Gestión del Talento y Cambio Organizacional*

La escasez global de talento especializado en GenAI con conocimiento financiero representa una barrera crítica, agravada por la resistencia interna al cambio en instituciones tradicionalmente conservadoras.

##### **Estrategias de Mitigación**

**Desarrollo interno:** Invertir en upskilling y reskilling específico por API. El Copilot necesita ingenieros especializados en RAG y curadores de contenido técnico. La API de Personalización requiere científicos de datos en ML predictivo y expertos en ética de IA. La API de Cumplimiento demanda talento que combine IA con conocimiento profundo de regulación financiera y AML.

**Contratación estratégica:** Identificar y atraer talento clave en áreas críticas de GenAI, complementado con cultura de experimentación controlada y liderazgo claro sobre el papel estratégico de la IA.

**Colaboración ecosistémica:** Establecer alianzas con universidades, startups de GenAI y consultoras especializadas.

##### **El Desafío de la "Fatiga de APIs"**

Una barrera subestimada es la creciente complejidad del ecosistema de APIs. La multiplicación de interfaces y la complejidad añadida por modelos de IA subyacentes pueden abrumar tanto a TPPs como bancos. Esto impulsa la demanda de "Agregadores de APIs Inteligentes", aunque estos podrían simplemente trasladar la complejidad a una nueva capa, convirtiéndose en nuevos puntos de dependencia que requieren cuidadosa gobernanza.

### ***5.3.5. Riesgos y Costes de la No Adopción o Adopción Lenta***

La inacción o adopción lenta de GenAI en APIs financieras conlleva riesgos estratégicos significativos que pueden ser más costosos que las barreras iniciales de implementación.

#### **Riesgos de la Inacción**

**Pérdida de competitividad:** Instituciones más ágiles que adopten APIs Inteligentes ofrecerán experiencias superiores, eficiencias operativas y productos más innovadores, dejando atrás a competidores lentos.

**Desconexión con expectativas del cliente:** Las nuevas generaciones digitalmente nativas esperan interacciones inteligentes y personalizadas. La no adopción puede resultar en pérdida masiva de clientes.

**Ineficiencias operativas persistentes:** Procesos manuales en cumplimiento, soporte a desarrolladores y atención al cliente seguirán siendo costosos y propensos a errores sin automatización inteligente.

**Dificultad para atraer talento:** Los profesionales con habilidades en IA buscarán organizaciones innovadoras. La reticencia tecnológica dificulta la atracción de talento crucial.

**Menor capacidad de gestión de riesgos:** Sin capacidades analíticas avanzadas de GenAI, las entidades serán más lentas detectando nuevos patrones de fraude o riesgos emergentes.

La parálisis por análisis puede ser más costosa que una adopción gradual y bien planificada.

### ***5.4. Hoja de Ruta Conceptual para la Adopción de APIs Inteligentes***

La transición hacia APIs Inteligentes requiere planificación estratégica y ejecución por fases. Esta hoja de ruta propone un camino lógico desde la exploración hasta la implementación a escala, reconociendo que en la empresa privada los pilotos raramente superan el año de duración.

#### **Fase 1: Fundacional y Experimentación Controlada (3-6 meses)**

**Objetivos:** Construir capacidades internas, fomentar cultura de IA e identificar casos de uso de alto impacto y bajo riesgo.

**Acciones clave:** Formación acelerada en fundamentos de GenAI, MLOps y ética; establecer marco inicial de IA responsable; evaluar plataformas GenAI y herramientas de middleware; iniciar piloto del Copilot de Integración de APIs Open Banking (menor riesgo, eficiencia interna); comenzar curación de base de conocimiento RAG y auditar fuentes de datos para futuras APIs.

### **Fase 2: Exploración Avanzada y Pilotos con Impacto Externo (6-9 meses)**

**Objetivos:** Expandir experimentación a casos de mayor complejidad, refinar gobernanza y medir valor concreto dentro del límite anual de pilotos empresariales.

**Acciones clave:** Pilotos controlados de API de Cumplimiento (asistencia en SARs, monitorización limitada); pilotos de API de Personalización en segmentos acotados (resúmenes financieros, alertas de flujo de caja); desarrollar middleware de GenAI (Microsoft Learn, s.f.) para orquestar servicios y gestionar "Compliance Firewall" (Lasso Security, s.f.); refinar marcos de IA responsable.

### **Fase 3: Escalado e Integración Profunda (9+ meses)**

**Objetivos:** Desplegar APIs exitosas a mayor escala e integrarlas profundamente en sistemas de negocio, transitando de pilotos a implementación productiva.

**Acciones clave:** Expandir uso de APIs exitosas; integrar con sistemas bancarios centrales; implementar monitorización robusta y MLOps avanzado; evolucionar continuamente la hoja de ruta según cambios tecnológicos y regulatorios.

Esta hoja de ruta es conceptual y debe adaptarse a la estrategia específica de cada entidad, respetando los límites temporales realistas de la empresa privada.

## **5.5. Tendencias Futuras en GenAI y APIs Financieras y Conexión con la Investigación**

La rápida evolución de GenAI continuará transformando las capacidades de las APIs Inteligentes. Esta investigación contribuye a responder cómo GenAI puede integrarse arquitectónicamente, sus desafíos inherentes y el valor que ofrece. Varias tendencias futuras son particularmente relevantes:

**Multimodalidad en LLMs:** Los modelos evolucionan para procesar texto, imágenes, audio y video simultáneamente. Esto habilitará APIs capaces de analizar documentos escaneados junto con datos transaccionales para Cumplimiento, o permitir interacciones

de voz contextuales para Personalización, incluyendo verificación de identidad multimodal (Ahsan Bilal, 2025).

**Agentes de IA Autónomos:** Surgirán "APIs de Agentes Financieros" que, con consentimiento del usuario, optimicen carteras automáticamente, negocien mejores condiciones de productos o gestionen suscripciones proactivamente. Esto intensifica desafíos éticos, de control y regulatorios.

