



Aplicación de Inteligencia Artificial dentro del Ecosistema de
Bancos Provinciales Argentinos

Profesora de trabajo final: Dra. Marcela Samela

Alumno: Facundo Lionel Villanueva

Trabajo Final de Carrera presentado para obtener el título de
Lic. en Gestión de Tecnología Informática

Diciembre, 2024

Resumen

El presente trabajo final de carrera es una propuesta de intervención en el campo profesional centrada en la aplicación de Inteligencia Artificial (IA) dentro del Ecosistema de Bancos Provinciales Argentinos (BPA). La presente propuesta consiste en un plan de desarrollo por etapas de un sistema de software que permita a estas entidades, a partir de una implementación gradual, incorporar IA en la gestión del riesgo crediticio, la detección del fraude y en la gestión y atención al cliente. El plan considera el contexto que atraviesan los BPA, relacionado con problemáticas propias de este tipo de instituciones, tales como limitaciones de recursos, el cumplimiento de normativas y el federalismo en Argentina. Se abordarán las bases necesarias para implementar IA en los BPA, incluyendo la gestión del riesgo crediticio, la detección de fraudes, el abandono de clientes, la recomendación personalizada de productos financieros y el uso de chatbots para atención al cliente. Además, se considerarán los desafíos previos a la implementación de IA, como la transformación digital en banca, la gobernanza de los datos y el modelo de madurez de gestión de datos, adaptados a la realidad de los BPA y a los aspectos regulatorios. Posteriormente se elaborará el plan de desarrollo objeto de este trabajo para el ecosistema definido. Este enfoque facilita una transición ordenada hacia el uso de IA, mejorando la eficiencia operativa, optimizando la calidad del servicio al cliente y fomentando una innovación tecnológica que responda a las necesidades específicas de estas instituciones. Al seguir un camino claro y factible para la implementación de IA por parte de los BPA, estas entidades contarán con mejores herramientas, en la búsqueda de una mayor inclusión financiera y de un crecimiento económico regional en Argentina, superando barreras a nivel federal y capitalizando las oportunidades que ofrece la IA.

Palabras clave: bancos provinciales argentinos, industria financiera, inteligencia artificial

Abstract

This final degree project is an intervention proposal in the professional field focused on the application of Artificial Intelligence (AI) within the ecosystem of Argentine Provincial Banks (BPA). This proposal consists of a staged development plan for a software system that enables these institutions, through a gradual implementation, to incorporate AI in credit risk management, fraud detection, and customer management and service. The plan considers the context faced by the APBs, addressing challenges typical of these institutions, such as resource limitations, regulatory compliance, and federalism in Argentina. The necessary foundations for implementing AI in BPA will be addressed, including credit risk management, fraud detection, customer churn, personalized financial product recommendations, and the use of chatbots for customer service. Additionally, challenges preceding AI implementation will be considered, such as digital transformation in banking, data governance, and the data management maturity model, adapted to the reality of BPA and regulatory aspects. Subsequently, the development plan for the defined ecosystem, which is the objective of this project, will be outlined. This approach facilitates an orderly transition toward AI adoption, improving operational efficiency, optimizing customer service quality, and fostering technological innovation that meets the specific needs of these institutions. By following a clear and feasible path for AI implementation in BPA, these entities will be equipped with better tools, striving for greater financial inclusion and regional economic growth in Argentina, overcoming federal barriers and capitalizing on the opportunities AI offers.

Keywords: argentine provincial banks, financial industry, artificial intelligence

Dedicatoria

A todas las personas – familia, amigos, profesores, alumnos y colegas – que me acompañaron en este largo recorrido universitario, lleno de aprendizajes, crecimiento, caídas y reintentos. A cada uno de ellos, mi sincera dedicatoria, acompañada de veinte años de gratitud.

Reconocimientos

A la profesora Dra. Marcela Samela, quien me ha acompañado a lo largo de tres materias en esta carrera, y ha sido una guía esencial en la realización del presente trabajo final. Agradezco su orientación, compromiso y motivación constante en cada etapa de este proceso.

A todos los profesores de la Universidad Abierta Interamericana (UAI) con quienes he cursado, y a la propia institución, por brindarme el sustento académico y las herramientas necesarias para desarrollar mis conocimientos en el campo de la tecnología y la información.

Quisiera también expresar mi reconocimiento a Grupo GYF, mi lugar de trabajo, que en todos estos años me ha brindado el espacio para desarrollarme profesionalmente y me permitió aplicar en la práctica lo aprendido en la universidad. Su apoyo fue inspiración fundamental para la idea de esta propuesta de intervención en el campo profesional.

A todos ellos, mi sincero reconocimiento y agradecimiento.

Índice General

Resumen.....	2
Abstract.....	3
Dedicatoria.....	4
Reconocimientos.....	5
Índice General.....	6
Índice de Gráficos.....	10
Índice de Tablas.....	11
Capítulo 1 - Introducción.....	12
1.1 Descripción del problema.....	12
<i>1.1.1 Planteo del Problema.....</i>	<i>13</i>
1.2 Justificación de la Propuesta de Intervención.....	13
1.3 Marco Institucional.....	14
1.4 Objetivo del Trabajo Final.....	15
<i>1.4.1 Objetivo General.....</i>	<i>15</i>
<i>1.4.2 Objetivos Específicos.....</i>	<i>16</i>
1.5 Resultados y contribución.....	16
Capítulo 2 - Estado del Arte.....	17
2.1 Introducción.....	17
2.2 Problemáticas de los Bancos Provinciales Argentinos.....	17
<i>2.2.1 Competencia en el Mercado Financiero.....</i>	<i>17</i>
<i>2.2.2 Marco Regulatorio.....</i>	<i>19</i>
<i>2.2.3 Situación del Federalismo en Argentina.....</i>	<i>20</i>
2.3 IA aplicada en Gestión de Riesgo Crediticio.....	21
2.4 IA aplicada en Detección de Fraudes.....	22
2.5 IA aplicada en Atención y Comportamiento del Cliente.....	24
Capítulo 3 – Marco Teórico.....	28
3.1 Introducción.....	28
3.2 Inteligencia Artificial.....	28

3.2.1 Concepto y Componentes de la Inteligencia Artificial.....	28
3.2.2 Concepto de Aprendizaje Automático o Machine Learning.....	29
3.2.3 Técnicas de Aprendizaje Automático Aplicadas a la Banca	30
3.2.4 Metodología de Implementación de Modelos de Machine Learning: CRISP-DM	31
3.3 Gestión del Riesgo Crediticio	33
3.3.1 Concepto de Gestión del Riesgo Crediticio	33
3.3.2 Concepto de Modelo de Riesgo Crediticio basado en Machine Learning.....	34
3.3.3 Implementación Práctica de un Modelo de Riesgo Crediticio Basado en IA	34
3.4 Detección de Fraudes.....	36
3.4.1 Concepto de Detección de Fraudes	36
3.4.2 Concepto de Modelos de Detección de Fraudes basados en Machine Learning	36
3.4.3 Implementación Práctica de Modelos de IA para Detección de Fraudes.....	37
3.5 Atención al Cliente y Experiencia del Usuario	38
3.5.1 Concepto de Atención al Cliente y Experiencia del Cliente	38
3.5.2 Concepto de Soluciones de IA aplicadas a la Atención al Cliente y Experiencia del Usuario..	38
3.5.2.1 Análisis Predictivo de Abandono de Cliente o Churn.....	38
3.5.2.2 Recomendación Personalizada de Productos Financieros	39
3.5.2.3 Chatbots	40
3.5.3 Implementación Práctica de Soluciones de IA aplicadas a la Atención al Cliente y Experiencia del Usuario.....	41
3.5.3.1 Implementación Práctica de Modelos de Churn.....	41
3.5.3.2 Implementación Práctica de Sistemas de Recomendación	41
3.5.3.3 Implementación Práctica de Chatbots	42
3.6 Consideraciones previas a la implementación de IA para los Bancos Provinciales Argentinos y sus conceptos	43
3.6.1 Introducción	43
3.6.2 Transformación Digital en la Banca.....	44
3.6.2.1 Concepto	44
3.6.2.2 Papel de la IA en la Transformación Digital en la Banca	45
3.6.3 Gobernanza de Datos en la Banca	46
3.6.3.1 Concepto	46
3.6.3.2 Relación al Marco Regulatorio del BCRA.....	46
3.6.4 El Modelo de Madurez de la Gestión de Datos	47
3.6.4.1 Concepto	47
3.6.4.2 Business Intelligence.....	48

Capítulo 4 – Propuesta de Intervención	50
4.1 Descripción	50
4.1.1 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos	50
4.1.2 Etapa 2: Implementación de BI	52
4.1.3 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio	53
4.1.4 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude	55
4.1.5 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes.....	57
4.1.6 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros	58
4.1.7 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente	59
4.2 Acciones a realizar	60
4.2.1 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos	60
4.2.1.1 Evaluación de la Infraestructura y Capacidad Organizacional (As Is).....	60
4.2.1.2 Definición del Modelo de Gobernanza de Datos (To Be)	61
4.2.1.3 Aplicación de Microsoft Fabric y Microsoft Purview (Implementación).....	62
4.2.2 Etapa 2: Implementación de BI	64
4.2.2.1 Alta y configuración de Power BI en Microsoft Fabric	64
4.2.2.2 Desarrollo y configuración de tableros en Power BI	65
4.2.2.3 Capacitación y soporte para usuarios de visualizaciones BI	66
4.2.3 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio	67
4.2.4 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude	68
4.2.5 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes.....	69
4.2.6 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros	71
4.2.7 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente	72
4.3 Determinación de recursos necesarios	74
4.3.2 Recursos Humanos.....	74
4.3.1 Recursos Tecnológicos.....	77
4.4 Cronograma de tareas	79
4.4.1 Convenciones definidas para el armado del cronograma	80
4.4.2 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos	81
4.4.3 Etapa 2: Implementación de BI	82

4.4.4 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio	83
4.4.5 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude	84
4.4.6 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes.....	85
4.4.7 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros	86
4.4.8 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente	87
4.4.9 Duración total estimada del proyecto	87
4.5 Factores externos condicionantes.....	88
4.5.1 Resistencia Cultural y Temores de Privacidad	88
4.5.2 Escasez de Datos para Entrenamiento de Modelos IA	89
4.5.3 Disponibilidad de Personal Especializado	89
4.5.3 Cambios en la Normativa del BCRA.....	90
4.6 Evaluación del Proyecto	91
4.6.1 Costos de Recursos Tecnológicos	91
4.6.2 Costos de Recursos Humanos	96
4.6.3 Resumen de Costos Totales del Proyecto	96
4.6.4 Matriz FODA de la propuesta de intervención	97
Conclusiones	100
Líneas Futuras de Trabajo	103
Anexo I.....	105
Acrónimos.....	128
Referencias.....	129

Índice de Gráficos

Figura 1 Marcos de gestión.....	19
Figura 2 Las estadísticas de estudios científicos en el campo bancario fraudulento en Scopus por año.....	24
Figura 3 Cantidad de Sectores donde se aplica más la IA en el servicio de atención al cliente ..	25
Figura 4 Tecnologías de Inteligencia artificial más usadas en atención al cliente.....	26
Figura 5 Flujo iterativo del método CRISP-DM	33
Figura 6 Niveles de madurez de la gestión de datos y su relación a BI e IA.....	48
Figura 7 Diagrama de Gantt – Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos.	81
Figura 8 Diagrama de Gantt – Etapa 2: Implementación de BI.....	82
Figura 9 Diagrama de Gantt – Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio.....	83
Figura 10 Diagrama de Gantt – Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude.	84
Figura 11 Diagrama de Gantt – Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes.	85
Figura 12 Diagrama de Gantt – Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros.	86
Figura 13 Diagrama de Gantt – Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente.	87
Figura 14 Cotización a través de la calculadora de costos de servicios Microsoft Azure	93
Figura 15 Cotización de Puestos de Trabajo en Mercado Libre	95

Índice de Tablas

Tabla 1 Entidades bancarias analizadas en Bolsas y Mercados Argentinos (ByMA).....	17
Tabla 2 Comparativa: Técnicas de Machine Learning aplicadas en la banca	31
Tabla 3 Comparación entre Modelos Basados en Reglas y Machine Learning en Chatbots	43
Tabla 4 Costos de recursos Azure considerados para la propuesta de intervención	92
Tabla 5 Costos de puestos de trabajo para la propuesta de intervención	94
Tabla 6 Costos de recursos humanos proyectados según las horas estimadas del proyecto	96
Tabla 7 Costos total de implementación de la propuesta de intervención	97
Tabla 8 Referencias Perfil – Columna titulada en tablas de estimaciones	105
Tabla 9 Estimación de Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos.....	106
Tabla 10 Estimación de Etapa 2: Implementación de BI	107
Tabla 11 Estimación de Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio	108
Tabla 12 Estimación de Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude	109
Tabla 13 Estimación de Etapa 5: Implementación de Modelo Predictivo de Churn (Abandono de Cliente).....	111
Tabla 14 Estimación de Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros	113
Tabla 15 Estimación de Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente	115
Tabla 16 Cuadro total de estimaciones por Etapa y Perfil	117
Tabla 17 Detalle complementario de datos a trasladar al sistema de gestión de planificación del proyecto.....	117

Capítulo 1 - Introducción

1.1 Descripción del problema

Según el Banco Central de la República Argentina (BCRA) (s.f.-a) del total de entidades financieras que opera en Argentina, un subconjunto está compuesto por entidades privadas (BCRA, s.f.-b) y públicas (BCRA, s.f.-c). En ambos grupos se identifican Bancos Provinciales Argentinos (BPA) que concentran la mayoría de sus clientes a nivel regional y que poseen recursos limitados, con relación a otras entidades bancarias con activos mayores, con las que deben competir (BCRA, s.f.-d).

Por otra parte, los autores Gutiérrez et al. (2022) afirman “Inmersos en un mundo de transformaciones, las entidades bancarias en Argentina se encuentran transitando la primera etapa de su proceso de transformación digital” (p. 11). En este contexto, los BPA enfrentan un desafío mayor, considerando que sus presupuestos y activos son menores respecto a los bancos analizados por Gutiérrez et al. (2022) y el ranking de activos del BCRA (BCRA, s.f.-d).

Si bien los bancos de mayor capital, como el Grupo Financiero Galicia y el Banco Macro, ya han comenzado su proceso de digitalización, el análisis de la información pública muestra que la implementación de IA y otras tecnologías disruptivas es incipiente, aunque en curso (Gutiérrez et al., 2022).

Además, muchos BPA se encuentran en zonas geográficas que concentran un público cliente con menos recursos. En este sentido, la forma en que funciona el federalismo argentino también condiciona sus posibilidades de progreso. Gervasoni (2024) destaca:

Es muy probable que las características de nuestro federalismo [...] expliquen en buena parte que, luego de largos años de gobiernos supuestamente comprometidos con la igualdad socioeconómica, [...] el país llegue a su cuarta década de democracia con un nivel de desigualdad peor que el que tenía al inicio del actual período democrático. (p. 25)

Adicionalmente, la regulación financiera en Argentina impone una carga de normativas con requerimientos en constante evolución, exigiendo a los bancos mantenerse en conformidad en todos sus puntos. Un ejemplo de esta carga normativa es la Comunicación A 7724 del BCRA, que exige que las instituciones financieras adopten ciertas medidas en la implementación de tecnologías avanzadas, como la Inteligencia Artificial (IA). Esta normativa impone la necesidad de documentar el uso de algoritmos, evaluar riesgos asociados y asegurar la transparencia y

explicabilidad de los modelos utilizados, lo que añade un nivel adicional de complejidad para los BPA que ya enfrentan limitaciones presupuestarias (BCRA, 2023).

En conclusión, estas entidades deben también competir con instituciones financieras locales, con grandes bancos y con fintechs que ofrecen servicios innovadores y altamente personalizados. En este contexto, es necesario e inevitable que los BPA deban contar con una forma de soportarse en tecnologías como IA, fundamentales para mantenerse competitivos y de este modo poder progresar.

1.1.1 Planteo del Problema

A partir de la descripción realizada del problema, el planteo específico del mismo es cómo los BPA pueden superar estas problemáticas, mejorar su eficiencia operativa y calidad de servicio reforzando su competitividad, mediante la implementación de tecnologías de Inteligencia Artificial (IA).

1.2 Justificación de la Propuesta de Intervención

En un mundo competitivo, inmersos en la era de la información junto a una evolución constante de tecnologías basadas en IA, los BPA están obligados a buscar métodos para implementar estas tecnologías de forma prioritaria. Esto es crucial para no quedar rezagados frente a otras entidades de mayor envergadura que ya están explotando estas tecnologías.

La implementación de tecnologías de IA aborda varios desafíos del sector bancario al añadir valor mediante la mejora de la eficiencia operativa, la personalización de los servicios al cliente, la detección de fraudes y el cumplimiento normativo (Sohail et al., 2021, pp. 1-2).

