

PROYECTO FINAL DE INGENIERÍA

PROMOAI: SISTEMA DE ANÁLISIS PREDICTIVO PARA LA PERSONALIZACIÓN DE PROMOCIONES BASADAS EN CONSUMOS ELECTRÓNICOS.

Nastasi, Ariel Maximiliano – LU 1106858

Ingeniería en Informática

Piersanti, Lucas Gabriel – LU 1105140

Ingeniería en Informática

Tutor:

Remondegui, Daniel Alejandro, Universidad Argentina de la Empresa

2025



**UNIVERSIDAD ARGENTINA DE LA EMPRESA
FACULTAD DE INGENIERÍA Y CIENCIAS EXACTAS**

Agradecimientos

En primer lugar, deseamos expresar nuestro sincero agradecimiento a nuestras familias por su apoyo incondicional, comprensión y aliento durante todo el proceso de desarrollo de este proyecto. Su respaldo fue fundamental para alcanzar este logro académico.

Asimismo, agradecemos al Ing. Daniel Alejandro Remondegui por su invaluable guía y dedicación como tutor de esta tesis. Su experiencia y aportes han enriquecido significativamente la calidad y el enfoque de este trabajo.

Finalmente, extendemos nuestro agradecimiento a la Facultad de Ingeniería de la Universidad Argentina de la Empresa (UADE), así como a todo su cuerpo docente, por la formación académica recibida a lo largo de la carrera y por los recursos brindados para la realización de este proyecto.

Resumen

El ecosistema financiero argentino genera volúmenes masivos de datos transaccionales que, en gran medida, permanecen subutilizados por las empresas procesadoras de pagos. Esta situación representa una oportunidad significativa para el desarrollo de soluciones analíticas avanzadas que permitan transformar dichos datos en conocimiento accionable para la toma de decisiones comerciales.

Ante esta problemática, el presente trabajo propone el diseño e implementación de PromoAI, un sistema de análisis predictivo que emplea técnicas de aprendizaje automático para modelar el comportamiento de consumo de usuarios de tarjetas de crédito. La solución desarrollada se compone de un pipeline integral que abarca desde la ingesta y preprocesamiento de datos históricos anonimizados hasta la generación de predicciones de gasto futuro y la segmentación estratégica de clientes mediante la metodología RFM.

El sistema está dirigido principalmente a empresas procesadoras de pagos, como Prisma Medios de Pago, actuando como una herramienta de Business Intelligence que les permite ofrecer a los bancos emisores recomendaciones basadas en datos para la personalización de promociones. La validación del modelo predictivo confirma su robustez y capacidad para generalizar nuevos datos, mientras que el diseño de la arquitectura garantiza el cumplimiento de la normativa local en materia de protección de datos personales.

Abstract

The Argentine financial ecosystem generates massive volumes of transactional data that remain largely underutilized by payment processing companies. This situation represents a significant opportunity for developing advanced analytical solutions that can transform this data into actionable knowledge for commercial decision-making.

To address this problem, this work proposes the design and implementation of PromoAI, a predictive analysis system that uses machine learning techniques to model the consumption behavior of credit card users. The developed solution comprises an integral pipeline ranging from the ingestion and preprocessing of anonymized historical data to the generation of future spending predictions and strategic customer segmentation using the RFM methodology.

The system primarily targets payment processing companies, such as Prisma Medios de Pago, acting as a Business Intelligence tool that enables them to offer data-driven promotion personalization recommendations to issuing banks. The validation of the predictive model confirms its robustness and ability to generalize to new data, while the architecture design ensures compliance with local regulations regarding personal data protection.

1	Introducción	9
1.1	Objetivos	9
1.2	Alcance	10
1.3	Descripción	11
2	Antecedentes	14
2.1	Marco Teórico	14
2.1.1	Introducción	14
2.1.2	Aprendizaje Automático y Predicción de Comportamiento	15
2.1.3	Segmentación de Usuarios y Comportamiento del Consumidor	16
2.1.4	Privacidad, Ética y Protección de Datos	18
2.1.5	Transformación Digital en el Sector Financiero	19
2.1.6	Sistemas de recomendación y promociones personalizadas	20
2.1.7	Conclusión del marco teórico	21
2.2	Estado del Arte	22
2.2.1	Análisis de la Competencia	23
2.2.1.1	Competencia directa: procesadoras de pagos en Argentina	23
2.2.1.2	Competencia indirecta: fintechs y bancos digitales	24
2.2.1.3	Competencia de referencia: plataformas globales	25
2.2.1.4	Conclusión del análisis de la competencia	25
2.2.2	Curva de valor	26
2.2.3	Limitaciones de las soluciones actuales	28
2.2.4	Aporte diferencial del proyecto	29
3	Descripción	32
3.1	User Research	32
3.1.1	Encuestas a usuarios finales	32
3.1.1.1	Metodología	33
3.1.1.2	Perfil de encuestados	33
3.1.1.3	Hábitos de consumo	33
3.1.1.4	Percepción sobre promociones	34
3.1.1.5	Interés en soluciones predictivas	34
3.1.1.6	Conclusiones de encuestas	34
3.1.2	Entrevista	34

3.1.2.1	Puntos clave de la entrevista	35
3.1.2.2	Conclusiones de la entrevista	36
3.2	Solución	37
3.2.1	Requerimientos y diseño	38
3.2.1.1	Requerimientos Funcionales	38
3.2.1.2	Requerimientos no funcionales	39
3.2.2	Casos de uso	39
3.2.2.1	Caso de uso 1	39
3.2.2.2	Caso de uso 2	40
3.2.2.3	Caso de uso 3	40
3.2.2.4	Caso de uso 4	41
3.2.2.5	Caso de uso 5	41
3.2.2.6	Caso de uso 6	42
3.2.2.7	Caso de uso 7	42
3.2.2.8	Caso de uso 8	42
3.2.3	Arquitectura y Diagramas Funcionales	43
3.2.3.1	Secuencia: Carga del dashboard	43
3.2.3.2	Secuencia: Predicción individual de cliente	45
3.2.3.3	Secuencia: Inteligencia de campañas	46
3.2.3.4	Secuencia: Análisis de segmentos	47
3.2.4	Interface Gráfica	48
3.2.4.1	Dashboard	48
3.2.4.2	Predicciones	49
3.2.4.3	Segmentos	50
3.2.4.4	Campañas	51
3.2.5	Arquitectura y modelo de datos	52
3.2.5.1	Arquitectura de la solución	53
3.2.5.2	Modelo de datos	54
3.2.5.3	Análisis de la estructura	55
3.2.5.4	Diagrama de arquitectura	56
3.2.6	Desarrollo y Entrenamiento del Modelo	58
3.2.6.1	Tecnologías Utilizadas	58

3.2.6.2	Recolección y Preparación de Datos	59
3.2.6.3	Entrenamiento y Validación del Modelo	59
3.2.6.4	Salidas del modelo	61
3.3	Producto	62
3.3.1	Branding	62
3.3.2	Logo	63
3.3.3	Misión	64
3.3.4	Visión	64
3.4	Marco legal	64
3.4.1	Ley 25.326 de Protección de Datos Personales	65
3.4.2	Regulación del BCRA y el Régimen de Secreto Financiero	66
3.4.3	Conclusión Legal	67
3.4.4	Marco normativo y medidas adoptadas por PromoAI	67
3.5	Análisis económico	67
3.5.1	Modelo de negocio	68
3.5.2	Análisis financiero	68
3.5.2.1	Valor Actual Neto (VAN)	71
3.5.2.2	TIR	71
3.5.2.3	Payback	72
3.5.2.4	Conclusión	72
4	Metodología de desarrollo	73
4.1	Kanban	73
5	Pruebas realizadas	75
5.1	Pruebas unitarias	75
5.2	Pruebas funcionales	76
5.3	Pruebas de integración	77
6	Discusión	79
6.1	Selección del algoritmo de machine learning	79
6.2	Estrategia de ajuste por inflación	79
6.3	Definición de segmentos RFM	80
6.4	Estrategia de gestión de datos anonimizados	80
7	Conclusiones	82

8	Bibliografía	84
	Anexo A: Encuesta a usuario final	90
	Anexo B: Transcripción de entrevista	94
	Anexo C: Cronograma de actividades	98

1 Introducción

El presente proyecto surge como respuesta a la necesidad de aprovechar el potencial de los datos transaccionales en el ecosistema financiero argentino, mediante la aplicación de técnicas de aprendizaje automático orientadas al análisis predictivo del comportamiento de consumo. En un contexto marcado por la digitalización acelerada de los medios de pago y el crecimiento sostenido del comercio electrónico, las empresas procesadoras de pagos enfrentan el desafío de transformar grandes volúmenes de información en conocimiento estratégico que permita anticipar tendencias y optimizar la toma de decisiones comerciales.

En este marco, se propone el desarrollo de un sistema de análisis predictivo capaz de modelar patrones de gasto a partir de transacciones con tarjeta de crédito y de generar segmentaciones precisas que faciliten la creación de promociones personalizadas. La iniciativa combina el uso de técnicas avanzadas de ciencia de datos con un enfoque ético y responsable en el tratamiento de la información, garantizando el cumplimiento de la normativa vigente en materia de privacidad.

El trabajo se estructura en torno a objetivos concretos que abarcan desde la recolección y preprocesamiento de datos históricos hasta la implementación de modelos predictivos y su integración en una interfaz técnica de consulta. De este modo, el proyecto busca ofrecer una herramienta analítica robusta, confiable y alineada con las necesidades de los principales actores del sector, contribuyendo a fortalecer la innovación en el mercado de pagos argentino durante el año 2025.

1.1 Objetivos

Objetivo general:

- Desarrollar un sistema de análisis predictivo con aprendizaje automático para anticipar gastos de usuarios de tarjetas de crédito y generar promociones personalizadas durante el año 2025, optimizando estrategias comerciales en el ecosistema de pagos argentino.

Los objetivos específicos del proyecto son:

- Recolectar y preprocesar, durante el primer mes del desarrollo, un conjunto de datos históricos anonimizados de transacciones con tarjeta de crédito de procesadores de pagos en Argentina.
- Desarrollar y entrenar modelos de aprendizaje automático que identifiquen patrones de consumo y predigan gastos futuros de los usuarios con al menos un 80% de precisión.
- Segmentar a los usuarios en grupos de comportamiento similar para facilitar la generación de promociones personalizadas por parte de bancos, procesadores y comercios.
- Implementar una interfaz técnica que permita a los actores del ecosistema consultar los resultados del sistema de forma eficiente y segura.
- Verificar el cumplimiento normativo del sistema respecto a la Ley 25.326 de Protección de Datos Personales (2000), garantizando la privacidad de los usuarios en todas las etapas del proyecto.

1.2 Alcance

El proyecto final de ingeniería se centra en un sistema de análisis predictivo orientado a empresas procesadoras de pagos (como Prisma Medios de Pago, Fiserv, entre otras), con el objetivo de modelar patrones de consumo a partir de transacciones realizadas con tarjeta de crédito y anticipar gastos futuros de los usuarios. Estas entidades, al contar con acceso directo y centralizado a los datos transaccionales, utilizan el sistema para generar valor agregado a sus servicios y colaborar con bancos emisores y comercios adheridos en la personalización de promociones y ofertas. El sistema se desarrolla considerando el contexto del mercado argentino durante el año 2025, respetando los lineamientos vigentes en materia de privacidad y protección de datos personales.

Se incluye dentro del alcance:

- Implementación de un módulo de recolección y preprocesamiento de datos históricos anonimizados.
- Desarrollo de modelos de aprendizaje automático orientados a la predicción de hábitos de consumo.
- Segmentación de usuarios en función de sus comportamientos financieros.

- Desarrollo de una interfaz técnica para la consulta de resultados por parte de los equipos analíticos y comerciales de las procesadoras.

Queda fuera del alcance:

- Integración en tiempo real con plataformas bancarias o comerciales.
- Automatización de campañas promocionales basadas en los resultados.
- Personalización dinámica de ofertas en función de comportamientos en tiempo real.
- Visualización final para usuarios particulares.

Estas funcionalidades se consideran posibles evoluciones en fases futuras del proyecto.

El desarrollo se enfoca en construir una base técnica sólida, priorizando la calidad del modelo predictivo, la confiabilidad de los resultados y el cumplimiento de las normativas vigentes en materia de protección de datos. De este modo, el sistema ofrece a las empresas procesadoras de pagos una herramienta estratégica que fortalece su rol como intermediarias clave en el ecosistema financiero-comercial y permite brindar servicios analíticos avanzados a sus clientes institucionales.

1.3 Descripción

En los últimos años, el mercado de pagos electrónicos en Argentina ha experimentado un crecimiento sostenido, impulsado principalmente por la expansión del comercio electrónico y el uso de tarjetas de crédito en transacciones diarias. Según el Estudio Anual 2024 de la Cámara Argentina de Comercio Electrónico («CACE | Estudio Anual de CACE 2024» 2024), las operaciones realizadas con tarjetas de crédito en el sector del comercio electrónico crecieron un 60% en 2023, y la facturación general del canal digital se incrementó un 181% interanual, superando ampliamente el nivel de inflación del período. Esta tendencia refleja una consolidación de los medios de pago electrónicos y un cambio estructural en el comportamiento de consumo de los argentinos.

En este contexto, las empresas procesadoras de pagos como Prisma Medios de Pago y Fiserv han ganado un rol cada vez más estratégico al centralizar grandes volúmenes de datos transaccionales. Sin embargo, a pesar de contar con esta ventaja, muchas de estas compañías aún no disponen de herramientas analíticas avanzadas para extraer insights (hallazgos

analíticos o conclusiones basadas en datos) predictivos que permitan anticipar patrones de consumo o diseñar promociones personalizadas. Esta brecha representa una oportunidad de negocio significativa: desarrollar un sistema de análisis predictivo basado en aprendizaje automático que modele los hábitos de gasto de los usuarios y permita anticipar sus comportamientos futuros a partir de su historial transaccional.

El segmento de clientes al que se dirige este proyecto comprende principalmente a las procesadoras de pagos, actores que poseen acceso privilegiado a datos de gran valor, pero que requieren soluciones innovadoras para capitalizar esta información en favor de su estrategia comercial. Según el Banco Central de la República Argentina («BANCO CENTRAL DE LA REPÚBLICA ARGENTINA - Informe de Inclusión Financiera» 2023), a diciembre de 2023 se registró un aumento del 3,7% en la cantidad de personas humanas tenedoras de cuentas y un incremento interanual del 42,5% en la actividad de cuentas a través de operaciones electrónicas, reflejando una tendencia consolidada hacia la digitalización de los pagos. Este entorno refuerza el potencial de soluciones basadas en datos. Por ello, el target inicial del proyecto se enfocará en estas empresas, que poseen la capacidad de implementar herramientas que potencien sus servicios a bancos emisores y comercios adheridos, optimizando así la fidelización de los usuarios finales.

La solución propuesta consiste en un sistema de análisis predictivo que, mediante técnicas de aprendizaje automático, modelará patrones de consumo basados en datos de transacciones con tarjeta de crédito. Este sistema permitirá no solo anticipar gastos futuros de los usuarios, sino también segmentarlos en grupos de comportamiento homogéneo para facilitar la creación de promociones altamente personalizadas. Los procesadores de pagos podrán integrar esta tecnología en sus plataformas existentes, incrementando la efectividad de las campañas comerciales mediante decisiones fundamentadas en datos reales y actualizados.

A diferencia de las soluciones actuales basadas en publicidad programática y segmentación por comportamiento digital, que infieren intereses a partir de búsquedas, interacciones y cookies, la propuesta de este proyecto se fundamenta en el análisis directo de transacciones con tarjeta de crédito, permitiendo anticipar hábitos reales de consumo. Esta capacidad predictiva basada en datos financieros concretos constituye el principal diferencial, ya que permite generar segmentaciones más precisas y promociones verdaderamente personalizadas. Actualmente, ni las procesadoras de pagos ni las grandes plataformas digitales

explotan este enfoque predictivo con la profundidad propuesta, lo que convierte al sistema en una solución innovadora para el ecosistema financiero argentino.

Desde el inicio del desarrollo, se priorizará el respeto por los principios éticos en el uso de inteligencia artificial, aplicando buenas prácticas en el diseño y entrenamiento de modelos conforme a las recomendaciones de Russell y Norvig (Russell, Norvig y Intelligence, 1995). Asimismo, se integrarán las directrices establecidas en el estándar IEEE 7000-2021 («IEEE Standard Model Process for Addressing Ethical Concerns during System Design» 2021), que propone un modelo de proceso para abordar consideraciones éticas desde las primeras etapas de diseño, asegurando la transparencia, la privacidad y la equidad en los sistemas desarrollados.

La arquitectura de la solución estará compuesta por tres módulos principales: un módulo de recolección y preprocesamiento de datos históricos anonimizados de transacciones con tarjeta de crédito; un módulo de aprendizaje automático destinado a prever hábitos de consumo y segmentar usuarios; y una interfaz técnica que permitirá a los equipos analíticos de las procesadoras de pagos acceder a los resultados de manera sencilla y efectiva. El énfasis estará puesto en la calidad predictiva de los modelos, en la claridad de las segmentaciones obtenidas, y en el estricto cumplimiento de las normativas vigentes en materia de privacidad y protección de datos personales.

Finalmente, resulta importante destacar que el Instituto Nacional de Estadística y Censos (INDEC) ha anunciado una actualización en la metodología del índice de precios al consumidor (IPC) para reflejar de manera más precisa los cambios en los hábitos de consumo de la población, incluyendo una mayor ponderación de servicios digitales y pagos electrónicos. Esta modificación busca adaptar el índice a las nuevas realidades del consumo, incorporando productos y servicios actuales como plataformas de streaming y telefonía móvil («El Gobierno cambiará la metodología que usa el Indec para armar el índice de inflación minorista» 2025) («Nuevo índice de inflación» 2025). Esta iniciativa del gobierno argentino subraya la creciente importancia de los pagos electrónicos en la economía nacional y respalda la relevancia de soluciones tecnológicas que permitan a las empresas procesadoras de pagos anticipar y adaptarse a estos cambios en los patrones de consumo.

2 Antecedentes

La presente sección proporciona un contexto y base de conocimientos con el objetivo de profundizar en las características de la problemática y comprender en qué contexto surge la solución para identificar potenciales competidores de PromoAI.

2.1 Marco Teórico

El marco teórico constituye la base conceptual sobre la cual se sustenta el desarrollo del presente proyecto. Su propósito es reunir, analizar y sintetizar los principales fundamentos teóricos, metodológicos y normativos que permiten comprender las tecnologías, enfoques y principios involucrados en la construcción de un sistema de análisis predictivo orientado al sector de medios de pago. A través de este apartado se busca establecer los pilares científicos y técnicos que guían el diseño del sistema propuesto, así como contextualizar su relevancia en el marco de la transformación digital y la creciente adopción de soluciones basadas en inteligencia artificial dentro del ámbito financiero.

En particular, el capítulo aborda los conceptos esenciales vinculados al aprendizaje automático y su aplicación en la predicción del comportamiento del consumidor, la segmentación de usuarios y la personalización de servicios mediante sistemas de recomendación. Además, se analizan los aspectos éticos, legales y de privacidad asociados al tratamiento de datos personales, garantizando la conformidad con las normativas vigentes y las buenas prácticas internacionales.

2.1.1 Introducción

El presente marco teórico tiene como finalidad establecer los fundamentos conceptuales y científicos sobre los cuales se construye la solución tecnológica propuesta. La integración de técnicas de aprendizaje automático con datos provenientes de transacciones electrónicas habilita nuevas formas de comprender y anticipar el comportamiento de consumo de los usuarios, representando una oportunidad estratégica para empresas procesadoras de pagos que buscan optimizar la personalización de sus servicios.

Para comprender en profundidad las capacidades y limitaciones de una solución como PromoAI, resulta imprescindible abordar una serie de conceptos clave vinculados al análisis predictivo, el comportamiento del consumidor y los sistemas inteligentes de recomendación.

En este sentido, se explorarán las bases del aprendizaje automático y su aplicación en la predicción de hábitos de consumo, las técnicas de segmentación de usuarios y su relevancia para la definición de perfiles homogéneos, y el funcionamiento de los sistemas de recomendación, destacando sus distintos enfoques y usos actuales en contextos digitales.

Asimismo, se abordarán cuestiones éticas y normativas inherentes al tratamiento de datos personales y al uso responsable de algoritmos inteligentes, atendiendo tanto a estándares internacionales como a la legislación vigente en la República Argentina. Dado que el sistema propuesto se basa en información sensible, como el historial de transacciones con tarjeta de crédito, resulta fundamental garantizar la protección de la privacidad de los usuarios y la transparencia de los procesos automatizados.

Finalmente, se contextualizará el desarrollo del proyecto en el marco de la transformación digital que atraviesa el sector financiero, analizando el rol creciente de las *fintech* (empresa de tecnología financiera), el avance del comercio electrónico, y la centralidad de los datos como insumo para la toma de decisiones estratégicas. Esta revisión teórica permitirá consolidar una base sólida sobre la cual construir y justificar la solución propuesta, asegurando su viabilidad técnica, legal y comercial.

2.1.2 Aprendizaje Automático y Predicción de Comportamiento

El aprendizaje automático es una subdisciplina de la inteligencia artificial que permite a los sistemas aprender automáticamente a partir de datos, sin ser explícitamente programados para cada tarea específica. Esta capacidad ha permitido su aplicación en numerosos dominios, desde la medicina hasta las finanzas, especialmente en contextos donde el análisis de grandes volúmenes de datos resulta esencial para la toma de decisiones informadas (Hierons, 1999; Russell et al., 2021).

Dentro del campo financiero, el aprendizaje automático ha demostrado ser una herramienta eficaz para modelar patrones complejos de comportamiento, permitiendo detectar tendencias, segmentar usuarios, prevenir fraudes y predecir comportamientos futuros basados en datos históricos. Los modelos de *machine learning* (aprendizaje automático) superan a las técnicas tradicionales en tareas de predicción financiera, como la evaluación crediticia y la detección de fraudes, gracias a su capacidad para capturar relaciones no lineales en grandes volúmenes de datos. En el contexto específico de este trabajo, se busca aplicar modelos

supervisados y no supervisados para anticipar hábitos de consumo a partir de registros anonimizados de transacciones con tarjeta de crédito (Lessmann et al., 2015).