**Avances en Explicabilidad (XAI):** Técnicas más robustas para interpretar modelos complejos son cruciales para APIs de Personalización y Cumplimiento. Podríamos ver "explicabilidad interactiva" donde usuarios dialoguen con la IA para entender recomendaciones o alertas (Ahsan Bilal, 2025).

**Aprendizaje Federado y Privacidad:** Permitirá a APIs de Personalización aprender de patrones de cohortes sin acceder a datos individuales, o colaboraciones entre bancos para entrenar modelos de detección de fraude de forma más segura.

**GenAI para Gobernanza de IA:** La API de Cumplimiento podría evolucionar para incluir módulos que auditen la equidad y robustez de otras APIs Inteligentes usando GenAI.

Estas tendencias sugieren APIs más integradas, contextuales y proactivas, pero cada avance requerirá cuidadosa consideración de implicaciones estratégicas, éticas y regulatorias. El desarrollo futuro debe basarse en patrones arquitectónicos sólidos (RAG, LLMaaS, Middleware) discutidos en este trabajo.

## Capítulo 6. Conclusiones y Líneas Futuras de Trabajo

Este TFM exploró la transformación de APIs tradicionales en "APIs Inteligentes" mediante GenAI en el ecosistema Open Banking/Finance. Este capítulo consolida los hallazgos sobre APIs Inteligentes, responde a las preguntas de investigación planteadas, identifica líneas futuras específicas para el desarrollo de APIs Inteligentes y ofrece recomendaciones estratégicas para su implementación exitosa.

### 6.1. Síntesis de Hallazgos sobre APIs Inteligentes

La investigación reveló el potencial disruptivo de GenAI para redefinir las APIs financieras, estructurado en temas transversales clave:

**Equilibrio entre Innovación y Gestión de Riesgos en APIs Inteligentes:** La integración de GenAI en APIs es técnicamente viable, pero requiere gestión proactiva de riesgos específicos como latencia, seguridad ante prompt injection, privacidad de datos y explicabilidad. Las APIs Inteligentes no pueden prosperar sin confianza y seguridad integradas desde el diseño.

**Gobernanza de Datos y Modelos como Habilitador de APIs Inteligentes:** La calidad de datos para entrenamiento y sistemas RAG determina la fiabilidad de las APIs Inteligentes. La gobernanza robusta de modelos GenAI -gestión de sesgos, monitorización continua, auditabilidad- es indispensable para el éxito de las APIs Inteligentes.

**Evolución Arquitectónica de APIs:** Las APIs Inteligentes trascienden el rol de conductos de datos para convertirse en orquestadores de inteligencia. El Middleware de GenAI emerge como capa esencial, actuando como "cortafuegos de cumplimiento" y centro neurálgico para la gestión de múltiples LLMs en APIs Inteligentes.

**Valor Diferencial de las APIs Inteligentes:** Las tres propuestas (Copilot de Integración de APIs Open Banking, Personalización Financiera, Cumplimiento Automatizado) demuestran cómo las APIs Inteligentes generan valor añadido significativo, desde optimizar integraciones hasta revolucionar la personalización financiera y transformar funciones de cumplimiento.

## **6.2. Respuesta a las Preguntas de Investigación sobre APIs Inteligentes**

**P1 - Integración Arquitectónica:** Las APIs Inteligentes superan limitaciones funcionales mediante patrones RAG, LLMaaS y Middleware de GenAI. Las propuestas demuestran aplicación práctica: el Copilot mejora interoperabilidad semántica, la API de Personalización analiza datos en tiempo real, y la API de Cumplimiento procesa patrones complejos.

**P2 - Arquitecturas Específicas:** La combinación RAG-LLMaaS-Middleware de GenAI constituye el enfoque arquitectónico más viable para APIs Inteligentes, proporcionando seguridad, eficiencia, escalabilidad y mantenibilidad específicas para el ecosistema financiero.

**P3 - Desafíos de APIs Inteligentes:** Las APIs Inteligentes enfrentan desafíos técnicos (latencia LLMs, costes, MLOps), operativos (monitorización, gobernanza), de seguridad (nuevos vectores de ataque), éticos (sesgos, transparencia) y regulatorios (AI Act, GDPR).

**P4 - Propuestas de Valor:** Las APIs Inteligentes ofrecen salto cualitativo: nuevos modelos de negocio para bancos, reducción de complejidad para TPPs, experiencias personalizadas para clientes, y oportunidades SupTech para reguladores.

## **6.3. Líneas Futuras Específicas para APIs Inteligentes**

### **Investigación Técnica para APIs Inteligentes:**

1. **XAI Avanzada para APIs Inteligentes:** Desarrollar "explicabilidad interactiva" donde usuarios dialoguen con APIs Inteligentes para entender decisiones, crucial para APIs de Personalización y Cumplimiento.
2. **SLMs Especializados para APIs Financieras:** Desarrollar modelos pequeños optimizados para la interpretación de jerga financiera específica y casos de uso particulares de APIs Inteligentes, reduciendo latencia y costes mientras mejorando la precisión en terminología sectorial.
3. **Estandarización de Metadatos para APIs Inteligentes:** Estandarización de Metadatos para APIs Inteligentes: Desarrollar esquemas estándar que vinculen explícitamente las APIs Inteligentes con marcos de gobernanza de IA, incluyendo metadatos sobre modelos subyacentes, sesgos conocidos, capacidades de explicabilidad y trazabilidad de decisiones algorítmicas.

### **Investigación Estratégica para APIs Inteligentes:**

4. **Nuevos Modelos de Monetización para APIs Inteligentes:** Investigar modelos basados en resultados o "Inteligencia como Servicio" específicos para APIs Inteligentes.
5. **Viabilidad del Middleware de GenAI:** Analizar si esta capa crítica para APIs Inteligentes debe ser capacidad interna, producto de nicho o servicio de plataforma.
6. **Impacto de APIs Inteligentes en la Estructura del Mercado:** Modelar cómo la concentración de inteligencia en APIs podría reconfigurar el poder de mercado financiero.