Por su parte, los autores Noreen et al. (2023) agregan que, dada la naturaleza de los datos en los bancos, la IA cumple un rol significativo en el procesamiento de datos para predecir el futuro de la economía y la industria bancaria (p. 3).

Un ejemplo del impacto positivo de la IA en el sector bancario es su capacidad para mejorar significativamente la detección de fraudes. Como mencionan Noreen et al. (2023), los algoritmos de IA utilizados en instituciones bancarias permiten monitorear comportamientos de clientes y personal de manera más eficaz, detectando anomalías que podrían representar fraudes, y logrando una prevención más rápida y precisa (p. 3). Además, destacan que la implementación de IA en el sector financiero ha contribuido a reducir los costos operativos mediante la automatización de

tareas y el procesamiento de grandes volúmenes de datos, con un ahorro proyectado de hasta USD 416 mil millones para 2023 (Noreen et al., 2023, p. 3).

Sohail et al. (2021) destacan cómo la IA está transformando el sector bancario al mejorar la experiencia del cliente mediante la personalización y optimizar la gestión de riesgos y el cumplimiento normativo a través de procesos automatizados y más precisos (pp. 2-3).

Dada la importancia de los BPA en el desarrollo económico y la inclusión financiera en las regiones que atienden, es crucial explorar y adoptar estas tecnologías para brindar mayor valor, mejorar la rentabilidad y trabajar de manera más eficiente de cara a los clientes.

Esta intervención no solo beneficiará a los BPA, sino también a sus clientes y a las economías regionales en las que operan, promoviendo una banca más eficiente, segura e inclusiva.

1.3 Marco Institucional

El marco institucional de este trabajo se sitúa en el contexto de los Bancos Provinciales Argentinos (BPA), que incluyen una serie de instituciones financieras con un rol fundamental en las economías regionales del país. Estos bancos desempeñan un papel esencial al fomentar el desarrollo económico local y la inclusión financiera, ofreciendo servicios en áreas que muchas veces quedan fuera del alcance de las entidades bancarias nacionales y privadas. Entre las entidades que podrían ser consideradas como parte de este grupo de BPA, basándonos en el nivel de sus activos (BCRA, s.f.-d), se encuentran: BanCor (Banco de la Provincia de Córdoba), Nuevo Banco de Santa Fe, Banco de la Provincia de Neuquén, Banco Entre Ríos (BERSA), Banco de Santiago del Estero, Banco de La Pampa, Banco de San Juan, Banco de Corrientes, Banco del Chubut, Nuevo Banco del Chaco, Banco Formosa, Banco de Santa Cruz, Banco de Tierra del Fuego, Banco Rioja, Banco Bica, Banco Dino, y Banco Masventas. Si bien se desconoce si alguna de estas entidades ya se encuentra embarcada en algún caso de aplicación basado en IA y, de la investigación en sitios web oficiales de estas entidades no se presenta información alguna relacionada, se reconoce que, aún con alguna implementación parcial, el plan de esta propuesta de intervención puede resultarle útil, ya sea para realizar ajustes, para alinear estrategias, revisarlas o directamente considerar en forma completa el plan propuesto.

Resulta relevante aclarar que, si bien se ha analizado el grupo de entidades que conforman a los BPA para este trabajo, el Banco de la Provincia de Buenos Aires ha sido excluido del grupo considerado. Si bien no se cuenta con conocimiento detallado sobre el grado de implementación

de IA, específicamente en lo que respecta a Machine Learning (ML), se entiende que el Banco de la Provincia de Buenos Aires posee una infraestructura tecnológica de gran escala debido a su tamaño según nivel de activos informado por el BCRA (s.f.-d) y teniendo en cuenta la naturaleza de la provincia a la que pertenece. Según información oficial, el Banco de la Provincia de Buenos Aires ha implementado un asistente virtual que actualmente resuelve el 70% de las consultas de sus clientes (Banco de la Provincia de Buenos Aires, s.f.), lo cual refleja un avance en la adopción de herramientas de IA. Por lo tanto, este banco se omite del grupo identificado de BPA en el presente estudio, ya que su capacidad tecnológica y recursos lo diferencian significativamente de las demás entidades provinciales aquí mencionadas.

Los BPA tienen un rol social relevante, promoviendo el acceso a servicios financieros en comunidades desatendidas y apoyando proyectos que favorecen el crecimiento regional. Esto convierte a los BPA en actores estratégicos para el desarrollo de sus provincias y para la reducción de desigualdades socioeconómicas. Sin embargo, esta misión también los enfrenta a desafíos particulares en términos de eficiencia y competitividad, especialmente en un contexto en el cual la banca digital y las fintech están avanzando rápidamente en el mercado financiero.

Los BPA también se encuentran condicionados por las exigencias regulatorias del BCRA, como la Comunicación A 7724 (BCRA, 2023), que establece controles en seguridad de la información y gestión de datos. Estas normativas requieren que los bancos implementen sistemas de gobernanza de datos robustos, con un enfoque en la seguridad y la mitigación de riesgos tecnológicos. Sin embargo, dado que los BPA generalmente disponen de menos recursos financieros y tecnológicos comparados con bancos de mayor tamaño, estas demandas regulatorias presentan un desafío significativo para su infraestructura y capacidad operativa. Estos aspectos serán analizados en mayor detalle en el punto 2.2 del presente trabajo, dentro del contexto del Estado del Arte.

1.4 Objetivo del Trabajo Final

1.4.1 Objetivo General

El objetivo general de esta propuesta de intervención es diseñar un plan de desarrollo por etapas de un sistema de software que implemente Inteligencia Artificial a partir de modelos predictivos de gestión de riesgo crediticio, detección de fraudes, atención al cliente y su comportamiento, dirigido a los Bancos Provinciales Argentinos.

1.4.2 Objetivos Específicos

- Diagnosticar las principales problemáticas enfrentadas por los Bancos Provinciales Argentinos en términos de recursos, cumplimiento normativo y competencia.
- Identificar prácticas de aplicación de inteligencia empresarial (BI) y políticas de gobernanza de datos en la industria financiera que deben formar parte del plan dirigido a Bancos Provinciales Argentinos, previo a la implementación de modelos predictivos de IA.
- Analizar las aplicaciones de IA basadas en modelos predictivos para la gestión de riesgo crediticio, detección de fraudes, y personalización de la atención al cliente en la industria financiera.
- Diseñar una estrategia de implementación gradual del sistema de software, priorizando cada caso de uso de menor a mayor complejidad.
- Elaborar un plan detallado que incluya acciones, cronograma, recursos necesarios y métodos de evaluación del proyecto para la implementación del sistema en los Bancos Provinciales Argentinos.

1.5 Resultados y contribución

Se espera que la propuesta de intervención mejore la eficiencia operativa de los BPA, reduciendo costos y optimizando procesos mediante la aplicación de IA. Esta mejora contribuirá al aumento de la calidad del servicio al cliente mediante la implementación de funcionalidades y experiencias más personalizadas y efectivas. Además, se fortalecerán procesos tales como la anticipación del riesgo crediticio y la detección de fraudes, considerando el cumplimiento normativo. Por último, se espera que estas mejoras contribuyan al fomento de la inclusión financiera y el crecimiento económico, al proporcionar soluciones accesibles y adaptadas a las necesidades de los clientes locales de distintas provincias y regiones de Argentina.

Capítulo 2 - Estado del Arte

2.1 Introducción

Este capítulo revisará el conocimiento actual sobre problemáticas que los BPA enfrentan respecto a la implementación de IA como herramienta de innovación. Por otra parte, contextualizará cómo la aplicación de IA ha contribuido a que las entidades financieras sean más eficientes y competitivas en procesos claves como la gestión del riesgo crediticio, la detección de fraude y la atención al cliente.

Respecto a las problemáticas que enfrentan los BPA, se considera a la competencia, donde participan entidades financieras con volúmenes de activos superiores a los BPA, junto a un escenario actual donde la adopción de tecnologías innovadoras resulta indispensable para mantener la eficiencia operativa. Además, las entidades que adopten IA deben cumplir regulaciones obligatorias, otro aspecto a tener en cuenta. Por último, se contempla también la presencia de un federalismo caracterizado por desigualdades en la Argentina.

2.2 Problemáticas de los Bancos Provinciales Argentinos

A continuación, se presenta información reciente de los últimos dos años que sustenta los casos de las tres problemáticas indicadas en la introducción de este capítulo.

2.2.1 Competencia en el Mercado Financiero

Los BPA se encuentran inmersos en un ecosistema financiero donde deben competir con bancos que poseen mayores activos (BCRA, s.f.-d).

Según Gutiérrez et al. (2022), la IA constituye la principal herramienta tecnológica cuyo uso se puede detectar de la lectura de la información pública de las entidades bancarias argentinas que analizó. Dicho análisis corresponde a un estudio cualitativo realizado sobre las entidades listadas en la Tabla 1.

Tabla 1

Entidades bancarias analizadas en Bolsas y Mercados Argentinos (ByMA)

Especie	Razón Social
BBAR	Banco BBVA Argentina SA

BHIP	Banco Hipotecario SA
BMA	Banco Macro SA
BPAT	Banco Patagonia SA
GGAL	Grupo Financiero Galicia SA
SUPV	Grupo Supervielle SA

Nota. Adaptado de Gutierrez et al. (2022, pp.7-8)

Asimismo, considera que "es probable que el desarrollo futuro del sistema financiero se base principalmente en el perfeccionamiento de los usos de estas herramientas tecnológicas" (Gutiérrez et al., 2022, p. 13).

Por otro lado, Adiguzel (2023), indica que, si las empresas comienzan a crecer y sus sistemas, estructuras, culturas, procesos, rutinas e incluso capacidades empiezan a ralentizarse, tendrán dificultades para adaptarse a los procesos de innovación y cambios, y pueden no ser eficientes. Además, agrega que, con la disminución en la eficiencia de las capacidades de la empresa, las habilidades que ya no se desarrollan pueden volverse inútiles o incluso perjudiciales (p. 5).

Por su parte, Capurro Behr (2023) justifica el desarrollo de un modelo recomendador de productos bancarios utilizando Machine Learning y Deep Learning, a partir de la competencia entre bancos tradicionales y bancos digitales:

El contexto de un mercado altamente competitivo caracterizado por el surgimiento de bancos digitales y la oferta creciente de productos y servicios innovadores, los bancos tradicionales que antes limitaban su cartera de productos se enfrentan a la necesidad de desarrollar nuevas estrategias para mantenerse competitivos, captar nuevos clientes y fidelizar a los actuales. (Capurro Behr, 2023, p.10)

En este contexto, los BPA, con menores recursos frente a otras entidades financieras (BCRA, s.f.-d), se ven forzados a adoptar estas tecnologías para poder ofrecer servicios competitivos y optimizar sus procesos internos.

2.2.2 Marco Regulatorio

La Comunicación A 7724 del BCRA introdujo cambios en los controles tecnológicos y de seguridad de la información que deben ser adoptados, imponiendo nuevas responsabilidades a la alta gerencia (BCRA, 2023).


En este sentido, Escobar (2023) indica que esto representó un desafío en su implementación para las entidades financieras (p. 3).

La alta gerencia de cada banco es responsable de asegurar la realización de evaluaciones de impacto, definiendo los apetitos de riesgo, es decir, cuánto riesgo la organización está dispuesta a aceptar dentro de sus operaciones habituales, en la utilización de tecnologías de IA (BCRA, 2023, p. 5).

La implementación de IA bajo las consideraciones de la Comunicación A7724 del BCRA contempla que los controles tecnológicos y de seguridad de la información integran el concepto de Gobierno de Tecnología y Seguridad de la Información. Estas políticas incluyen la gestión efectiva y segura de los sistemas tecnológicos, enfocándose en proteger la confidencialidad, integridad y disponibilidad de los datos. Además, deben establecer marcos de gestión para áreas críticas como la seguridad de la información, continuidad del negocio y ciberincidentes (Escobar, 2023, p. 8). A continuación, en la Figura 1 se observa que, en el primer marco correspondiente a la gestión de la tecnología de la información, recae la IA en caso de aplicarla. Es el primero de los marcos para atender, bloqueante para los subsiguientes (Escobar, 2023, p. 5).

Figura 1

Marcos de gestión



Nota. Adaptado de *Esquema N°2: Marcos de gestión* (p. 5) por Escobar, 2023, Análisis de los cambios en los controles tecnológicos de la Comunicación A 7724 del BCRA en las entidades financieras, CC BY-NC-ND 4.0

De este modo, la alta gerencia y el directorio tienen responsabilidades explícitas en la implementación y supervisión de estos marcos, lo que refuerza su papel en la mitigación de riesgos relacionados con la tecnología (Escobar, 2023, p. 6). Además, agrega:

Se espera que estos actores clave desempeñen un papel activo en la implementación y el cumplimiento de los controles y prácticas de seguridad de la información. Esto implica una participación directa en la supervisión de las actividades de gobierno, así como un compromiso continuo con la mejora de los procesos y la mitigación de riesgos relacionados con la tecnología y la seguridad de la información. (p. 8).

2.2.3 Situación del Federalismo en Argentina

Una particularidad de los BPA es su situación geográfica y la forma en que el federalismo argentino distribuye los recursos fiscales.

Según Gervasoni (2024), es paradójico que Argentina se haya vuelto más desigual en las últimas cuatro décadas de democracia, ya que los modelos estándar de economía política sugieren que la distribución del ingreso debería ser más equitativa cuando el poder lo detienen las mayorías, en lugar de una élite o una persona. Además, agrega que, aunque no hay evidencia concluyente que vincule causalmente la democracia con una mayor equidad socioeconómica, tampoco hay razón para creer que la democracia empeore la distribución del ingreso. Sin embargo, en Argentina, tanto la desigualdad como la pobreza en 2024 son peores que en 1983, que ya era un año difícil (pp.14-15).

Existen ciertas características del federalismo que pueden contribuir a resultados regresivos. Tres de estas características son particularmente relevantes. La primera se refiere a las dinámicas políticas y distributivas comunes en cualquier sistema federal. La segunda proviene de la combinación de reglas típicas de cualquier sistema federal con particularidades de la versión argentina. La tercera es una consecuencia directa de las peculiaridades del federalismo fiscal en Argentina (Gervasoni, 2024, p. 15).

Finalmente, Gervasoni (2024) indica que, la ley de coparticipación establece que algunas provincias ricas reciban transferencias por habitante mayores que otras provincias mucho más pobres.

Por otra parte, en el contexto del tercer Congreso Federal Bancario de la Asociación de Bancos Públicos y Privados de la República Argentina (ABAPPRA), a través del comunicado

oficial emitido por la entidad, se destacó la necesidad de corregir las asimetrías impositivas y regulatorias que actualmente afectan a la banca federal frente a las fintechs y la solicitud al BCRA, para que acelere la regularización de las asimetrías que afectan a la banca federal (Asociación de Bancos Públicos y Privados de la República Argentina [ABAPPRA], 2024). Asimismo, el congreso indica entre sus conclusiones “Requerimos un marco regulatorio específico para la banca pública provincial, considerando su rol como agente financiero de los estados provinciales y su mandato social orientado al desarrollo y fomento regional.” (ABAPPRA, 2024, párrafo 1).

El comunicado oficial sobre dicho Congreso concluye:

La banca federal de ABAPPRA tiene un papel crucial que desempeñar en el desarrollo económico y social sostenible de Argentina. A través de su compromiso con el fortalecimiento del crédito, la equidad competitiva, la sustentabilidad y la inclusión financiera, la banca federal puede contribuir a un futuro más próspero para todos los argentinos. (ABAPPRA, 2024, párrafo 2).

2.3 IA aplicada en Gestión de Riesgo Crediticio

Los modelos predictivos basados en IA han transformado la gestión de riesgo crediticio en el sector financiero, ofreciendo un nivel de precisión que supera a los métodos tradicionales.

Según González-Rossano et al. (2023), las instituciones financieras en el mundo poseen una ventana de oportunidad al utilizar los avances tecnológicos en el manejo de grandes volúmenes de datos para innovar técnicas de clasificación de riesgo, en beneficio tanto del crecimiento de su propio negocio como del mejoramiento de las condiciones de vida de la sociedad (p. 1580).

Tal y como indica González-Rossano et al. (2023), “La literatura sobre el análisis del riesgo crediticio muestra evidencias de los beneficios del uso de algoritmos de clasificación que hacen uso de grandes cantidades de información, adicional a la que los puntajes de crédito tradicionales emplean” (p. 1570). Esta capacidad de procesamiento de datos permite identificar con mayor antelación a los clientes con riesgo de morosidad, lo que ha permitido reducir la tasa de impagos significativamente.

Sumado a lo anterior, Zapata Yanez (2024) fortalece este enfoque sobre la utilización de metodologías de aprendizaje automático en la clasificación de riesgo crediticio, mediante la aplicación de modelos de Árboles de decisión y Random Forest. Y destaca:

Si bien por un lado el modelo de Random Forest puede ofrecer precisiones en las predicciones ligeramente superiores, el Árbol de Decisión brinda una ventaja significativa en términos de interpretabilidad y facilidad de implementación en entornos financieros prácticos. [...]