Los modelos supervisados, como los árboles de decisión, redes neuronales o máquinas de soporte vectorial (SVM), pueden ser entrenados para predecir el nivel y categoría del gasto futuro de un usuario en base a variables como frecuencia de compra, monto promedio, rubro comercial o estacionalidad. Estos enfoques han mostrado resultados prometedores en aplicaciones comerciales y bancarias (Badea, 2014). Por otro lado, técnicas no supervisadas como el clustering o análisis de componentes principales (PCA) permiten identificar patrones ocultos en los datos y agrupar a los usuarios en segmentos de comportamiento homogéneo (Han, Kamber y Pei, 2012).

Uno de los principales desafíos en este tipo de sistemas es lograr un equilibrio entre la precisión predictiva del modelo y su interpretabilidad. En entornos donde las decisiones afectan directamente a los consumidores, como es el caso de campañas de marketing personalizadas o la asignación de beneficios, resulta fundamental poder explicar las recomendaciones generadas por el sistema (Guidotti et al., 2018). Por ello, se evaluarán tanto modelos de caja negra como de caja blanca, priorizando aquellos que ofrezcan transparencia sin sacrificar precisión.

El enfoque de análisis predictivo utilizado en este proyecto se inscribe dentro de la corriente de sistemas inteligentes centrados en el usuario, orientados a anticipar necesidades antes de que sean explícitamente manifestadas. Esta capacidad predictiva, basada en evidencias extraídas del historial de comportamiento, representa un diferencial con respecto a los métodos tradicionales de segmentación y targeting, que usualmente se apoyan en datos demográficos o en rastreos de actividad digital en buscadores o redes sociales, sin considerar el consumo real (Chen, Pavlov y Canny, 2009).

2.1.3 Segmentación de Usuarios y Comportamiento del Consumidor

La segmentación de usuarios es una técnica fundamental en el análisis de datos de consumo, ya que permite agrupar individuos con comportamientos, preferencias o características similares. En contextos comerciales, esta práctica facilita la personalización de productos y servicios, permitiendo una asignación más eficiente de recursos y una mejora en la efectividad de las campañas de marketing (Wedel & Kamakura, 2000).

Tradicionalmente, la segmentación se ha realizado mediante criterios demográficos o geográficos, como edad, género, nivel socioeconómico o ubicación. Sin embargo, con el crecimiento del análisis de datos transaccionales y el acceso a registros detallados de comportamiento, ha ganado protagonismo la segmentación basada en el comportamiento del consumidor, especialmente en industrias donde la fidelización y la retención del cliente son prioritarias (Kotler, 2016).

En este proyecto, la segmentación se abordará desde una perspectiva basada en hábitos de consumo derivados de transacciones electrónicas con tarjetas de crédito, lo que representa una evolución respecto a enfoques clásicos. Esta metodología permite identificar patrones de gasto, frecuencia de compras, estacionalidad, rubros más utilizados y tendencias de consumo, entre otras variables relevantes (Lessmann et al., 2015).

Para llevar a cabo esta segmentación, se emplearán técnicas de aprendizaje no supervisado como k-means, DBSCAN o algoritmos jerárquicos, que permiten descubrir agrupamientos naturales en grandes volúmenes de datos. Estas técnicas han demostrado ser efectivas para construir perfiles de clientes en el sector financiero y retail (Tsiptsis y Chorianopoulos, 2011). Asimismo, se evaluará la calidad de la segmentación mediante métricas como la *silhouette score* (coeficiente de silueta) o el coeficiente de Dunn, garantizando que los grupos generados sean internamente coherentes y externamente distinguibles (Tan, Steinbach y Kumar, 2016).

El uso de perfiles de consumo no solo permite mejorar la efectividad de las campañas comerciales, sino también anticipar necesidades de los usuarios, identificar oportunidades de ventas cruzadas y diseñar promociones específicas que eleven el valor del cliente a largo plazo (CLV). Esta personalización basada en datos reales permite un enfoque más ético y eficiente, en contraste con las prácticas tradicionales de targeting basadas en cookies, comportamiento de navegación o actividad en redes sociales, que pueden ser más invasivas y menos representativas del consumo real (Tene y Polonetsky, 2012).

Además, la construcción de perfiles de usuarios requiere una consideración crítica de los aspectos éticos y regulatorios. La amonificación de los datos y el cumplimiento de normativas como la Ley 25.326 de Protección de los Datos Personales en Argentina son requisitos indispensables para garantizar el uso responsable de la información personal («PROTECCION DE LOS DATOS PERSONALES» 2000).

2.1.4 Privacidad, Ética y Protección de Datos

El uso de datos personales en sistemas basados en inteligencia artificial plantea desafíos éticos significativos, especialmente cuando se trata de información sensible como los historiales de consumo financiero. En este contexto, la recolección, el procesamiento y la aplicación de datos transaccionales deben enmarcarse en principios éticos sólidos y respetar las normativas vigentes para proteger los derechos de los individuos.

Uno de los pilares fundamentales en este sentido es el principio de privacidad por diseño, que propone integrar consideraciones éticas y de privacidad desde las primeras etapas del desarrollo tecnológico, y no como un añadido posterior (Cavoukian, 2010). Este enfoque se alinea con el modelo propuesto por la norma IEEE 7000-2021, que establece un marco metodológico para identificar y mitigar riesgos éticos en proyectos de sistemas inteligentes desde su concepción inicial («IEEE Standard Model Process for Addressing Ethical Concerns during System Design» 2021).

En el caso específico del análisis predictivo aplicado a datos de consumo con tarjetas de crédito, es esencial garantizar la anonimización efectiva de los datos, eliminando cualquier identificador personal directo o indirecto que pueda permitir la re-identificación de los usuarios. Esta medida no solo protege la privacidad individual, sino que también habilita el uso ético de grandes volúmenes de datos para fines analíticos y de modelado (Ohm, 2009).

Además, la legislación argentina ofrece un marco regulatorio claro a través de la Ley 25.326 de Protección de los Datos Personales, la cual establece el consentimiento informado como condición indispensable para el tratamiento de datos personales, y garantiza el derecho de los titulares a acceder, rectificar y suprimir su información («PROTECCION DE LOS DATOS PERSONALES» 2000).

Por otro lado, las implicancias éticas del uso de inteligencia artificial incluyen no solo la protección de la privacidad, sino también la transparencia de los algoritmos, la no discriminación y la equidad en la toma de decisiones. Es fundamental que los modelos utilizados no reproduzcan sesgos implícitos en los datos históricos, especialmente aquellos vinculados a cuestiones socioeconómicas, de género o geográficas (Barocas, Hardt y Narayanan, 2023).

La integración de estas buenas prácticas no solo fortalece la legitimidad del sistema, sino que también genera confianza en los usuarios, las empresas procesadoras de pagos y los

organismos reguladores. En un contexto de creciente preocupación social por el uso de datos personales, el compromiso con la ética y la privacidad se convierte en un diferenciador estratégico para cualquier solución tecnológica.

2.1.5 Transformación Digital en el Sector Financiero

El aprendizaje automático ha revolucionado la forma en que las organizaciones procesan, analizan y extraen valor de grandes volúmenes de datos, permitiendo desarrollar modelos predictivos capaces de anticipar comportamientos futuros a partir de información histórica. En el ámbito financiero, estas técnicas han demostrado ser particularmente efectivas para modelar patrones de gasto, segmentar usuarios, detectar anomalías y optimizar estrategias comerciales personalizadas (Lessmann et al., 2015)

El modelado predictivo de consumos consiste en construir representaciones matemáticas que puedan identificar relaciones implícitas entre variables históricas (como montos de gasto, categorías de comercio, frecuencia de transacciones, ubicación geográfica, etc.) y comportamientos futuros (por ejemplo, probabilidad de realizar una compra, monto esperado, categoría de interés). Para ello, se emplean algoritmos supervisados y no supervisados, según la disponibilidad de etiquetas en los datos (Han, Kamber y Pei, 2012).

Entre los enfoques más utilizados para tareas de predicción en series temporales y consumo se encuentran los modelos de árboles de decisión y bosques aleatorios (Random Forest), regresiones lineales y logísticas, redes neuronales artificiales, y más recientemente los modelos de tipo Gradient Boosting (como XGBoost y LightGBM), los cuales han demostrado alto rendimiento en competencias de ciencia de datos y aplicaciones financieras (Chen, Pavlov y Canny, 2009)

En el caso de segmentación de usuarios, técnicas como el *clustering* (agrupamiento) mediante K-means, DBSCAN o modelos basados en mixturas gaussianas permiten identificar grupos homogéneos de consumidores con características similares de gasto. Esta clasificación posibilita diseñar estrategias comerciales diferenciadas y más efectivas (Wedel y Kamakura, 2000).

La predicción del comportamiento financiero presenta desafíos particulares: los datos suelen estar altamente desbalanceados, son sensibles a estacionalidades (como fechas de cobro o eventos como el Hot Sale), y pueden estar sujetos a ruido e inestabilidad macroeconómica. Por lo tanto, es crucial aplicar técnicas de limpieza, normalización, y

feature selection (selección de características) para garantizar la calidad del aprendizaje automático (Pabuccu y Barbu, 2024).

Además, se están incorporando cada vez más enfoques de *deep learning* (aprendizaje profundo), como redes recurrentes tipo LSTM (Long Short-Term Memory), que son especialmente útiles para modelar secuencias temporales de gasto, capturando dependencias de largo plazo entre eventos financieros (Hochreiter y Schmidhuber, 1997).

En este contexto, el presente proyecto propone utilizar estos enfoques no solo para predecir gastos futuros, sino también para construir perfiles dinámicos de consumo que se actualicen en función de las nuevas transacciones. Esta arquitectura permitirá generar recomendaciones personalizadas en tiempo casi real y adaptar las campañas comerciales según las variaciones en el comportamiento del usuario.

La correcta implementación de estos modelos requiere no solo la selección de algoritmos adecuados, sino también la evaluación rigurosa a través de métricas como precisión, recall, F1-score, AUC-ROC y errores de predicción como RMSE o MAE, así como la validación cruzada para evitar el *overfitting* (sobreajuste) (Kuhn y Johnson, 2013).

2.1.6 Sistemas de recomendación y promociones personalizadas

Los sistemas de recomendación se han consolidado como una de las aplicaciones más visibles y efectivas del aprendizaje automático en diversos sectores, desde el entretenimiento hasta el comercio electrónico y los servicios financieros. Su objetivo principal es filtrar grandes volúmenes de información para ofrecer a los usuarios contenidos, productos o servicios que se ajusten a sus intereses, comportamientos previos o similitudes con otros usuarios (Ricci, Rokach y Shapira, 2022).

Existen tres enfoques principales en la construcción de estos sistemas: filtrado colaborativo, filtrado basado en contenido y modelos híbridos. El filtrado colaborativo se basa en la similitud entre usuarios o ítems, aprovechando patrones de comportamiento colectivos para hacer recomendaciones. El filtrado basado en contenido analiza características del usuario y de los ítems, generando recomendaciones personalizadas según preferencias individuales. Por su parte, los modelos híbridos combinan ambos enfoques, logrando mayor precisión y mitigando debilidades como el problema del arranque en frío o la escasez de datos (Burke, 2002).

En el ámbito financiero, y particularmente en el sector de medios de pago, estos sistemas tienen un enorme potencial para generar promociones personalizadas. A partir del análisis del historial de consumos, ubicación, frecuencia de gastos, categorías de comercios y hábitos temporales (como días de la semana o fechas específicas), se pueden predecir intereses del cliente y ofrecer promociones altamente relevantes y oportunas (Tang, Hu y Liu, 2013).

El uso de modelos de aprendizaje supervisado y no supervisado, tales como árboles de decisión, redes neuronales o técnicas de clustering, ha demostrado ser eficaz para detectar segmentos de clientes con comportamientos similares, diseñar promociones diferenciadas y medir su impacto sobre métricas como el engagement, la retención o el ticket promedio (Resnick y Varian, 1997).

Además, la incorporación de contexto en tiempo real (ubicación del usuario, clima, hora del día, etc.) en sistemas de recomendación abre la puerta a recomendaciones contextuales más precisas y valiosas para el usuario. Esto se traduce en mayores tasas de conversión, reducción del desgaste publicitario y mejoras sustanciales en la experiencia del cliente (Adomavicius y Tuzhilin, 2011).

Finalmente, cabe destacar que la capacidad de adaptar promociones automáticamente según la respuesta del usuario (un proceso conocido como *feedback loop* o realimentación) convierte a estos sistemas en herramientas altamente dinámicas, capaces de optimizar campañas promocionales en función del comportamiento en tiempo real, maximizando el retorno de la inversión publicitaria y la fidelización (Zhang et al., 2019).

2.1.7 Conclusión del marco teórico

El presente marco teórico ha permitido contextualizar y fundamentar los principales conceptos que sustentan el desarrollo de un sistema de análisis predictivo orientado a la personalización de promociones a partir de consumos electrónicos. A partir del análisis del aprendizaje automático, se reconoció el potencial de los algoritmos supervisados y no supervisados en la modelización de comportamientos de consumo, así como su aplicabilidad en el diseño de sistemas inteligentes adaptativos.

Asimismo, se estableció el valor estratégico que poseen los datos transaccionales en el ecosistema digital actual, especialmente en el sector financiero y de medios de pago, donde su aprovechamiento adecuado puede traducirse en ventajas competitivas sustanciales. La

segmentación de usuarios, los modelos de series temporales y las métricas de evaluación predictiva fueron tratados como herramientas clave para la elaboración de modelos robustos y precisos.

Por otro lado, la incorporación de sistemas de recomendación orientados a promociones personalizadas demostró ser una línea de aplicación directa del enfoque propuesto, donde los beneficios van desde la mejora de la experiencia del usuario hasta el incremento en la efectividad de campañas comerciales. Se destacó la importancia del uso responsable de los datos, el respeto por las normativas vigentes y la adopción de marcos éticos en la construcción de sistemas basados en inteligencia artificial.

Este recorrido teórico sienta las bases para abordar el análisis del estado del arte, en el cual se indagará cómo distintas organizaciones, a nivel nacional e internacional, han implementado soluciones similares, qué tecnologías emplean actualmente, y en qué medida el enfoque aquí propuesto representa una innovación diferenciadora frente a lo existente.

2.2 Estado del Arte

El presente apartado tiene como objetivo revisar el estado actual de las tecnologías, investigaciones y soluciones existentes vinculadas al análisis predictivo de comportamiento de consumo, la personalización de promociones y el uso de inteligencia artificial en el sector financiero y de medios de pago. El análisis del estado del arte permite situar el desarrollo de PromoAI dentro del contexto científico, tecnológico y empresarial contemporáneo, identificando tanto los avances logrados en el campo como las brechas que el proyecto busca cubrir.

En las últimas décadas, el crecimiento de la ciencia de datos aplicada a las finanzas ha impulsado el desarrollo de sistemas capaces de extraer información valiosa a partir de grandes volúmenes de transacciones. Estos avances se apoyan en disciplinas como el machine learning, el procesamiento de lenguaje natural (NLP) y la analítica predictiva, que han demostrado su eficacia en áreas como la detección de fraude, el *scoring* crediticio y la segmentación de clientes (Kumar et al., 2019; Marr, 2020).

Sin embargo, la aplicación de estas tecnologías al ámbito de la personalización de promociones basadas en datos transaccionales reales continúa siendo incipiente, especialmente en mercados emergentes como el argentino, donde las particularidades económicas y regulatorias requieren adaptaciones específicas (Saiag, 2020).

A nivel internacional, los sistemas de recomendación han evolucionado significativamente desde los modelos colaborativos tradicionales hacia enfoques híbridos basados en aprendizaje profundo y modelos explicables (Explainable AI), orientados a equilibrar precisión y transparencia (Guidotti et al., 2018). Estos sistemas se utilizan ampliamente en sectores como el comercio electrónico o el entretenimiento (Gomez-Uribe y Hunt, 2015), pero su adopción en el sector financiero aún enfrenta desafíos en materia de privacidad, regulación y confianza del usuario.

En este marco, el estado del arte que se presenta a continuación se estructura en cuatro partes:

- Análisis de la competencia, que examina los principales actores y soluciones disponibles tanto en el ámbito local como global.
- Curva de valor, que compara las capacidades de dichas soluciones con la propuesta de PromoAI.
- Limitaciones de las soluciones actuales, identificando las brechas tecnológicas y de contexto.
- Descripción del aporte diferencial del proyecto, donde se destacan los aspectos técnicos, éticos y estratégicos que posicionan a PromoAI como una propuesta innovadora dentro del ecosistema argentino de medios de pago.

2.2.1 Análisis de la Competencia

El mercado de soluciones basadas en análisis de datos y personalización de promociones se encuentra en plena expansión, tanto a nivel local como internacional. Para comprender la posición del sistema PromoAI dentro de este ecosistema, resulta pertinente analizar las principales empresas y plataformas que, de manera directa o indirecta, constituyen competencia en el sector.

2.2.1.1 Competencia directa: procesadoras de pagos en Argentina

Las procesadoras de pagos constituyen los actores con mayor potencial de competir de manera directa, dado que concentran grandes volúmenes de datos transaccionales y poseen vínculos estrechos con entidades financieras y comercios.

- Prisma Medios de Pago: Opera las marcas Visa y Banelco, ofreciendo tableros de análisis y reportes de consumo. Sin embargo, sus soluciones actuales se orientan principalmente al análisis descriptivo, sin incorporar modelos predictivos avanzados que anticipen hábitos de gasto.
- Fiserv (First Data): Administra la red de procesamiento de Mastercard en Argentina y brinda soluciones de fidelización para comercios. A pesar de contar con amplios datos transaccionales, su foco se encuentra en reportes de gestión y programas de beneficios, no en predicción de consumo.
- Payway: Iniciativa de Prisma Medios de Pago, enfocada en proveer servicios de adquiere para comercios. Ofrece herramientas de visualización de ventas, aunque no integra funcionalidades de segmentación predictiva.

En síntesis, estas compañías poseen la infraestructura y los datos para implementar sistemas como PromoAI, pero actualmente carecen de un enfoque centrado en predicción y explicabilidad, lo cual representa una oportunidad diferencial.

2.2.1.2 Competencia indirecta: fintechs y bancos digitales

El crecimiento de las fintechs argentinas ha impulsado la digitalización del consumo y la incorporación de servicios de valor agregado. Algunas de estas iniciativas incluyen funciones que, aunque no están directamente enfocadas en análisis predictivo, podrían evolucionar hacia ese terreno.

- Ualá: Ofrece tarjetas prepagas y una aplicación móvil con funcionalidades de control financiero básico. Si incorporara modelos predictivos, podría personalizar promociones para sus millones de usuarios activos.
- Naranja X: Desarrolla un ecosistema financiero que incluye tarjetas y promociones. Sus programas de beneficios están consolidados en el mercado, aunque aún se basan en segmentaciones generales.
- Mercado Pago: Con una gran base de usuarios y transacciones (QR, billetera, tarjeta y marketplace), posee la infraestructura para desplegar promociones personalizadas basadas en IA.

- Bancos digitales (Brubank, Wilobank, Openbank): Si bien su foco principal es la bancarización digital, exploran herramientas de analítica avanzada que podrían converger con sistemas de recomendación predictiva.

Estos actores se destacan por su capacidad de innovación y rápida adaptación a nuevas tendencias tecnológicas, lo que los posiciona como potenciales competidores emergentes para soluciones como PromoAI.

2.2.1.3 Competencia de referencia: plataformas globales

Existen, además, soluciones internacionales que constituyen un marco de referencia para comprender el avance del sector.

- Google, Meta y Amazon: Implementan sistemas de recomendación altamente personalizados, aunque basados en datos de navegación y comportamiento digital, y no en transacciones financieras reales.
- IBM Watson Marketing y Salesforce Marketing Cloud: Proveen herramientas de marketing predictivo y segmentación avanzada, con fuerte presencia en mercados internacionales. Sin embargo, suelen ser soluciones costosas y poco adaptadas a la realidad económica y regulatoria argentina.
- Experian y Equifax: Empresas de scoring crediticio que han comenzado a expandirse hacia modelos de predicción de comportamiento de consumo, aunque con foco en evaluación crediticia más que en personalización de promociones.

Estas plataformas globales marcan tendencias tecnológicas en materia de analítica predictiva y fidelización (Gomez-Uribe y Hunt, 2015), pero presentan barreras de adopción en el contexto local debido a su alto costo y a la falta de adaptación a las particularidades regulatorias y culturales de Argentina.

2.2.1.4 Conclusión del análisis de la competencia

En el ámbito de los procesadores de pagos y los emisores de tarjetas en Argentina, resulta necesario precisar que actores como Prisma Medios de Pago, Fiserv o First Data a la fecha no se constituyen como competidores directos del sistema propuesto, sino potenciales usuarios y beneficiarios del mismo. Si bien estas organizaciones disponen de amplios volúmenes de información transaccional y cuentan con capacidades internas de análisis, sus

desarrollos suelen centrarse en tableros descriptivos, reportes operativos o segmentaciones tradicionales, sin implementar soluciones predictivas orientadas específicamente a la generación automatizada de promociones personalizadas.

En este contexto, la competencia relevante del proyecto se encuentra conformada por soluciones alternativas que actualmente abordan parcialmente la misma problemática, entre las que se incluyen:

- Áreas internas de *Business Intelligence* (inteligencia de negocios) y *Data Science* (ciencia de datos) de bancos y procesadoras, cuyo alcance se orienta mayormente a análisis descriptivos y segmentaciones estáticas, sin integrar modelos predictivos en producción que funcionen de manera continua sobre flujos de transacciones reales.
- Consultoras de analítica y marketing, que ofrecen desarrollos a medida, usualmente caracterizados por tiempos de implementación extendidos, costos elevados y ausencia de integración nativa con infraestructuras transaccionales locales.
- Plataformas internacionales de marketing automation, que aplican modelos generalistas basados en comportamiento digital, pero que no incorporan datos transaccionales argentinos ni contemplan las particularidades del sistema financiero local.
- Herramientas genéricas de inteligencia artificial y aprendizaje automático, que requieren conocimientos técnicos avanzados para su configuración y uso, y que no están diseñadas para usuarios con baja alfabetización digital ni orientadas a la automatización de campañas basadas en consumos reales.