## ***6.4. Recomendaciones Específicas para APIs Inteligentes***

### **Para Instituciones Financieras implementando APIs Inteligentes:**

1. Adopción progresiva comenzando con el Copilot de Integración de APIs Open Banking (menor riesgo, ROI claro).
2. Priorizar gobernanza de IA y "cumplimiento por diseño" específico para APIs Inteligentes.
3. Invertir en Middleware de GenAI como capa crítica para orquestar APIs Inteligentes.

### **Para Desarrolladores de APIs Inteligentes:**

4. Diseñar para confianza integrando explicabilidad específica para contextos financieros.
5. Implementar seguridad adaptada a nuevos riesgos de GenAI en APIs.
6. Construir arquitecturas modulares que faciliten la evolución de APIs Inteligentes.

## **Conclusión Final**

Las APIs Inteligentes representan la próxima frontera en la evolución de Open Finance, transformando interfaces pasivas en orquestadores proactivos de inteligencia financiera. Su materialización exitosa requiere equilibrar innovación audaz con gestión rigurosa de riesgos, priorizando siempre la confianza, transparencia y responsabilidad que el sector financiero demanda. Las APIs Inteligentes no son solo una evolución tecnológica, sino una redefinición fundamental de cómo las instituciones financieras crean, entregan y monetizan valor en la era de la IA.

## Capítulo 7. Bibliografía

- Accenture. (2025). *Banking: The future is back | Trends shaping the industry in 2025 and beyond*. Obtenido de Accenture: <https://www.accenture.com/content/dam/accenture/final/industry/banking/document/Accenture-Banking-Top-10-Trends-2025-Report.pdf>
- Accenture. (s.f.). *AI: A Declaration of Autonomy*. Obtenido de Accenture: <https://www.accenture.com/content/dam/accenture/final/accenture-com/document-3/Accenture-Tech-Vision-2025.pdf>
- Accenture, U. F. (enero de 2025). *Generative AI in Action: Opportunities & Risk Management in Financial Services*. Obtenido de UK Finance: <https://www.ukfinance.org.uk/system/files/2025-01/Generative%20AI%20in%20action-opportunities%20&%20risk%20management%20in%20%20financial%20services.pdf>
- Ahmadreza Tavasoli, M. S. (abril de 2025). *Responsible Innovation: A strategic Framewrok for Financial LLM integration*. Obtenido de arXiv: <https://arxiv.org/html/2504.02165v1>
- Ahsan Bilal, D. E. (abril de 2025). *LLMs for Explainable AI: A comprehensive Survey*. Obtenido de arXiv: <https://arxiv.org/html/2504.00125v1>
- Akshar Prabhu Desai, T. R. (octubre de 2024). *Opportunities and challenges of Generative-AI in Finance*. Obtenido de arXiv: <https://arxiv.org/html/2410.15653v4>
- Amazon Web Services. (s.f.). *Amazon Bedrock FAQs*. Obtenido de AWS: <https://aws.amazon.com/bedrock/faqs/>
- Analyst Prep. (s.f.). *Generative Artificial Intelligence in Finance: Risk Considerations*. Obtenido de Analyst Prep: <https://analystprep.com/study-notes/frm/part-2/current-issues-in-financial-markets/generative-artificial-intelligence-in-finance-risk-considerations/>
- Apexon. (s.f.). *RegTech Solutions Simplify Compliance & Reduce Risk*. Obtenido de Apexon: <https://www.apexon.com/resources/fact-sheets/empowering-financial-institutions-with-regtech-solutions-for-confident-compliance/>
- A-Team insight. (2025). *7 AI-Powered RegTech Newcomers to Watch in 2025*. Obtenido de A-Team insight: <https://a-teaminsight.com/blog/7-ai-powered-regtech-newcomers-to-watch-in-2025/?brand=rti>

- AWS. (s.f.). *Build an Amazon Bedrock based digital lending solution on AWS*. Obtenido de AWS: <https://aws.amazon.com/blogs/machine-learning/build-an-amazon-bedrock-based-digital-lending-solution-on-aws/>
- AWS. (s.f.). *nCino Transforms Financial Services with Anthropic's Claude in Amazon Bedrock | AWS Case Study*. Obtenido de AWS: <https://aws.amazon.com/solutions/case-studies/ncino-video-case-study/>
- AWS Static. (s.f.). *6 key guidelines secure and reliable generative AI applications on Amazon Bedrock*. Obtenido de AWS Static: [https://d1.awsstatic.com/onedam/marketing-channels/website/aws/en\\_US/events/approved/documents/6-key-guidelines-for-building-secure-and-reliable-generative-ai-applications-on-amazon-bedrock.pdf](https://d1.awsstatic.com/onedam/marketing-channels/website/aws/en_US/events/approved/documents/6-key-guidelines-for-building-secure-and-reliable-generative-ai-applications-on-amazon-bedrock.pdf)
- BBVA. (s.f.). *BBVA creates a stress test in Spain to measure generative AI bias*. Obtenido de BBVA: <https://www.bbva.com/en/innovation/bbva-creates-a-stress-test-in-spanish-to-measure-generative-ai-bias/>
- Bhattacharya, D. P. (diciembre de 2024). *Explainable AI and Interpretability - Building Trust*. Obtenido de Infosys Consulting: [https://blogs.infosys.com/infosys-consulting/wp-content/uploads/2024/12/5853\\_EXPLAINABLE-AI-AND-INTERPRETABILITY-BUILDING-TRUST\\_WEB.pdf](https://blogs.infosys.com/infosys-consulting/wp-content/uploads/2024/12/5853_EXPLAINABLE-AI-AND-INTERPRETABILITY-BUILDING-TRUST_WEB.pdf)
- CloudOptimo. (s.f.). *Amazon Bedrock vs Azure OpenAI vs Google Vertex AI: An In-Depth Analysis*. Obtenido de CloudOptimo: <https://www.cloudoptimo.com/blog/amazon-bedrock-vs-azure-openai-vs-google-vertex-ai-an-in-depth-analysis/>
- Cohere. (2025). *Generative AI in Finance | Use Cases, Benefits & The Future*. Obtenido de Cohere: <https://cohere.com/blog/generative-ai-in-finance>
- Cohere. (2025). *What is RAG Architecture? A New Approach to LLMs*. Obtenido de Cohere: <https://cohere.com/blog/rag-architecture>
- Dao, T., Fu, D. Y., Ermon, S., Rudra, A., & Ré, C. (s.f.). *FlashAttention: Fast and Memory-Efficient Exact Attention with IO-Awareness*. 2025.
- DATA, NTT. (s.f.). *Future-Proofing Banking IT Systems with Generative AI and BIAN*. Obtenido de NTT DATA: <https://uk.nttdata.com/insights/blog/future-proofing-banking-it-systems-with-generative-ai-and-bian>
- Deepchecks. (s.f.). *How do response time and latency factor into LLM evaluation?* Obtenido de Deepchecks: <https://www.deepchecks.com/question/response-time-latency-llm-evaluation/>