Con un enfoque continuo en la mejora e innovación, las instituciones financieras pueden fortalecer su capacidad para identificar y mitigar los riesgos asociados con la morosidad crediticia, promoviendo así la estabilidad y la salud financiera a largo plazo. (p. 31)

Bajo el enfoque de Medina Reyes et al. (2024), los modelos predictivos tradicionales, como el Logit o el Probit, tienden a subestimar o sobreestimar ciertos riesgos crediticios en función de las características del cliente, mientras que el modelo Difuso es capaz de proporcionar una mejor estimación ajustada para diferentes escenarios de incertidumbre.

El modelo Fuzzy Gaussian Logistic Credit Score ha demostrado ser más eficiente en la administración del riesgo crediticio en comparación con los modelos tradicionales. En particular, este enfoque mejora la capacidad de las instituciones financieras para tomar decisiones informadas, dado que permite evaluar mejor las incertidumbres y riesgos asociados a los créditos. Además, ofrece una medición más precisa de las pérdidas esperadas para diferentes niveles de incertidumbre, lo que se traduce en una reducción significativa de los costos asociados al riesgo crediticio (Medina Reyes et al., 2024, p. 201).

Para los BPA, adoptar la aplicación de modelos de gestión de riesgo crediticio podrían representar una ventaja competitiva, especialmente en un entorno donde la capacidad de anticipar riesgos es crucial para la estabilidad financiera.

2.4 IA aplicada en Detección de Fraudes

La detección de fraudes es una de las áreas donde la IA ha tenido un impacto considerable en la industria financiera. En el caso de los BPA, el impacto toma mayor relevancia, al permitir mitigar los riesgos financieros en un entorno con recursos limitados.

Según Toluwani (2024), el uso de la IA para la detección de fraudes ha revolucionado la seguridad en el sector financiero, proporcionando nuevas herramientas para identificar, prevenir y mitigar actividades fraudulentas en bancos y servicios financieros (p. 130).


Entre los aspectos clave del uso de IA para la detección de fraudes, Toluwani (2024) destaca la mayor precisión en la identificación de actividades fraudulentas, debido a la capacidad de los algoritmos para analizar grandes volúmenes de datos y detectar patrones y anomalías que los métodos tradicionales no identifican. Además, agrega que la IA permite la supervisión en tiempo real, lo que facilita a las instituciones financieras reaccionar de manera oportuna ante fraudes potenciales, minimizando las pérdidas y el impacto en los clientes. Otro beneficio que menciona es la reducción de falsos positivos, lo que mejora la eficiencia operativa y reduce molestias innecesarias para los usuarios. La automatización de estos procesos a través de IA ha reducido los costos al eliminar la intervención manual y optimizar la asignación de recursos. Finalmente, resalta que los sistemas de IA están en constante aprendizaje, adaptándose a las nuevas tácticas de fraude y fortaleciendo su capacidad para enfrentar amenazas futuras (Toluwani, 2024).

Por otra parte, Mytnyk et al. (2023) señalaron que los algoritmos de clasificación propuestos, basados en redes neuronales artificiales, permiten determinar el tipo de transacción según características específicas. Este modelo ha demostrado una mejora significativa en la precisión para detectar transacciones fraudulentas, destacando la efectividad de la tecnología de IA en el procesamiento de grandes volúmenes de datos, así como en la reducción de falsos positivos y la optimización de las respuestas operativas (p. 16).

A continuación, a través de la Figura 2 Mytnyk et al. (2023) expone un marco de investigaciones en el ámbito del fraude cuya fuente es Scopus (base de datos multidisciplinaria de citas y resúmenes de bibliografía revisada por pares). En dicho marco se sustenta la utilización de métodos de aprendizaje automático basados en detección de fraudes.

Figura 2

Las estadísticas de estudios científicos en el campo bancario fraudulento en Scopus por año.



Nota. Adaptado de *The statistics of scientific studies in fraudulent banking field in Scopus by year*. (p. 3) por Mytnyk et al., 2023, Application of artificial intelligence for fraudulent banking operations recognition, CC BY 4.0

Por último, Noreen et al. (2023) señalan que las instituciones financieras enfrentan un riesgo creciente de fraude debido al alto volumen de transacciones y la complejidad de las operaciones. En respuesta a esto, afirman que la IA, a través de algoritmos avanzados y aprendizaje no supervisado, facilita el monitoreo del comportamiento de clientes y empleados, simplificando la prevención del fraude, automatizando tareas humanas en el sector bancario y ayudando a prevenir amenazas que afectan las funciones empresariales (p. 3).

2.5 IA aplicada en Atención y Comportamiento del Cliente

Según Rojas Ahumada et al. (2023):

La inteligencia artificial en el servicio al cliente muestra que los chatbots se están convirtiendo en una tecnología cada vez más utilizada para mejorar la eficiencia y reducir el costo del servicio al cliente. En particular, los sectores de turismo/hotelería, finanzas y servicios públicos son las aplicaciones más frecuentes de esta tecnología. (p. 217)

La Figura 3 resalta que de los principales sectores donde se está aplicando a la IA como un aliado para la atención al cliente, el Financiero (con valor 5) es el primero.

Figura 3

Cantidad de Sectores donde se aplica más la IA en el servicio de atención al cliente




Nota. Adaptado de *Figura 7. Cantidad de Sectores donde se aplica más la IA en el servicio de atención al cliente según bibliografía. Elaboración propia.* (p. 216) por Rojas Ahumada et al., 2023, El impacto de la Inteligencia Artificial en la mejora de la atención al cliente: Una revisión sistémica, CC BY 4.0

Esta tecnología permite que los asistentes humanos se centren en problemas más complejos, mientras que los chatbots manejan las consultas más sencillas, reduciendo las colas de los centros de atención y mejorando la eficiencia general del servicio. Según Rojas Ahumada et al. (2023), "los chatbots son una de las aplicaciones más utilizadas en la atención al cliente para brindar respuestas rápidas y efectivas a las consultas de los usuarios" (p. 201). No obstante, indican que el éxito de la IA en la atención al cliente no solo depende de la eficiencia que aporte, sino también de la satisfacción del cliente con la tecnología.

A través de la Figura 4, Rojas Ahumada et al. (2023) indican gráficamente que la tecnología más implementada en el servicio de atención al cliente corresponde a los chatbots.

Figura 4

Tecnologías de Inteligencia artificial más usadas en atención al cliente



Nota. Adaptado de *Figura 6. Tecnologías de Inteligencia artificial más usadas según bibliografía. Elaboración propia.* (p. 214) por Rojas Ahumada et al., 2023, El impacto de la Inteligencia Artificial en la mejora de la atención al cliente: Una revisión sistémica, CC BY 4.0

Contribuyendo a este enfoque, Noreen et al. (2023) agregan que la implementación de chatbots en el sector bancario ha demostrado ser una herramienta eficaz para interactuar con los clientes y resolver consultas de manera rápida y eficiente, sin necesidad de intervención humana. Estos sistemas no solo proporcionan respuestas automáticas a las preguntas más comunes, sino que también recopilan datos valiosos sobre las consultas de los usuarios, lo que permite mejorar la resolución de problemas futuros. Además, la adopción de IA en la atención al cliente está directamente relacionada con la satisfacción de los usuarios, quienes valoran las respuestas rápidas y personalizadas. Por último, Noreen et al. (2023) afirman que, a través del aprendizaje automático, los bancos pueden predecir el comportamiento de los clientes y adaptar sus servicios a sus necesidades, lo que mejora la experiencia del cliente y contribuye a su fidelización (p. 3).

Por otra parte, Mayor Lupo (2023) se enfoca en la aplicación del análisis predictivo de comportamiento del cliente mediante el modelo de churn, demostrando la importancia de la

estimación de la probabilidad de abandono por cliente a la hora de implementar un programa de retención a corto plazo. Concluye:

Finalmente podemos afirmar que la probabilidad de abandono brinda información valiosa para anticiparse a posibles pérdidas de clientes y tomar medidas proactivas. Al segmentar a los clientes según su probabilidad de abandono, se pueden diseñar estrategias personalizadas de retención y desarrollar campañas específicas dirigidas a los segmentos de mayor riesgo de fuga. [...]

En resumen, los análisis descriptivos de resultados y los casos de uso han demostrado que la probabilidad de abandono es una herramienta estratégica para las gerencias del banco, brindando información valiosa que les permite tomar decisiones informadas y asignar recursos de manera eficiente en la lucha contra la fuga de clientes. (p. 65)

Por último, según Capurro Behr (2023):

El desarrollo de un modelo recomendador de productos bancarios utilizando técnicas de Machine Learning y Deep Learning puede ser una iniciativa estratégica para las entidades financieras. Este modelo puede ayudar a mejorar la satisfacción del cliente y fortalecer las relaciones con el banco al ofrecer recomendaciones personalizadas y relevantes. (p. 54).

El abordaje se basó en la construcción y demostración de la eficacia de un modelo basado en factorización matricial neural, que combina la linealidad de la factorización matricial con la no linealidad del perceptrón multicapa, permitiendo reducir falsos positivos, logrando identificar correctamente las interacciones con datos limitados. (Capurro Behr, 2023).

Capítulo 3 – Marco Teórico

3.1 Introducción

El propósito de este Marco Teórico es establecer el fundamento conceptual de los temas vinculados a la integración eficaz de la IA en las operaciones de los BPA, con base en el sustento teórico de estudios anteriores. Para ello, se revisa la teoría y modelos relevantes en IA que aplican a esta propuesta de intervención, es decir, la gestión de riesgos, la detección de fraudes, la atención al cliente y otros conceptos previos que deben ser considerados por los BPA para la implementación de IA. Dichos conceptos corresponden a Transformación Digital, Gobernanza de Datos y la Analítica Descriptiva y Diagnóstica aplicable a los datos, dentro del marco del Modelo de Madurez de la Gestión de Datos.

3.2 Inteligencia Artificial

3.2.1 Concepto y Componentes de la Inteligencia Artificial

Según el BCRA (2023), la IA es definida como el "conjunto de teorías y algoritmos que permiten llevar a cabo tareas que, típicamente, requieren capacidades propias de la inteligencia humana" (p. 74).

En un sentido más académico, Russell y Norvig (2010) definen a la IA como la disciplina que estudia y desarrolla algoritmos y sistemas capaces de realizar tareas que normalmente requerirían inteligencia humana. Estas tareas incluyen desde la capacidad de aprender a partir de datos y experiencias hasta la toma de decisiones automatizadas basadas en un procesamiento complejo de información (p. 1).

Continuando con el concepto aportado por Russell y Norvig (2010), se presentan cuatro enfoques que ilustran los fundamentos de la IA. El primero aplica a pensar humanamente, que refiere al intento de imitar los procesos de pensamiento humano, incluyendo actividades como la resolución de problemas, el aprendizaje y la toma de decisiones. El segundo es el pensamiento racional, cuyo enfoque busca modelar procesos de pensamiento lógicos, basados en reglas formales, para lograr que las máquinas razonen de manera óptima. Aquí, la IA intenta implementar procesos que sigan principios racionales para resolver problemas. El tercer enfoque considera al acto humano, es decir, la IA buscando simular el comportamiento humano en tareas que

normalmente requerirían inteligencia cuando las realiza una persona, como la interacción con usuarios a través de chatbots o asistentes virtuales. Y el último enfoque es el del acto racional, centrado en el diseño de "agentes inteligentes" que toman decisiones óptimas basadas en la información disponible, maximizando su eficiencia y capacidad de adaptación, lo que es crucial para aplicaciones como los sistemas de recomendación o la automatización de procesos en la banca (Russell y Norvig, 2010, pp. 2-5)

Entre los componentes principales de la IA se destacan el aprendizaje automático o Machine Learning, el procesamiento de lenguaje natural (NLP), las redes neuronales y los sistemas expertos. Estos subcampos contribuyen significativamente a la eficiencia y automatización en la banca. El aprendizaje automático permite la creación de modelos predictivos que anticipan comportamientos financieros, mientras que el NLP facilita la automatización de interacciones mediante chatbots y asistentes virtuales, mejorando la atención al cliente y reduciendo costos operativos (González-Rossano et al., 2023; Rojas Ahumada et al., 2023).

3.2.2 Concepto de Aprendizaje Automático o Machine Learning

BCRA (2023) define al aprendizaje automático o Machine Learning (ML) como la “rama de la inteligencia artificial que consiste en conseguir que un ordenador extraiga conclusiones a partir del análisis estadístico de los datos que se introducen, mediante un proceso que va mejorando de modo automático conforme se incorpora más evidencia al algoritmo” (p. 72).

Por otra parte, Domingos (2015) indica que el aprendizaje automático, o Machine Learning (ML), es un subcampo de la inteligencia artificial que permite que los algoritmos se desarrollen a partir de los datos, lo que automatiza la creación de soluciones más allá de lo que se podría lograr con programación manual. Describe esta tecnología como algoritmos que construyen otros algoritmos, permitiendo a las máquinas aprender de ejemplos y descubrir patrones que no siempre podemos describir explícitamente. Esta capacidad convierte al ML en una herramienta poderosa para analizar grandes volúmenes de información y resolver problemas complejos de manera eficiente, especialmente en sectores que requieren análisis precisos y rápidos, como el financiero (pp. 7-8).

Desde una tercera perspectiva que resalta la capacidad del aprendizaje automático para mejorar continuamente su desempeño en función de los datos procesados, haciendo énfasis en el

proceso iterativo de aprendizaje basado en la experiencia, Mitchell (1997), define el aprendizaje automático como un programa de computadora que se considera que aprende de la experiencia E respecto a alguna clase de tareas T y medida de rendimiento P, si su rendimiento en tareas de T, medido por P, mejora con la experiencia E (p. 2).

3.2.3 Técnicas de Aprendizaje Automático Aplicadas a la Banca

El sector bancario ha adoptado diversas técnicas de ML para optimizar sus operaciones y mejorar la toma de decisiones, siendo los árboles de decisión y Random Forest dos de las más utilizadas. Según Zapata Yanez (2024), “la metodología de árboles de decisión ofrece una solución interpretable y fácilmente comprensible, mientras que Random Forest proporciona un enfoque más robusto y escalable mediante la combinación de varios árboles de decisión” (p. 2) permitiendo la clasificación precisa de los clientes según su perfil de riesgo crediticio.

La técnica de árboles de decisión facilita la segmentación a partir de variables como el historial de pagos y los ingresos, proporcionando una herramienta útil para la gestión proactiva del riesgo, mientras que la técnica de Random Forest ha demostrado ser especialmente eficaz en escenarios donde se requiere analizar grandes volúmenes de datos, como en el sector financiero. La combinación de varios modelos permite reducir el riesgo de sobreajuste y mejorar la precisión general en la toma de decisiones. (Zapata Yanez, 2024, pp. 28-30).

Por otra parte, las redes neuronales artificiales (ANN) se utilizan en el sector financiero para abordar problemas complejos, como la predicción de la deserción de clientes (churn rate). Según Noreen et al. (2023), mediante el análisis de datos transaccionales y operativos, las ANN permiten clasificar a los clientes según su probabilidad de abandonar la institución bancaria, optimizando así las estrategias de retención (p. 8). Esta capacidad refleja el potencial de las ANN para descubrir patrones complejos en los datos que son difíciles de identificar con métodos tradicionales.

A continuación, se presenta la Tabla 2 con una comparativa que resume las características principales de estas técnicas, destacando sus beneficios, limitaciones y aplicaciones más relevantes en el ámbito financiero.

Tabla 2*Comparativa: Técnicas de Machine Learning aplicadas en la banca*

Técnica	Ventajas	Desventajas	Casos de Uso	Referencias
Árboles de decisión	Interpretabilidad, fácil implementación	Puede sobreajustar	Gestión del riesgo crediticio	Zapata Yanez (2024)
Random Forest	Alta precisión, robustez	Menor interpretabilidad	Predicción de fraude y churn	Zapata Yanez (2024)
Redes Neuronales	Capacidad para patrones complejos	Requiere gran cantidad de datos	Predicción de churn	Noreen et al. (2023)
Regresión Logística	Fácil interpretación	Limitada en relaciones no lineales	Predicción de abandono	Brito et al. (2024)

Nota. Elaboración propia.

3.2.4 Metodología de Implementación de Modelos de Machine Learning: CRISP-DM

Tal y como describen Chapman et al. (2000, pp. 6-7), la metodología CRISP-DM se diseñó para proporcionar una estructura probada y flexible que guía cada fase de un proyecto de ciencia de datos, facilitando su implementación. Esta metodología ofrece un marco práctico, fundamentado en la experiencia aplicada y no en teorías abstractas, con el fin de garantizar consistencia y efectividad en el desarrollo y éxito de los modelos.

Esta metodología CRISP-DM organiza el ciclo de vida de un proyecto de minería de datos en fases bien definidas, especificando las tareas correspondientes a cada fase y las relaciones entre estas. Este marco permite que las conexiones entre tareas pueden variar según los objetivos, el contexto y el interés del usuario, así como en función de los datos disponibles (Chapman et al., 2000, p. 10).