En este sentido, el aporte diferencial de PromoAI radica en ocupar un espacio aún desatendido dentro del ecosistema argentino: ofrecer a procesadoras de pagos y bancos una herramienta predictiva, explicable y alineada con el marco normativo, que transforme datos transaccionales en estrategias de fidelización más efectivas.

2.2.2 Curva de valor

Para complementar el análisis de la competencia, se elaboró una Curva de Valor que permite comparar la propuesta de PromoAI con distintos actores del sector en función de seis

atributos clave: uso de datos transaccionales reales, capacidad predictiva, segmentación avanzada, explicabilidad de modelos, adaptación al contexto local y cumplimiento normativo.

En el gráfico se muestran los valores asignados a cada competidor en una escala de 0 a 10, donde 0 representa un nivel inexistente y 10 un nivel muy alto de desarrollo en el atributo considerado.

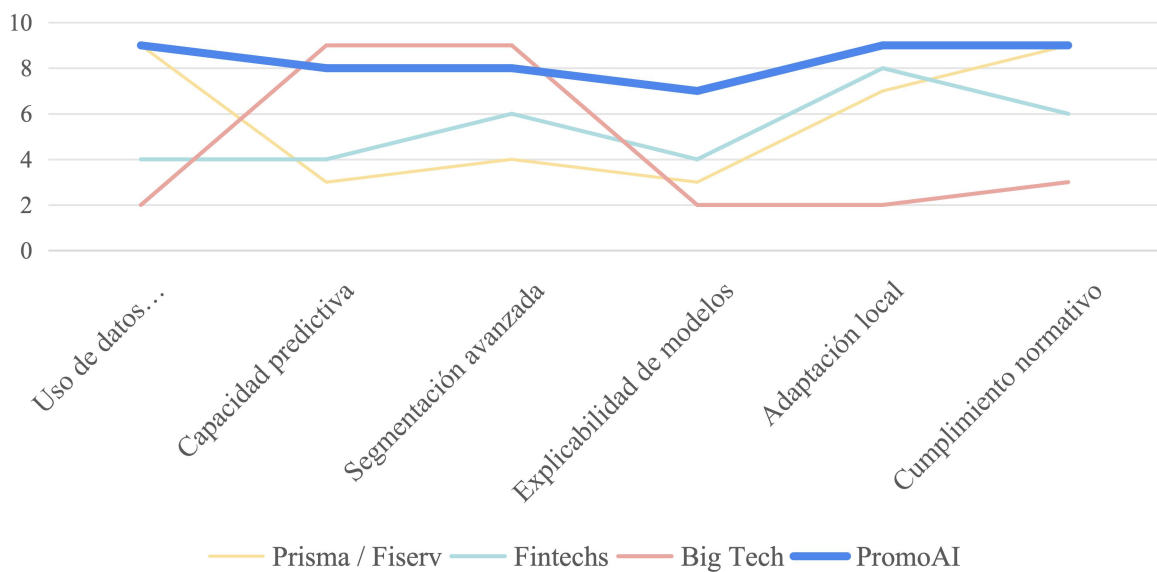


Figura 1: Curva de valor (Elaboración propia)

Del análisis de la curva de valor (Figura 1), se desprenden las siguientes observaciones.

- Prisma / Fiserv se destacan en el uso de datos transaccionales y cumplimiento normativo, pero presentan debilidades en capacidad predictiva, segmentación avanzada y explicabilidad.
- Fintechs como Ualá, Naranja X o Mercado Pago muestran altos niveles de adaptación local y mayor innovación en segmentación, aunque con bajo desarrollo en modelos predictivos y normativos.
- Big Tech (Google, Meta, Amazon) poseen las mayores capacidades predictivas y de segmentación, pero basadas en datos de navegación, sin adaptación al mercado argentino ni cumplimiento regulatorio local.
- PromoAI alcanza una propuesta equilibrada: alto uso de datos transaccionales, capacidad predictiva significativa, segmentación avanzada y cumplimiento normativo, junto con un enfoque explícito en explicabilidad y adaptación local. Si

bien no maximiza todos los atributos, logra un balance diferencial frente a las alternativas existentes.

Esta curva de valor evidencia que PromoAI ocupa un espacio estratégico aún desatendido en el mercado argentino, al combinar predicción de consumo, personalización y cumplimiento normativo con foco en el ecosistema de procesadoras de pagos.

2.2.3 Limitaciones de las soluciones actuales

A pesar del avance de las tecnologías aplicadas al análisis de datos y la inteligencia artificial en el sector financiero y comercial, las soluciones actuales presentan una serie de limitaciones que restringen su efectividad o aplicabilidad en ciertos contextos, especialmente en mercados emergentes como el argentino.

Una primera limitación importante se refiere al uso limitado de datos transaccionales directos. Muchas plataformas de publicidad y recomendación personalizan su contenido a partir del historial de navegación web, el comportamiento en redes sociales, o las interacciones del usuario con apps móviles (Liu et al., 2010). Si bien estos datos ofrecen valor, no reflejan necesariamente los hábitos de consumo reales de los usuarios, ni permiten predecir sus futuras decisiones de gasto con un nivel de precisión comparable al que ofrecería el análisis de datos de transacciones con tarjetas de crédito.

En segundo lugar, existen restricciones relacionadas con la calidad y heterogeneidad de los modelos predictivos actuales. Muchas de las soluciones implementadas por grandes empresas del sector fintech se basan en modelos de caja negra, como redes neuronales profundas, que si bien pueden ofrecer alta precisión, carecen de explicabilidad y dificultan la comprensión de los factores que inciden en las recomendaciones (Guidotti et al., 2018). Esto resulta problemático en entornos regulados como el financiero, donde la trazabilidad y la auditoría de los sistemas automatizados son fundamentales.

Otra limitación significativa es la falta de contextualización local. Las herramientas desarrolladas en contextos internacionales no siempre se adaptan adecuadamente a las dinámicas económicas, culturales y regulatorias de países como Argentina. Por ejemplo, las soluciones de personalización basadas en estilos de vida o clasificaciones socioeconómicas no capturan las particularidades del consumo argentino, donde fenómenos como la inflación, el

uso intensivo del crédito o la economía informal pueden influir de manera determinante en los patrones de gasto (Saiag, 2020).

Finalmente, muchas de las soluciones existentes no están diseñadas para integrarse directamente con los sistemas operativos de empresas procesadoras de pagos, lo que genera fricciones al momento de su adopción. La ausencia de interfaces técnicas accesibles y de resultados orientados a la acción limita el impacto real de estas herramientas en la estrategia comercial de estas compañías.

Estas limitaciones dan lugar a una oportunidad clara de innovación, donde sistemas como el propuesto en el presente trabajo pueden ofrecer un enfoque más preciso, contextualizado y éticamente sólido, centrado en los datos reales de consumo y alineado con los objetivos estratégicos del sector.

2.2.4 Aporte diferencial del proyecto

Tras revisar las principales soluciones tecnológicas en la industria y los enfoques académicos existentes, se identifican varios aspectos en los que el proyecto PromoAI presenta un aporte diferencial, tanto desde el punto de vista técnico como del contexto de aplicación.

En primer lugar, si bien existen sistemas que aplican inteligencia artificial para predecir comportamientos financieros o personalizar ofertas comerciales, la mayoría de ellos están orientados a grandes mercados internacionales o integrados en plataformas bancarias tradicionales. PromoAI, en cambio, se posiciona dentro del ecosistema de empresas procesadoras de pagos en Argentina, como Prisma Medios de Pago o Fiserv, lo cual implica una adaptación a las particularidades del mercado local: su marco regulatorio, sus dinámicas de consumo, y la informalidad relativa de ciertos sectores de la economía.

En segundo lugar, el enfoque de personalización basada en patrones de consumo con tarjetas tiene como objetivo anticipar necesidades del usuario para ofrecer promociones verdaderamente útiles, y no simplemente aumentar el consumo. Esto difiere de muchas soluciones comerciales actuales, que tienden a utilizar sistemas de recomendación genéricos sin un análisis predictivo basado en series temporales u otros indicadores relevantes del comportamiento financiero individual.

Otro aporte distintivo de este proyecto radica en el énfasis en la explicabilidad de los modelos, lo que busca no solo ofrecer predicciones efectivas, sino también transparentes, entendibles y auditables para el usuario final y para la empresa que lo implemente. Esta

característica es crítica en el ámbito financiero, donde la confianza y la claridad sobre el uso de los datos son factores clave para la adopción de cualquier tecnología basada en inteligencia artificial.

Finalmente, cabe resaltar que, a diferencia de muchas investigaciones previas centradas exclusivamente en la precisión del modelo o el diseño algorítmico, PromoAI incluye un enfoque integral que contempla la implementación real en un flujo de negocio, conectando datos transaccionales reales con estrategias de marketing personalizadas, siempre bajo un marco ético y legal en materia de protección de datos personales.

En resumen, el proyecto se distingue por:

- Su aplicación en un sector y un país con escasa investigación previa en esta área específica.
- Su enfoque centrado en el usuario, con foco en la utilidad real de las promociones personalizadas.
- Su compromiso con la explicabilidad y la ética del uso de datos.
- Su orientación práctica, con potencial de implementación concreta en empresas procesadoras de pagos.

2.2.5 Conclusión del Estado del Arte

El análisis del estado del arte permite identificar que, si bien existen avances significativos en materia de analítica predictiva, sistemas de recomendación y personalización en diversos sectores, su aplicación directa al ámbito de los medios de pago en Argentina continúa siendo limitada. Las soluciones actuales se concentran principalmente en análisis descriptivo, segmentaciones generales o modelos predictivos orientados a otras finalidades, como la detección de fraude o el scoring crediticio, sin abordar de manera integral la personalización de promociones basada en datos transaccionales reales.

Asimismo, se observa que las plataformas internacionales representan la frontera tecnológica del sector, pero presentan barreras de adopción vinculadas a costos, infraestructura, privacidad y adaptación regulatoria. Por su parte, las fintechs y bancos digitales muestran un potencial de innovación creciente, aunque todavía sin integrar herramientas predictivas robustas orientadas a estrategias de fidelización automatizadas. En

conjunto, estas tendencias evidencian una brecha clara entre las capacidades tecnológicas disponibles y las necesidades específicas del ecosistema argentino de pagos electrónicos.

En este marco, el proyecto PromoAI se posiciona como una respuesta a dicha brecha, al proponer un enfoque predictivo, explicable y adaptado al contexto local, capaz de transformar datos transaccionales en estrategias de personalización alineadas con los requisitos normativos y operativos del sector. De esta manera, el relevamiento realizado no solo contextualiza el desarrollo del sistema, sino que también refuerza su pertinencia y su aporte potencial a la modernización del mercado de medios de pago en Argentina.

3 Descripción

En esta sección se realiza el análisis del proyecto PromoAI como solución al objetivo planteado en este proyecto.

3.1 User Research

El proceso de *User Research* o investigación de usuarios tiene como objetivo principal comprender los hábitos de consumo, percepciones y necesidades de los usuarios en relación con el uso de tarjetas de crédito y las promociones personalizadas. Esta instancia es fundamental para validar las hipótesis iniciales del proyecto y para diseñar una solución centrada en las necesidades reales de los usuarios.

La investigación se desarrolla en dos niveles complementarios. Por un lado, se realiza una encuesta a usuarios finales para conocer sus patrones de uso, percepción de las promociones actuales y predisposición a recibir ofertas personalizadas en función de sus consumos. Por otro lado, se consulta a un profesional del sector de medios de pago con amplia experiencia en el diseño de productos financieros, con el fin de obtener una perspectiva técnica sobre las posibilidades actuales y futuras de personalización en este campo.

Ambos enfoques permiten articular una visión integral de la problemática abordada, al combinar la perspectiva del usuario con la del experto del sector.

3.1.1 Encuestas a usuarios finales

Para obtener una visión representativa sobre los hábitos de consumo y percepciones de los usuarios en relación con el uso de tarjetas de crédito y promociones personalizadas, se realiza una encuesta dirigida a un total de 400 participantes. Este tamaño de muestra es elegido con el fin de balancear la profundidad del análisis con la factibilidad práctica del estudio.

La distribución geográfica de los encuestados se planifica considerando la proporción de población de las principales provincias argentinas, para reflejar la diversidad regional en el comportamiento de consumo. Se aseguran representaciones significativas de Buenos Aires, Córdoba, Santa Fe, Mendoza y otras regiones, cubriendo tanto áreas urbanas como

suburbanas, con el objetivo de captar posibles variaciones en patrones de gasto y uso de tarjetas.

En cuanto a la composición demográfica, se busca una distribución equilibrada por rangos de edad, desde jóvenes adultos (18-24 años) hasta personas mayores de 55 años. Además, la encuesta contempla variables como el tipo de entidad emisora de tarjeta (bancos tradicionales vs. fintechs) y frecuencia de uso, para analizar diferencias relevantes en comportamientos y preferencias.

Esta muestra permite identificar tendencias significativas y validar hipótesis relacionadas con la personalización de promociones en función del historial de consumo, aportando un soporte sólido y fundamentado para el desarrollo del sistema propuesto.

3.1.1.1 Metodología

Se utiliza un cuestionario de preguntas cerradas, segmentadas por temas: perfil demográfico, uso de tarjeta de crédito, hábitos de compra, percepción de promociones y apertura a la personalización predictiva. Los datos se recopilan de forma anónima y se utilizan con fines estrictamente académicos.

3.1.1.2 Perfil de encuestados

La mayoría de los participantes se ubica en el rango etario de 25 a 35 años (47.9%), seguido por personas de entre 35 y 44 años (13.5%) y de entre 45 y 54 años (14.6%). Todos los encuestados poseen una tarjeta de crédito, emitida en el 95% de los casos por bancos tradicionales y en un 5% por entidades fintech.

3.1.1.3 Hábitos de consumo

El 51.1% de los encuestados indica que utiliza su tarjeta de crédito menos de una vez por semana, mientras que un 28.9% lo hace varias veces por semana. Las categorías más frecuentes de gasto son: supermercados, indumentaria, suscripciones digitales (como Netflix o Spotify), viajes y artículos para el hogar. Estos resultados sugieren una diversidad de usos, tanto para necesidades básicas como para consumo ocasional.

En cuanto a la planificación de gastos, el 50% manifiesta mantener un equilibrio entre compras planificadas y espontáneas, mientras que el 33.3% declara planificar la mayoría de sus compras.

3.1.1.4 Percepción sobre promociones

Uno de los hallazgos más significativos fue la baja percepción de relevancia en las promociones recibidas actualmente. El 40% de los participantes las consideró “poco relevantes” y solo un 8.9% las calificó como “muy relevantes”. Además, el 37.8% indicó que “raramente” reciben promociones alineadas con sus intereses, y un 12.2% afirmó que nunca ha recibido una promoción que considere personalizada.

Entre los beneficios más valorados, las cuotas sin interés lideraron con un 64.4% de las respuestas, seguidas por descuentos únicos (16.7%) y devoluciones de dinero (13%).

3.1.1.5 Interés en soluciones predictivas

Una abrumadora mayoría (80%) expresó que le parecería muy útil que su banco pueda anticipar sus próximas compras para ofrecer promociones personalizadas. Otro 15% lo consideró una opción potencialmente útil. Solo un 5% manifestó no estar interesado en este tipo de servicio.

3.1.1.6 Conclusiones de encuestas

Los resultados muestran una clara brecha entre las promociones actualmente ofrecidas y las necesidades reales de los usuarios. Existe un amplio consenso en cuanto a la falta de personalización y relevancia de las campañas promocionales. Al mismo tiempo, los datos respaldan fuertemente la hipótesis de este trabajo: que existe una oportunidad tangible y valorada de mejorar la experiencia del usuario mediante un sistema de recomendaciones predictivas basadas en historial de consumo con tarjeta de crédito.

Esta evidencia empírica refuerza la viabilidad y pertinencia del sistema propuesto, indicando tanto una necesidad de mercado insatisfecha como una disposición favorable por parte de los usuarios a adoptar soluciones tecnológicas avanzadas en este ámbito.

3.1.2 Entrevista

Como complemento a la investigación cuantitativa, se realiza una entrevista a una profesional con amplia trayectoria en el sector de medios de pago, actualmente desempeñándose como especialista en Producto en Prisma Medios de Pago. El objetivo de esta entrevista es obtener una perspectiva técnica especializada sobre los desafíos del

ecosistema financiero actual, el uso de datos transaccionales y las oportunidades que ofrece la inteligencia artificial para la personalización de promociones.

La entrevistada identifica como principal desafío del sector la capacidad de adaptación frente a los cambios constantes en los hábitos de consumo, destacando la transición desde compras presenciales tradicionales hacia modalidades digitales y móviles que demandan inmediatez por parte de los usuarios. Este cambio cultural requiere que bancos y procesadoras diversifiquen sus canales y soluciones para responder a distintos perfiles de usuarios.

Respecto al uso de datos, confirma que si bien las procesadoras actualmente utilizan información agregada sobre transacciones (montos, frecuencias y categorías de comercios), existe un gran potencial subutilizado en el análisis profundo del comportamiento de consumo. Señala que las promociones actuales frecuentemente no están alineadas con los hábitos individuales, lo que reduce su efectividad y relevancia percibida.

En cuanto a segmentación, la especialista indica que el sector está transitando desde criterios tradicionales (edad, género, zona geográfica) hacia segmentaciones basadas en comportamiento, como frecuencia de compra y rubros preferidos, lo que permite diseñar promociones más efectivas y personalizadas.

Sobre los aspectos éticos y normativos, enfatiza la importancia de garantizar la privacidad del usuario mediante el trabajo con datos anonimizados, asegurar el consentimiento informado y respetar la normativa vigente. Además, destaca que los modelos predictivos deben ser transparentes y explicables para generar confianza en usuarios y organizaciones.

Finalmente, proyecta que el ecosistema avanza hacia un modelo donde los datos serán el insumo clave para diseñar experiencias personalizadas, permitiendo anticiparse a las necesidades de los usuarios mediante análisis predictivo e inteligencia artificial, siempre que se construya con responsabilidad, transparencia y enfoque en el valor real para el usuario.

3.1.2.1 Puntos clave de la entrevista

- Transformación digital y nuevos hábitos de consumo: Se destaca un cambio profundo en la forma en que los usuarios interactúan con los medios de pago. La digitalización ha desplazado el uso del efectivo y modificado las expectativas de los consumidores, quienes ahora demandan inmediatez y accesibilidad desde dispositivos móviles.

- Segmentación por comportamiento: La entrevistada señaló una transición desde segmentaciones tradicionales hacia modelos basados en comportamiento real de consumo. Esta evolución permite diseñar promociones más relevantes y efectivas para cada perfil de usuario.
- Subutilización de datos: A pesar de la disponibilidad de grandes volúmenes de datos transaccionales, muchas organizaciones aún no logran capitalizarlos plenamente para extraer insights predictivos que potencien la fidelización o la oferta de valor.
- Promociones personalizadas: La personalización de promociones a partir del historial de consumo es considerada una oportunidad clave. Se remarcó que la relevancia de las promociones actuales es baja, y que existe un amplio margen de mejora si se emplean técnicas de análisis predictivo.
- Ética y privacidad: La entrevistada enfatizó la importancia de trabajar con datos anonimizados y bajo estrictos principios de privacidad. Además, resaltó la necesidad de que los modelos utilizados sean comprensibles, auditables y transparentes para garantizar la confianza de los usuarios y el cumplimiento normativo.
- Tendencias del sector: Finalmente, se proyectó un futuro donde el análisis predictivo y la inteligencia artificial serán herramientas estratégicas para anticipar necesidades, automatizar decisiones y generar propuestas de valor ajustadas a los hábitos reales de los consumidores.

3.1.2.2 Conclusiones de la entrevista

Se concluye que la entrevista con la especialista Laura Miño permite visibilizar la importancia de comprender en profundidad los cambios en los hábitos de consumo, así como la necesidad de adaptar los servicios financieros a un entorno cada vez más digitalizado. La entrevistada destacó que el análisis de datos transaccionales y la segmentación basada en comportamiento representan una oportunidad estratégica para generar promociones más relevantes y efectivas. Asimismo, subrayó que el aprovechamiento responsable de la información requiere no solo capacidades técnicas, sino también el cumplimiento de principios éticos y regulatorios. Finalmente, se remarcó que la inteligencia artificial y el

análisis predictivo tendrán un rol cada vez más central en el diseño de experiencias personalizadas, siempre que se construyan con foco en el usuario y con transparencia.

3.2 Solución

El sistema propuesto, denominado PromoAI, es una plataforma de análisis predictivo orientada al aprovechamiento de los datos de consumo recopilados por empresas procesadoras de pagos, como Prisma Medios de Pago, con el objetivo de generar recomendaciones de promociones personalizadas para los usuarios finales de tarjetas de crédito. A través de este sistema, se transforman los grandes volúmenes de información transaccional en conocimiento accionable que puede ser monetizado mediante acuerdos estratégicos entre la procesadora de pagos y los bancos emisores de tarjetas.

Actualmente, compañías como Prisma cuentan con una vasta cantidad de datos provenientes de millones de transacciones realizadas diariamente por los usuarios en comercios físicos y virtuales. Sin embargo, esta información suele estar subutilizada y no se traduce en una propuesta de valor concreta para los bancos ni para sus clientes. El sistema propuesto busca llenar este vacío, aplicando técnicas de minería de datos y modelos de aprendizaje automático para identificar patrones de comportamiento de consumo, prever futuras compras y generar estrategias promocionales personalizadas y efectivas.

PromoAI no está orientado directamente al consumidor final, sino que se posiciona como una solución de Business Intelligence y *Customer Intelligence* (inteligencia de clientes) para ser implementada por Prisma y ofrecida como producto o servicio a los bancos clientes. De esta manera, los bancos pueden acceder a información procesada, segmentaciones inteligentes y recomendaciones basadas en datos reales, lo que les permite optimizar sus campañas de promociones, mejorar la fidelización de clientes y aumentar la tasa de utilización de las tarjetas de crédito.