Evestnet - Yodlee. (s.f.). *Financial API Platform*. Obtenido de Evestnet - Yodlee:  
<https://www.yodlee.com/financial-api>

*Explaible AI in finance*. (2025). Obtenido de The World Conference on Explainable Artificial Intelligence: <https://xaiworldconference.com/2025/explainable-ai-in-finance/>

FinOps. (s.f.). *Optimizing GenAI Usage: A FinOps Perspective on Cost, Performance, and Efficiency*. Obtenido de FinOps: <https://www.finops.org/wg/optimizing-genai-usage/>

Gaurav Kwatra, K. S. (abril de 2025). *Shaping The Future Of AI And Quantum in Financial Services*. Obtenido de Oliver Wyman: <https://www.oliverwyman.com/our-expertise/insights/2025/apr/ai-quantum-technology-transform-financial-services.html>

Google Cloud. (s.f.). *Architectural overview | Anti Money Laundering AI*. Obtenido de Google Cloud: <https://cloud.google.com/financial-services/anti-money-laundering/docs/concepts/architectural-overview>

Google Cloud Blog. (s.f.). *Improve your gen AI app velocity with Inference-as-a-Service*. Obtenido de Google Cloud Blog: <https://cloud.google.com/blog/products/ai-machine-learning/improve-your-gen-ai-app-velocity-with-inference-as-a-service>

Google Cloud. (s.f.). *Five Generative Ai use cases cases for the financial services industry*. Obtenido de Google Cloud: <https://cloud.google.com/blog/topics/financial-services/five-generative-ai-use-cases-financial-services-industry>

Google Cloud. (s.f.). *Generative AI and data governance | Generative AI on Vertex AI*. Obtenido de Google Cloud: <https://cloud.google.com/vertex-ai/generative-ai/docs/data-governance>

Google Cloud. (s.f.). *Google Cloud*. Obtenido de ROI on gen AI for financial services: a dozen-plus reasons it's happening now: <https://cloud.google.com/transform/financial-services-banking-insurance-gen-ai-roi-report-dozen-reasons-ai-value>

Google Cloud. (s.f.). *Try Anthropic's claude models on Google Cloud's Vertex AI*. Obtenido de Google Cloud: <https://cloud.google.com/products/model-garden/claude>

Grady, B. (s.f.). *Whast is Explainable AI? Benefits & best Practices q*. Obtenido de Qlik: <https://www.qlik.com/us/augmented-analytics/explainable-ai>

- Growth Acceleration Partners . (abril de 2025). *AI in Finance: Challenges and Use Cases*. Obtenido de Growth Acceleration Partners (GAP): <https://www.growthaccelerationpartners.com/blog/challenges-and-use-cases-of-generative-ai-in-finance>
- Ilyin, S. (s.f.). *AISP and PISP in Open Banking: UNDERstanding Their Roles*. Obtenido de Wallarm: <https://www.wallarm.com/what/aisp-and-pisp-roles-responsibilities-and-impact-on-open-banking>
- Iván Balsategui, S. G. (2024). *LA INTELIGENCIA ARTIFICIAL EN EL SISTEMA FINANCIERO: IMPLICACIONES Y AVANCES BAJO LA PERSPECTIVA DE UN BANCO CENTRAL*. Obtenido de Banco de España: [https://www.bde.es/f/webbe/GAP/Secciones/Publicaciones/InformesBoletinesRevistas/RevistaEstabilidadFinanciera/24/1\\_REF47\\_Artificial.pdf](https://www.bde.es/f/webbe/GAP/Secciones/Publicaciones/InformesBoletinesRevistas/RevistaEstabilidadFinanciera/24/1_REF47_Artificial.pdf)
- Ivan Iaroshev, R. P. (2024). *Evaluation Retrieval-Augmented Generation Models for Financial Report Question and Answering*. Obtenido de MDPI: <https://www.mdpi.com/2076-3417/14/20/9318>
- Joshi, S. (mayo de 2025). *A Comprehensive survey of AI Agent Frameworks and Their Applications in Financial Services*. Obtenido de Preprint.org: <https://www.preprints.org/manuscript/202505.0971/v1>
- Larry Lerner, V. C. (abril de 2025). *How banks can turn AI's promise into real impact*. Obtenido de McKinsey & Company: <https://www.mckinsey.com/industries/financial-services/our-insights/banking-matters/how-banks-can-turn-ais-promise-into-real-impact>
- Lasso Security. (s.f.). *Enterprise Security for GenAI in Financial Services | Real-World Risks*. Obtenido de Lasso Security: <https://www.lasso.security/resources/genai-in-financial-services--powerful-but-risky>
- Lucinity. (s.f.). *GenAI Agents are Transforming Compliance with Efficiency and Accuracy*. Obtenido de Lucinity: <https://lucinity.com/blog/genai-agents-transforming-kyc-workflows-and-strengthening-aml-compliance>
- Machine. (s.f.). *How to solve the Open Banking interoperability challenge*. Obtenido de Machine: <https://www.machine.news/the-planet-sized-problem-with-open-banking-and-how-to-solve-it/>
- Macro Global. (s.f.). *The GenAI revolution in Open Banking: A Closer Look*. Obtenido de Macro Global: <https://www.macroglobal.co.uk/blog/regulatory-technology/gen-ai-transforming-open-banking/>