Comprensión del Negocio: La primera fase del proceso consiste en comprender los objetivos del negocio y las necesidades estratégicas que motivan el proyecto. Esto implica identificar los problemas o áreas de oportunidad que se desean abordar. Una comprensión clara del

negocio permite alinear los resultados del modelo con las expectativas de la organización (Chapman et al., 2000, p. 10).

Comprensión de los Datos: Una vez definidos los objetivos de negocio, la siguiente fase se enfoca en la recopilación y análisis preliminar de los datos disponibles. Esta etapa permite identificar las fuentes relevantes, evaluar la calidad de los datos y detectar posibles problemas que puedan afectar el desempeño del modelo. (Chapman et al., 2000, p. 10).

Preparación de los Datos: Esta fase implica el proceso de selección, limpieza y transformación de los datos, para asegurar que estén en un formato adecuado para el entrenamiento del modelo. En muchos casos, es necesario realizar tareas como la imputación de valores faltantes, la normalización de variables y la selección de características clave. En esta etapa, se decide qué datos serán utilizados específicamente por los modelos (Chapman et al., 2000, p. 11).

Modelado: En esta fase se seleccionan y entrenan modelos para aplicar a los datos previamente preparados. La metodología CRISP-DM permite probar varios modelos y ajustar sus parámetros para maximizar su desempeño. (Chapman et al., 2000, p. 11).


Evaluación: Antes de desplegar el modelo en un entorno productivo, se debe evaluar su calidad y rendimiento para asegurar que cumple con los objetivos de negocio y satisface las necesidades de la organización. La evaluación también considera si los resultados son comprensibles y si no están alineados con los objetivos del negocio, pueden rechazarse (Chapman et al., 2000, p. 11).

Despliegue: En esta última fase, el modelo se integra en los sistemas operativos de la entidad y comienza a generar resultados en tiempo real. La creación del modelo no marca el final del proyecto. Aunque el objetivo sea ampliar el conocimiento sobre los datos, los resultados obtenidos deben organizarse y presentarse de una forma útil para el cliente. En muchos casos, el despliegue implica integrar modelos en los procesos de toma de decisiones de la organización, como la personalización en tiempo real de páginas web o la evaluación periódica de bases de datos de marketing. La fase de despliegue puede variar en complejidad, desde generar un informe hasta implementar un proceso repetible de minería de datos en toda la empresa. Frecuentemente, es el propio cliente, y no el analista de datos, quien lleva a cabo los pasos de despliegue. No obstante,

es importante que el cliente comprenda desde el inicio las acciones necesarias para aprovechar los modelos creados (Chapman et al., 2000, p. 11).

Figura 5

Flujo iterativo del método CRISP-DM



Nota. Elaboración propia, inspirado en Chapman et al. (2000).

3.3 Gestión del Riesgo Crediticio

3.3.1 Concepto de Gestión del Riesgo Crediticio

Se define la gestión de riesgo crediticio como la instauración de una estructura que favorece a los directivos y alta gerencia en la toma de decisiones relacionadas con el riesgo (García, 2009; Gonzales y Vaz, 2014, como se citó en Rivera et al., 2021, p. 72). Esta definición enfatiza la importancia de establecer una estructura organizacional que facilite la toma de decisiones

informadas sobre riesgos crediticios, permitiendo a las instituciones financieras evaluar, mitigar y gestionar eficazmente la probabilidad de incumplimiento en la devolución de créditos.

3.3.2 Concepto de Modelo de Riesgo Crediticio basado en Machine Learning

Según Broby (2022), un modelo de riesgo crediticio basado en ML utiliza grandes volúmenes de datos históricos y actuales para identificar patrones complejos en el comportamiento financiero de los clientes. Estos modelos aplican algoritmos de clasificación, como árboles de decisión y Random Forest, que son efectivos para manejar grandes volúmenes de datos estructurados y facilitan la interpretación de los resultados. La capacidad de estos modelos para ajustarse en función de cambios en los patrones de comportamiento o en las condiciones económicas los hace especialmente útiles para el sector financiero, permitiendo una evaluación en tiempo real del riesgo crediticio y automatizando procesos anteriormente manuales (Broby, 2022, p. 149-155)

Medina Reyes et al. (2024) concluyen que los modelos Fuzzy Gaussian Logistic Credit Score, aplicados en instituciones financieras, permiten un manejo más eficiente del riesgo crediticio comparado con los modelos tradicionales, mejorando así la toma de decisiones bajo incertidumbre y reduciendo los costos asociados al riesgo. Además, la capacidad de estos modelos para ajustar la estimación del riesgo en función de las condiciones económicas cambiantes resulta clave para entidades con recursos limitados (p. 182).

Zapata Yáñez (2024) enfatiza que los modelos de Random Forest ofrecen robustez y escalabilidad al combinar múltiples árboles de decisión, logrando así mejorar la precisión en la predicción de riesgos crediticios. Además, estos modelos permiten gestionar la complejidad en los datos y abordar problemas con volúmenes grandes y diversas variables financieras. La autora destaca que los Árboles de Decisión son una alternativa útil para entornos con recursos limitados, gracias a su facilidad de implementación y su capacidad interpretativa, lo que los convierte en una herramienta valiosa en la toma de decisiones financieras (pp. 28-32).

3.3.3 Implementación Práctica de un Modelo de Riesgo Crediticio Basado en IA

La adopción de modelos de ML en la gestión del riesgo crediticio implica una serie de pasos que se consolidan a partir de los estudios que se citan en este punto.

En primer lugar, Broby (2022) enfatiza la importancia de contar con sistemas capaces de manejar grandes volúmenes de datos y de integrar múltiples fuentes de información, como datos financieros históricos, variables macroeconómicas y comportamientos de pago de clientes, lo cual permite una visión integral del riesgo (p. 152).

Una vez garantizada la infraestructura, la entidad debe seleccionar el modelo más adecuado a sus necesidades específicas. Los algoritmos de clasificación como Random Forest y árboles de decisión han demostrado ser eficaces debido a su facilidad de implementación y alta interpretabilidad, aspectos especialmente relevantes para instituciones con recursos limitados. Estos modelos ofrecen resultados precisos y comprensibles, permitiendo identificar clientes de alto riesgo con mayor eficacia que los enfoques tradicionales (Zapata Yáñez, 2024; Noriega et al., 2023).

El entrenamiento del modelo es una etapa crítica en la que se utilizan datos históricos para ajustar los parámetros del algoritmo. Según Noriega et al. (2023) la calidad de los datos es un factor determinante en el rendimiento del modelo, por lo que es necesario aplicar técnicas de preprocesamiento, como la normalización o la imputación de valores faltantes, para asegurar la consistencia de los insumos. La validación cruzada es esencial en esta fase, ya que permite medir la precisión del modelo y evitar el sobreajuste, asegurando que pueda generalizarse adecuadamente a nuevos datos. La métrica AUC (Area Under the Curve) es recomendada para medir la capacidad del modelo de distinguir entre clientes solventes y de alto riesgo, minimizando así el riesgo de sobreajuste (pp. 7-11).

Una vez validado, el modelo se integra en los sistemas operativos de la entidad financiera, lo que requiere un monitoreo continuo. Esto permite que el modelo se actualice periódicamente con nuevas entradas de datos, adaptándose a las condiciones cambiantes del mercado y mejorando así su relevancia a lo largo del tiempo. La implementación de pipelines de datos automatizados facilita esta actualización, asegurando que las decisiones crediticias estén siempre alineadas con las circunstancias actuales (Noriega et al., 2023, pp. 7-11).

Finalmente, la adopción de IA en la gestión del riesgo crediticio implica también un cambio cultural dentro de la organización. Broby (2022) señala la importancia de capacitar a los equipos en la interpretación de los resultados generados por los modelos de ML y fomentar una cultura

orientada a los datos, donde la IA se perciba como una herramienta estratégica que complementa las habilidades humanas (p. 152).

3.4 Detección de Fraudes

3.4.1 Concepto de Detección de Fraudes

Como describe Vanini et al. (2023), la detección de fraudes en el sector financiero implica identificar actividades sospechosas en las transacciones de los usuarios para prevenir pérdidas económicas y preservar la integridad del sistema. La detección efectiva se basa en identificar patrones anómalos en tiempo real para bloquear transacciones fraudulentas y minimizar tanto el impacto financiero como los riesgos operativos de las instituciones (pp. 1-2).

Históricamente, las técnicas de detección se basaban en reglas estáticas y análisis retrospectivo, lo que generaba limitaciones para responder a amenazas emergentes. La IA ha superado estas barreras al permitir que los sistemas evolucionen y se adapten conforme cambian los patrones de comportamiento de los usuarios. Según Mytnyk et al. (2023), las técnicas modernas de detección integran no solo datos históricos sino también información en tiempo real, maximizando así la capacidad de respuesta y minimizando falsos positivos.

3.4.2 Concepto de Modelos de Detección de Fraudes basados en Machine Learning

Un modelo de ML aplicado a la detección de fraudes es un sistema basado en algoritmos cuyo objetivo es identificar patrones anómalos en los datos financieros, diferenciando entre transacciones legítimas y actividades fraudulentas (Vanini et al., 2023, p. 3). A diferencia de los enfoques tradicionales, que dependen de reglas estáticas predefinidas, estos modelos son dinámicos y evolucionan conforme cambian los comportamientos de los usuarios y los métodos de ataque (Mytnyk et al., 2023). Esta capacidad de adaptación permite a los sistemas mantenerse actualizados y responder de manera más eficaz a fraudes emergentes en tiempo real, mejorando así la seguridad y eficiencia en las instituciones financieras (Vanini et al., 2023, p. 4).

Estos modelos se dividen en dos enfoques principales: supervisados y no supervisados. Los modelos supervisados, como Random Forest y Gradient Boosting, requieren datos etiquetados previamente, es decir, transacciones marcadas como fraudulentas o no fraudulentas, para entrenar al modelo en la clasificación de nuevas transacciones (Zapata Yáñez, 2024). Por su parte, los

modelos no supervisados, como los autoencoders, no dependen de datos etiquetados; en su lugar, buscan identificar anomalías comparando cada nueva transacción con patrones típicos observados en los datos históricos. Esto permite detectar comportamientos sospechosos que no habían sido previstos explícitamente (Mytnyk et al., 2023).

El uso de redes neuronales es especialmente relevante en la detección de fraudes debido a su capacidad para analizar tanto datos estructurados como no estructurados. Estas redes pueden procesar transacciones complejas, como transferencias internacionales, para identificar relaciones ocultas que podrían ser indicativas de fraude. Los modelos basados en redes neuronales también son altamente efectivos para adaptarse a patrones de fraude emergentes, mejorando su precisión a través del aprendizaje continuo y la optimización automática de parámetros (Vanini et al., 2023).

3.4.3 Implementación Práctica de Modelos de IA para Detección de Fraudes

La selección del modelo adecuado dependerá de la cantidad de datos etiquetados disponibles. En las fases iniciales, un modelo supervisado como Random Forest es altamente efectivo para la detección de patrones anómalos y comportamientos sospechosos, proporcionando una alta precisión y robustez. Según Zapata Yáñez (2024), el modelo de Random Forest permite identificar clientes con riesgos potenciales, obteniendo un puntaje F1 del 93% y una precisión general del 93% en la clasificación de transacciones, lo que demuestra su eficacia y capacidad de generalización en grandes volúmenes de datos (pp. 25-27). Este enfoque inicial puede ser complementado con ajustes progresivos basados en la retroalimentación operativa, mejorando así la capacidad del sistema para adaptarse a nuevas dinámicas del entorno financiero.

Por otra parte, Vanini et al. (2023) destacan que los Bagged Decision Trees (BDT) son especialmente efectivos en la detección de comportamientos anómalos en sistemas de banca electrónica, gracias a su capacidad para combinar múltiples árboles de decisión entrenados con subconjuntos de datos históricos. Este enfoque reduce el riesgo de sobreajuste y mejora la precisión, proporcionando una herramienta robusta y adaptable a instituciones con recursos tecnológicos limitados (p. 9).

Finalmente, es crucial que los modelos se integren con sistemas en tiempo real que bloqueen o alerten sobre fraudes potenciales de forma automática. La capacidad de actuar rápidamente es un factor diferenciador que aporta la IA en este campo, permitiendo mitigar

pérdidas antes de que impacten significativamente a la entidad o sus clientes (Mytnyk et al., 2023, p. 2).

3.5 Atención al Cliente y Experiencia del Usuario

3.5.1 Concepto de Atención al Cliente y Experiencia del Cliente

Homburg et al. (2015) explican que la atención y experiencia del cliente incluye la interacción continua y significativa en diferentes puntos de contacto, buscando no solo satisfacer necesidades inmediatas, sino también fomentar relaciones a largo plazo mediante un soporte adaptado y efectivo durante todo el recorrido del cliente (pp. 381-385)

Lemon y Verhoef (2016) indican que la experiencia del cliente (CX), por otro lado, se centra en cómo los clientes perciben estas interacciones en su totalidad, incluyendo factores emocionales y funcionales. Esta experiencia es multidimensional y comprende todas las etapas del recorrido del cliente, desde la pre-compra hasta el servicio postventa (p. 70).

La gestión efectiva de la CX es crucial para mejorar la satisfacción y la lealtad de los clientes, como afirman Kokins et al. (2021), quienes destacan que las empresas que optimizan su customer journey mediante puntos de contacto coherentes logran una mayor fidelización y recomendación (pp. 2-3). Por su parte, Helkkula et al. (2012) argumentan que la experiencia del cliente no solo mejora la percepción de los servicios, sino que también permite a las empresas identificar oportunidades para la innovación en el diseño de productos y servicios (pp. 61-63).

3.5.2 Concepto de Soluciones de IA aplicadas a la Atención al Cliente y Experiencia del Usuario

Como se expuso en el estado del arte, la inteligencia artificial ha transformado radicalmente la forma en que las instituciones financieras abordan la atención al cliente, permitiendo una mayor eficiencia y personalización. En los siguientes sub incisos se abordan los conceptos relacionados a modelos de churn, sistemas de recomendación personalizados y chatbots, que no solo automatizan tareas repetitivas, sino que también mejoran la experiencia del cliente al brindar respuestas rápidas y relevantes.

3.5.2.1 Análisis Predictivo de Abandono de Cliente o Churn

Según Tékouabou et al. (2022), el análisis predictivo del abandono de clientes, conocido como churn, es un tipo de análisis que utiliza algoritmos de aprendizaje automático para detectar

patrones en los datos históricos de clientes que puedan indicar una alta probabilidad de abandono. El objetivo es implementar estrategias preventivas basadas en estas predicciones para mantener la retención y optimizar los recursos.

Las técnicas utilizadas para la predicción incluyen regresión logística, árboles de decisión, bosques aleatorios y XGBoost, cada una con ventajas específicas en términos de interpretabilidad y precisión. Los algoritmos de ensamble, como destaca Tékouabou et al. (2022), combinan varios modelos para mejorar el rendimiento global, permitiendo que las instituciones gestionen de forma más eficiente las fugas de clientes. Además, dado que las muestras de clientes que abandonan suelen ser significativamente menores, los autores recomiendan el uso de técnicas de balanceo de datos como SMOTE para evitar sesgos en los modelos predictivos.

Brito et al. (2024) resaltan que la implementación de técnicas avanzadas de preprocesamiento y balance de datos, como ADASYN y NEARMISS, es fundamental para mejorar la precisión de los modelos de predicción de churn en entornos de datos desbalanceados, ayudando a reducir la influencia de clases mayoritarias y permitiendo una predicción más robusta (pp. 10-12).

Ambos estudios coinciden en que la predicción de churn no solo mejora la eficiencia operativa, sino que también maximiza la rentabilidad de las instituciones financieras al retener clientes de alto valor. La combinación de técnicas avanzadas de Machine Learning, junto con un enfoque estratégico de gestión del abandono, permite a los bancos anticiparse a las necesidades de los clientes y evitar pérdidas significativas.

3.5.2.2 Recomendación Personalizada de Productos Financieros

Según Noreen et al. (2023), la inteligencia artificial permite a los bancos analizar y predecir el comportamiento de los clientes mediante algoritmos de Machine Learning, lo que facilita el desarrollo de planes y recomendaciones financieras adaptadas a las preferencias individuales. Este enfoque no solo mejora la satisfacción del cliente, sino que también optimiza la experiencia digital en banca, cumpliendo con las expectativas de respuestas rápidas y contenido personalizado (p. 3).