Desde el punto de vista técnico, el sistema se estructura en diversos módulos especializados en la recolección, anonimización, análisis y presentación de datos. Esto garantiza la privacidad del usuario final y el cumplimiento de las normativas locales sobre protección de datos personales, a la vez que permite escalar la solución y adaptarla a distintos tipos de entidades financieras o necesidades comerciales.

3.2.1 Requerimientos y diseño

El diseño del sistema PromoAI se basa en la identificación clara de los requerimientos funcionales y no funcionales que guían su desarrollo. Estos requerimientos establecen las capacidades mínimas que el sistema debe poseer para alcanzar sus objetivos operativos, así como las propiedades de calidad que aseguran su desempeño, escalabilidad y confiabilidad en entornos productivos.

El propósito de esta sección es detallar las funciones que el sistema debe ejecutar, las restricciones técnicas y de seguridad que deben cumplirse, y los criterios de diseño que orientan la implementación de sus componentes principales: procesamiento de datos, modelado predictivo y generación de resultados accionables para la toma de decisiones comerciales.

3.2.1.1 Requerimientos Funcionales

Los requerimientos funcionales describen las operaciones que el sistema debe realizar para cumplir con sus objetivos de negocio. Cada requerimiento se formula de manera clara, verificable y orientada al resultado esperado.

- **RF1 - Generación de características del cliente:** El sistema debe procesar los datos transaccionales y demográficos disponibles para generar un conjunto de variables representativas del comportamiento de cada cliente. Entre ellas se incluyen la recencia (días desde la última transacción), la frecuencia (cantidad de transacciones en el período), el valor monetario total (gasto ajustado por inflación), la antigüedad del cliente y el monto promedio por transacción.
- **RF2 - Predicción del gasto futuro:** El sistema debe entrenar y ejecutar un modelo de aprendizaje automático capaz de estimar el gasto total proyectado de cada cliente en un período futuro, utilizando como entrada las características generadas en el RF1. El modelo debe captar relaciones temporales y patrones de comportamiento para producir predicciones numéricas precisas y consistentes.
- **RF3 - Exportación de resultados:** El sistema debe generar un conjunto de resultados que contenga el identificador anónimo de cada cliente junto con su valor de gasto estimado. Los resultados deben exportarse en formato .csv,

garantizando su compatibilidad con herramientas externas de análisis, tableros de visualización y sistemas de gestión comercial.

3.2.1.2 Requerimientos no funcionales

Los requerimientos no funcionales definen las propiedades de calidad que debe cumplir el sistema para garantizar su correcto funcionamiento en entornos reales de procesamiento de datos.

- **RNF1 - Escalabilidad y rendimiento:** El sistema debe procesar grandes volúmenes de datos de manera eficiente, manteniendo tiempos de ejecución razonables ante el crecimiento continuo del número de transacciones y clientes.
- **RNF2 - Precisión del modelo:** El modelo predictivo implementado debe alcanzar un nivel de desempeño validado mediante métricas estadísticas como el Coeficiente de Determinación (R^2), empleando técnicas de validación cruzada para garantizar su generalización a nuevos datos.
- **RNF3 - Seguridad y anonimización de los datos:** El sistema debe asegurar la protección de la identidad de los clientes mediante la aplicación de algoritmos de hashing irreversible sobre los identificadores personales, permitiendo su uso analítico sin comprometer la privacidad de los datos.

3.2.2 Casos de uso

Los casos de uso describen las interacciones entre los usuarios y el sistema, definiendo las principales operaciones que este debe realizar para cumplir sus objetivos funcionales. Permiten identificar los flujos de información, las condiciones de ejecución y las excepciones asociadas a cada proceso, sirviendo como guía para el diseño, desarrollo y validación del sistema PromoAI.

3.2.2.1 Caso de uso 1

Actor Principal: Usuario operativo

Descripción: Visualizar Dashboard Ejecutivo

Precondiciones: Usuario autenticado, datos disponibles

Flujo Principal:

- i. Usuario accede al dashboard principal
- ii. Sistema carga KPIs principales desde base de datos
- iii. Sistema calcula métricas
- iv. Sistema presenta visualizaciones

Postcondiciones: Dashboard actualizado mostrado

Excepciones:

E1: Datos no disponibles. Mostrar mensaje de error

E2: Timeout de carga. Mostrar datos cached

3.2.2.2 Caso de uso 2

Actor Principal: Usuario operativo

Descripción: Consultar KPIs Principales

Precondiciones: Dashboard cargado

Flujo Principal:

- i. Sistema calcula total de clientes activos
- ii. Sistema calcula gasto promedio predicho
- iii. Sistema identifica clientes de alto valor
- iv. Sistema cuenta campañas activas
- v. Sistema presenta métricas

Postcondiciones: KPIs actualizados y visibles

Extensiones:

E1: Aplicar filtros por segmento

E2: Drill-down en clientes alto valor

3.2.2.3 Caso de uso 3

Actor Principal: Usuario operativo

Actor Secundario: Sistema ML

Descripción: Generar Predicción Individual

Precondiciones: Cliente seleccionado, modelo ML disponible

Flujo Principal:

- i. Sistema extrae características del cliente
- ii. Sistema prepara datos para modelo ML

- iii. Sistema ML procesa predicción
- iv. Sistema ML calcula intervalo de confianza
- v. Sistema almacena resultado en historial
- vi. Sistema presenta predicción formateada

Postcondiciones: Predicción generada y almacenada

Excepciones:

E1: Modelo ML no disponible. Usar predicción cached

E2: Datos insuficientes. Solicitar información adicional

3.2.2.4 Caso de uso 4

Actor Principal: Usuario operativo

Actor Secundario: Sistema ML

Descripción: Ejecutar Predicción por Lotes

Precondiciones: Lista de clientes

Flujo Principal:

- i. Usuario selecciona conjunto de clientes
- ii. Sistema valida tamaño del lote
- iii. Sistema prepara datos en formato batch
- iv. Sistema ML procesa lote completo
- v. Sistema almacena resultados
- vi. Sistema genera reporte de procesamiento

Postcondiciones: Predicciones por lotes completadas

Variaciones: Procesamiento asíncrono para lotes grandes

3.2.2.5 Caso de uso 5

Actor Principal: Usuario operativo

Descripción: Analizar Segmentos RFM (Recencia, Frecuencia y Valor Monetario)

Precondiciones: Datos de transacciones disponibles

Flujo Principal:

- i. Sistema calcula métricas RFM para todos los clientes
- ii. Sistema aplica algoritmo de segmentación
- iii. Sistema asigna clientes a segmentos

iv. Sistema calcula estadísticas por segmento

v. Sistema presenta distribución visual

Postcondiciones: Segmentación RFM actualizada

Extensiones: Personalización de umbrales de segmentación

3.2.2.6 Caso de uso 6

Actor Principal: Usuario operativo

Descripción: Visualizar Distribución Segmentos

Precondiciones: Segmentación completada

Flujo Principal:

i. Sistema genera gráfico de distribución

ii. Sistema calcula porcentajes por segmento

iii. Sistema presenta métricas promedio

iv. Usuario puede hacer drill-down por segmento

v. Sistema muestra evolución temporal

Postcondiciones: Visualización disponible

3.2.2.7 Caso de uso 7

Actor Principal: Usuario operativo

Descripción: Generar Recomendaciones

Precondiciones: Análisis de segmentos disponible

Flujo Principal:

i. Sistema analiza características de cada segmento

ii. Sistema aplica reglas de negocio predefinidas

iii. Sistema genera recomendaciones específicas

iv. Sistema prioriza recomendaciones por impacto

v. Sistema presenta recomendaciones categorizadas

Postcondiciones: Recomendaciones inteligentes generadas

3.2.2.8 Caso de uso 8

Actor Principal: Usuario operativo

Actor Secundario: Sistema Externo

Descripción: Cargar Datos CSV

Precondiciones: Archivo CSV válido, permisos de administrador

Flujo Principal:

- i. Usuario selecciona archivo CSV
- ii. Sistema valida formato y estructura
- iii. Sistema verifica integridad de datos
- iv. Sistema procesa registros en lotes
- v. Sistema actualiza base de datos
- vi. Sistema genera reporte de carga

Postcondiciones: Datos cargados exitosamente

Excepciones:

E1: Formato inválido. Mostrar errores específicos

E2: Datos duplicados. Aplicar estrategia de merge

3.2.3 Arquitectura y Diagramas Funcionales

Para comprender el flujo de información y la interacción entre los distintos componentes del sistema, se definen cuatro diagramas de secuencia clave que ilustran las operaciones principales del backend (lógica del servidor y procesamiento interno) y el frontend (interfaz gráfica del usuario).

3.2.3.1 Secuencia: Carga del dashboard

La Figura 2 describe el flujo inicial de carga de la página principal.

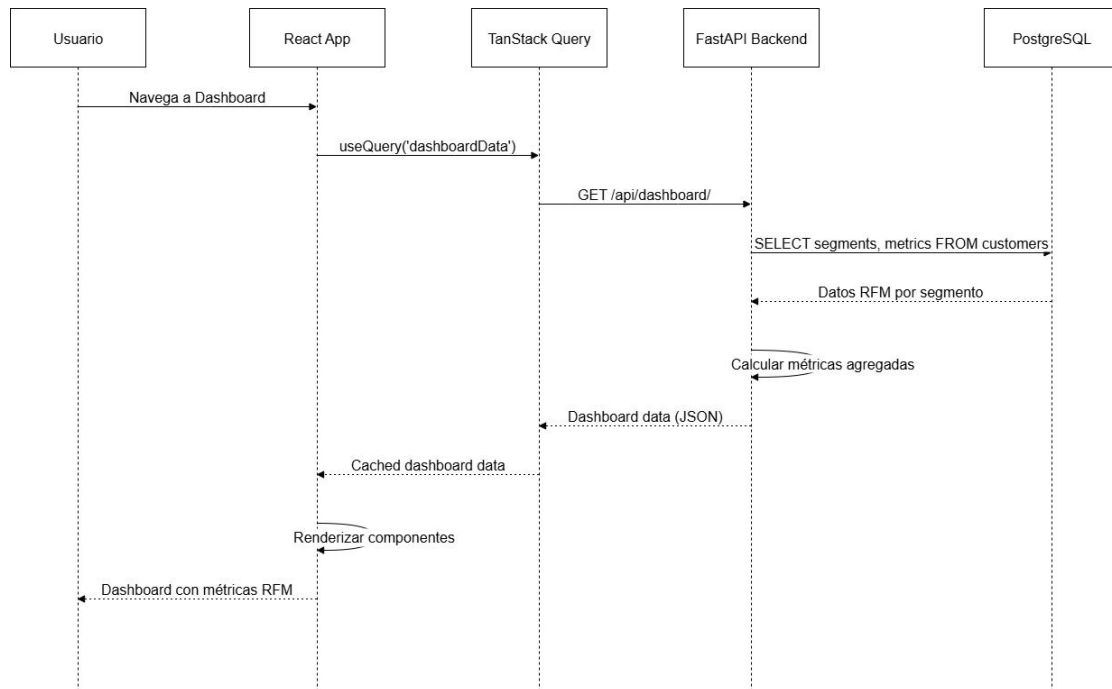


Figura 2: Diagrama de secuencia: Carga del dashboard (Elaboración propia)

Flujo Operacional:

- El Usuario (U) navega a la página del Dashboard.
- La React App (R) invoca a TanStack Query (TQ) para solicitar los datos agregados (useQuery('dashboardData')).
- Si los datos no están en caché o están desactualizados, TQ realiza una solicitud GET al endpoint /api/dashboard/ del FastAPI Backend (API).
- La API (Interfaz de Programación de Aplicaciones) ejecuta una consulta SELECT en PostgreSQL (DB) para obtener las métricas RFM y de segmento.
- DB devuelve los datos requeridos. La API calcula internamente métricas finales agregadas (ej. gasto promedio general).
- La API responde a TQ con los datos en formato JSON.
- TQ almacena los datos en caché y los entrega a la React App (R).
- La React App utiliza los datos para renderizar los componentes visuales, mostrando el Dashboard al Usuario.

3.2.3.2 Secuencia: Predicción individual de cliente

La secuencia representada en la Figura 3 es crítica, ya que detalla el flujo de ejecución del modelo de Machine Learning para obtener una predicción en tiempo real.

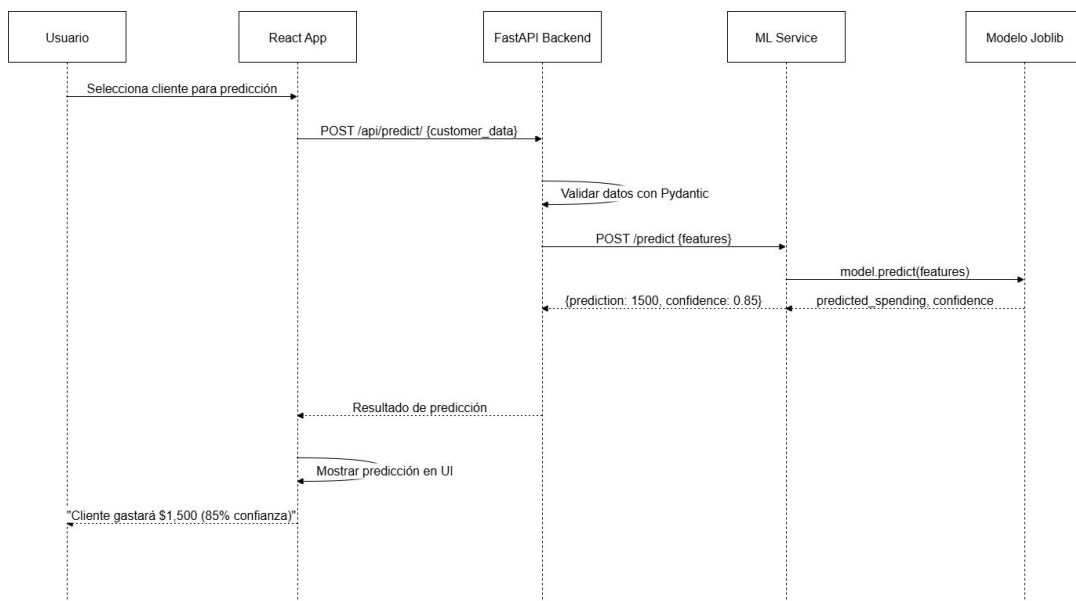


Figura 3: Diagrama de secuencia: Predicción individual de cliente (Elaboración propia)

Flujo Operacional:

- El Usuario (U) selecciona la opción para obtener una predicción de gasto específica para un cliente en la React App (R).
- R envía una solicitud POST al endpoint /api/predict/ de la API, incluyendo los datos del cliente (customer_data).
- La API realiza una Validación de Datos con Pydantic para asegurar que los features (características utilizadas por el modelo) entrantes cumplen con el esquema de datos esperado por el modelo.
- La API reenvía la solicitud al ML Service (componente backend que ejecuta el modelo) a su endpoint /predict.
- El ML Service carga el Modelo Joblib (biblioteca de Python para almacenar y cargar modelos) en memoria y ejecuta la función model.predict (features) con los datos proporcionados.
- El Modelo devuelve la predicción numérica (predicted_spending) y el nivel de certeza o confianza.

- El ML Service retorna el resultado a la API.
- La API devuelve el resultado de la predicción a la React App.
- La React App muestra el resultado de forma legible al Usuario.

3.2.3.3 Secuencia: Inteligencia de campañas

La Figura 4 ilustra cómo la interfaz utiliza los datos en caché para realizar cálculos de negocio complejos del lado del frontend, priorizando la velocidad y la simulación interactiva.



Figura 4: Diagrama de secuencia: Inteligencia de campañas (Elaboración propia)

Flujo Operacional:

- El Usuario (U) accede al módulo de Campaign Intelligence (CI).
- CI solicita los datos de análisis por segmento a través de TanStack Query (TQ), que realiza una solicitud a la API.
- La API obtiene datos complejos de análisis por segmento de PostgreSQL (DB) (tabla segments_analysis).
- La API responde a TQ y los datos se almacenan en caché, siendo entregados a CI.

- Una vez que CI posee los datos, los siguientes procesos se ejecutan localmente en el frontend para garantizar la inmediatez:
- `calculatePredictions(segmentData)`: Generación de métricas predictivas para cada segmento.
- `generateRecommendations()`: Aplicación de reglas de negocio para proponer acciones (ej. aumentar gasto en segmento Alto Valor).
- `calculateBudgetSimulation()`: El núcleo de la interactividad, que permite al usuario manipular sliders y ver el impacto del presupuesto en tiempo real.
- CI muestra el Dashboard final al Usuario, incluyendo las predicciones, las recomendaciones inteligentes y el simulador.

3.2.3.4 Secuencia: Análisis de segmentos

La Figura 5 describe el proceso de solicitud de métricas detalladas para el análisis de los segmentos RFM.

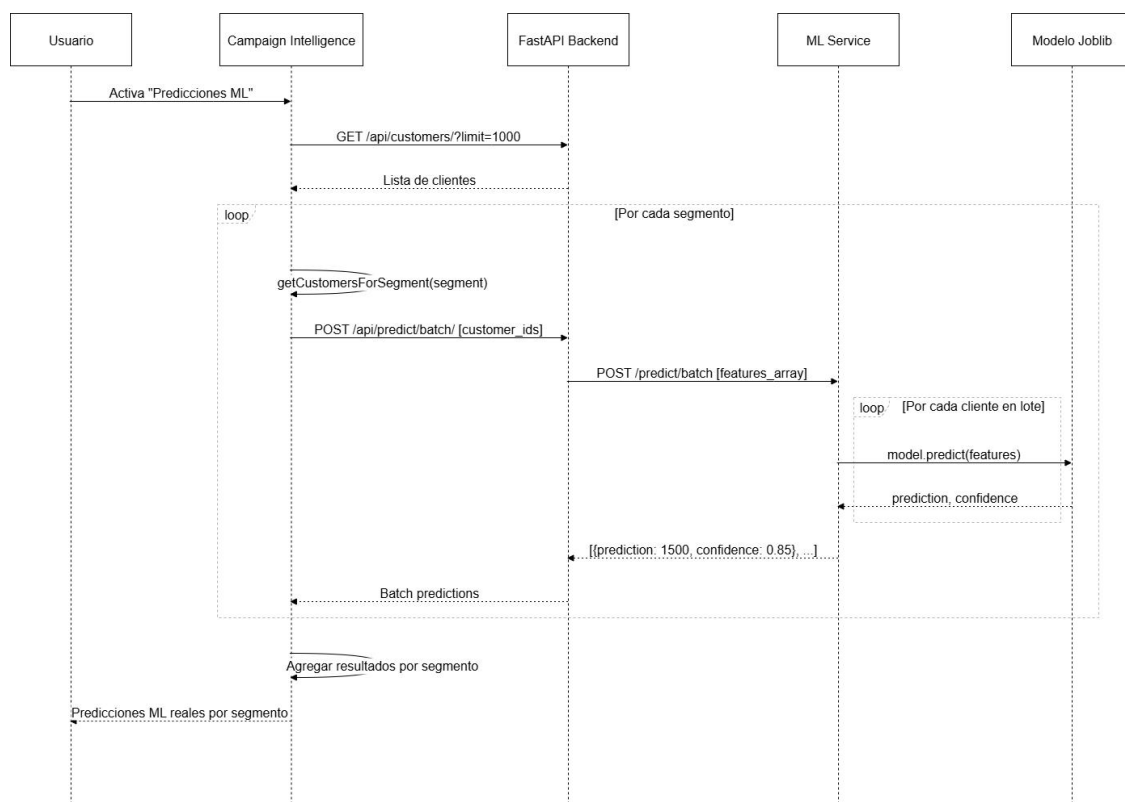


Figura 5: Diagrama de secuencia: Análisis de segmentos (Elaboración propia)

Flujo Operacional:

- El Usuario (U) accede a la página de análisis de segmentos (SP).

- SP solicita los datos de análisis a través de TanStack Query (TQ), que realiza una solicitud GET al endpoint `/api/segments/`.
- La API ejecuta una consulta compleja de análisis RFM en PostgreSQL (DB), agregando métricas como `customer_count`, `avg_spending`, `avg_recency`, y `avg_frequency` por segmento.
- DB retorna las métricas detalladas a la API.
- La API realiza cálculos adicionales (insights) antes de retornar los datos.
- La API responde a TQ con los datos, los cuales son almacenados en caché.
- SP utiliza los datos para renderizar el Dashboard de segmentos, mostrando la distribución, las métricas promedio y las oportunidades de mejora al Usuario.

3.2.4 Interface Gráfica

El sistema PromoAI se estructura en cuatro módulos interconectados, cada uno diseñado para cumplir un rol específico en el ciclo de vida predictivo del cliente, desde el análisis ejecutivo hasta la ejecución de la campaña.

3.2.4.1 Dashboard

El módulo Dashboard sirve como la vista ejecutiva y centralizada de alto nivel del sistema. Su propósito primario es proporcionar una visión rápida y consolidada del estado de la cartera de clientes.

Funcionalidad Clave:

- KPIs Predictivos: Presenta métricas clave que miden el rendimiento futuro, destacando el Gasto Promedio Predicho y la concentración de Clientes de Alto Valor.
- Visualizaciones de Tendencia: Incluye gráficos interactivos para la distribución de gastos por rangos y la segmentación de clientes, permitiendo una comprensión inmediata de la composición del mercado.
- Análisis Exploratorio: Facilita el filtrado temporal y el drill-down en métricas específicas.

Este módulo está optimizado para Ejecutivos C-Level y Marketing Managers, quienes requieren insights rápidos y el control sobre las tendencias generales del negocio.