- Manor-Liechtman, G. (s.f.). *Prompt Filtering with OpenAI: Using GPT for GPT Access Control*. Obtenido de Permit.io: <https://www.permit.io/blog/ai-prompt-classification-for-access-control>
- Master of Code Global. (s.f.). *Generative AI in Finance: Use Cases & Real Examples*. Obtenido de Master of Code Global: <https://masterofcode.com/blog/generative-ai-in-finance>
- Microsoft Learn. (s.f.). *Architecture of Copilot in finance and operations apps - Finance*. Obtenido de Microsoft Learn: <https://learn.microsoft.com/en-us/dynamics365/fin-ops-core/dev-itpro/copilot/copilot-architecture>
- Microsoft Learn. (s.f.). *GenAI gateway reference architecture using APIM*. Obtenido de Microsoft Learn: <https://learn.microsoft.com/en-us/ai/playbook/solutions/generative-ai/genai-gateway/reference-architectures/apim-based>
- Microsoft Learn. (s.f.). *Multi Agents Banking Assistant with Java and Langchain - Code Samples*. Obtenido de Microsoft Learn: <https://learn.microsoft.com/en-us/samples/azure-samples/agent-openai-java-banking-assistant/agent-openai-java-banking-assistant/>
- Microsoft Learn. (s.f.). *RAG and generative AI - Azure AI Search*. Obtenido de Microsoft Learn: <https://learn.microsoft.com/en-us/ai/playbook/solutions/generative-ai/genai-gateway/reference-architectures/apim-based>
- Milvus. (s.f.). *How does OpenAI handle privacy and data security?* Obtenido de Milvus: <https://milvus.io/ai-quick-reference/how-does-openai-handle-privacy-and-data-security>
- Miquido. (2025). *How Much Does Generative AI Cost? Estimating the Cost of GenAI App in 2025*. Obtenido de Miquido: <https://www.miquido.com/blog/how-much-does-generative-ai-cost/>
- Miquido. (s.f.). *Cost Analysis: Implementing generative AI in Your Organization*. Obtenido de Alphabold: <https://www.alphabold.com/cost-analysis-implementing-generative-ai-in-your-organization/>
- Nagarro. (s.f.). *Unlock Open Banking Success With API Assessment & Benchmarking*. Obtenido de Nagarro: <https://www.nagarro.com/en/blog/open-banking-success-with-api-assessment-benchmarking>
- NextGent Cloud. (s.f.). *How Companies are Using LLMs to Power Customer Risk Assessment*. Obtenido de NextGent Cloud:

<https://www.nexgencloud.com/blog/case-studies/how-companies-are-using-llms-to-power-customer-risk-assessment?hsLang=en>

OpenAI. (enero de 2025). *usage policies*. Obtenido de OpenAI: <https://openai.com/policies/usage-policies>

OpenAI. (s.f.). *Reasoning best practices*. Obtenido de OpenAI API: <https://platform.openai.com/docs/guides/reasoning-best-practices>

Pareek, A. (2025). *Striim Unveils Groundbreaking AI-Powered Data Governance with Real-Time Compliance on Google Cloud*. Obtenido de Striim: <https://www.striim.com/press/real-time-compliance-google-cloud/>

Philip Mavrepis, G. M. (2024). *XAI for ALL: Can Large Language Models Simplify Explainable AI?* Obtenido de ResearchGate: [https://www.researchgate.net/publication/390373276\\_XAI\\_for\\_All\\_Can\\_Large\\_Language\\_Models\\_Simplify\\_Explainable\\_AI](https://www.researchgate.net/publication/390373276_XAI_for_All_Can_Large_Language_Models_Simplify_Explainable_AI)

Plaid. (s.f.). *Personal Finance Insights | Data APIs*. Obtenido de Plaid: <https://plaid.com/insights-solution/>

Plaid. (s.f.). *Using ML to counter GenAI with new identity verification features*. Obtenido de Plaid: <https://plaid.com/blog/plaid-idv-enhancements-fight-fraud/>

Pruralsight. (s.f.). *Securing your RAG application: A comprehensive guide*. Obtenido de Pluralsight: <https://www.pluralsight.com/resources/blog/ai-and-data/how-to-secure-rag-applications-AI>

PYMNTS.com. (2025). *Three Macro Trends in GenAI for Financial Services*. Obtenido de PYMNTS.com: <https://www.pymnts.com/artificial-intelligence-2/2025/three-macro-trends-in-genai-for-financial-services/>

Ralston, J. (s.f.). *What Is Generative AI Security?* Obtenido de Palo Alto Networks: <https://www.paloaltonetworks.co.uk/cyberpedia/what-is-generative-ai-security>

Reco Security Experts. (febrero de 2025). *GenAI Security: Risks, Benefits and Best Practices*. Obtenido de Reco: <https://www.reco.ai/learn/genai-security>

Reuters, T. (s.f.). *Revolutionizing SARs filings and investigation efficiency through AI*. Obtenido de Thomson Reuters: <https://www.thomsonreuters.com/en-us/posts/investigation-fraud-and-risk/ai-revolution-sars-filings/>