Por su parte, Li y Song (2024) destacan que los sistemas de recomendación de productos financieros impulsados por inteligencia artificial, especialmente mediante el uso de tecnologías avanzadas como el modelo Transformer, el aprendizaje por transferencia (transfer learning) y las

redes neuronales de grafos (GNN), permiten capturar patrones complejos en el comportamiento de los usuarios y en la información de productos. Este enfoque potencia la precisión y la personalización de las recomendaciones, logrando que los productos financieros se adapten mejor a las necesidades individuales de los clientes, lo cual incrementa la satisfacción del usuario y la eficiencia en los servicios financieros (p. 4)

3.5.2.3 Chatbots

Según Rojas Ahumada et al. (2023), los chatbots son aplicaciones de inteligencia artificial orientadas a automatizar la interacción con los usuarios, permitiendo una respuesta rápida y eficiente a consultas frecuentes. Su uso ha demostrado ser especialmente eficaz en sectores como el turismo, las finanzas y los servicios públicos, donde los tiempos de espera pueden reducirse significativamente mediante estas herramientas. Esta automatización libera a los agentes humanos de tareas repetitivas, permitiéndoles concentrarse en problemas más complejos que requieren una mayor intervención personal.

Además, Rojas Ahumada et al. (2023) explican que los chatbots no solo optimizan los recursos humanos, sino que también mejoran la satisfacción del cliente al brindar soluciones inmediatas y evitar la saturación en los centros de atención. Muchos sistemas operan mediante reglas predefinidas, y algunos más avanzados aprovechan datos históricos de interacciones para adaptar sus respuestas, ofreciendo soluciones más alineadas con las necesidades específicas de los clientes (pp. 214-215).

Desde un punto de vista técnico, según Ortiz-Garces et al. (2024), los chatbots son sistemas diseñados para interactuar con los usuarios mediante NLP, utilizando modelos como BERT y GPT para interpretar las consultas de manera más precisa y generar respuestas adaptadas al contexto. Estos sistemas son esenciales en sectores que requieren interacción constante con los usuarios, como las finanzas y los servicios públicos, permitiendo gestionar eficazmente grandes volúmenes de consultas de manera automatizada.

Asimismo, Olujimi y Ade-Ibijola (2023) destacan que los chatbots automatizan consultas frecuentes, reduciendo la intervención humana y mejorando la eficiencia operativa. Esta integración de NLP en los chatbots no solo optimiza la experiencia del cliente, sino que también libera a los agentes humanos para tareas más especializadas y complejas.

3.5.3 Implementación Práctica de Soluciones de IA aplicadas a la Atención al Cliente y Experiencia del Usuario

3.5.3.1 Implementación Práctica de Modelos de Churn

La implementación de un modelo de predicción de churn en una entidad financiera requiere un enfoque metódico basado en la preparación de datos y la selección de algoritmos adecuados. Según Brito et al. (2024), el primer paso fundamental es contar con un conjunto robusto de datos históricos que capture las interacciones de los clientes, incluyendo información transaccional y datos sociodemográficos. Estos datos deben ser preprocesados para abordar el desequilibrio en la distribución de las clases, aplicando técnicas como el sobremuestreo con ADASYN y el submuestreo mediante NEARMISS para mejorar la capacidad predictiva del modelo.

El siguiente paso consiste en desarrollar modelos basados en aprendizaje automático que permitan identificar patrones predictivos de abandono. Brito et al. (2024) recomiendan utilizar algoritmos como XGBoost y elastic net, que han demostrado ser eficaces en escenarios financieros al combinar precisión con interpretabilidad. Además, el enfoque debe incluir optimización de hiperparámetros mediante técnicas bayesianas, maximizando métricas clave como el área bajo la curva de precisión-recall (PR-AUC).

Tékouabou et al. (2022) sugieren que la selección de características basadas en el comportamiento transaccional, como los indicadores de recencia, frecuencia y valor monetario (RFM), mejora significativamente la capacidad del modelo para predecir la probabilidad de churn. A medida que el sistema recoge más datos y ajusta sus predicciones, la entidad puede desarrollar estrategias de retención personalizadas, enfocadas en los clientes con mayor riesgo de abandono.

3.5.3.2 Implementación Práctica de Sistemas de Recomendación

Noreen et al. (2023) destacan que la inteligencia artificial permite a los bancos analizar grandes volúmenes de datos sobre el comportamiento del cliente, lo que facilita ofrecer servicios personalizados que responden a sus necesidades y preferencias. Esta capacidad de adaptación no solo mejora la satisfacción del usuario, sino que también fortalece la relación entre el banco y sus clientes, generando mayores oportunidades de interacción en el tiempo (p. 3).

Por otra parte, la clave de un sistema exitoso radica en asegurar la relevancia y oportunidad de las recomendaciones, maximizando la satisfacción del cliente y fomentando la retención mediante estrategias de venta cruzada y fidelización (Li y Song, 2024).

Li y Song (2024) sugieren que los sistemas más avanzados deben evolucionar hacia modelos híbridos, combinando filtrado colaborativo con técnicas basadas en contenido. Esta integración permite resolver desafíos como la "frialidad inicial" (cold start), común en sistemas que carecen de información sobre nuevos usuarios. Además, los sistemas pueden utilizar embedding para capturar relaciones complejas entre productos y clientes, mejorando la precisión de las recomendaciones (pp. 3-4).

Además, Li y Song (2024) explican que los sistemas de recomendación de productos financieros pueden personalizarse mediante el uso de métodos como el filtrado colaborativo y los modelos basados en contenido, los cuales permiten analizar tanto el comportamiento de los usuarios como las características de los productos. Estos enfoques se adaptan a las necesidades individuales de cada cliente y permiten anticipar sus preferencias, ofreciendo productos más complejos como hipotecas o planes de inversión, alineados con su perfil financiero y comportamiento histórico (p. 2).

3.5.3.3 Implementación Práctica de Chatbots

Según Noreen et al. (2023), la tecnología de chatbots en los bancos no solo permite resolver consultas de los clientes de manera automática, sin necesidad de intervención humana, sino que también recopila datos sobre dichas consultas, lo que contribuye a mejorar la resolución de problemas en el futuro (p. 3).

Por otra parte, Rojas Ahumada et al. (2023) indican que, la implementación de chatbots en una entidad financiera comienza por identificar los casos de uso más comunes en atención al cliente, tales como consultas de saldo, transferencias bancarias y bloqueos de tarjetas. Estos chatbots pueden operar inicialmente mediante reglas predefinidas, permitiendo abordar consultas frecuentes con rapidez y eficiencia.

Ortiz-Garcés et al. (2024) sugieren que, a medida que el chatbot acumula interacciones, es recomendable evolucionar hacia un modelo de aprendizaje automático que pueda adaptarse a patrones específicos del cliente, mejorando la personalización de las respuestas. Además, ambos

autores destacan que un sistema de escalación eficiente es fundamental para transferir consultas complejas a agentes humanos, garantizando la resolución adecuada de problemas.

Los chatbots basados en reglas permiten resolver las consultas más frecuentes con rapidez y eficiencia. Sin embargo, la transición a modelos de aprendizaje automático mejora la capacidad de adaptación a los patrones del cliente, incrementando así la personalización del servicio (Rojas Ahumada et al., 2023; Ortiz-Garcés et al., 2024). La Tabla 3 representa un resumen comparativo de las diferencias entre chatbots basados en reglas y chatbots con aprendizaje automático en términos de capacidades, escalabilidad y eficiencia.

Tabla 3
Comparación entre Modelos Basados en Reglas y Machine Learning en Chatbots

Aspecto	Chatbots basados en reglas	Chatbots con Machine Learning	Referencias
Árboles de decisión	Interpretabilidad, fácil implementación	Puede sobreajustar	Zapata Yanez (2024)
Random Forest	Alta precisión, robustez	Menor interpretabilidad	Zapata Yanez (2024)
Redes Neuronales	Limitado a patrones simples	Capacidad para detectar patrones complejos, requiere gran cantidad de datos	Noreen et al. (2023)
Regresión Logística	Fácil interpretación	Limitada en relaciones no lineales	Brito et al. (2024)

Nota. Elaboración propia.

3.6 Consideraciones previas a la implementación de IA para los Bancos Provinciales Argentinos y sus conceptos

3.6.1 Introducción

Los conceptos fundamentales sobre IA, ML y los casos de aplicación abordados en esta propuesta de intervención, resultan indispensables de ser complementados por otras temáticas que los BPA, deben considerar antes de emprender un plan orientado a implementar IA. En este sentido, se abordan los conceptos clave de transformación digital en la banca, el establecimiento

de una metodología mínima de gobernanza de datos, y el desarrollo de un análisis descriptivo y diagnóstico de los datos mediante Business Intelligence (BI). Este último se enmarca en el modelo de madurez de gestión de datos de Gartner (s.f.), el cual plantea la evolución progresiva desde la analítica descriptiva hasta la prescriptiva. Mediante la inclusión de estos conceptos y su consideración en forma previa a la implementación de IA en los BPA, se asegura una conexión coherente y complementaria con el análisis presentado en el estado del arte, ofreciendo una visión práctica que los BPA deben contemplar para alcanzar el desarrollo tecnológico que garantice su competitividad.

3.6.2 Transformación Digital en la Banca

3.6.2.1 Concepto

Según Verhoef et al. (2019), la transformación digital en la banca implica la adopción de tecnologías digitales que permiten alterar los procesos empresariales existentes, optimizar la eficiencia operativa y crear nuevos modelos de negocio. Este proceso no solo moderniza las operaciones internas, sino que también habilita nuevas formas de generar valor mediante el análisis de datos y el uso de plataformas digitales, lo que responde a las expectativas cambiantes de los clientes. Además, explican que este tipo de transformación afecta profundamente las estructuras organizacionales y obliga a las empresas a reconsiderar su integración de tecnologías innovadoras a nivel global (p 891).

Por otro lado, Fitzgerald et al. (2013) definen que la transformación digital implica un uso estratégico de tecnologías emergentes como dispositivos móviles y análisis integrados, mejorando tanto la experiencia del cliente como la eficiencia operativa. Además, estos autores subrayan que la transformación digital requiere un cambio cultural profundo en las organizaciones, donde líderes y colaboradores deben adaptarse a nuevas formas de trabajo basadas en datos.

Generalizando en cuanto a industrias y dentro del contexto de América Latina, Lugo (2021) expone, mediante la entrevista realizada a Raúl Katz, Doctor en Ciencias Políticas y Administración de Empresas y Magíster en Tecnologías y Políticas de Comunicación por el Massachusetts Institute of Technology, lo siguiente:

El desarrollo del sector de las telecomunicaciones en América Latina y especialmente el de la transformación digital representan la clave para conseguir un incremento de la

productividad y de los ingresos, mejoras en los resultados sanitarios y educativos, y fomentar el desarrollo y crecimiento económico de toda América Latina. (Lugo, 2021, p. 71)

Esta transformación se presenta como una oportunidad para cerrar brechas económicas y sociales, promoviendo una mayor conectividad, la modernización de procesos y la innovación en los servicios ofrecidos (Lugo, 2021).

3.6.2.2 Papel de la IA en la Transformación Digital en la Banca

La transformación digital en el sector bancario ha requerido una profunda adaptación que va más allá de la simple digitalización de procesos. Según Cuesta et al. (2015), la integración de tecnologías avanzadas y la automatización de procesos permiten a los bancos modernizar sus infraestructuras y mejorar tanto su eficiencia operativa como su capacidad de respuesta a las demandas del mercado. Estas innovaciones, junto con el uso de técnicas analíticas sofisticadas, contribuyen a personalizar servicios y optimizar la oferta de productos financieros (Cuesta et al., 2015, pp. 5-7).

Según indica con mención explícita a IA, Cuesta (2015) afirma:

Es también en esta etapa del camino hacia la digitalización en la que las entidades se plantean automatizar procesos que permitan eliminar tareas manuales y repetitivas, mejorando la eficiencia y aportando mayor agilidad a todo el sistema...por ejemplo, comienzan a utilizarse técnicas analíticas y sofisticados algoritmos basados en inteligencia artificial para mejorar el scoring, proponer de forma automatizada productos a medida o proporcionar asesoramiento personalizado (p. 6).

Además, la inteligencia artificial (IA) desempeña un papel crucial en la mejora de procesos operativos complejos. Según Leiva Tames et al. (2020), la implementación de sistemas de IA permite estandarizar flujos de trabajo y centralizar la gestión de datos, lo que no solo optimiza los recursos tecnológicos, sino que también agiliza la toma de decisiones en contextos de alta complejidad. Estas ventajas son esenciales para la transformación digital, donde la eficiencia operativa y la reducción de errores se convierten en factores clave para el éxito organizacional (Leiva Tames et al., 2020, p. 17).

En conclusión, la IA se ha convertido en una herramienta indispensable en la transformación digital del sector bancario, no solo mejorando la eficiencia interna, sino también facilitando la innovación y adaptación en un mercado cada vez más competitivo. Es por esto que al incluirla, los BPA estarán implícitamente potenciando el concepto de transformación digital.

3.6.3 Gobernanza de Datos en la Banca

3.6.3.1 Concepto

La gobernanza de datos es un conjunto de prácticas, políticas y procesos que permiten a las organizaciones gestionar sus datos como un activo estratégico. Según DAMA International (2009), la gobernanza de datos implica la planificación, supervisión y control de los datos en toda la organización. Esto incluye actividades como la definición de estrategias de datos, la implementación de políticas para asegurar su calidad, y la supervisión de su correcto uso. Un sistema efectivo de gobernanza garantiza que los datos sean confiables, accesibles, protegidos y gestionados de acuerdo con las necesidades de la organización.

En el sector bancario, la gobernanza de datos es crucial debido al gran volumen de información que se maneja diariamente y a la necesidad de asegurar la integridad y seguridad de estos datos. Tal y como se describe en el DAMA-DMBOK, la correcta gobernanza de datos permite a las entidades financieras gestionar de manera eficiente sus activos de información, reduciendo riesgos operacionales y mejorando la toma de decisiones estratégicas basadas en datos precisos y bien gestionados (DAMA International, 2009). Además, facilita el cumplimiento de normativas específicas del sector, contribuyendo a la transparencia y eficiencia operativa.

3.6.3.2 Relación al Marco Regulatorio del BCRA

La normativa 7724 del BCRA establece requisitos mínimos para la gestión y control de los riesgos tecnológicos y de seguridad de la información en las entidades financieras. Esta normativa subraya la importancia de que las entidades bancarias implementen un marco de gobernanza de la tecnología y seguridad de la información alineado con la gestión integral de riesgos y los objetivos del negocio. Según BCRA (2023), las entidades “deberán asegurar la implementación de prácticas efectivas para el control interno y la gestión de riesgos de su entorno operativo de tecnología y seguridad de la información” (p. 3).

Tal como analiza BDO Argentina (2023), la gobernanza de datos juega un papel clave en cumplir con este marco regulatorio, ya que garantiza que los datos se gestionan de manera segura, conforme a las normas establecidas y con un enfoque en la resiliencia operativa. Según BDO Argentina (2023), esta normativa no solo pone foco en la ciber resiliencia, sino también en la necesidad de que la alta gerencia y el directorio estén involucrados activamente en la supervisión de los marcos de gestión de riesgos y seguridad, asignando roles y responsabilidades claras para mitigar los riesgos tecnológicos.

Por lo tanto, la gobernanza de datos, estructurada según estándares internacionales como los descritos en el DAMA-DMBOK (DAMA International, 2009), permite a las entidades financieras cumplir con las exigencias regulatorias, asegurando la calidad, seguridad y disponibilidad de los datos en todo su ciclo de vida.

Como ejemplo, el modelo de gestión de datos del Banco de la República de Colombia también puede servir como referencia de buenas prácticas, dado que integra una estructura de gobierno que abarca tanto datos estructurados como no estructurados, garantizando su seguridad y accesibilidad (Banco de la República, 2019).

3.6.4 El Modelo de Madurez de la Gestión de Datos

3.6.4.1 Concepto

El modelo de madurez de la gestión de datos proporciona a las organizaciones una guía clara para evaluar su capacidad de gestión y aprovechamiento de los datos a lo largo del tiempo.


Según Gartner (s.f.), el modelo de madurez describe la evolución de una organización en el uso de datos y analítica, facilitando su transición desde la recolección y uso básico de datos hacia la implementación de análisis avanzados que apoyan la toma de decisiones estratégicas y optimización de procesos. El modelo de madurez permite a las organizaciones medir su estado actual, identificar áreas de mejora y trazar un camino claro para alcanzar niveles más avanzados de gestión de datos y analítica (Gartner, s.f.).

Por su parte, Castillo Abarca et al. (2020) señalan que los modelos de madurez, específicamente en el ámbito de la inteligencia de negocios (BI), permiten a las organizaciones no solo medir su capacidad actual, sino también alinear las actividades y procesos con los niveles de madurez del modelo seleccionado. Esta alineación es fundamental para asegurar que la

implementación de proyectos de BI, o cualquier estrategia basada en datos, sea efectiva y se ajuste a las necesidades y capacidades de la organización. Los niveles del modelo de madurez van desde el uso básico de datos descriptivos hasta el uso avanzado de análisis prescriptivos y predictivos, lo cual es crucial para que las organizaciones puedan maximizar el valor de sus datos. (Castillo Abarca et al., 2020).

Figura 6

Niveles de madurez de la gestión de datos y su relación a BI e IA.