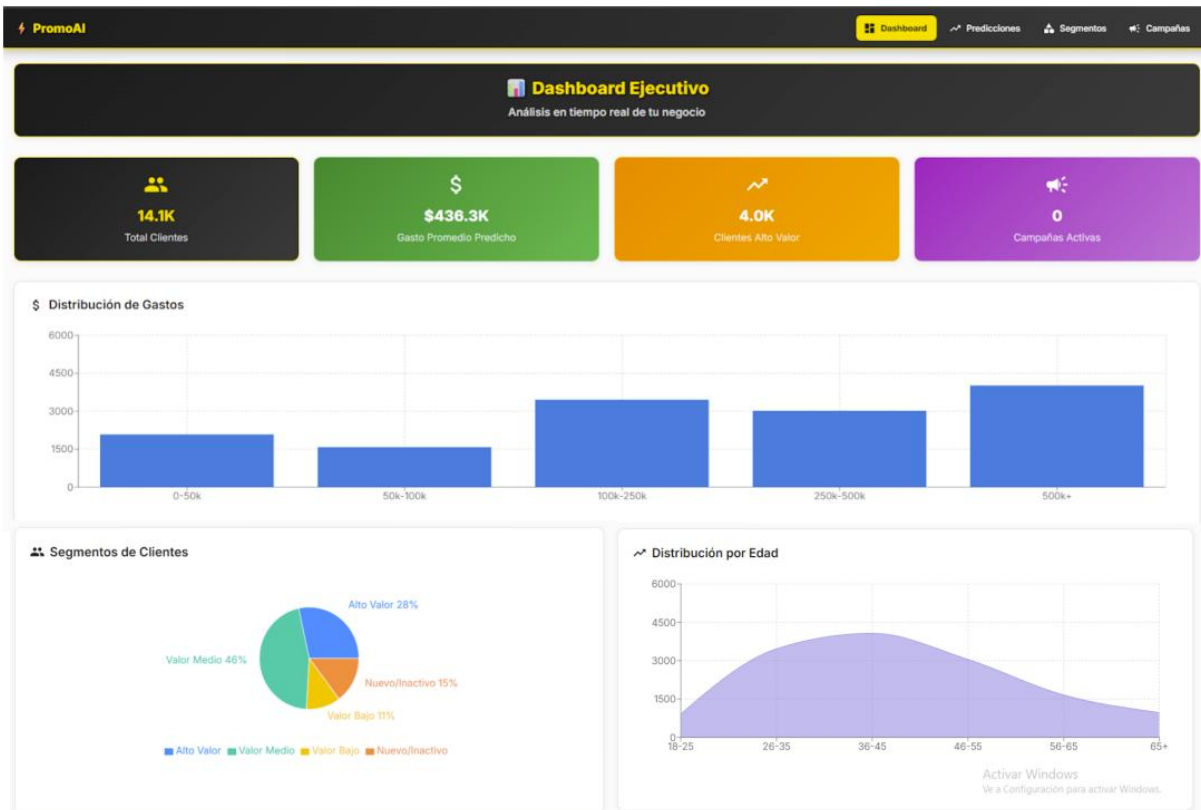


Figura 6: Pantalla Dashboard (Elaboración propia)

3.2.4.2 Predicciones

El módulo Predicciones gestiona el proceso de análisis predictivo de gasto, integrando directamente la funcionalidad del servicio de Machine Learning desarrollado. Su función es la orquestación de la inferencia del modelo.

Funcionalidad Clave:

- **Inferencia en Tiempo Real:** Permite la generación de predicciones individuales para clientes específicos y la ejecución de predicciones masivas por lotes.
- **Procesamiento de Features:** Se comunica con el ML Service para procesar las características del cliente (features), como la recencia, frecuencia, monto promedio, y variables demográficas.
- **Reporte de Confianza:** Retorna la predicción de gasto futuro junto con el intervalo de confianza asociado al modelo.

- Validación y Auditoría: Mantiene un historial de las predicciones realizadas y facilita la validación continua de la precisión del modelo.

Este módulo es la herramienta principal para Analistas de Datos y Customer Success Managers, quienes basan sus decisiones estratégicas en resultados cuantificables y modelos validados

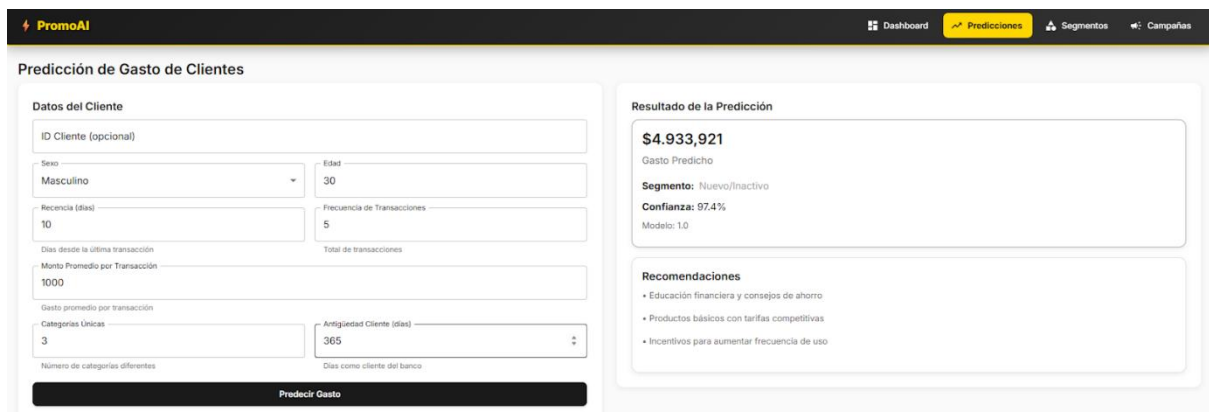


Figura 7: Pantalla Predicciones (Elaboración propia)

3.2.4.3 Segmentos

El módulo Segmentos se encarga de la clasificación estratégica y el análisis estructural de la base de clientes mediante la implementación de la metodología RFM (Recencia, Frecuencia, Monetario).

Funcionalidad Clave:

- Clasificación Automática: Calcula las métricas RFM y asigna automáticamente a los clientes a categorías estratégicas en función de su comportamiento transaccional.
- Análisis Estructural: Presenta distribuciones visuales de segmentos, métricas promedio por categoría y la evolución temporal de la segmentación.
- Insights Estratégicos: Genera insights automatizados sobre las características demográficas y comportamentales de cada segmento, identificando oportunidades de intervención o mejora.

Este módulo es fundamental para Marketing Managers y Analistas de Negocio que buscan comprender la composición de la cartera para diseñar estrategias de comunicación y retención.

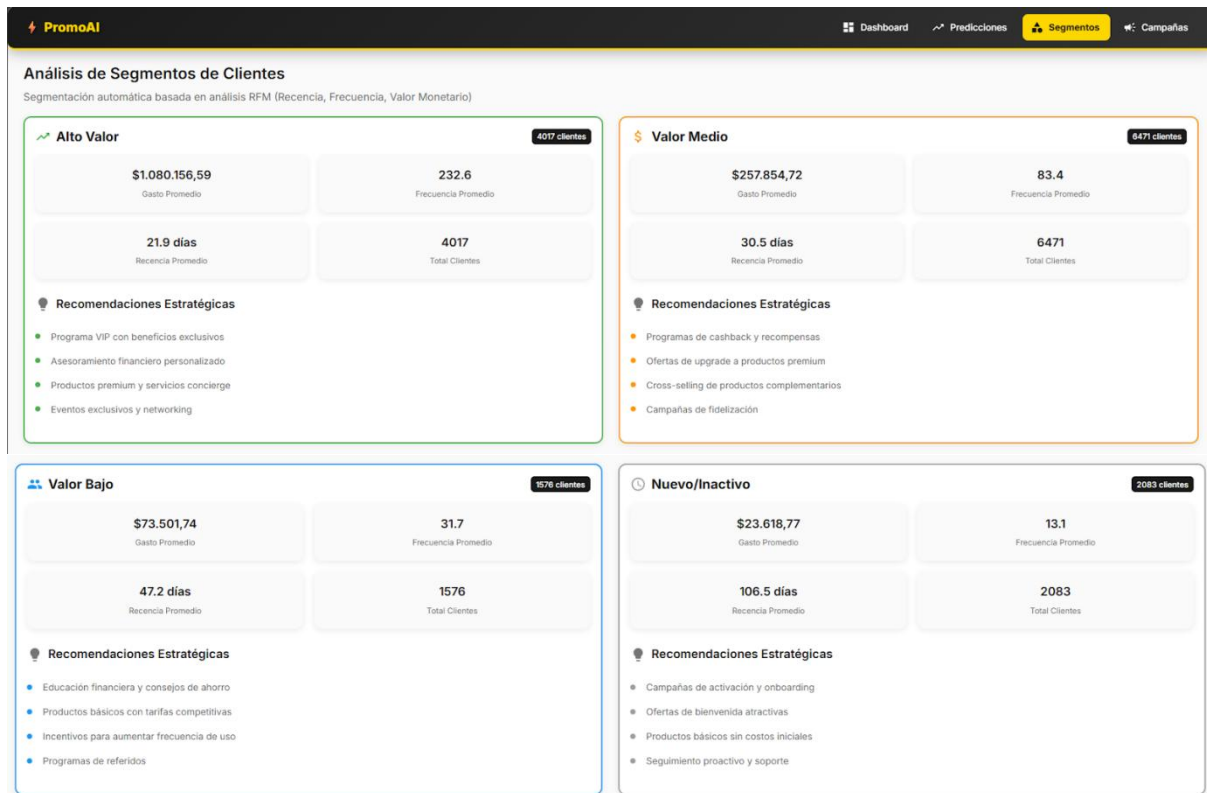


Figura 8: Pantalla Segmentos (Elaboración propia)

3.2.4.4 Campañas

El módulo Campañas representa la capa de inteligencia aplicada, convirtiendo las predicciones y la segmentación en estrategias de marketing optimizadas.

Funcionalidad Clave:

- **Cálculo de Rentabilidad:** Utiliza la segmentación RFM y las predicciones de gasto ML para calcular los ingresos esperados y sugerir la distribución óptima de presupuesto por segmento.
- **Simulador Interactivo:** Incorpora un simulador what-if que permite a los usuarios ajustar presupuestos en tiempo real para visualizar el impacto estimado en el ROI y el alcance de la campaña.
- **Recomendaciones Inteligentes:** Genera sugerencias de acción basadas en reglas de negocio y análisis de comportamiento, específicas para cada segmento (ej. priorizar retención sobre adquisición).

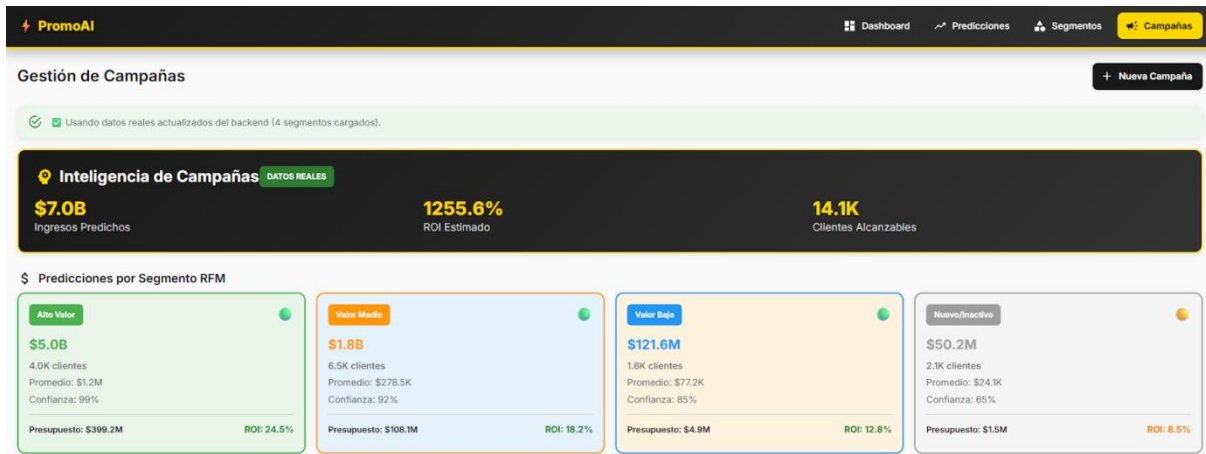


Figura 9: Pantalla cálculo de rentabilidad (Elaboración propia)

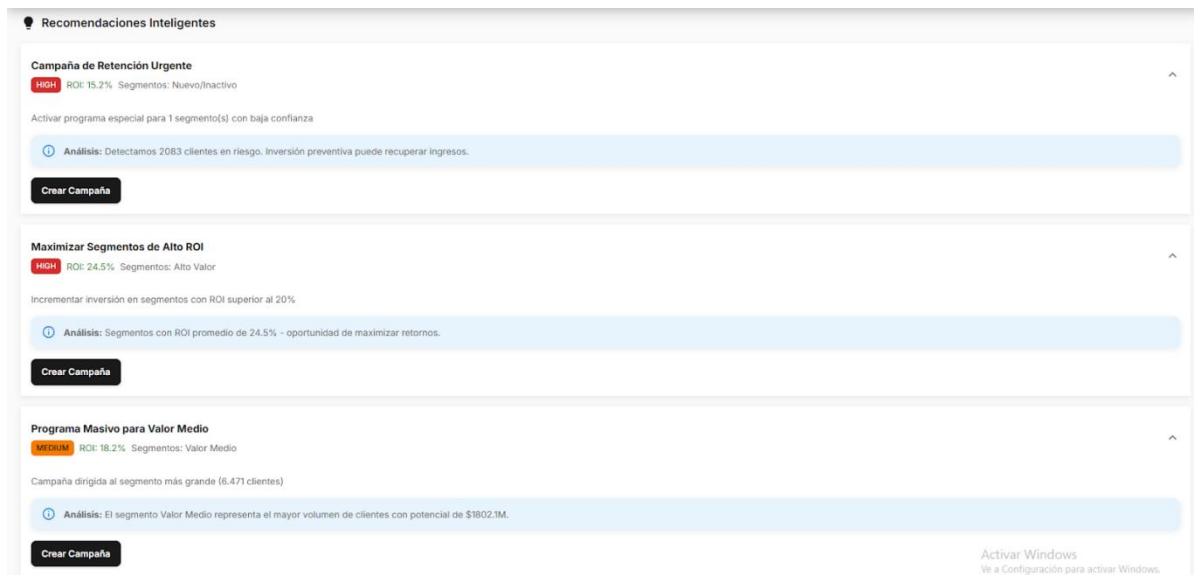


Figura 10: Pantalla recomendaciones inteligentes (Elaboración propia)




Figura 11: Pantalla simulador interactivo (Elaboración propia)

3.2.5 Arquitectura y modelo de datos

La arquitectura y el modelo de datos del sistema PromoAI fueron diseñados para garantizar eficiencia, seguridad y escalabilidad en el tratamiento de información transaccional. Ambos componentes se integran para soportar el flujo completo de procesamiento: desde la

ingesta y transformación de datos anonimizados, hasta la generación de predicciones y su posterior visualización por los equipos analíticos. Esta estructura permite un desarrollo modular, adaptable y alineado con los estándares de la industria financiera.

3.2.5.1 Arquitectura de la solución

La arquitectura del sistema ha sido diseñada para responder a los requerimientos específicos del proyecto: capturar datos históricos anonimizados, preprocesarlos adecuadamente, aplicar modelos de aprendizaje automático para identificar patrones de consumo, segmentar usuarios y presentar los resultados a los equipos internos de la procesadora de pagos mediante una interfaz técnica clara y eficiente.

La arquitectura de la solución se concibe en una estructura de capas que garantiza la modularidad y la escalabilidad del sistema. Cada capa cumple un rol específico en el proceso, desde la ingesta de datos hasta la generación del resultado final, asegurando una separación clara de responsabilidades.

- **Capa de Origen de Datos:** En la base de la arquitectura se encuentra la fuente de datos primigenia: el sistema transaccional del banco. Este sistema contiene las tablas relacionales que registran los movimientos de las tarjetas de los clientes, sus datos demográficos y la categorización de los rubros de gasto.
- **Capa de Procesamiento y Transformación:** Esta capa es el motor de la solución. Utiliza un motor de base de datos para ejecutar consultas SQL que extraen, agregan y limpian los datos. En esta etapa, se aplican transformaciones críticas como la anonimización del DNI y el ajuste de los montos por inflación. Posteriormente, se emplea Python con la librería pandas para refinar el dataset, realizar la ingeniería de características final y prepararlo para el modelado.
- **Capa de Machine Learning:** En esta capa se aloja el modelo predictivo. Se utiliza la librería scikit-learn en Python para entrenar el RandomForestRegressor. El modelo es el encargado de aprender los patrones de gasto a partir del dataset de entrenamiento y de generar las predicciones para los nuevos clientes.
- **Capa de Salida:** Esta es la capa final, responsable de entregar los resultados. El producto de la predicción, un archivo .csv, se genera para que pueda ser

fácilmente consumido por otras plataformas. Este formato universal permite que el área de negocio o los sistemas de visualización de datos accedan a las predicciones sin dependencias técnicas adicionales.

3.2.5.2 Modelo de datos

La procesadora de pagos provee un conjunto de vistas relacionales que constituyen la base para la construcción del sistema. Estas vistas están diseñadas bajo un modelo orientado a transacciones, con un núcleo central representado por la tabla movimiento_presentado, la cual se relaciona con dimensiones complementarias como cuenta, tarjeta, sucursal, rubro e ipc_data.

Un aspecto clave del modelo es el uso sistemático de campos *hasheados* (tokenizados), que permiten mantener la trazabilidad entre entidades y operaciones sin exponer datos sensibles. Este enfoque asegura el cumplimiento de la Ley 25.326 de Protección de Datos Personales y de las regulaciones del BCRA, al tiempo que habilita el análisis estadístico y predictivo.

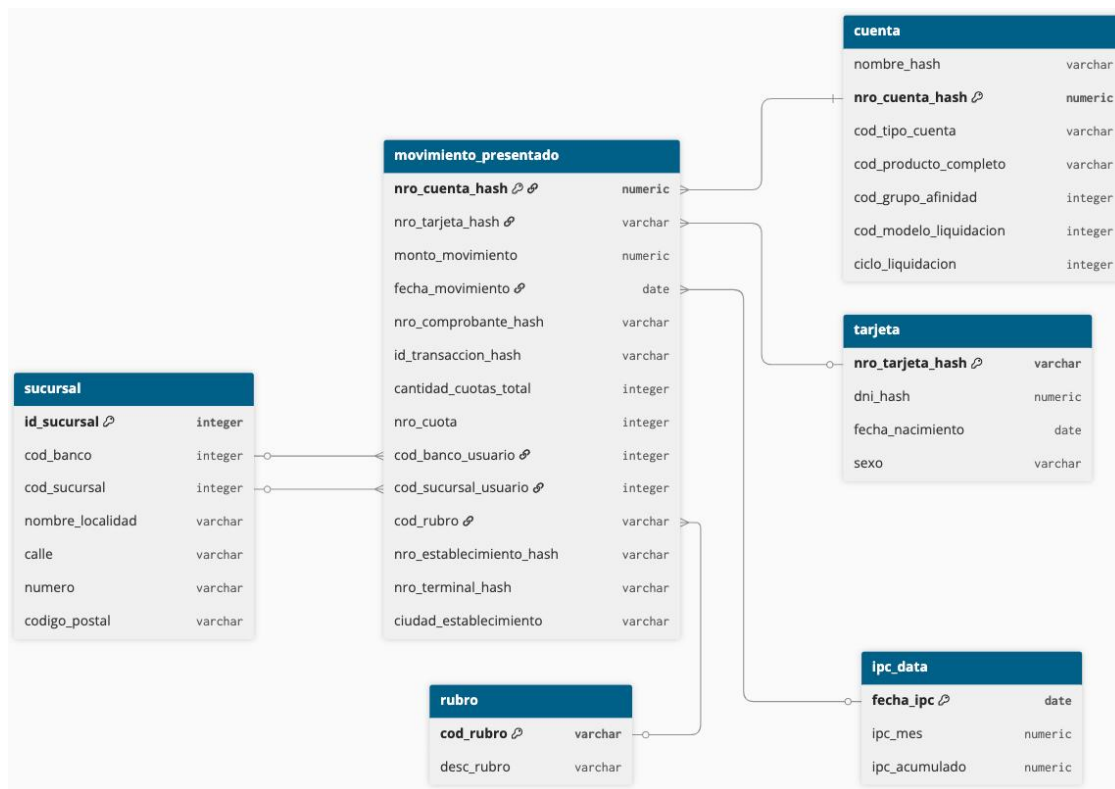


Figura 12: Diagrama de estructura de datos (Elaboración propia)

- **movimiento_presentado:** Tabla central del modelo, contiene el detalle de cada transacción realizada por los usuarios.
 - Identificadores tokenizados: nro_cuenta_hash, nro_tarjeta_hash, nro_comprobante_hash, id_transaccion_hash, nro_establecimiento_hash, nro_terminal_hash.
 - Datos financieros: monto_movimiento, cantidad_cuotas_total, nro_cuota.
 - Contexto de la operación: fecha_movimiento, ciudad_establecimiento, cod_rubro.
 - Vínculos institucionales: cod_banco_usuario, cod_sucursal_usuario.
- **cuenta:** Describe el producto financiero asociado, con atributos como cod_tipo_cuenta, cod_producto_completo, cod_grupo_afinidad y ciclo_liquidacion. Esto permite clasificar usuarios por tipo de cuenta y condiciones de uso.
- **tarjeta:** Contiene información vinculada a la tarjeta tokenizada (nro_tarjeta_hash), incluyendo dni_hash, fecha_nacimiento y sexo, lo cual habilita segmentaciones demográficas generales bajo un esquema anonimizado.
- **sucursal:** Representa la entidad física del banco vinculada a la operación. Incluye cod_banco, cod_sucursal, nombre_localidad, calle, número y codigo_postal. Esto habilita análisis geográficos y territoriales.
- **rubro:** Tabla de referencia que categoriza la actividad comercial del establecimiento. A través de cod_rubro y desc_rubro, permite clasificar los consumos en sectores económicos homogéneos.
- **ipc_data:** Fuente externa de contexto económico, que integra el índice de precios al consumidor (ipc_mes, ipc_acumulado) asociado a una fecha_ipc. Su inclusión habilita correlacionar la evolución de consumos con la variación inflacionaria.