Sarthak Pande, G. R. (2025). *Generative AI for Dynamic Financial Planning and Risk Profiling*. Obtenido de ResearchGate: [https://www.researchgate.net/publication/390336714\\_Generative\\_AI\\_for\\_Dyna](https://www.researchgate.net/publication/390336714_Generative_AI_for_Dyna)

mic\_Financial\_Planning\_and\_Risk\_Profiling\_1\_st\_Sandeep\_Chitalkar\_3\_rd\_Ga  
yatri\_Revanwar\_4\_th\_Aniket\_Yelmalwar\_5\_th\_Aarsha\_J\_Cherian

Scalefocus. (s.f.). *AI in the Banking Sector: Risks and Challenges*. Obtenido de Scalefocus: <https://www.scalefocus.com/blog/ai-in-the-banking-sector-risks-and-challenges>

Services, A. W. (s.f.). *Build a gen AI-powered financial assistant with Amazon Bedrock multi-agent collaboration*. Obtenido de AWS: <https://aws.amazon.com/blogs/machine-learning/build-a-gen-ai-powered-financial-assistant-with-amazon-bedrock-multi-agent-collaboration/>

Shijie Wu, O. I. (2023). *BloombergGPT: A Large Language Model for Finance*. Obtenido de arXiv: <https://arxiv.org/html/2303.17564v3>

Stripe. (s.f.). *What is open finance and how does it work?* Obtenido de Stripe: <https://stripe.com/resources/more/what-is-open-finance-here-is-what-you-need-to-know>

Surovtseva, A. (abril de 2025). *Generative AI in banking Promising use cases and potential hurdles*. Obtenido de ITRex Group: <https://itrexgroup.com/blog/generative-ai-in-banking/>

Tech, Vamsi Talks. (s.f.). *The Copilot Pattern: An Architectural Approach to AI-Assisted software*. Obtenido de Vamsi Talks Tech: <https://www.vamsitalkstech.com/ai/the-copilot-pattern-an-architectural-approach-to-ai-assisted-software/>

The Financial Brand. (enero de 2025). *Composing the future - Digital Banking trends 2025*. Obtenido de The Financial Brand: <https://static.thefinancialbrand.com/uploads/2025/01/ebankIT-Trends-and-Predictions-Report.pdf>

The Lasso Team. (2024). *RAG Security: Risks and Mitigation Strategies*. Obtenido de Lasso Security: <https://www.lasso.security/blog/rag-security>

## **ANEXO I**

### **APENDICE: GLOSARIO DE TERMINOS Y SIGLAS**

**AI Act:** Reglamento (UE) 2024/1689 sobre Inteligencia Artificial de la Unión Europea

**AISP:** Account Information Service Provider (Proveedor de Servicios de Información de Cuentas)

**AML:** Anti-Money Laundering (Prevención del Blanqueo de Capitales)

**ANN:** Approximate Nearest Neighbor (Vecino Más Cercano Aproximado)

**API:** Application Programming Interface (Interfaz de Programación de Aplicaciones)

**APIM:** API Management (Gestión de APIs)

**APIs Inteligentes:** Interfaces de programación que integran capacidades de IA Generativa para procesamiento contextual y personalizado