Nota. Elaboración propia, inspirado en Gartner (s.f.).

3.6.4.2 Business Intelligence

Según Castillo Abarca et al. (2020), Business Intelligence (BI) utiliza técnicas de análisis de datos para ayudar a las organizaciones a explotar sus datos históricos, facilitando la toma de decisiones estratégicas y operativas. Su implementación contribuye a un análisis más profundo de los datos organizacionales, permitiendo una mejor comprensión del comportamiento de las variables clave para la toma de decisiones (Castillo Abarca et al., 2020, p. 631).

Por otro lado, Reyes-Sarmiento (2022), resalta que BI en el sector bancario permite integrar diversas fuentes de datos y analizar grandes volúmenes de información de forma eficiente. Herramientas como Power BI facilitan la creación de reportes y tableros que ofrecen una visualización clara e intuitiva de los indicadores clave, optimizando la toma de decisiones y el control de procesos. Además, la implementación de BI en la banca puede mejorar la eficiencia de los procesos en un 24%, lo que impacta positivamente en la rentabilidad y la satisfacción del cliente (Reyes-Sarmiento, 2022, pp. 7-17).

Como conclusión de este inciso, BI es una herramienta esencial para cualquier organización que busque maximizar el valor de sus datos, proporcionando un enfoque integral para la toma de decisiones y la optimización de procesos, basado en analítica descriptiva y diagnóstica, previo a la implementación de IA.

Capítulo 4 – Propuesta de Intervención

4.1 Descripción

Tal y como se estableció en el objetivo general, en la presente propuesta de intervención se diseña un plan de implementación por etapas de un sistema de software que utiliza modelos predictivos de inteligencia artificial (IA) para gestionar el riesgo crediticio, detectar fraudes y mejorar la atención al cliente y su comportamiento, dirigido a Bancos Provinciales Argentinos (BPA).

El plan de intervención se estructura en varias etapas que aseguran una implementación gradual, permitiendo a los BPA adaptarse progresivamente tanto en términos tecnológicos como organizacionales. Aunque las etapas iniciales 1 y 2 requieren un orden secuencial, las posteriores pueden adaptarse a la disponibilidad de recursos y prioridades de cada BPA, incluso ejecutándose en paralelo. No obstante, se plantea un plan en orden como una forma posible de aplicación. A continuación, se presenta la descripción de cada etapa.

Cabe resaltar que los conceptos, enfoques y aplicaciones de los autores citados en el Marco Teórico han sido seleccionados debido a su relación directa con esta propuesta. Así, a medida que se describa cada etapa, se referenciarán específicamente modelos y aplicaciones basados en los trabajos de autores citados en el capítulo 3, mostrando cómo cada teoría y aplicación respalda la implementación de los modelos considerados en el plan de implementación.

4.1.1 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos

El plan comienza con una fase de diagnóstico en la que se evaluarán las infraestructuras tecnológicas existentes, el estado actual de los datos disponibles y las capacidades organizacionales para implementar IA. Este análisis servirá para identificar brechas, áreas de mejora y oportunidades clave en el manejo de datos. En esta etapa el plan considera la implementación de un sistema de gobernanza de datos que garantice la calidad, seguridad y accesibilidad de la información, teniendo en cuenta los aspectos revisados tratados en el punto “3.6.3 Gobernanza de Datos en la Banca” correspondiente al Marco Teórico del presente trabajo.

El proceso de gobernanza de datos a implementar consta de tres fases. La primera fase es conocida como “As Is”, que refiere a la planificación y evaluación inicial donde se identifica la situación actual de la gestión y el gobierno de datos, así como las capacidades existentes. La segunda fase, conocida como “To Be” corresponde al diseño del gobierno de datos, y su objetivo es establecer una visión organizada de los datos y aquellos procesos para conseguirlo, definir el modelo aspiracional, definir una ficha resumen de iniciativas y la conceptualización de casos de uso, proporcionando un marco adecuado para la definición de un plan de gobierno del dato que esté alineado con los recursos y capacidades disponibles. La última fase corresponde a la implementación, cuyo objetivo es la ejecución de los procesos y flujos definidos durante las dos fases previas. La implementación se debe llevar a la práctica a través de un caso de uso concreto, en calidad de piloto.

Más allá del plan de acciones definido que surja como resultado de las fases “As Is” y “To be”, técnicamente el proyecto requiere la implementación como mínimo del Data Warehouse centralizado que albergue los datos de los distintos sistemas de negocio sobre los cuales el BPA realizará BI o aplicará modelos de IA, así como un catalogador de los datos de acuerdo con las políticas de gobierno de datos definidas. Entonces, al evaluar la implementación de un entorno de Data Warehouse centralizado, habrá que seleccionar una plataforma que ofrezca no solo almacenamiento y procesamiento de datos, sino también una integración sólida con herramientas de gobernanza y análisis. Laxminarayana et al. (2024) enfatizan que, la elección de una plataforma de datos depende de las necesidades específicas y las características internas de cada entidad y subrayan el papel del Chief Data Officer (CDO) en gestionar esta decisión estratégica para facilitar la gobernanza de datos, la optimización de procesos y la toma de decisiones basada en datos.

A los efectos de la presente propuesta de intervención, se justifica el uso de Microsoft Fabric en el contexto de gobernanza de datos, de acuerdo con dos características principales que hacen de esta plataforma una solución sólida para cumplir con los objetivos de accesibilidad, seguridad, escalabilidad y cumplimiento normativo en el manejo de datos. La primera característica refiere a que Microsoft Fabric permite gestionar y proteger los datos de forma centralizada, facilitando su descubrimiento y uso confiable dentro de las organizaciones (Microsoft, s.f.-b). Además, mediante su integración con Microsoft Purview, Fabric fortalece la

gobernanza al ofrecer un control avanzado sobre el acceso, la protección contra pérdidas de datos, y el cumplimiento regulatorio (Microsoft, s.f.-a), (Microsoft, s.f.-d).

4.1.2 Etapa 2: Implementación de BI

Una vez establecido el entorno del repositorio centralizado de datos con su correspondiente ingesta desde los orígenes que el BPA defina y su correspondiente procedimiento de gobernanza de datos, el siguiente paso es planificar la implementación de BI. Esta implementación inicial permitirá a los BPA identificar patrones y tendencias, optimizar la toma de decisiones estratégicas y monitorizar KPIs (indicadores clave de desempeño) de manera centralizada, logrando así alcanzar el nivel de madurez de analítica descriptiva y diagnóstica tratada en el punto 3.6.4 del Marco Teórico.

La manera en que se materializa la aplicación de BI en la presente propuesta de intervención es a través de la herramienta interactiva de visualización de datos Power BI (Microsoft, s.f.-i), ampliamente recomendada por su interfaz intuitiva, capacidad de integración con múltiples fuentes de datos y facilidad para generar informes y visualizaciones dinámicas.

Es importante aclarar que la elección de Power BI para el análisis y visualización de datos en esta propuesta no excluye la posibilidad de que el BPA decida implementar otra plataforma que mejor se ajuste a sus necesidades específicas. En efecto, la selección de herramientas dependerá de las características internas y los requerimientos propios de cada entidad. No obstante, la propuesta considera en el plan la selección de Power BI, debido a los beneficios destacados por Vizuite Chancay y Ayala Bolaños (2024), quienes subrayan:

La herramienta de Power BI es parte de la gestión del conocimiento y tecnológica de una empresa, por lo tanto, influye en su competitividad como tal, al incrementar el conocimiento, porque provoca un cambio cultural y fomenta la innovación y la tecnología (p. 14).

Power BI facilita la conversión de datos dispersos en conocimiento empresarial relevante, lo que impulsa la toma de decisiones estratégicas y mejora la competitividad organizacional. Además, Power BI proporciona una interfaz intuitiva para la creación de informes visuales interactivos y se integra fácilmente con múltiples fuentes de datos, lo que lo convierte en una herramienta eficaz para entornos empresariales (Vizuite Chancay y Ayala Bolaños, 2024).

Por otra parte, como parte de Microsoft Fabric, Power BI también asegura una integración robusta con otros componentes de esta plataforma, promoviendo así un ecosistema tecnológico unificado y seguro para la gestión y el análisis de datos (Microsoft, s.f.-f).

Para lograr que un BPA alcance el nivel de madurez de la gestión de datos presentado en el punto 3.6.4 del presente trabajo en cuanto a una analítica descriptiva y diagnóstica de los casos de negocio que posteriormente pueden ser potenciados por la aplicación de IA, se consideran los siguientes casos:

Tablero de Segmentación de Clientes y Perfilado: Este análisis permite agrupar clientes en segmentos de comportamiento y elaborar perfiles detallados, lo cual es esencial para entender sus motivaciones y mejorar la personalización de productos y servicios. La segmentación y perfilado utilizan como datos de entrada que deberá disponer el BPA alimentados en su Data Warehouse, demográficos, transaccionales, historial de productos y comportamiento digital, visualizados mediante gráficos de segmentación, mapas de calor y matrices de correlación, entre otros. Estos insights facilitan decisiones informadas en áreas de marketing y optimización de la experiencia del cliente.

Tablero de Análisis de Riesgo Crediticio: Este tablero apoya en la evaluación y gestión del riesgo crediticio asociado a los diferentes segmentos de clientes, basándose en su historial crediticio, patrones de gasto y puntuaciones de riesgo. Visualizaciones como mapas de calor de riesgo, gráficos de líneas de evolución del riesgo y tablas de riesgo por tipo de préstamo permiten la identificación de áreas de oportunidad y estrategias de mitigación de riesgos, mejorando así la efectividad de las políticas crediticias.

4.1.3 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio

En esta etapa, la propuesta de intervención busca integrar un modelo predictivo de IA para gestionar el riesgo crediticio, utilizando técnicas de ML que permitan al BPA optimizar su proceso de evaluación y asignación de créditos, minimizando así el riesgo de morosidad. Para lograr la implementación del modelo, se recomienda el uso de algún método de baja complejidad para el equipo de aplicación encargado por parte del BPA, basado en estudios de aplicación previos, como el caso que proponen Tana Pilacúan y Viteri Orozco (2024), el cual tiene como objetivo predecir

la probabilidad de incumplimiento de los clientes, basándose en variables como historial de pagos, comportamientos financieros y características demográficas.

Según demostraron Tana Pilacúan y Viteri Orozco (2024), la aplicación de un modelo predictivo para la evaluación de riesgo crediticio, utilizando principalmente algoritmos de Regresión Logística y Random Forest, resulta apropiado para este tipo de tareas de clasificación en entornos financieros debido a su capacidad para manejar grandes volúmenes de datos y ofrecer interpretabilidad y precisión en la predicción de riesgos (pp. 28-30).

Una implementación factible entonces del modelo predictivo de riesgo crediticio visto en el trabajo de Tana Pilacúan y Viteri Orozco (2024), implica el uso de algoritmos de ML supervisados, que permiten a las instituciones financieras estimar la probabilidad de incumplimiento de pagos de sus clientes. Este enfoque se centra en predecir la capacidad de los clientes para cumplir con sus obligaciones crediticias, basándose en datos históricos y características relevantes de cada cliente. Según Tana Pilacúan y Viteri Orozco (2024), estos modelos han demostrado ser efectivos en la clasificación de clientes en categorías de riesgo, permitiendo una gestión optimizada de las decisiones crediticias (pp. 58-59).

En cuanto a regresión logística, este modelo es ampliamente utilizado debido a su simplicidad y capacidad interpretativa. La regresión logística permite clasificar los clientes en función de si tienen o no dificultades de pago, siendo eficaz en la evaluación de riesgo crediticio cuando se busca un modelo fácilmente explicable. La simplicidad de la regresión logística, que calcula la probabilidad de un evento binario, hace que sea adecuada para este tipo de análisis y facilita su integración en los procesos operativos del banco (Tana Pilacúan y Viteri Orozco, 2024, pp. 29-34).

El otro caso aplicado basado en random forest se utiliza en este contexto para mejorar la precisión de las predicciones al combinar múltiples árboles de decisión. Este modelo es particularmente efectivo para evitar el sobreajuste, ya que emplea múltiples subconjuntos de datos para crear árboles de decisión independientes. Random forest también permite manejar variables categóricas y continuas, mejorando así la robustez y precisión del modelo predictivo en el análisis de riesgo (Tana Pilacúan y Viteri Orozco, 2024, pp. 46-51).

Para aplicar estos modelos se debe considerar la Evaluación de Características y Datos de Entrenamiento, donde los datos de entrada para estos modelos deberán incluir variables financieras y no financieras, tales como historial de pagos, datos demográficos, ingresos, tipos de productos contratados entre otros. De acuerdo con Tana Pilacúan y Viteri Orozco (2024), estas características proporcionan una visión detallada del perfil crediticio del cliente y ayudan a los modelos a identificar patrones relevantes para la predicción de riesgos.

En relación al entrenamiento y validación de los modelos, los mismos se entrenan utilizando un conjunto de datos históricos que reflejan el comportamiento de los clientes en sus pagos. Tana Pilacúan y Viteri Orozco (2024) recomiendan el uso de un enfoque de partición de datos (entrenamiento y validación) para asegurar que el modelo generalice correctamente en datos nuevos. La precisión del modelo se evalúa a través de métricas como la precisión, el F1-score y la tasa de error de clasificación, asegurando que se identifiquen correctamente tanto los casos de cumplimiento como de incumplimiento.

En cuanto a la interpretabilidad y la aplicación operativa, la transparencia del modelo es esencial en el entorno bancario, donde la interpretabilidad es clave para cumplir con regulaciones y proporcionar explicaciones claras a los usuarios internos. La regresión logística es particularmente útil en este aspecto, ya que permite comprender cómo cada variable afecta la probabilidad de incumplimiento, facilitando así una gestión crediticia informada y precisa (Tana Pilacúan y Viteri Orozco, 2024, p. 57).

4.1.4 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude

En esta etapa, la intervención se orienta hacia la implementación de un modelo predictivo de IA en la cual un BPA pueda detectar patrones fraudulentos en las transacciones en línea, es decir, en aquellas actividades relacionadas con el acceso y uso de las plataformas de e-banking (banca electrónica, home banking, etc) por parte de los clientes. Continuando con plantear un plan cuyo método de aplicación sea de modelos de baja complejidad para el equipo de aplicación encargado por parte del BPA, se propone la aplicación de casos previamente estudiados, como el de los autores Vanini et al. (2023).

El tipo de fraude a predecir incluye intentos de acceso no autorizados o secuestro de cuenta, donde un agente externo intenta controlar la sesión del usuario legítimo. Siguiendo el enfoque de

Vanini et al. (2023), este modelo utiliza los ya mencionados BDT o árboles de decisión embolsados, un método que permite clasificar comportamientos inusuales en las sesiones de usuario, como posible señal de fraude. Esta técnica facilita al BPA la incursión en ML sin requerir infraestructura avanzada, logrando un balance entre efectividad y simplicidad en el proceso de detección de fraudes mediante el análisis de patrones conductuales específicos (Vanini et al., 2023).

Recomendándose entonces la adopción de un enfoque basado en estudios precedentes que aplican el aprendizaje por transferencia, según Vanini et al. (2023), este método considera los patrones normales de los usuarios como base, lo que permite identificar actividades que pueden diferir significativamente del comportamiento habitual del cliente (Vanini et al., 2023, p. 9). De esta manera, se hace posible detectar actividades fraudulentas en casos de control de cuentas por agentes externos, tales como bots o actores humanos malintencionados.

En cuanto al enfoque técnico del modelo, según Vanini et al. (2023), los BDT se presentan como una elección adecuada dada su capacidad de manejo de datos y su precisión para la clasificación binaria en problemas como la detección de fraude. Este enfoque combina múltiples árboles entrenados con diferentes subconjuntos de datos, lo cual incrementa la robustez y reduce el riesgo de sobreajuste. Cada árbol clasifica la probabilidad de que una transacción esté asociada a un comportamiento anómalo, o “no propio del cliente.” Como explican Vanini et al. (2023), el valor de la función de decisión es igual al promedio de probabilidades observado para todos los árboles en el bosque (p. 9), lo cual permite una clasificación más precisa de las transacciones.

El modelo se implementa en dos fases clave: la fase de aprendizaje, en la cual se diferencian los comportamientos de clientes frente a comportamientos atípicos, y la fase de predicción, donde el modelo clasifica sesiones y transacciones con base en los patrones identificados (Vanini et al., 2023).

En cuanto a la interpretabilidad y aplicación operativa, según Vanini et al. (2023), los BDT ofrecen una alta interpretabilidad, lo que facilita a una entidad a entender cómo ciertos factores (e.g., la hora de la transacción y la ubicación del usuario), influyen en la clasificación de actividades sospechosas. Este enfoque transparente permitirá a los responsables de seguridad analizar los resultados del modelo y ajustar las estrategias de prevención de fraude de manera efectiva y comprensible. En consecuencia, el modelo actuará como una herramienta de apoyo para la detección proactiva de fraude.