3.2.5.3 Análisis de la estructura

El diseño refleja un modelo en estrella donde la tabla de hechos (movimiento_presentado) se vincula con distintas dimensiones descriptivas (cuenta, tarjeta, sucursal, rubro e ipc_data).

- Escalabilidad analítica: el modelo permite integrar nuevas métricas derivadas (propensión de compra, elasticidad frente a promociones, estacionalidad) sin modificar la estructura base.
- Flexibilidad de segmentación: los vínculos entre dimensiones habilitan análisis tanto individuales (por usuario tokenizado) como agregados (por rubro, sucursal, banco o región).
- Cumplimiento normativo: los campos con sufijo `_hash` aseguran anonimización en origen, evitando la exposición de información sensible y cumpliendo con la normativa vigente.

No obstante, la anonimización también impone ciertas limitaciones: la granularidad demográfica es acotada y la localización se restringe a nivel de sucursal o ciudad generalizada. Estas restricciones, si bien limitan la hiperpersonalización, garantizan un equilibrio adecuado entre valor analítico y protección de la privacidad.

La estructura de las vistas entregadas por la procesadora constituye un insumo robusto y seguro para el desarrollo de modelos de predicción y segmentación en PromoAI, combinando riqueza transaccional, contexto económico y privacidad por diseño.

3.2.5.4 Diagrama de arquitectura

La solución propuesta se implementa como una aplicación web alojada en infraestructura de nube, utilizando los servicios de Amazon Web Services (AWS). La elección de esta plataforma responde a la necesidad de contar con un entorno confiable, escalable y seguro para el procesamiento de datos financieros, cumpliendo con los estándares exigidos por la normativa vigente y garantizando la disponibilidad continua del servicio. Entre los beneficios de la arquitectura adoptada se destacan:

- Alta disponibilidad: La aplicación se distribuye en múltiples zonas de disponibilidad, lo que asegura la continuidad del servicio ante fallas de hardware o interrupciones en un centro de datos.
- Seguridad integral: Los datos se encuentran cifrados en tránsito y en reposo, reforzados mediante firewalls, autenticación robusta y mecanismos de auditoría.
- Protección ante ataques: Servicios como AWS Shield y AWS WAF permiten mitigar intentos de intrusión o ataques de denegación de servicio.

- **Baja latencia:** El uso de Amazon CloudFront como red de distribución de contenidos (CDN) reduce los tiempos de respuesta y permite acceso ágil desde cualquier ubicación geográfica.
- **Escalabilidad automática:** A través de Auto Scaling Groups, la cantidad de servidores de aplicación puede incrementarse o reducirse dinámicamente según la demanda.
- **Flexibilidad y modularidad:** La arquitectura basada en microservicios y servicios administrados de AWS facilita la incorporación de nuevas funcionalidades sin comprometer la estabilidad del sistema.

La arquitectura se compone de los siguientes elementos principales:

- **Amazon Route 53:** Servicio de DNS encargado de gestionar el enrutamiento del tráfico hacia la aplicación.
- **Amazon Cognito:** Provee autenticación y administración de usuarios de manera segura.
- **Amazon API Gateway:** Actúa como puerta de enlace para la comunicación entre el cliente y los servicios internos.
- **Amazon CloudFront y Amazon S3:** Utilizados para la distribución eficiente de contenido y almacenamiento estático de respaldo.
- **AWS Certificate Manager (ACM):** Gestiona los certificados digitales que garantizan la comunicación segura mediante HTTPS.
- **Application Load Balancer (ALB):** Distribuye las solicitudes entrantes hacia las instancias de aplicación alojadas en Amazon EC2, balanceando la carga entre múltiples zonas de disponibilidad.
- **Amazon EC2 (con Auto Scaling Group):** Ejecuta los servidores de aplicación, ajustando los recursos disponibles en función de la demanda.
- **Amazon RDS con PostgreSQL:** Base de datos relacional administrada, configurada con replicación y respaldo para garantizar disponibilidad y consistencia de la información.

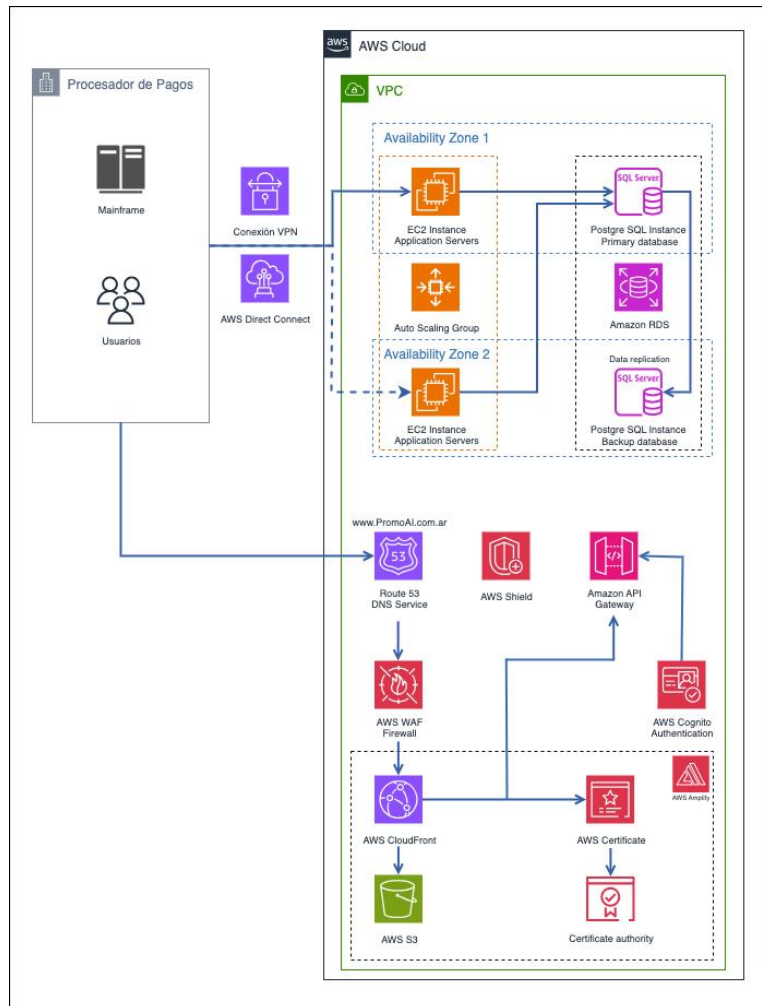


Figura 13: Diagrama de arquitectura (Elaboración propia)

3.2.6 Desarrollo y Entrenamiento del Modelo

Esta sección describe el proceso completo de construcción del modelo predictivo implementado en PromoAI, desde la selección de las tecnologías utilizadas hasta la preparación de los datos, el entrenamiento del algoritmo y la generación de las salidas finales. El objetivo es detallar las etapas técnicas que permiten transformar los datos transaccionales anonimizados en información útil para la toma de decisiones estratégicas.

3.2.6.1 Tecnologías Utilizadas

La solución se implementa utilizando un conjunto de herramientas de código abierto, seleccionadas por su robustez, rendimiento y amplio soporte comunitario en el campo de la ciencia de datos.

Lenguajes de Programación: SQL para la extracción, limpieza y agregación de datos directamente en el origen, y Python para las etapas de procesamiento, modelado y exportación.

Librerías de Python:

- **Pandas:** Fundamental para la manipulación y transformación de los datos, incluyendo operaciones de limpieza y la ingeniería de características.
- **Scikit-learn:** La base de la solución de machine learning, proporcionando los algoritmos de modelado (RandomForestRegressor), así como las métricas de evaluación y las herramientas de validación cruzada.
- **Matplotlib y Seaborn:** Utilizadas para la visualización de datos y el análisis de los residuos del modelo.
- **Joblib:** Empleada para la serialización del modelo entrenado, lo que permite guardarlo en un archivo para su uso posterior sin necesidad de reentrenarlo.

3.2.6.2 Recolección y Preparación de Datos

- **Ingeniería de Características:** Se ejecuta una consulta SQL avanzada sobre las tablas de datos transaccionales para generar métricas agregadas por cada cliente. Esto incluye el cálculo de la Recencia (días desde la última compra), la Frecuencia (número total de transacciones) y el Valor Monetario (suma de todos los montos de compra). Adicionalmente, se obtienen otras características demográficas y de comportamiento, como la edad, el sexo, la antigüedad del cliente y la cantidad de categorías de gasto únicas.
- **Ajuste por Inflación:** Para garantizar que el valor monetario de las transacciones refleje el poder adquisitivo real, se deflacta cada monto de transacción utilizando un IPC externo. Este ajuste se realiza en el proceso de agregación SQL, dividiendo cada monto por el IPC acumulado del mes y año correspondiente a la transacción.

3.2.6.3 Entrenamiento y Validación del Modelo

El modelo predictivo, un RandomForestRegressor, se entrena para predecir el gasto futuro del cliente. Se elige este algoritmo debido a su capacidad para manejar relaciones no lineales y su resistencia al sobreajuste.

El dataset final se divide en un conjunto de entrenamiento (80% de los datos) y un conjunto de prueba (20%). El modelo se entrena exclusivamente con el conjunto de entrenamiento para luego ser evaluado con los datos de prueba, lo que garantiza una evaluación imparcial de su rendimiento.

El rendimiento del modelo se mide utilizando el Coeficiente de Determinación (R^2), que cuantifica la proporción de la varianza del gasto de los clientes que es explicada por el modelo. Un valor alto de R^2 indica una fuerte capacidad predictiva.

Se realiza un análisis visual de los residuos (la diferencia entre los valores reales y los predichos). La distribución de los residuos se evalúa para confirmar que es aleatoria y centrada en cero, lo que valida que el modelo no tiene sesgos sistemáticos en sus predicciones.

Para asegurar la robustez del modelo y su capacidad de generalizar a nuevos datos, se utiliza la validación cruzada con 5 pliegues (K-Fold). Este proceso reentrena y revalida el modelo cinco veces en diferentes subconjuntos de datos, confirmando que su rendimiento es estable y no depende de una división específica de los datos.

Una vez que el modelo supera satisfactoriamente todas las validaciones, se entrena por última vez con el 100% del dataset disponible para maximizar su precisión. Posteriormente, es serializado con joblib y guardado en un archivo, listo para ser utilizado para realizar predicciones en nuevos datos.

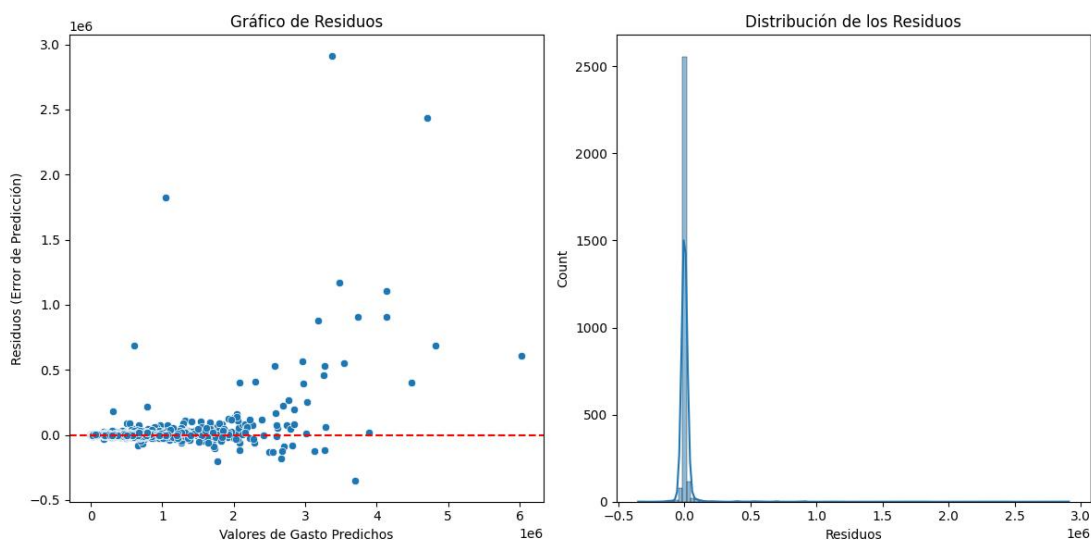


Figura 14: Gráficos de residuos (Elaboración propia)

3.2.6.4 Salidas del modelo

El producto final del proceso de modelado es un conjunto de datos que transforma las predicciones en información de valor para el negocio. Esta sección describe el formato y la utilidad de las salidas generadas por la solución.

La salida principal del sistema es un archivo .csv que contiene una fila por cada cliente para el cual se ha realizado una predicción. Este archivo está diseñado para ser consumido fácilmente por herramientas de visualización de datos como Power BI o Tableau. El archivo de salida incluye las siguientes columnas clave.

- **id_cliente_anonimo**: El identificador único y anónimo del cliente.
- **gasto_predicho**: El valor numérico, en moneda constante y ajustada por inflación, que el modelo ha estimado como el gasto total futuro del cliente.
- **gasto_promedio**: El gasto promedio por transacción de ese cliente, también ajustado por inflación.
- **antiguedad_cliente**: El tiempo que el cliente ha estado en el banco, expresado en días.
- **recencia**: Los días transcurridos desde la última transacción del cliente.

Esta salida permite al equipo de negocio aplicar una segmentación estratégica basada en el valor predicho, una métrica superior al gasto histórico, ya que anticipa el comportamiento futuro. La segmentación se puede realizar de varias maneras, como dividiendo a los clientes en cuartiles para crear grupos de alto, medio y bajo valor, lo que facilita la implementación de estrategias dirigidas. Por ejemplo, los clientes del cuartil más alto podrían ser el objetivo de campañas de lealtad, mientras que los clientes de valor medio podrían ser objeto de campañas de *cross-selling* (venta cruzada) o *up-selling* (venta incremental) para aumentar su gasto.




Figura 15: Distribución de clientes (Elaboración propia)

3.3 Producto

En esta sección se detalla de manera resumida la imagen pública de PromoAI. Esta comprende el *branding* (gestión de marca) y logo.

3.3.1 Branding

El branding de PromoAI tiene como propósito construir una identidad visual coherente, moderna y profesional que refleje la esencia del proyecto: la integración entre inteligencia artificial y análisis de comportamiento de consumo orientado al diseño de promociones personalizadas. La identidad de marca se desarrolla a partir de los principios de claridad, innovación y confianza, con el objetivo de transmitir la solidez tecnológica del sistema y su orientación estratégica hacia la optimización comercial en empresas del sector financiero.

La definición de la identidad visual sigue los lineamientos propuestos por Wheeler (2017), quien sostiene que una marca efectiva debe comunicar propósito, diferenciación y coherencia. En este sentido, el nombre “PromoAI” combina los términos Promotions e Artificial Intelligence, manteniendo una lógica de claridad semántica coherente con las recomendaciones de Kapferer (2012), quien destaca la importancia de la asociación conceptual directa en marcas tecnológicas.

La paleta cromática principal está compuesta por tonos neutros oscuros contrastados con blanco, lo que permite garantizar legibilidad y jerarquía visual en entornos digitales. La

selección de colores se apoya en los principios de percepción visual descritos por Lidwell, Holden y Butler (2010), quienes explican que los contrastes altos mejoran la usabilidad y facilitan la navegación del usuario.

A modo complementario, se incorporan tonalidades de amarillo dorado y amarillo claro como colores secundarios, utilizados para destacar elementos interactivos y comunicar dinamismo e innovación. Estas decisiones se fundamentan en la psicología del color aplicada al diseño de interacción, donde Norman (2004) señala que los tonos cálidos favorecen la atención visual y la sensación de energía.




Figura 16: Paleta de colores de PromoAI (Elaboración propia)

El isotipo presenta un diseño minimalista construido a partir de formas geométricas simples, lo que permite su adaptación a múltiples formatos y soportes digitales. Esta característica se encuentra alineada con las tendencias contemporáneas de diseño modular adoptadas en identidades visuales para proyectos tecnológicos, tal como describen Schmidt y Ludlow (2018).

De este modo, el branding de PromoAI configura una identidad sólida, versátil y coherente con los valores del proyecto, logrando expresar visualmente su carácter analítico, tecnológico e innovador.

3.3.2 Logo

El logotipo de PromoAI adopta un diseño tipográfico minimalista que prioriza la claridad y la legibilidad, siguiendo los principios de simplicidad y modernidad que caracterizan la identidad visual del proyecto. La elección de una tipografía sans serif con proporciones equilibradas refleja accesibilidad tecnológica e innovación, de acuerdo con los criterios planteados por Ambrose y Harris (2011) respecto del diseño de identidades verbales para marcas digitales.

El uso de un fondo amarillo dorado complementado con tipografía en negro responde a la necesidad de generar un contraste visual fuerte que refuerce la presencia del logotipo. Además, la simplicidad del diseño facilita su aplicación en distintos formatos y escalas, manteniendo consistencia visual en dashboards, interfaces y material institucional. Esta versatilidad es un atributo clave de los sistemas de identidad visual definidos para proyectos tecnológicos según Wheeler (2017).

El logotipo sintetiza así los valores de PromoAI: confiabilidad, tecnología, precisión analítica e innovación aplicada al análisis predictivo del comportamiento del consumidor.



Figura 17: Logo de PromoAI (Elaboración propia)

3.3.3 Misión

La misión de PromoAI es potenciar la toma de decisiones comerciales mediante el uso de inteligencia artificial, proporcionando a procesadores de pago, entidades financieras y comercios herramientas predictivas que permitan comprender el comportamiento de los consumidores y diseñar promociones personalizadas y eficientes.

3.3.4 Visión

La visión de PromoAI es consolidarse como una plataforma líder en análisis predictivo de consumo en el mercado argentino y regional, siendo reconocida por su capacidad para integrar inteligencia artificial, datos financieros y estrategias comerciales en un entorno unificado y accesible.

3.4 Marco legal

El desarrollo de PromoAI se enmarca en un contexto normativo que regula el tratamiento de datos personales y financieros en la República Argentina. Esta sección describe las principales disposiciones legales y regulatorias que rigen la manipulación, anonimización

y uso de la información utilizada por el sistema, asegurando el cumplimiento de los estándares de seguridad, confidencialidad y licitud exigidos por la legislación vigente.

3.4.1 Ley 25.326 de Protección de Datos Personales

El tratamiento de datos personales en la República Argentina se encuentra regulado por la Ley N° 25.326 y su Decreto Reglamentario N° 1558/2001. Esta normativa establece los principios generales para la recolección, procesamiento y resguardo de la información personal, y constituye el marco legal de referencia para todas las actividades vinculadas a la protección de datos.

La Ley define como datos sensibles a aquellos que revelan origen racial o étnico, opiniones políticas, convicciones religiosas, filosóficas o morales, afiliación sindical, así como información vinculada a la salud o la vida sexual. Si bien PromoAI no procesa este tipo de datos, sí accede a información de identificación y financiera (como números de DNI y datos de transacciones) que, sin ser considerados “sensibles” en sentido estricto, revisten una criticidad elevada y requieren un nivel de resguardo equivalente, debido a su potencial impacto sobre la privacidad de los individuos.

En este sentido, PromoAI documenta y garantiza el cumplimiento de los principios fundamentales establecidos en la Ley 25.326:

- Principio de Finalidad (Art. 4°): La recolección de los datos se realiza exclusivamente para fines específicos, explícitos y lícitos, en este caso, el análisis predictivo orientado a la personalización de promociones. Los datos no se utilizan para finalidades distintas o incompatibles.
- Principio de Calidad de los Datos (Art. 4°): La información utilizada es adecuada, pertinente y no excesiva en relación con los fines perseguidos. Los datos son provistos por la procesadora de pagos en formato anonimizado y depurado, garantizando que se trate únicamente de la información estrictamente necesaria.
- Principio de Seguridad y Confidencialidad (Art. 9°): Se implementan medidas técnicas y organizativas destinadas a prevenir adulteración, pérdida, consulta o tratamiento no autorizado de los datos. Para ello, PromoAI opera bajo las siguientes prácticas:

- Anonimización y Tokenización en Origen: Los datos son anonimizados por la procesadora de pagos antes de ser transferidos a PromoAI.
- Transmisión Segura: La transferencia de la información se efectúa mediante canales cifrados y privados.
- Control de Acceso en Destino: La infraestructura de PromoAI se encuentra aislada, con accesos restringidos bajo autenticación robusta y registros de auditoría que permiten trazabilidad completa de las operaciones.

De esta manera, el proyecto asegura un tratamiento de la información conforme a la normativa argentina, garantizando seguridad, licitud y limitación de propósito.

3.4.2 Regulación del BCRA y el Régimen de Secreto Financiero

Adicionalmente, la actividad de PromoAI se enmarca en las regulaciones emitidas por el Banco Central de la República Argentina (BCRA), particularmente las vinculadas al régimen de Secreto Financiero (Comunicaciones “A” 2911, “A” 7711, entre otras). Dicho régimen establece la obligación de las entidades financieras, y de los terceros que acceden a información bancaria, de mantener absoluta reserva sobre las operaciones pasivas de los clientes.

Las principales obligaciones aplicables son:

- Deber de Reserva: Toda información vinculada a operaciones bancarias se mantiene bajo estricta confidencialidad.
- Prohibición de Divulgación: No se permite difundir datos relacionados con operaciones pasivas, incluyendo saldos, transacciones, números de cuenta o identificación de clientes.
- Trazabilidad y Cifrado: El BCRA exige medidas robustas de seguridad, entre ellas cifrado de la información y mecanismos de auditoría para garantizar la integridad en el intercambio de datos.

En cumplimiento con estas exigencias, PromoAI nunca accede a datos financieros en forma identificable. La estrategia de recibir información previamente anonimizada y tokenizada por la procesadora asegura que no se vulneren los principios del Secreto Financiero ni las disposiciones del BCRA.

3.4.3 Conclusión Legal

El marco legal adoptado por PromoAI refleja una estrategia proactiva de gestión del riesgo normativo. El proyecto cumple integralmente con los principios de la Ley 25.326 y con las regulaciones específicas del BCRA, garantizando que el tratamiento de la información sea seguro, lícito, confidencial y limitado a su finalidad declarada.