**BaaS:** Banking as a Service (Banca como Servicio)

**BIAN:** Banking Industry Architecture Network (Red de Arquitectura de la Industria Bancaria)

**Blue-Green Deployment:** Técnica de despliegue que utiliza dos entornos idénticos

**CCP:** California Consumer Privacy Act (Ley de Privacidad del Consumidor de California)

**CDD:** Customer Due Diligence (Diligencia Debida del Cliente)

**CE:** Conformité Européenne (Marcado de Conformidad Europea)

**CFT:** Combating the Financing of Terrorism (Lucha contra la Financiación del Terrorismo)

**Chunking:** Proceso de dividir documentos en fragmentos para procesamiento RAG

**CMEK:** Customer-Managed Encryption Keys (Claves de Cifrado Gestionadas por el Cliente)

**COIN:** Plataforma de análisis de contratos de JPMorgan

**Compliance Firewall:** Cortafuegos de cumplimiento para interacciones con LLMs

**Copilot:** Asistente de IA para desarrollo de software

**DAST:** Dynamic Application Security Testing (Pruebas Dinámicas de Seguridad de Aplicaciones)

**DLP:** Data Loss Prevention (Prevención de Pérdida de Datos)

**DPA:** Data Processing Agreement (Acuerdo de Procesamiento de Datos)

**EBA:** European Banking Authority (Autoridad Bancaria Europea)

**Embedding:** Representación vectorial de texto o datos

**Endpoint:** Punto final de una API donde se pueden realizar solicitudes

**FAIDA:** Framework de API Inteligente Dinámica y Auto-Adaptativa

**FAPI:** Financial-grade API (API de Grado Financiero)

**FDX:** Financial Data Exchange (Intercambio de Datos Financieros)

**FedRAMP:** Federal Risk and Authorization Management Program

**Feature Flags:** Técnica de desarrollo que permite activar/desactivar funcionalidades

**FinOps:** Financial Operations (Operaciones Financieras)

**FinPile:** Conjunto de datos financieros de Bloomberg

**GDPR:** General Data Protection Regulation (Reglamento General de Protección de Datos)

**GenAI:** Generative Artificial Intelligence (Inteligencia Artificial Generativa)

**GPU:** Graphics Processing Unit (Unidad de Procesamiento Gráfico)

**GraphQL:** Lenguaje de consulta y manipulación de datos para APIs

**HIPAA:** Health Insurance Portability and Accountability Act

**HTTP:** Hypertext Transfer Protocol (Protocolo de Transferencia de Hipertexto)

**IAM:** Identity and Access Management (Gestión de Identidades y Accesos)

**IBAN:** International Bank Account Number (Número de Cuenta Bancaria Internacional)

**IDE:** Integrated Development Environment (Entorno de Desarrollo Integrado)

**IFRS:** International Financial Reporting Standards (Normas Internacionales de Información Financiera)

**IndexGPT:** Modelo de IA de JPMorgan para análisis de inversiones

**IoT:** Internet of Things (Internet de las Cosas)

**ISO:** International Organization for Standardization (Organización Internacional de Normalización)

**KNN:** K-Nearest Neighbors (K-Vecinos Más Cercanos)

**KYC:** Know Your Customer (Conoce a tu Cliente)

**LangChain:** Framework para desarrollo de aplicaciones con LLMs

**LIME:** Local Interpretable Model-agnostic Explanations

**LLM:** Large Language Model (Modelo de Lenguaje Grande)

**LLMaaS:** LLM as a Service (LLM como Servicio)

**LlamaIndex:** Framework para construcción de aplicaciones RAG

**LoRA:** Low-Rank Adaptation (Adaptación de Rango Bajo)

**MAPE-K:** Monitor, Analyse, Plan, Execute, Knowledge (framework de sistemas adaptativos)

**ML:** Machine Learning (Aprendizaje Automático)

**MLOps:** Machine Learning Operations (Operaciones de Aprendizaje Automático)

**mTLS:** Mutual Transport Layer Security (Seguridad de Capa de Transporte Mutua)

**NextGenPSD2:** Estándar del Berlin Group para implementación de PSD2

**NLP:** Natural Language Processing (Procesamiento de Lenguaje Natural)

**NeMo:** Plataforma de NVIDIA para desarrollo de modelos conversacionales

**OAuth2:** Protocolo de autorización para APIs

**OpenID Connect:** Capa de identidad sobre OAuth 2.0

**OpenAPI:** Especificación para describir APIs REST

**PaLM:** Pathways Language Model de Google

**PAR:** Pushed Authorization Request (Solicitud de Autorización Empujada)

**PCI DSS:** Payment Card Industry Data Security Standard

**PFM:** Personal Financial Management (Gestión Financiera Personal)

**PII:** Personally Identifiable Information (Información Personal Identificable)

**PISP:** Payment Initiation Service Provider (Proveedor de Servicios de Iniciación de Pagos)

**PKCE:** Proof Key for Code Exchange (Clave de Prueba para Intercambio de Código)

**Prompt Chaining:** Técnica de encadenamiento de prompts para LLMs

**Prompt Injection:** Ataque de seguridad contra sistemas de IA generativa

**PSD2:** Payment Services Directive 2 (Directiva de Servicios de Pago 2)

**PSD3:** Payment Services Directive 3 (Directiva de Servicios de Pago 3)

**PSR:** Payment Services Regulation (Regulación de Servicios de Pago)

**RAG:** Retrieval-Augmented Generation (Generación Aumentada por Recuperación)

**RBAC:** Role-Based Access Control (Control de Acceso Basado en Roles)

**RegTech:** Regulatory Technology (Tecnología Regulatoria)

**REST:** Representational State Transfer (Transferencia de Estado Representacional)

**ROI:** Return on Investment (Retorno de la Inversión)

**SaaS:** Software as a Service (Software como Servicio)

**SAR:** Suspicious Activity Report (Informe de Actividad Sospechosa)

**SAST:** Static Application Security Testing (Pruebas Estáticas de Seguridad de Aplicaciones)

**SCA:** Strong Customer Authentication (Autenticación Reforzada del Cliente)

**SHAP:** SHapley Additive exPlanations (Explicaciones Aditivas de Shapley)

**SLA:** Service Level Agreement (Acuerdo de Nivel de Servicio)

**SLM:** Small Language Model (Modelo de Lenguaje Pequeño)

**SOC:** Service Organization Control (Control de Organización de Servicios)

**SupTech:** Supervisory Technology (Tecnología Supervisora)

**TCO:** Total Cost of Ownership (Costo Total de Propiedad)

**TPP:** Third Party Provider (Proveedor de Terceros)

**TPU:** Tensor Processing Unit (Unidad de Procesamiento Tensorial)

**TTFT:** Time to First Token (Tiempo hasta el Primer Token)

**TTLT:** Time to Last Token (Tiempo hasta el Último Token)

**UIF:** Unidad de Inteligencia Financiera

**VPC:** Virtual Private Cloud (Nube Privada Virtual)

**WebSocket:** Protocolo de comunicación bidireccional

**XAI:** Explainable Artificial Intelligence (Inteligencia Artificial Explicable)

**XML:** eXtensible Markup Language (Lenguaje de Mercado Extensible)

**XS2A:** Access to Account (Acceso a la Cuenta)

## **APENDICE: GLOSARIO DE INSTITUCIONES, BANCOS, CORPORACIONES, ORGANIZACIONES Y ENTIDADES**

**Amazon Web Services (AWS):** Proveedor global de servicios en la nube de Amazon, que ofrece plataformas como Amazon Bedrock para el desarrollo y despliegue de aplicaciones de IA generativa, incluyendo modelos LLM y herramientas de escalabilidad para entornos financieros.

**Anthropic:** Empresa de IA especializada en modelos de lenguaje grandes (LLM) como Claude, enfocada en seguridad y alineación ética; sus modelos se integran en plataformas cloud para aplicaciones financieras, con énfasis en razonamiento complejo y cumplimiento normativo.

**Azure OpenAI Service:** Servicio de Microsoft que proporciona acceso a modelos de OpenAI (como GPT-4) a través de la nube Azure, diseñado para aplicaciones empresariales con énfasis en integración con ecosistemas Microsoft y cumplimiento de normativas como GDPR.

**BBVA:** Banco Bilbao Vizcaya Argentaria, una institución financiera española que explora GenAI para mejorar servicios como asistentes virtuales y APIs de Open Banking, destacando en innovación fintech en Europa.