4.1.5 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes

En esta etapa se propone la implementación de un modelo predictivo de churn que permita al BPA que lo aplique identificar patrones de abandono de clientes y aplicar medidas de retención de manera proactiva. Este modelo, de baja complejidad para facilitar su aplicación por parte del equipo de un BPA, toma como referencia casos explorados en el Marco Teórico (Tékouabou et al., 2022; Brito et al., 2024; Mayor Lupo, 2023). No obstante, es importante aclarar que un BPA puede decidir tomar cualquiera de las aplicaciones de los autores citados, así como buscar otros análogos. A efectos de este plan, se selecciona el trabajo de Brito et al. (2024) debido a su simplicidad, su adaptabilidad a instituciones con limitaciones en infraestructura y recursos, y su enfoque en el balanceo de datos y en la interpretación de resultados en el contexto bancario.

El modelo predictivo de churn basado en Brito et al. (2024), se alimentará de múltiples fuentes de datos internos y externos, entre los que se incluyen transacciones, interacciones en canales digitales (como home banking y uso de apps móviles) y características demográficas de los clientes, así como datos de segmentación específicos del banco. El objetivo principal es identificar aquellos clientes con una alta probabilidad de abandonar la institución y establecer estrategias de retención adaptadas a sus necesidades y patrones de comportamiento.

Según Brito et al. (2024), el proceso de construcción del modelo debe iniciar con la recopilación de datos históricos, incluyendo variables demográficas, comportamiento transaccional, y uso de servicios digitales, como frecuencia y tipo de transacciones, saldo promedio y características sociodemográficas. Este enfoque permite obtener una visión detallada del comportamiento de los clientes, fundamentando las predicciones en patrones significativos de uso de productos y canales del banco. Además, dado que el modelo aborda la predicción de churn como una clasificación binaria, se realizarán ajustes para equilibrar las clases, empleando técnicas como ADASYN o NEARMISS, con el fin de reducir el sesgo y mejorar la precisión predictiva en bases de datos con distribuciones desiguales (Brito et al., 2024).

Una vez en funcionamiento, el modelo predictivo será capaz de clasificar a los clientes en función de su riesgo de abandono, generando probabilidades de churn que permitirán a los gestores de relaciones (área comercial, marketing, tomadores de decisiones) establecer estrategias dirigidas, tales como campañas de fidelización o ajustes en los servicios, y tomar decisiones informadas para la retención de clientes.

4.1.6 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros

La implementación del modelo predictivo de recomendación personalizada para productos financieros en un BPA podrá recomendar productos financieros básicos de un banco, tales como cuentas de ahorro, tarjetas de crédito y préstamos personales, aprovechando las capacidades de aprendizaje automático para captar patrones relevantes en el comportamiento de los clientes. Se plantea entonces en este punto, la aplicación de un modelo ya validado para el caso de predicción mediante el estudio de Li y Song (2024). Se deja aclarado que el BPA que siga este plan puede optar por la aplicación de un modelo distinto que cumpla con el propósito, no obstante, la presente propuesta asegura una aplicación viable y demostrada en el trabajo de Li y Song (2024), justificada desde la perspectiva de un caso adecuado que expone un enfoque técnico para sistemas de recomendación basados en deep learning, incluyendo métodos como el Transformer y el uso de GNN. Esta aplicación aporta bases suficientes para discutir tanto la descripción como las acciones necesarias para implementar un modelo inicial de recomendaciones, especialmente útil para una intervención gradual en entidades con recursos limitados.

Se recomienda entonces emplear una solución híbrida de filtrado colaborativo combinado con métodos basados en contenido, simplificando así el proceso de implementación para el equipo a cargo, y garantizando una mayor relevancia en las recomendaciones iniciales (Li y Song, 2024).

Siguiendo el enfoque propuesto por Li y Song (2024), el sistema se basa en la captura y análisis de datos históricos transaccionales y demográficos para generar recomendaciones. En este primer caso, el filtrado colaborativo permite identificar similitudes en los comportamientos de usuarios con perfiles parecidos, mientras que el modelo basado en contenido complementa las recomendaciones al analizar las características específicas de cada producto y las preferencias explícitas de los usuarios. La implementación de esta técnica híbrida se considera adecuada debido a su capacidad de personalizar las recomendaciones con base en datos disponibles, lo que resulta esencial para bancos que cuentan con limitaciones de recursos tecnológicos y financieros, ya que evita la complejidad de modelos más avanzados (Li y Song, 2024).

Para garantizar el éxito de este sistema, es fundamental que las recomendaciones iniciales se limiten a productos financieros sencillos que tengan un bajo nivel de riesgo y alta demanda, de modo que se pueda evaluar la aceptación del modelo por parte de los clientes sin comprometer

recursos en productos de mayor complejidad. El objetivo final es mejorar las oportunidades de venta cruzada y fidelización a través de una oferta personalizada que aumente la satisfacción del cliente y genere un impacto positivo en la retención de usuarios (Li y Song, 2024).

4.1.7 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente

La propuesta de implementación inicial del chatbot para el servicio de atención al cliente en el BPA se inspira en los beneficios generales descritos por Rojas Ahumada et al. (2023). Este enfoque destaca por su simplicidad y efectividad en la gestión de consultas frecuentes, especialmente en contextos con limitaciones de recursos tecnológicos y financieros, como podría ser el caso de los BPA. Aunque se exploraron alternativas en el Marco Teórico, incluyendo el enfoque avanzado de Ortiz-Garcés et al. (2024) con procesamiento de lenguaje natural avanzado, la propuesta inicial basada en reglas se ajusta mejor a los recursos y objetivos de esta implementación gradual. Esta guía se presenta como un plan flexible, permitiendo que el BPA adopte la opción que considere más alineada con su capacidad operativa o con otras aplicaciones análogas que desee implementar.

En la práctica, el chatbot basado en el trabajo de Rojas Ahumada et al. (2023) se configurará como un sistema de reglas predefinidas, diseñado para responder a consultas comunes de los clientes, tales como consultas de saldo, horarios de atención y localización de sucursales. La elección de un sistema basado en reglas responde a la necesidad de implementar un sistema eficiente, que no dependa de infraestructura avanzada ni de procesamiento de lenguaje natural, lo cual resulta más accesible y económicamente viable para una etapa inicial de incursión en IA.

Para el éxito de esta implementación, se recomienda definir una base de conocimiento sólida que se alimente de datos históricos sobre interacciones frecuentes en los canales de atención al cliente del BPA. Estos datos incluirán preguntas frecuentes y respuestas estándar, las cuales permitirán que el chatbot brinde soluciones inmediatas y reduzca la carga de trabajo de los agentes humanos en el centro de atención. Rojas Ahumada et al. (2023) sugieren que la recopilación de datos puede enfocarse en variables relevantes para optimizar el desempeño del chatbot y adaptarlo progresivamente a las necesidades del público del BPA.

Además, se requerirá un entorno de implementación que permita integrar el chatbot en los canales digitales del banco, tales como la página web o la aplicación móvil. La plataforma elegida

deberá ser compatible con tecnologías de baja complejidad y soportar la actualización continua de la base de conocimiento, para que el chatbot pueda evolucionar y mejorar sus respuestas en función de la retroalimentación de los usuarios.

En conclusión, la implementación del chatbot, inspirada en los principios descritos por Rojas Ahumada et al. (2023), ofrecerá una solución efectiva y asequible para mejorar la atención al cliente en el BPA, proporcionando una experiencia de usuario optimizada sin requerir inversiones elevadas en tecnología avanzada. Este chatbot reducirá la carga de trabajo de los agentes humanos y mejorará la experiencia del usuario al ofrecer asistencia 24/7.

4.2 Acciones a realizar

La presente sección detalla el plan necesario para llevar a cabo la propuesta de intervención. Las acciones están organizadas según las etapas descritas en la sección anterior. Es importante tener en cuenta, que las acciones mencionadas son abordadas desde el punto de vista de un BPA que se encuentra en situación de aplicación cero de cualquiera de las etapas, no obstante, cada BPA sabrá considerar de las acciones que se describen a continuación la totalidad, cierta parcialidad o la adecuación análoga en caso de estar utilizando una herramienta de otros proveedores a los citados.

4.2.1 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos

El diagnóstico inicial será el paso cimental para evaluar el estado actual de los BPA en cuanto a su infraestructura tecnológica, la calidad y disponibilidad de sus datos, y las capacidades organizacionales necesarias para implementar inteligencia artificial (IA). A través de este diagnóstico, se identificarán brechas, limitaciones y oportunidades en el manejo de datos que influirán en la implementación de IA. En función de este, se aplicará el repositorio de datos centralizado por parte de un BPA, junto a su correspondiente política de gobierno de datos. Este detalle se describe en los siguientes incisos.

4.2.1.1 Evaluación de la Infraestructura y Capacidad Organizacional (As Is)

Se deberá llevar a cabo la fase “As Is” tal y como fue descrita en el punto 4.1.1, mediante un análisis de la infraestructura tecnológica existente, incluyendo sistemas de gestión de datos, almacenamiento, plataformas de procesamiento y herramientas de seguridad. Este análisis se

complementará con una evaluación de las capacidades organizacionales, particularmente en lo que respecta a la preparación del personal para adoptar nuevas tecnologías y la alineación con las normativas vigentes, como la normativa 7724 del BCRA.

Este análisis permitirá identificar áreas clave donde es necesaria una mejora, como la automatización de procesos, la calidad de los datos, la capacidad de procesamiento de grandes volúmenes de información y la seguridad de los sistemas.

En conclusión, estas son las principales actividades:

- Análisis de la situación actual
- Identificación de los dominios y subdominios que cubren las distintas fuentes de datos en alcance
- Conceptualización del modelo de datos que cubra el mapa de dominios y subdominios
- Identificar de las fuentes de información; las características de seguridad y privacidad
- Validar la existencia de un modelo de clasificación de información que catalogue e inventaríe los datos para la ingesta
- Roles asignados que nos permitan determinar sus criterios de seguridad
- Identificar procedimientos de tratamiento y acceso a los datos
- Análisis de la gestión de los datos.

4.2.1.2 Definición del Modelo de Gobernanza de Datos (To Be)

Continuando con la segunda fase “To Be” de acuerdo con lo descrito en el punto 4.1.1 se deberán definir los distintos procesos y metodologías que se abordarán para cubrir las necesidades detectadas.

En primer lugar, se tratará el concepto de “Estrategia y Políticas”. Se definirán políticas claras de manejo de datos que cubran desde la recolección hasta la eliminación, asegurando el cumplimiento de las normativas del BCRA y otras regulaciones relevantes.

En segundo lugar, se definirán “Roles y Responsabilidades”. Se asignarán roles específicos, como custodios o administradores de los datos (Data Stewards), se identificarán los responsables

de negocio conocedores de los distintos orígenes de datos (Data Owners), responsables de la calidad y seguridad de los datos. La correcta asignación de estos roles permitirá el cumplimiento de las políticas que exige la normativa 7724 (BCRA, 2023) de identificación de responsabilidades y que los datos sean gestionados adecuadamente.

En tercer lugar, se implementarán los procesos de auditoría y control. Con procesos regulares de auditoría de datos se podrá garantizar la verificación de los estándares de calidad y seguridad. Estos controles incluirán la trazabilidad del origen de los datos, la validación de su integridad y la documentación de las transformaciones que sufren a lo largo de su ciclo de vida.

En conclusión, estas son las principales actividades:

- Diseñar un catálogo y glosario de datos.
- Definir roles y responsabilidades de todos los agentes involucrados en la gestión de datos.
- Establecer el modelo de interacción con diferentes áreas en relación con el plan de gobierno de datos.
- Definir los comités de gobernanza de datos y otros foros de soporte.
- Establecer procesos y procedimientos del marco de trabajo de gobernanza.
- Elaborar un plan de formación y capacitación en gobernanza de datos, con una metodología para gestionar el cambio organizacional.
- Diseñar procedimientos para clasificar los niveles de confidencialidad de la información ingresada al Data Warehouse.
- Crear un procedimiento para gestionar excepciones en el modelo de gobernanza.
- Establecer esquemas de seguridad, perfiles de usuario estándar y políticas para la gobernanza de datos.

4.2.1.3 Aplicación de Microsoft Fabric y Microsoft Purview (Implementación)

Tal y como fue descrito en el punto 4.1.1 en este punto se deberá proceder a la implementación del plan de gobierno de datos definido, con la correspondiente implementación de un Data Warehouse utilizando Microsoft Fabric como herramienta tecnológica, de acuerdo a lo justificado en 4.1.1. Es importante aclarar que el plan contempla que la aplicación se realice sobre

un piloto, es decir, sobre un origen de datos correspondiente a un sistema que representa un negocio del BPA. Luego se puede iterar su implementación ampliando a los demás orígenes.

En primer lugar, se deberá dar de alta la cuenta en Azure y dar de alta el recurso Microsoft Fabric. Esto incluye el alta de las primeras credenciales y permisos necesarios. Luego se deberá dar de alta el recurso OneLake para Data Lake y Data Warehouse, que servirá como almacenamiento centralizado. Este incluirá tanto el Data Lake, para datos crudos, como el Data Warehouse, para datos estructurados y transformados según los esquemas predefinidos. En tercer lugar se deberá realizar la configuración de la Integración con Fuentes de Datos, implementando pipelines en Data Factory o Dataflow para la ingesta de datos desde fuentes externas, como APIs propias, softwares de terceros, bases de datos, archivos de texto, y hojas de cálculo. Esto permite la captura de datos en tiempo real o por lotes, según los requerimientos. Esto dará lugar al cuarto paso, consistente en implementar los procesos de ingesta y transformación de datos, ya sea a través de scripts en lenguajes de programación como Python o pipelines de Fabric para transformar los datos entrantes en formatos adecuados para su almacenamiento en el Data Warehouse. Esto incluye limpieza, agregación y normalización de datos para facilitar análisis y consultas. Posteriormente se deberá establecer el modelo de datos en OneLake, definiendo tablas y relaciones dentro del Data Warehouse que estructuren la información, creando agregaciones temporales y estableciendo columnas de datos integrados y nuevos datos necesarios para el análisis. Por último, la implementación de los flujos de trabajo para almacenamiento y recuperación de datos en OneLake, incluyendo opciones de recuperación ante desastres (DR) para asegurar la continuidad del negocio (Microsoft, s.f.-b), (Microsoft, s.f.-c).

Ya contando con Fabric y su Data Warehouse funcionando, se deberá proceder al alta y configuración de Microsoft Purview, para finalmente implementar el catálogo de datos y las políticas de permisos y acceso a los datos (Microsoft, s.f.-e).

En conclusión, estas son las principales actividades:

- Establecer esquemas de seguridad, perfiles de usuario estándar y políticas para la gobernanza de datos.
- Dar de alta cuenta en Azure, configurar Microsoft Fabric, con permisos y credenciales necesarias.

- Crear y configurar OneLake como el almacenamiento central, con un Data Lake para datos crudos y un Data Warehouse para datos estructurados.
- Integrar Fuentes de Datos ya sea con Data Factory o Dataflow para ingestar datos desde múltiples fuentes como APIs y archivos.
- Transformar e Ingestar Datos, ya sea aplicando scripts o pipelines para limpiar y organizar los datos en formatos de almacenamiento.
- Definir Esquemas de Datos, configurando tablas y relaciones en el Data Warehouse para estructurar la información.
- Establecer Flujos de Trabajo de Datos para el almacenamiento y recuperación de datos, con opciones de recuperación ante desastres.
- Crear la cuenta de Purview con configuraciones de almacenamiento y encriptación, integrada a Fabric.
- Definir las Políticas de Seguridad y Acceso, mediante roles en Azure AD, políticas de acceso y retención de datos.
- Definir el Catálogo de Datos, estructurado en colecciones y etiquetado de clasificación.
- Configurar el Flujo de Trabajo de Gobernanza: Establecimiento de políticas de acceso, detección de riesgos y linaje de datos.

4.2.2 Etapa 2: Implementación de BI

En esta etapa, se debe implementar BI, actuando como puente entre la gobernanza de datos y el análisis predictivo, utilizando Power BI dentro del ecosistema de Microsoft Fabric. En los siguientes incisos se describen las acciones, considerando la implementación del recurso tecnológico correspondiente, así como el desarrollo de los tableros necesarios para el análisis de datos, permitiendo generar informes automáticos, monitorear KPIs y evaluar el rendimiento de productos financieros.

4.2.2.1 Alta y configuración de Power BI en Microsoft Fabric

Se deberá configurar la cuenta de Power BI. Considerando que Power BI se integra en Microsoft Fabric, se procederá a la activación de licencias y permisos específicos para los usuarios de BPA que operarán los tableros de análisis. Esta configuración incluye la asignación de roles para administrar, visualizar y editar informes y tableros (Microsoft, s.f.-a).

Luego se deberán definir los permisos de acceso y seguridad para los usuarios en Power BI, respetando los roles ya definidos en el marco de gobernanza de Microsoft Fabric. De esta forma, los permisos de visualización y edición en los tableros de Power BI estarán alineados con las políticas de seguridad de los datos ya establecidas en Purview (Microsoft, s.f.-e).