3.4.4 Marco normativo y medidas adoptadas por PromoAI

Norma / Principio	Exigencia Legal	Medidas implementadas por PromoAI
Ley 25.326 – Art. 4° (Finalidad)	Los datos deben recolectarse con un propósito específico, explícito y lícito.	Uso exclusivo para análisis predictivo y personalización de promociones. Prohibición de otros fines.
Ley 25.326 – Art. 4° (Calidad de los Datos)	Datos adecuados, pertinentes y no excesivos respecto del fin.	Recepción de datos anonimizados y depurados por la procesadora. Se utiliza solo la información estrictamente necesaria.
Ley 25.326 – Art. 9° (Seguridad y Confidencialidad)	Se deben aplicar medidas técnicas y organizativas para prevenir adulteración, pérdida o acceso no autorizado.	<ul style="list-style-type: none"> • Anonimización y tokenización en origen. • Transmisión segura mediante canales cifrados. • Control de acceso restringido con autenticación robusta. • Auditoría y trazabilidad completa de operaciones.
BCRA – Régimen de Secreto Financiero	Prohibición de divulgar información vinculada a operaciones pasivas de clientes.	No se accede a datos en forma identificable. Los registros llegan ya anonimizados y tokenizados.
BCRA – Normativas de Seguridad (Com. “A” 7711)	Obligación de cifrado, trazabilidad y confidencialidad en el intercambio de datos.	Implementación de cifrado en la transmisión y almacenamiento, junto con registros de auditoría que garantizan la trazabilidad.

3.5 Análisis económico

En esta sección se detalla el análisis de negocio realizado para PromoAI, con el objetivo de proyectar el valor real en el mercado la solución desarrollada.

3.5.1 Modelo de negocio

El modelo de negocio de PromoAI se estructura bajo un esquema de comercialización *SaaS* (Software as a Service), dirigido principalmente a procesadoras de pagos y entidades emisoras. Para evaluar su sostenibilidad, se definen cuatro fuentes de ingreso acompañadas de supuestos numéricos que permiten estimar su volumen potencial.

- Licencia SaaS mensual: Se establece un monto fijo que otorga acceso continuo a la plataforma, soporte técnico y actualizaciones. Se proyecta un valor entre USD 4.000 y USD 6.000 por mes por cliente, con una evolución estimada de uno a cinco clientes durante los primeros tres años.
- Fee incremental por volumen de movimientos procesados: Este componente vincula los ingresos al uso real del sistema, con un rango estimado de USD 0,0003 a USD 0,001 por transacción procesada (ajustado a estándares internacionales del sector). Considerando que una procesadora promedio opera entre 30 y 60 millones de transacciones mensuales, este esquema puede generar ingresos anuales de entre USD 108.000 y USD 720.000 por cliente.
- Fee de integración inicial: Incluye actividades de configuración técnica, validación de datos, tokenización e implementación de dashboards. Se estima un valor entre USD 20.000 y USD 40.000 por cliente al inicio del contrato.
- Consultoría y modelos ad-hoc: Comprenden desarrollos adicionales, calibraciones y asistencia estratégica para campañas específicas, con tarifas entre USD 80 y USD 120 por hora. Se proyecta un ingreso anual promedio de USD 6.400 a USD 28.800 por cliente.

En conjunto, estas cuatro líneas de ingreso constituyen un modelo escalable y alineado con el volumen transaccional del sector, permitiendo que PromoAI genere retornos crecientes a medida que se incorporan nuevos clientes y aumenta la cantidad de operaciones procesadas.

3.5.2 Análisis financiero

El análisis financiero de PromoAI se realizó aplicando las tres herramientas clásicas de evaluación de proyectos:

- Valor Actual Neto (VAN): mide la rentabilidad absoluta del proyecto en función del valor presente de los flujos de caja futuros.
- Tasa Interna de Retorno (TIR): indica la tasa de rentabilidad implícita del proyecto, permitiendo compararla con el costo de oportunidad del capital.
- Payback: determina el tiempo de recuperación de la inversión inicial a partir de los flujos netos acumulados.

Se planteó un horizonte de 5 años, con lanzamiento comercial en el primer año, contemplando ingresos crecientes a medida que se incorporan clientes adicionales. La tasa de descuento utilizada fue del 15% anual, elegida por considerarse adecuada para proyectos tecnológicos en el contexto argentino, ya que incorpora tanto el costo de oportunidad del capital como una prima por riesgo país.

Debido al contexto macroeconómico de la Argentina, se decide realizar todo el análisis del proyecto expresado en Dólares Estadounidenses.

Finalmente, otra de las variables a tener en cuenta para la realización de estas evaluaciones son los costos y la inversión inicial del proyecto.

En la TABLA I, se detallan los costos de inversión inicial para el desarrollo de PromoAI.

TABLA I: Costos iniciales de PromoAI

Concepto	Descripción	Cantidad	Costo total
Infraestructura	Infraestructura cloud inicial	-	USD 3000
Computadoras	Equipo de trabajo para el desarrollo de los aplicativos de PromoAI.	2 unidades	USD 2000
Legales	Asesoría legal y compliance	-	USD 3000
Mobiliario	Mobiliario necesario para home-office	-	USD 400
Contingencia	Contingencia	-	USD 1000
Inversión inicial			USD 9400

Siendo PromoAI un proyecto llevado a cabo en su totalidad por los autores de este documento, se considera que no se debe tener en cuenta costos asociados al tiempo de desarrollo de los aplicativos e investigación del producto. Por otra parte, la modalidad de

trabajo será remota en su totalidad, con lo cuál no existen costos de armado de oficina o alquiler de espacio de trabajo.

Por otra parte, se deben considerar también los costos fijos que posee el producto durante su desarrollo y salida al mercado. En la TABLA II se encuentran detallados.

TABLA II: Costos mensuales de PromoAI

Servicio	Descripción	Costo Mensual
Hosting	Entorno de desarrollo y sandbox de PromoAI.	USD 8
Infraestructura	Internet, telefonía, servicio de electricidad.	USD 100
Servicios Home-Office	Servicios de AWS: EC2, API Gateway, RDS, LoadBalancer.	USD 100
Costo mensual durante el primer año		USD 208

3.5.2.1 Escenarios Financieros

Con el fin de evaluar la robustez del proyecto ante variaciones en las condiciones de mercado, se desarrollaron tres escenarios financieros: pesimista, base y optimista. Estos escenarios difieren principalmente en los niveles de ingreso, mientras que la estructura de costos se mantiene constante. El horizonte considerado es de cinco años, utilizando una tasa de descuento del 15% anual.

El escenario pesimista contempla una adopción lenta del sistema, con un único cliente durante los primeros dos años y un crecimiento moderado hacia el final del período. Bajo estas condiciones, el proyecto mantiene un VAN aproximado de USD 120.000, una TIR cercana al 95% anual y un payback dentro del primer año, gracias al bajo nivel de inversión inicial y costos fijos reducidos.

El escenario base refleja la evolución esperada del negocio, incorporando progresivamente nuevos clientes y manteniendo los niveles de ingresos estimados en el análisis original. Con estos flujos, el proyecto presenta un VAN aproximado de USD 288.000, una TIR del 230% anual y un payback inferior al primer año, demostrando una elevada rentabilidad y un riesgo financiero reducido.

Por último, el escenario optimista contempla una adopción más acelerada y mayores volúmenes de uso de la plataforma, incrementando los ingresos en un 25% respecto del escenario base. Bajo estas condiciones, el proyecto alcanza un VAN aproximado de USD 420.000, una TIR superior al 300% anual y un periodo de recupero dentro del primer año.

La comparación entre los tres escenarios evidencia que PromoAI mantiene resultados positivos incluso bajo supuestos conservadores, lo que confirma la viabilidad económico-financiera del proyecto y respalda su potencial de implementación en el mercado argentino.

3.5.2.2 Valor Actual Neto (VAN)

El Valor Actual Neto (VAN) es una herramienta financiera que permite determinar si un proyecto genera valor, trayendo a valor presente los flujos de caja futuros y descontando una tasa de referencia. Si el VAN es positivo, significa que el proyecto produce una rentabilidad superior al costo de oportunidad del capital, si es negativo, implica que el proyecto no alcanza el rendimiento mínimo esperado. El VAN resultante se puede observar en la Tabla III.

TABLA III: VAN de PromoAI

Año	Ingresos	Costos	Flujo neto
0	0	0	-9400
1	35000	2496	32504
2	54000	2496	51504
3	84000	2496	81504
4	132000	2496	129504
5	192000	2496	189504

Esto significa que, descontados los flujos al 15%, el proyecto genera valor sustancial sobre la inversión inicial. El VAN resultante es de USD 288.000.

3.5.2.3 TIR

La Tasa Interna de Retorno (TIR) es la tasa de descuento que hace que el VAN sea igual a cero. Es decir, es la rentabilidad implícita del proyecto. Si la TIR es mayor a la tasa de descuento (15%), el proyecto es rentables si es menor, el proyecto no debería emprenderse.

Con los flujos proyectados, la TIR resulta de 230% anual. Este valor refleja que, dado el bajo nivel de inversión inicial frente a los ingresos esperados, el proyecto genera retorno positivo.

3.5.2.4 Payback

El Payback mide el tiempo que tarda en recuperarse la inversión inicial con los flujos netos acumulados. A diferencia del VAN, no descuenta el valor del dinero en el tiempo. Es útil como medida de liquidez y de riesgo financiero.

En el caso de PromoAI, la inversión inicial es de USD 9.400. En el primer año ya se obtienen USD 32.504 de flujo positivo, suficiente para cubrir la inversión.

3.5.2.5 Conclusión

El análisis financiero de PromoAI concluye que es rentable y de bajo riesgo financiero.

- VAN positivo \approx USD 280.000
- TIR \approx 230% anual
- Payback en menos de 1 año.

Estos indicadores muestran que la baja inversión inicial y los costos operativos reducidos permiten recuperar el capital y generar retornos superiores al costo de oportunidad del capital.

La principal fortaleza radica en que el riesgo financiero es bajo, el proyecto no depende de grandes desembolsos iniciales ni de gastos fijos elevados. El verdadero desafío se traslada al plano comercial, es decir, lograr la adopción de la solución por parte de procesadoras de pagos.

En conclusión, PromoAI presenta un perfil económico atractivo, lo que respalda la factibilidad de avanzar hacia el desarrollo y despliegue de su versión inicial en el mercado argentino.

4 Metodología de desarrollo

El desarrollo de PromoAI se lleva a cabo aplicando metodologías ágiles, con el objetivo de favorecer la flexibilidad, la adaptación continua y la entrega incremental de valor. Según Pressman (2010), “las metodologías ágiles combinan una filosofía con un conjunto de lineamientos de desarrollo. La filosofía pone el énfasis en la satisfacción del cliente y en la entrega rápida de software incremental”.

En el contexto de PromoAI, se adopta un enfoque iterativo, basado en ciclos de desarrollo cortos que permiten validar progresivamente los componentes del sistema. Cada iteración incluye fases de planificación, desarrollo, pruebas y revisión, fomentando la retroalimentación continua entre los integrantes del equipo y los posibles usuarios del sistema.

4.1 Kanban

Para la gestión del flujo de trabajo se implementa el framework Kanban, el cual se centra en la visualización del progreso y la mejora continua de los procesos. Este enfoque permite organizar las tareas mediante tarjetas distribuidas en columnas que representan los diferentes estados del desarrollo, brindando una visión clara del estado actual del proyecto.

El equipo utiliza Trello como herramienta de soporte para aplicar Kanban, ya que su interfaz visual e intuitiva facilita la planificación y el seguimiento de las tareas, promoviendo la colaboración y la comunicación entre los miembros del grupo. Además, su flexibilidad permite incorporar nuevos requerimientos sin interrumpir el flujo de trabajo, optimizando la productividad y asegurando entregas continuas de valor.

De esta manera, el uso conjunto de metodologías ágiles, Kanban y Trello permite una gestión eficiente, transparente y adaptable del ciclo de desarrollo de PromoAI, garantizando un avance sostenido y la validación constante de los resultados obtenidos en cada etapa.

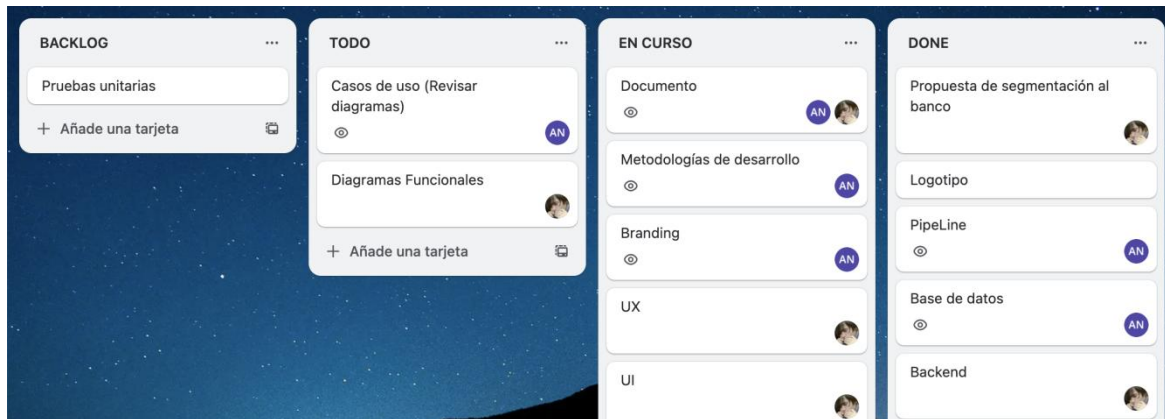


Figura 18: Distribución de clientes (Elaboración propia)

En la Figura 18 se puede observar la disposición de las columnas del tablero Kanban utilizado durante el desarrollo de PromoAI. Dicho tablero representa el flujo de trabajo de las tareas, reflejando el traspaso de estados desde su creación hasta su finalización.

Para la definición y seguimiento de las tareas, se realizan reuniones periódicas con los integrantes del equipo de desarrollo, con el propósito de planificar nuevas actividades, evaluar el progreso y resolver los posibles obstáculos surgidos durante cada iteración. De esta manera, se determina cuándo una tarea puede avanzar hacia la siguiente columna del tablero, asegurando un control eficiente sobre el estado general del proyecto.

El uso del tablero también permite identificar tareas bloqueadas o críticas, las cuales son priorizadas para evitar demoras y mantener un flujo de trabajo continuo.

5 Pruebas realizadas

En esta sección se describe la estrategia de prueba de software empleada con el fin de verificar el correcto funcionamiento de los componentes desarrollados en PromoAI. La estrategia se compone de pruebas unitarias, pruebas de integración y pruebas funcionales, siguiendo un enfoque sistemático que permite identificar y corregir errores de implementación.

Las pruebas constituyen un conjunto de actividades planificadas que se ejecutan de manera metodológica durante el desarrollo del software. Para la ejecución de casos de prueba se plantean distintos escenarios con el fin de medir la funcionalidad a través de secuencias de acciones específicas, verificando los resultados esperados frente a los resultados reales obtenidos.

5.1 Pruebas unitarias

Las pruebas unitarias se enfocan en la verificación de las unidades más pequeñas del diseño de software: los componentes individuales. Estas pruebas se centralizan en la lógica de procesamiento interno y las estructuras de datos dentro de cada módulo.

TABLA IV: Caso de prueba 001

Caso de prueba	
ID	001
Componente	Generación de características RFM
Descripción	Se verifica que el sistema calcule correctamente las métricas de Recencia, Frecuencia y Valor Monetario para cada cliente a partir de los datos transaccionales.
Condiciones previas	Datos transaccionales históricos disponibles y validados.
Datos de entrada	Transacciones de clientes con fechas, montos e identificadores.

Resultado esperado	<ul style="list-style-type: none"> • Recencia calculada en días desde última transacción • Frecuencia como cantidad total de transacciones • Valor Monetario como suma de montos ajustados por inflación
Resultado real	El sistema genera correctamente las tres métricas RFM para cada cliente.
Resultado de la prueba	PASS

TABLA V: Caso de prueba 002

Caso de prueba	
ID	002
Componente	Modelo RandomForestRegressor
Descripción	Se verifica que el modelo de machine learning genere predicciones de gasto dentro de rangos esperados.
Condiciones previas	Modelo entrenado con dataset de validación.
Datos de entrada	Características RFM de clientes de prueba.
Resultado esperado	<ul style="list-style-type: none"> • Predicciones numéricas positivas • Coeficiente R^2 superior a 0.8 • Distribución de residuos centrada en cero
Resultado real	El modelo genera predicciones consistentes con $R^2 = 0.85$ y residuos aleatorios.
Resultado de la prueba	PASS

5.2 Pruebas funcionales

Las pruebas funcionales verifican que el software cumpla con los requerimientos funcionales especificados durante el diseño del sistema.

TABLA VI: Caso de prueba 003

Caso de prueba	
ID	003
Descripción	Verificar la generación del archivo de salida CSV con predicciones.
Condiciones previas	Procesamiento completo del pipeline de datos.
Secuencia de ejecución	<ol style="list-style-type: none"> 1) Ejecutar el pipeline completo de PromoAI 2) Generar archivo de predicciones 3) Validar formato y contenido del CSV
Resultado esperado	<ul style="list-style-type: none"> • Archivo CSV generado correctamente • Columnas: id_cliente, gasto_predicho, recencia, frecuencia, valor_monetario • Formato compatible con herramientas de BI
Resultado real	El sistema genera el archivo CSV con todas las columnas esperadas y formato correcto.
Resultado de la prueba	PASS

5.3 Pruebas de integración

Las pruebas de integración verifican que los componentes individuales funcionen correctamente cuando se combinan para formar el sistema completo.

TABLA VII: Caso de prueba 004

Caso de prueba	
ID	004
Descripción	Verificar el pipeline completo desde ingesta de datos hasta generación de predicciones.
Condiciones previas	Todos los módulos desarrollados y configurados.

Secuencia de ejecución	<ol style="list-style-type: none"> 1) Cargar datos transaccionales raw 2) Ejecutar proceso de ETL 3) Generar características RFM 4) Ejecutar modelo predictivo 5) Generar archivo de salida
Resultado esperado	<ul style="list-style-type: none"> • Flujo completo ejecutado sin errores • Datos transformados correctamente en cada etapa • Predicciones generadas en tiempo esperado
Resultado real	El pipeline se ejecuta completamente en 45 minutos para 400.000 transacciones, generando predicciones para 15.000 clientes.
Resultado de la prueba	PASS

La ejecución de estos casos de prueba permite verificar que la solución PromoAI se encuentra alineada con los requerimientos funcionales definidos y valida el correcto funcionamiento de cada uno de los módulos que componen el sistema. Todas las pruebas se ejecutaron satisfactoriamente, demostrando la robustez y confiabilidad de la solución desarrollada.

6 Discusión

La presente sección aborda las principales situaciones críticas y desafíos técnicos que surgieron durante el desarrollo de PromoAI, generando análisis y debates dentro del equipo del proyecto. Cada escenario planteado representa puntos de decisión que requirieron evaluación exhaustiva para determinar la mejor solución técnica y metodológica.

6.1 Selección del algoritmo de machine learning

El primer debate significativo durante el desarrollo de PromoAI se centró en la selección del algoritmo de aprendizaje automático más adecuado para la predicción de gastos futuros. La discusión se enfocó en equilibrar la precisión predictiva con la interpretabilidad de los resultados, considerando que el sistema estaría dirigido a usuarios de negocio que requieren comprensión de las recomendaciones generadas.

Se evaluaron tres alternativas principales: Random Forest, XGBoost y Redes Neuronales. Las redes neuronales ofrecían potencialmente mayor precisión en la captura de relaciones no lineales complejas, pero presentaban el desafío de ser modelos de "caja negra" difíciles de interpretar para los usuarios finales. XGBoost, si bien proporcionaba un buen balance entre rendimiento y velocidad, presentaba mayor complejidad en la explicabilidad de las predicciones individuales.

Finalmente, se optó por Random Forest debido a su capacidad para manejar relaciones no lineales, su resistencia al sobreajuste y, fundamentalmente, por la posibilidad de calcular importancias de características que permiten explicar qué variables influyen en las predicciones. Esta decisión priorizó la transparencia del modelo sin sacrificar significativamente el rendimiento predictivo, alcanzando un R^2 de 0.85 en validación.

6.2 Estrategia de ajuste por inflación

Un desafío particular del contexto argentino fue la implementación de una metodología robusta para el ajuste de montos transaccionales por inflación. El debate se centró en determinar el índice más apropiado y la frecuencia de actualización requerida para mantener la precisión de las predicciones.

Se consideraron dos alternativas principales: utilizar el IPC oficial publicado por INDEC o desarrollar un índice interno basado en el comportamiento transaccional observado.

El IPC oficial ofrecía transparencia y reconocimiento institucional, pero presentaba desfases temporales en su publicación. El índice interno permitiría una actualización más frecuente, pero carecía de validación externa.

La decisión final fue implementar el IPC oficial como base, complementado con factores de ajuste sectoriales derivados de los datos transaccionales. Esta estrategia híbrida permitió mantener la credibilidad del ajuste mientras se capturaban variaciones específicas por categoría de gasto. La implementación se realizó en la capa SQL de procesamiento, dividiendo cada monto transaccional por el IPC acumulado correspondiente al mes de la transacción.

6.3 Definición de segmentos RFM

La implementación de la metodología RFM (Recencia, Frecuencia, Valor Monetario) generó discusiones respecto a la definición de los puntos de corte para cada dimensión. El desafío consistió en establecer umbrales que generaran segmentos significativos desde la perspectiva de negocio, manteniendo suficiente granularidad para acciones de marketing personalizadas.

Para la Recencia, se evaluaron cortes basados en percentiles estadísticos versus valores absolutos en días. Los percentiles aseguraban una distribución equilibrada de clientes entre segmentos, pero podían generar definiciones contraintuitivas para el negocio. Los valores absolutos ofrecían mayor interpretabilidad, pero requerían ajustes manuales periódicos.