**Berlin Group:** Consorcio europeo de instituciones financieras que desarrolla estándares como NextGenPSD2 para la implementación de PSD2, promoviendo la interoperabilidad de APIs en Open Banking.

**Bloomberg:** Empresa global de tecnología financiera que proporciona datos, análisis y herramientas como BloombergGPT, un LLM especializado en finanzas entrenado con datos propietarios para tareas como análisis de sentimiento y procesamiento de información financiera.

**ChromaDB:** Base de datos vectorial de código abierto diseñada para almacenar y buscar embeddings en aplicaciones de IA, utilizada en arquitecturas RAG para gestión de conocimiento en contextos financieros.

**CloudOptimo:** Consultora especializada en optimización de nubes y análisis comparativos de plataformas de IA como Amazon Bedrock, Azure OpenAI y Google Vertex AI, enfocada en soluciones empresariales.

**Cohere:** Empresa de IA que desarrolla modelos LLM como Command, orientados a aplicaciones empresariales en finanzas, con énfasis en seguridad, soberanía de datos y despliegues privados.

**Deepchecks:** Plataforma para validación y monitorización de modelos de IA, utilizada para analizar latencia y rendimiento en aplicaciones de GenAI, incluyendo entornos financieros.

**Elasticsearch:** Motor de búsqueda y análisis distribuido de código abierto, con capacidades vectoriales para bases de datos en arquitecturas RAG, aplicado en gestión de conocimiento financiero.

**Investnet:** Proveedor de tecnología financiera que ofrece plataformas para gestión de riqueza y análisis de datos, integrando APIs para personalización en servicios financieros.

**European Banking Authority (EBA):** Autoridad reguladora europea que supervisa el cumplimiento de normativas como PSD2, PSD3 y PSR, enfocada en estándares de APIs y protección al consumidor en banca abierta.

**FAISS:** Biblioteca de Facebook AI para búsqueda de similitud eficiente en vectores, utilizada en sistemas RAG para recuperación de información en aplicaciones financieras.

**FDX (Financial Data Exchange):** Organización sin fines de lucro en Norteamérica que desarrolla estándares para el intercambio seguro de datos financieros, similar a Berlin Group en Europa.

**GitHub:** Plataforma de desarrollo colaborativo propiedad de Microsoft, conocida por herramientas como GitHub Copilot, un asistente de IA para generación de código, aplicado en contextos de integración de APIs.

**Google Cloud (Vertex AI):** Plataforma de IA de Google que ofrece modelos como Gemini y herramientas para MLOps, con énfasis en escalabilidad y cumplimiento normativo para aplicaciones financieras.

**IG Group:** Empresa británica de trading en línea que utiliza modelos como Claude de Anthropic para razonamiento financiero complejo y mejora de productividad en operaciones.

**JPMorgan:** Banco de inversión estadounidense que desarrolla herramientas de IA como COIN (para análisis de contratos) e IndexGPT (para inversiones), pionero en aplicaciones de GenAI en finanzas.

**LangChain:** Framework de código abierto para construir aplicaciones con LLM, utilizado en orquestación de flujos RAG y middleware de GenAI en entornos financieros.

**LlamaIndex:** Framework para indexación y recuperación de datos en aplicaciones RAG, aplicado en la construcción de bases de conocimiento para APIs inteligentes.

**Metro Credit Union:** Cooperativa de crédito estadounidense que utiliza GenAI para procesar préstamos, reduciendo tiempos y tasas de rechazo mediante análisis automatizado.

**Microsoft:** Corporación tecnológica que ofrece Azure OpenAI y herramientas como API Management (APIM) para gobernanza de APIs, integrando GenAI en ecosistemas empresariales.

**Milvus:** Base de datos vectorial de código abierto para gestión de embeddings a gran escala, utilizada en sistemas RAG para aplicaciones financieras de alto volumen.

**Morgan Stanley:** Banco de inversión global que implementa GenAI para personalización avanzada y recomendaciones financieras basadas en datos de Open Banking.

**NatWest:** Banco británico que utiliza GenAI para mejorar asistentes virtuales y servicios de Open Banking, enfocándose en experiencias de cliente personalizadas.

**nCino:** Proveedor de software bancario basado en la nube que integra modelos como Claude para automatizar procesos como la creación de memorandos de crédito.

**Nexgencloud:** Empresa de tecnología que analiza latencia en inferencia de IA, proporcionando insights para optimizar rendimiento en aplicaciones financieras.

**NVIDIA:** Empresa de tecnología que desarrolla hardware (GPUs/TPUs) y plataformas como NeMo para modelos conversacionales, esencial para entrenamiento e inferencia de LLM en finanzas.

**Ntropy:** Startup fintech que ofrece categorización inteligente de transacciones mediante ML, integrada en APIs de personalización financiera.

**Open Banking UK:** Iniciativa regulatoria del Reino Unido que establece estándares para APIs de banca abierta, promoviendo la competencia y la innovación.

**OpenAI:** Organización de investigación en IA que desarrolla modelos como GPT-4, con aplicaciones en finanzas pero con restricciones éticas para usos como asesoramiento financiero.

**Pinecone:** Proveedor de bases de datos vectoriales gestionadas para aplicaciones de IA, utilizada en arquitecturas RAG para recuperación de información financiera.

**Plaid:** Plataforma fintech estadounidense que ofrece APIs para agregación de datos financieros y conexión segura con bancos, facilitando Open Banking.

**TrueLayer:** Proveedor europeo de APIs de Open Banking que habilita pagos y acceso a datos, con énfasis en interoperabilidad y cumplimiento de PSD2.

**Weaviate:** Base de datos vectorial de código abierto con capacidades de IA, utilizada para gestión de conocimiento en sistemas RAG financieros.

**Yodlee:** Proveedor de agregación de datos financieros que ofrece APIs para categorización de transacciones y análisis, integrado en soluciones de personalización.