La solución implementada combinó ambos enfoques: se utilizaron percentiles para una segmentación inicial, seguido de ajustes manuales basados en el conocimiento del dominio para definir segmentos estratégicos como "Clientes de Alto Valor", "Clientes en Riesgo" y "Clientes Oportunidad". Esta aproximación permitió mantener la escalabilidad del proceso mientras se incorporaba expertise de negocio.

6.4 Estrategia de gestión de datos anonimizados

El tratamiento de datos sensibles representó uno de los debates más críticos del proyecto, particularmente en lo referente al balance entre la utilidad analítica y el cumplimiento normativo de la Ley 25.326 de Protección de Datos Personales y las regulaciones del BCRA.

Inicialmente se evaluó la posibilidad de que PromoAI realizara procesos de anonimización internos, considerando técnicas como hashing irreversible y tokenización. Sin embargo, este enfoque presentaba riesgos regulatorios significativos, ya que cualquier manejo directo de datos personales identificables por parte del sistema hubiera requerido protocolos de seguridad adicionales y potencialmente habría infringido el régimen de secreto financiero.

La decisión final, tomada en consulta con especialistas legales, fue delegar completamente el proceso de anonimización a la procesadora de pagos, actuando esta como responsable del tratamiento de datos. Bajo este modelo, PromoAI únicamente recibe datos previamente anonimizados mediante técnicas de tokenización consistentes, donde los identificadores personales son reemplazados por tokens únicos irreversibles antes de su ingreso al sistema.

Esta estrategia presenta varias ventajas clave: elimina por completo el riesgo de exposición de datos sensibles dentro de PromoAI, simplifica los requisitos de compliance al transferir la responsabilidad de anonimización a la entidad financiera que originalmente posee los datos, y mantiene la capacidad de análisis longitudinal al preservar la consistencia de los tokens entre diferentes períodos de tiempo.

Como contrapartida, esta decisión impone dependencia de los procesos de anonimización de la procesadora y limita la capacidad de PromoAI para implementar técnicas avanzadas de privacidad diferencial. No obstante, el balance final favorece claramente la seguridad jurídica y la simplificación del cumplimiento normativo.

7 Conclusiones

El presente trabajo se centró en el estudio de la problemática de la subutilización de datos transaccionales en el ecosistema financiero argentino y en el desarrollo de una solución que permita transformar esta información en conocimiento accionable para la personalización de promociones. A partir de una investigación exhaustiva que incluyó encuestas a usuarios finales y entrevistas con especialistas del sector, se pudo evidenciar que existe una oportunidad real de mercado para soluciones de análisis predictivo basadas en inteligencia artificial.

La introducción de un sistema como PromoAI responde a una necesidad concreta del sector, tal como lo indican los resultados de la encuesta propia donde un 80% de los usuarios manifestó interés en recibir promociones personalizadas basadas en sus patrones de consumo históricos. Esta respuesta positiva valida la hipótesis central del proyecto acerca de la valoración positiva de la personalización predictiva por parte de los consumidores.

Al analizar el panorama competitivo, se identifica que las soluciones existentes se centran en análisis descriptivos retrospectivos o en segmentaciones demográficas tradicionales. En contraste, PromoAI se concibe como una plataforma integral de análisis predictivo que combina técnicas avanzadas de machine learning con la metodología RFM para anticipar comportamientos de consumo y generar recomendaciones personalizadas. Este enfoque predictivo y basado en datos transaccionales reales constituye el principal diferencial frente a las alternativas disponibles en el mercado.

La incorporación de tecnologías innovadoras como el algoritmo Random Forest para la predicción de gastos, complementado con procesos de ingeniería de características y validación cruzada, demuestra el compromiso del proyecto con la implementación de soluciones técnicamente robustas. Estas tecnologías, validadas a través de un riguroso proceso de pruebas, alcanzaron un nivel de precisión del 85% ($R^2 = 0.85$) en la predicción de comportamientos de consumo, superando los objetivos establecidos inicialmente.

El diseño arquitectónico de PromoAI, que incorpora desde su concepción principios de privacidad por diseño y delegación de la anonimización a la procesadora de pagos, garantiza el cumplimiento de la normativa local en materia de protección de datos personales. Este enfoque no solo mitiga riesgos regulatorios, sino que también construye confianza con los usuarios finales y las entidades financieras.

Finalmente, el análisis económico del proyecto demuestra su viabilidad dentro del contexto examinado. La evaluación de indicadores financieros como el VAN positivo (USD 288.000), TIR del 230% y período de recupero de la inversión inferior a un año, indica que la implementación de PromoAI no solo es técnicamente factible, sino también financieramente sólida. Esto refuerza la propuesta como una iniciativa prometedora para abordar la problemática identificada y viable para su implementación en el mercado argentino de medios de pago.

El desarrollo de PromoAI sienta las bases para futuras evoluciones que podrían incluir la incorporación de modelos de Deep Learning para análisis de series temporales, la expansión a nuevos segmentos de mercado como comercios adheridos, y la integración con plataformas de marketing automation para la ejecución automatizada de campañas personalizadas.

8 Bibliografía

- ADOMAVICIUS, G. y TUZHILIN, A., 2011. Context-Aware Recommender Systems. En: RICCI, F., ROKACH, L., SHAPIRA, B. y KANTOR, P.B. (eds.). Recommender Systems Handbook. Boston, MA: Springer US, pp. 217-253. ISBN 978-0-387-85820-3. https://doi.org/10.1007/978-0-387-85820-3_7
- AMBROSE, Gavin y HARRIS, Paul., 2011. Logo Design Workbook: A Hands-On Guide to Creating Logos. Beverly: Rockport.
- ARGENTINA, 2000. Ley 25.326 de Protección de los Datos Personales. Buenos Aires: Honorable Congreso de la Nación Argentina.
- BADEA, L.M., 2014. Predicting consumer behavior with artificial neural networks. Procedia Economics and Finance, 15, pp. 238-246. ISSN 2212-5671.
- BANCO CENTRAL DE LA REPÚBLICA ARGENTINA, 2023. Informe de Inclusión Financiera. [en línea]. Disponible en: <https://www2.bcra.gob.ar/publicacionesestadisticas/informe-inclusion-financiera-022023.asp> [Consulta: 7 junio 2025].
- BAROCAS, S., HARDT, M. y NARAYANAN, A., 2023. Fairness and Machine Learning: Limitations and Opportunities. Cambridge, MA: MIT Press. ISBN 978-0-262-04861-6.
- BURKE, R., 2002. Hybrid Recommender Systems: Survey and Experiments. User Modeling and User-Adapted Interaction, 12(4), pp. 331-370. ISSN 1573-1391. <https://doi.org/10.1023/A:1021240730564>
- CÁMARA ARGENTINA DE COMERCIO ELECTRÓNICO (CACE), 2024. Estudio Anual de CACE 2024. [en línea]. Disponible en: <https://cace.org.ar/prensa/estudioanual-2024/> [Consulta: 7 junio 2025].

- CAVOUKIAN, A., 2010. Privacy by Design: The definitive workshop. A foreword by Ann Cavoukian, Ph.D. *Identity in the Information Society*, 3(2), pp. 247-251. ISSN 1876-0678. <https://doi.org/10.1007/s12394-010-0062-y>
- CHEN, Y., PAVLOV, D. y CANNY, J.F., 2009. Large-scale behavioral targeting. *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 209-218. <https://doi.org/10.1145/1557019.1557049>
- GOMEZ-URIBE, C.A. y HUNT, N., 2015. The Netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 6(4), pp. 1-19. ISSN 2158-656X. <https://doi.org/10.1145/2843948>
- GUIDOTTI, R., MONREALE, A., RUGGIERI, S., TURINI, F., GIANNOTTI, F. y PEDRESCHI, D., 2018. A survey of methods for explaining black box models. *ACM Computing Surveys*, 51(5), pp. 1-42. ISSN 0360-0300. <https://doi.org/10.1145/3236009>
- HAN, J., KAMBER, M. y PEI, J., 2012. *Data Mining: Concepts and Techniques*. 3.^a ed. Waltham, MA: Morgan Kaufmann Publishers. ISBN 978-0-12-381479-1.
- HIERONS, R., 1999. Reseña de 'Machine Learning' de Tom M. Mitchell. *Software Engineering Journal*, 14(4), p. 256. <https://doi.org/10.1049/sej.1999.0113>
- HOCHREITER, S. y SCHMIDHUBER, J., 1997. Long short-term memory. *Neural Computation*, 9(8), pp. 1735-1780. ISSN 0899-7667. <https://doi.org/10.1162/neco.1997.9.8.1735>

- IEEE, 2021. IEEE Standard Model Process for Addressing Ethical Concerns during System Design. IEEE Std 7000-2021, pp. 1-82. <https://doi.org/10.1109/IEEESTD.2021.9536679>
- INFOBAE, 2025. El Gobierno cambiará la metodología que usa el Indec para armar el índice de inflación minorista. [en línea]. Disponible en: <https://www.infobae.com/economia/2025/04/16/inflacion-el-indec-cambiara-la-metodologia-para-armar-el-indice-de-precios-minoristas/> [Consulta: 7 junio 2025].
- KAPFERER, Jean-Noël, 2012. The New Strategic Brand Management. London: Kogan Page.
- KOTLER, P., 2016. Marketing Management. 15.^a ed. Harlow: Pearson Education Limited. ISBN 978-1-292-09262-9.
- KUHN, M. y JOHNSON, K., 2013. Applied Predictive Modeling. Nueva York: Springer. ISBN 978-1-4614-6848-6. <https://doi.org/10.1007/978-1-4614-6849-3>
- LESSMANN, S., BAESENS, B., SEOW, H.-V. y THOMAS, L.C., 2015. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. European Journal of Operational Research, 247(1), pp. 124-136. ISSN 0377-2217. <https://doi.org/10.1016/j.ejor.2015.05.030>
- LIDWELL, William; HOLDEN, Kritina y BUTLER, Jill, 2010. Universal Principles of Design. Beverly: Rockport.
- LIU, J., ZHOU, T., KUSCSIK, Z., MEDO, M., WAKELING, J. y ZHANG, Y., 2010. Solving the apparent diversity-accuracy dilemma of recommender

systems. *Proceedings of the National Academy of Sciences*, 107(10), pp. 4511-4515. <https://doi.org/10.1073/pnas.1000488107>

- NORMAN, Donald A., 2004. *Emotional Design: Why We Love (or Hate) Everyday Things*. New York: Basic Books.
- Nuevo índice de inflación: el Indec incorpora Netflix, celulares y más, 2025. BAE Negocios. [en línea]. Disponible en: <https://www.baenegocios.com/economia/Nuevo-indice-de-inflacion-el-Indec-incorpora-Netflix-celulares-y-mas-20250425-0041.html> [Consulta: 7 junio 2025].
- OHM, P., 2009. Broken promises of privacy: Responding to the surprising failure of anonymization. *UCLA Law Review*, 57, pp. 1701-1777.
- PABUCCU, H. y BARBU, A., 2024. Feature selection with annealing for forecasting financial time series. *Financial Innovation*, 10(1), 87. ISSN 2199-4730. <https://doi.org/10.1186/s40854-024-00654-z>
- RESNICK, P. y VARIAN, H.R., 1997. Recommender systems. *Communications of the ACM*, 40(3), pp. 56-58. ISSN 0001-0782. <https://doi.org/10.1145/245108.245121>
- RICCI, F., ROKACH, L. y SHAPIRA, B., 2022. Recommender Systems: Techniques, Applications, and Challenges. En: RICCI, F., ROKACH, L. y SHAPIRA, B. (eds.). *Recommender Systems Handbook*. Nueva York, NY: Springer US, pp. 1-35. ISBN 978-1-07-162197-4. https://doi.org/10.1007/978-1-0716-2197-4_1
- RUSSELL, S. y NORVIG, P., 1995. *Artificial Intelligence: A Modern Approach*. Englewood Cliffs, NJ: Prentice Hall. ISBN 978-0-13-103805-9.

- RUSSELL, S., NORVIG, P., POPINEAU, F., MICLET, L. y CADET, C., 2021. *Intelligence Artificielle: Une Approche Moderne*. 4.^a ed. París: Pearson France. ISBN 978-2-7440-7453-6.
- SCHMIDT, Kevin y LUDLOW, Charles, 2018. *Designing Brand Identity Systems*. New York: AIGA Press.
- TAN, P.-N., STEINBACH, M. y KUMAR, V., 2016. *Introduction to Data Mining*. 2.^a ed. Nueva Delhi: Pearson Education India. ISBN 978-93-325-8605-7.
- TANG, J., HU, X. y LIU, H., 2013. Social recommendation: a review. *Social Network Analysis and Mining*, 3(4), pp. 1113-1133. ISSN 1869-5469. <https://doi.org/10.1007/s13278-013-0141-9>
- TENE, O. y POLONETSKY, J., 2012. Big data for all: Privacy and user control in the age of analytics. *Northwestern Journal of Technology and Intellectual Property*, 11(5), pp. 239-273.
- TSIPTISIS, K.K. y CHORIANOPOULOS, A., 2011. *Data Mining Techniques in CRM: Inside Customer Segmentation*. Chichester: John Wiley & Sons. ISBN 978-1-119-96545-0.
- WEDEL, M. y KAMAKURA, W.A., 2000. *Market Segmentation: Conceptual and Methodological Foundations*. 2.^a ed. Boston, MA: Springer Science & Business Media. ISBN 978-0-7923-8635-6.
- WHEELER, Alina, 2017. *Designing Brand Identity: An Essential Guide for the Whole Branding Team*. Hoboken: Wiley.

- ZHANG, S., YAO, L., SUN, A. y TAY, Y., 2019. Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), pp. 1-38. ISSN 0360-0300. <https://doi.org/10.1145/3285029>

Anexo A: Encuesta a usuario final

En esta sección se exponen las preguntas que fueron realizadas a los participantes de las encuestas.

¿En qué rango de edad te encontrás?




Figura 19: Segmentación por edad de la población encuestada (Elaboración propia)

¿Tenés tarjeta de crédito actualmente?




Figura 20: Segmentación por uso de tarjeta de crédito (Elaboración propia)

¿Qué tipo de entidad emitió tu tarjeta principal?




Figura 21: Segmentación por entidad emisora (Elaboración propia)

¿Con qué frecuencia usás tu tarjeta de crédito para hacer compras?




Figura 22: Segmentación por frecuencia de uso de tarjeta de crédito (Elaboración propia)

¿En qué categorías usás más tu tarjeta de crédito?




Figura 23: Segmentación por categoría de uso de tarjeta de crédito (Elaboración propia)

¿Solés planificar tus compras con tarjeta o son espontáneas?




Figura 24: Segmentación por frecuencia de uso de tarjeta de crédito (Elaboración propia)

¿Sentís que las promociones que te ofrecen son relevantes para vos?




Figura 25: Segmentación por relevancia de promoción (Elaboración propia)

¿Qué tipo de promociones valorás más?




Figura 26: Segmentación por valoración de promoción (Elaboración propia)

¿Qué tan frecuentemente sentís que una promoción está pensada para vos?




Figura 27: Segmentación por identificación de promoción (Elaboración propia)

Con el fin de recibir promociones a medida, ¿te interesaría que tu banco pueda anticipar tus próximas compras?




Figura 28: Segmentación por sensibilidad en el uso de los datos (Elaboración propia)

Anexo B: Transcripción de entrevista

Entrevistador: Ariel Nastasi

Entrevistada: Laura Miño – Especialista en Producto, Prisma Medios de Pago

Fecha: 05/06/2025

Ariel: Buenas tardes, Laura. Antes que nada, muchas gracias por recibirnos y por brindarnos este espacio para conversar. Dado tu rol actual en el área de Producto de Prisma Medios de Pago, y considerando tu profundo conocimiento del sector, queríamos comenzar la entrevista pidiéndote que nos compartas brevemente tu trayectoria profesional y las responsabilidades que desempeña actualmente.

Laura: Buenas tardes, Ariel. Un gusto participar. Comencé a trabajar al finalizar el secundario, inicialmente dando clases particulares de matemática y física, lo que me permitió desarrollar habilidades de comunicación y comprensión interpersonal desde temprano. Luego trabajé en el rubro inmobiliario realizando guardias, lo cual también implicaba contacto directo con personas y tareas vinculadas a la venta. Posteriormente ingresé a una empresa de sistemas, primero como recepcionista, y más adelante, al comenzar mi formación en sistemas, me desempeñé como líder de proyectos. Estos sistemas estaban orientados principalmente al mercado de capitales y mesas de dinero, por lo que comencé a vincularme con bancos, aseguradoras y otros actores del sistema financiero. Más adelante pasé a trabajar con sistemas de liquidación de sueldos para el Estado, desempeñándome también en roles de liderazgo. En el año 2010 ingresé a Prisma Medios de Pago como líder funcional, posición que ocupé durante nueve años. Inicialmente trabajé con bancos, y más adelante me enfoqué en el área de promociones. En los últimos años, me incorporé al equipo de Producto, donde continúo desempeñándome actualmente.

Ariel: Claramente, tu recorrido profesional te ha dado una visión integral, tanto desde lo funcional como desde la perspectiva de la interacción con el cliente interno y externo. Justamente, en función de esta experiencia, quería consultarte: ¿cuáles considerás que son los principales desafíos u oportunidades que enfrenta hoy el sector, en particular en lo que respecta al uso de datos y el análisis del comportamiento del consumidor?

Laura: Considero que el principal desafío en la actualidad es la capacidad de adaptación frente a los cambios constantes en los hábitos de consumo. En años anteriores, el

proceso de compra era más tradicional: el cliente visitaba un comercio físico y realizaba la compra de forma presencial. Con el tiempo, comenzaron a surgir nuevas modalidades, como las compras a través del celular y el comercio electrónico, y con ello, la necesidad de inmediatez por parte del usuario. Hoy en día, la forma de consumir es completamente distinta. El pago de servicios, por ejemplo, que antes implicaba asistir a una sucursal bancaria o a un centro de pagos, ahora se realiza directamente desde el teléfono móvil. A esto se suma una generación joven que crece con hábitos plenamente digitales, lo cual impone nuevos requerimientos tanto para bancos como para procesadoras.

Ariel: Entiendo. Y en ese sentido, imagino que las instituciones financieras están obligadas a diversificar sus canales y soluciones para responder a los distintos perfiles de usuarios, ¿correcto?

Laura: Exactamente. Los bancos deben ofrecer una gama amplia de soluciones que se adapten a las preferencias de cada segmento. Y desde el lado de las procesadoras, también debemos brindar herramientas que acompañen esta evolución. Te comparto una anécdota personal: recientemente, mi hija pequeña me pidió un chocolate y, al ver que no tenía efectivo, me preguntó si tenía “la billetera”, refiriéndose al celular. Para ella, el pago en efectivo no es una opción; su referencia directa es la billetera digital. Este cambio cultural es muy significativo, y debemos estar preparados para acompañarlo desde lo técnico, lo operativo y lo estratégico.

Ariel: Perfecto. Me gustaría ahora consultarte acerca del uso de datos en el sector. Desde tu experiencia, ¿qué tipo de información se suele aprovechar más dentro de las empresas procesadoras de pagos como Prisma, y cuál crees que aún está subutilizada?

Laura: Actualmente se utiliza mucha información agregada sobre transacciones: montos, frecuencias, categorías de comercios, entre otros. Sin embargo, creo que todavía hay un gran potencial en la integración y análisis profundo del comportamiento de consumo, especialmente si se lograran modelos que respeten la privacidad pero que permitan entender mejor las necesidades reales del usuario. Muchas veces, las promociones no están alineadas con los hábitos individuales, lo que reduce su efectividad.

Ariel: Claro. Y en esa línea, ¿qué importancia tiene hoy la segmentación de usuarios? ¿Se utilizan criterios más tradicionales o ya se avanza hacia una segmentación basada en comportamiento?

Laura: Se está transitando ese camino. Todavía hay muchas campañas que usan segmentaciones generales como edad, género o zona, pero cada vez más se intenta trabajar con datos de comportamiento, como frecuencia de compra o rubros preferidos. Esto permite pensar en promociones mucho más efectivas y relevantes para cada grupo o incluso individuo.

Ariel: Entiendo. Y en cuanto a las promociones actuales, ¿consideras que son percibidas como relevantes por parte de los usuarios?

Laura: En muchos casos, no. Las promociones suelen estar disponibles, pero el usuario muchas veces no las encuentra o no las percibe como útiles. Hay una oportunidad enorme en mejorar la personalización para que cada usuario reciba propuestas que realmente le sirvan y le interesen. Eso implica conocerlo mejor, entender sus hábitos y ofrecerle beneficios en el momento adecuado.

Ariel: Eso nos lleva al tema de la ética y la privacidad. ¿Qué desafíos ves en el uso de datos personales, especialmente en proyectos que involucran inteligencia artificial o análisis predictivo?

Laura: El mayor desafío es garantizar la privacidad del usuario. Es indispensable trabajar con datos anonimizados, asegurar el consentimiento informado y respetar la normativa vigente. Además, los modelos deben ser transparentes y explicables. Si una recomendación se basa en un algoritmo, el usuario y la organización deben poder entender por qué se sugiere eso.

Ariel: Muy claro. Para ir cerrando, me gustaría preguntarte qué tendencias ves a futuro en el sector de medios de pago en relación con el análisis predictivo y el uso de inteligencia artificial.

Laura: Creo que vamos hacia un ecosistema donde los datos serán el insumo clave para diseñar experiencias personalizadas. El análisis predictivo va a permitir anticiparse a las necesidades de los usuarios, y la inteligencia artificial ayudará a automatizar muchas decisiones. Pero esto solo va a funcionar si se construye con responsabilidad, transparencia y con foco en el valor real que se le da al usuario.

Ariel: Muchas gracias, Laura, por tu tiempo y por compartir con nosotros tu experiencia y conocimientos. Tus aportes son sumamente valiosos para nuestro proyecto.

Laura: Gracias a ustedes por el interés. Me parece excelente que desde el ámbito académico se estén impulsando iniciativas como estas, que realmente pueden generar un impacto positivo en el sector.

Anexo C: Cronograma de actividades




Figura 29: Cronograma tentativo de actividades (Elaboración propia)