4.2.2.2 Desarrollo y configuración de tableros en Power BI

El desarrollo de tableros de análisis descriptivo y diagnóstico aplicando BI en sus primeras etapas también involucra la exploración y el análisis de datos, por lo que, los principios de la metodología CRISP-DM pueden aplicarse al BI, considerando su foco en la comprensión del negocio y de los datos (Chapman et al., 2000). Aunque CRISP-DM está orientada a proyectos de minería de datos y aprendizaje automático, sus fases iniciales, como la *Comprensión del Negocio*, *Comprensión de los Datos* y *Preparación de los Datos*, se adaptan a BI en etapas tempranas. Por tal motivo es importante aclarar que las siguientes acciones relacionadas con el tratamiento de los datos pueden llevarse a cabo utilizando dicha metodología.

Asimismo, por cada tablero que materialice la aplicación mínima necesaria de BI para un BPA, de acuerdo con el punto 4.1.2 de la presente propuesta de intervención, se deberán configurar las conexiones entre Power BI y el Data Warehouse en Microsoft Fabric, permitiendo la consulta directa y centralizada de datos. Los tableros deberán ser configurados para actualizaciones automáticas, permitiendo que los usuarios accedan a información en tiempo real o con intervalos de actualización predefinidos. Posteriormente, los tableros se organizarán en carpetas o secciones específicas según su propósito (e.g., riesgo crediticio, perfilado de clientes), facilitando la navegación y accesibilidad de los usuarios. Finalmente se deberán configurar los permisos y seguridad de acceso a cada visualización de cada tablero para mantener la privacidad y seguridad de los datos de acuerdo con las políticas de gobernanza de datos.

Luego, se realizarán las acciones específicas por cada tablero, tal y como se indican a continuación.

Desarrollo del Tablero de Segmentación de Clientes y Perfilado: para la implementación de este tablero, se deberán utilizar diversas variables demográficas, transaccionales y de comportamiento.

En primer lugar, se deberá definir el modelo de segmentación y perfilado, identificando para ello las dimensiones clave para la segmentación (edad, género, ubicación geográfica, nivel de educación, ingresos) y los indicadores de perfilado (frecuencia transaccional, uso de productos financieros).

Posteriormente se deberá realizar la integración de datos y selección de variables. Para ello, se deberán cargar datos demográficos, transaccionales y digitales en Power BI desde el Data Warehouse, asegurando que las variables estén disponibles en formatos estandarizados y listos para análisis.

A partir de este punto se desarrollarán las visualizaciones. Para esto se deberán aplicar los distintos indicadores: configurar gráficos de barras, mapas de calor y matrices de correlación que permitan visualizar la distribución de clientes por segmentos y patrones de consumo. Los gráficos de cohorte, permiten analizar la lealtad y los comportamientos de retención.

Desarrollo del Tablero de Análisis de Riesgo Crediticio: Para implementar este tablero, se deberán definir indicadores existentes de Riesgo que posea el BPA, seleccionando las métricas actuales (historial crediticio, puntuaciones de riesgo, patrones de gasto y datos macroeconómicos). Es importante aclarar que se considera como precondition que como todo banco que realiza préstamos, la entidad cuenta con algún manejo, aunque en este punto sea sin herramientas de apoyo basadas en IA, de riesgo crediticio, como las mencionadas.

Posteriormente se tendrán que preparar e integrar los datos de riesgo. Para ello, se deberán cargar y normalizar los datos relacionados con crédito, comportamiento financiero y condiciones geográficas, asegurando su conformidad con las normativas locales y BCRA.

Luego se deberán desarrollar las visualizaciones correspondientes, ya sea a través de gráficos de dispersión, matrices de correlación y diagramas de embudo que visualicen la viabilidad de otorgamiento de créditos y la exposición a riesgos. Los mapas de calor permitirán identificar regiones con alto riesgo crediticio, facilitando la gestión de políticas crediticias.

4.2.2.3 Capacitación y soporte para usuarios de visualizaciones BI

Capacitación de los usuarios clave: Se desarrollarán sesiones de capacitación para los usuarios clave en Power BI, orientadas a la interpretación de visualizaciones y la generación de reportes en base a las necesidades específicas de cada área del BPA.

Creación de guías y manuales de uso: Para garantizar el uso eficiente de los tableros y la integración de Power BI con Fabric, se distribuirán guías y manuales específicos que describan los flujos de trabajo, los procedimientos de acceso y las metodologías para el análisis de datos.

4.2.3 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio

La implementación del modelo predictivo de riesgo crediticio requiere una serie de acciones clave para asegurar su efectividad y precisión en la clasificación de clientes según su nivel de riesgo. Cabe aclarar que dichos pasos cumplen con la metodología CRISP-DM, tal y como se presenta en el Marco Teórico de este trabajo, en el punto 3.2.4.

La primera acción fundamental consiste en la *recopilación y preparación de los datos*. Es necesario extraer, limpiar y estructurar los datos provenientes de fuentes internas del BPA, incluyendo información histórica de pagos, datos demográficos y patrones de comportamiento financiero. Estos datos proporcionan una base sólida para el entrenamiento y validación del modelo, lo que permite capturar tendencias y comportamientos que influyen en el riesgo crediticio. La selección de variables relevantes se realiza considerando aquellas que presentan una correlación significativa con el riesgo de morosidad, como lo recomiendan Tana Pilacuán y Viteri Orozco (2024).

Posteriormente, se procede a la fase de *entrenamiento del modelo*. En esta etapa, el conjunto de datos se divide en datos de entrenamiento y validación para optimizar la capacidad predictiva del modelo en datos futuros. Se entrena el modelo de regresión logística con el objetivo de generar una clasificación binaria, previendo la probabilidad de incumplimiento o cumplimiento en los pagos. Esta técnica resulta especialmente útil debido a su simplicidad y facilidad de interpretación, permitiendo que los usuarios internos del banco comprendan cómo cada variable impacta en el riesgo de incumplimiento (Tana Pilacuán y Viteri Orozco, 2024).

Con el modelo entrenado, se evalúa su rendimiento en la fase de *validación*, empleando métricas como la precisión y el F1-score, esenciales para asegurar la correcta identificación de patrones de incumplimiento y minimizar los falsos positivos. Adicionalmente, el modelo Random Forest se incorpora para mejorar la robustez y precisión en la predicción del riesgo crediticio, utilizando su capacidad para combinar múltiples árboles de decisión y reducir el riesgo de sobreajuste. Este enfoque permite capturar relaciones no lineales y gestionar variables tanto

continuas como categóricas, lo que contribuye a la adaptabilidad del modelo en distintos segmentos de clientes.

Una vez completada la validación del modelo, se *despliega* la solución en el entorno de producción del BPA. Este paso incluye la configuración de alertas y reportes automatizados que notifican a los responsables de crédito cuando un cliente clasificado como de alto riesgo solicita un préstamo o una línea de crédito. La integración del modelo en los sistemas de decisión del banco facilita la gestión proactiva del riesgo, permitiendo tomar medidas preventivas basadas en los resultados del modelo predictivo.

La última acción en este proceso se centra en la *evaluación y optimización continua del modelo*. De manera periódica, se revisa la efectividad del modelo y se ajusta en función de los cambios en el comportamiento del cliente y las condiciones del mercado. Este enfoque de retroalimentación garantiza que el modelo se mantenga relevante y alineado con las necesidades del BPA, permitiendo ajustes oportunos y mejorando la precisión a medida que se acumulan nuevos datos.

4.2.4 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude

Para asegurar la efectividad y precisión del modelo de detección de fraude, la implementación requiere de las acciones que se describen a continuación y sobre las cuales nuevamente es importante mencionar que siguen la metodología CRISP-DM, tal como se explica en el Marco Teórico de este trabajo, en la sección 3.2.4.

En primer lugar, se debe proceder a la *recopilación y preparación de los datos* históricos de transacciones y de sesiones de usuario en plataformas de e-banking que posea el BPA (home banking, core bancario, etc). Se deberán estructurar estos datos, eliminando valores atípicos o datos incompletos, para poder identificar patrones anómalos con claridad. Como señala Vanini et al. (2023), los datos de sesión y transacción, tales como el historial de clics, tiempo entre interacciones y detalles técnicos (e.g., dirección IP y agente HTML), constituyen la base de las características de entrada del modelo. La selección de variables incluye elementos financieros y de comportamiento que muestren una correlación con patrones de fraude, permitiendo una visión detallada del uso de las plataformas, es decir, detectando diferencias entre patrones de acceso y uso por parte de usuarios legítimos vs. posibles agentes fraudulentos.

Luego, se deberá continuar con la fase de *entrenamiento y validación del modelo*. Vanini et al. (2023) sugieren que el uso de aprendizaje supervisado en este tipo de modelo permite distinguir sesiones legítimas de las fraudulentas mediante patrones históricos de cada cliente. La división de datos en conjuntos de entrenamiento y validación asegura que el modelo generalice de manera adecuada. Durante la validación, se emplean métricas como la tasa de falsos positivos y la recall, que permiten verificar la precisión y efectividad del modelo para detectar casos de fraude sin generar alertas excesivas.

Posteriormente se deberá proceder al *despliegue e integración en el entorno operativo*. Con el modelo entrenado y validado, se desplegará en el entorno de producción del BPA, integrándolo en los sistemas de e-banking. El modelo generará alertas automáticas en tiempo real para notificar actividades sospechosas, facilitando una respuesta proactiva y permitiendo al BPA tomar decisiones rápidas ante posibles fraudes. Estas alertas deberán estar configuradas para ajustarse al umbral de probabilidad de fraude recomendado por el modelo.

Finalmente, mediante el *monitoreo y optimización continua*, se deberá mantener la precisión y efectividad del modelo, evaluándolo continuamente, ajustándolo conforme a los cambios en patrones de fraude y en el comportamiento de los clientes. Este monitoreo periódico permitirá mejorar el rendimiento del modelo con datos nuevos, manteniendo su relevancia y precisión en el tiempo.

4.2.5 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes

Para asegurar una implementación efectiva del modelo de churn basado en el trabajo de Brito et al. (2024), se sugieren las siguientes acciones, siguiendo la metodología CRISP-DM (Chapman et al., 2000) como base estructural.

Comenzando con la *recopilación y preparación de datos*, se deberán recolectar datos históricos relevantes (e.g., incluyendo transacciones, interacciones en canales digitales y datos demográficos de los clientes).

Luego se deberá ejecutar la *limpieza de datos* exhaustiva, eliminando valores atípicos y gestionando datos incompletos para garantizar que el conjunto de datos sea apto para el entrenamiento del modelo. De acuerdo con Brito et al. (2024), balancear las clases de datos

mediante técnicas como ADASYN o NEARMISS para asegurar una mejor capacidad predictiva en una base de datos con clases desiguales, donde la tasa de abandono es típicamente menor.

Como tercera acción, la *selección de variables relevantes* implicará definir las características clave que influyen la probabilidad de churn, tales como frecuencia de transacciones, antigüedad, nivel de uso de productos digitales y ubicación geográfica, entre otras variables relevantes. Se deberán considerar características de segmentación de clientes según criterios como RFM, que ofrecen una visión del comportamiento transaccional que permite afinar la predicción de abandono (Brito et al., 2024).

De acuerdo con (Brito et al., 2024), en cuarto lugar, el *entrenamiento y validación del modelo* implicará entrenar el modelo usando un algoritmo supervisado de baja complejidad como XGBoost, que ha demostrado ser eficaz para conjuntos de datos pequeños y medianos, y que permite ajustar los hiperparámetros para optimizar la precisión y la interpretabilidad del modelo. Se deberán dividir los datos en conjuntos de entrenamiento y validación (70-30) para asegurar que el modelo generalice correctamente en datos no vistos y mitigue el riesgo de sobreajuste. Al emplear métricas de rendimiento como AUC-ROC y F1-Score para evaluar el desempeño del modelo y su capacidad se identificarán correctamente a los clientes con alto riesgo de abandono.

El anteúltimo paso requiere el *despliegue* e integración en el entorno operativo; esto implicará integrar el modelo en el sistema operativo del BPA, configurando alertas para que los responsables de atención al cliente reciban notificaciones sobre los clientes clasificados con alta probabilidad de churn. Se establecerá un umbral de probabilidad que determine cuándo se activa una alerta de retención, permitiendo priorizar esfuerzos en los clientes con mayor riesgo de abandono (Brito et al., 2024).

Por último, el *monitoreo y optimización continua* requerirá aplicar un chequeo continuo para revisar el desempeño del modelo y ajustarlo en función de los cambios en el comportamiento de los clientes y en el entorno económico. Se deberán realizar ajustes periódicos en el modelo con nuevos datos para asegurar que mantenga su relevancia y precisión, permitiendo que el BPA responda efectivamente a patrones emergentes en el churn de clientes.

4.2.6 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros

La implementación de un sistema de recomendación personalizada para productos financieros en un BPA, considerando un escenario de recursos limitados, requiere llevar a cabo acciones organizadas, siguiendo una orden de acciones y metodología similar a la de los modelos aplicados en los puntos previos (ver puntos 4.2.3, 4.2.4, 4.2.5). A continuación, se describen las acciones, contextualizadas al ámbito de este caso.

Mediante la *recopilación y preparación de datos* se cumplirá con el primer paso. Para este modelo, el proceso implicará extraer y organizar datos relevantes, como el historial transaccional, datos demográficos y registros de interacciones previas con productos del banco. Cabe aclarar que, a esta altura, muchos de los datos a extraer ya estarán previamente explotados mediante proceso de extracción de datos para satisfacer a los modelos previos. Según Li y Song (2024), contar con un perfil detallado de cada cliente es esencial para generar recomendaciones relevantes y alineadas con sus necesidades.

Además, se deberá realizar una *limpieza de los datos*, manejando valores incompletos y eliminando posibles duplicados para asegurar que el modelo opere con información precisa y libre de ruido. Nuevamente, en el caso de que ciertos orígenes ya hayan sido tratados para el tratamiento de modelos previos, este paso podrá ser más rápido.

El siguiente paso será mediante el *entrenamiento y validación del modelo*. El enfoque sugerido, basado en Li y Song (2024), es utilizar un modelo de filtrado colaborativo combinado con técnicas basadas en contenido, optimizando así la capacidad de hacer recomendaciones iniciales adaptadas a cada cliente. Se dividirán los datos en conjuntos de entrenamiento y prueba para evaluar su precisión y capacidad de generalización. Las métricas de precisión y cobertura serán las principales herramientas para medir el rendimiento del modelo en esta fase inicial.

A continuación, se deberá proceder con el *despliegue* en un entorno de producción controlado. Esta implementación se realizará de forma limitada a un grupo específico de clientes, permitiendo observar y ajustar el modelo de acuerdo con la respuesta obtenida. Esto asegura que el sistema pueda afinarse antes de una implementación a gran escala, minimizando riesgos y

maximizando la receptividad del usuario. Además, se generarán reportes periódicos para evaluar la aceptación de las recomendaciones, orientando ajustes futuros del modelo (Li y Song, 2024).

Finalmente, se realizará una *revisión y ajuste continuo* del modelo para mantener su precisión y relevancia. Esto implica el reentrenamiento regular del sistema, idealmente cada trimestre o semestre, para adaptarse a cambios en las preferencias de los clientes y en las condiciones del mercado. Li y Song (2024) destacan la importancia de esta práctica para mejorar progresivamente la efectividad del modelo, asegurando que continúe ofreciendo recomendaciones precisas y alineadas con las necesidades del cliente.

4.2.7 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente

La implementación del chatbot comienza con una fase de planificación estratégica en la que el BPA define los objetivos específicos y el alcance del sistema, estableciendo los tipos de consultas que el chatbot responderá en su fase inicial. Esta etapa permitirá limitar al sistema con tareas de bajo nivel que optimicen la carga operativa del banco sin exigir infraestructura avanzada. Según Rojas Ahumada et al. (2023), la identificación de estas consultas debe basarse en un análisis de datos históricos de interacciones con clientes, seleccionando preguntas frecuentes que demandan respuestas rápidas y estandarizadas. Este enfoque permite establecer una base de conocimiento sólida, configurada para responder consultas básicas, como horarios de operación, saldos y ubicación de sucursales.

Posteriormente, se procede a la selección de la plataforma tecnológica más adecuada para el despliegue del chatbot. La implementación del chatbot para el servicio de atención al cliente en el BPA permite flexibilidad en la selección de herramientas tecnológicas, considerando que el trabajo de Rojas Ahumada et al. (2023) no menciona recursos específicos para la implementación de chatbots. En este contexto, se sugiere que el BPA considere herramientas open-source como Rasa (s.f.) y Botpress (s.f.), en sus planes de pricing free. Si no, otra perspectiva coherente con la implementación de recursos tecnológicos dentro de un mismo ecosistema tratado en tópicos anteriores, es la del servicio Azure AI Bot Service (Microsoft, s.f.-h) que es compatible con los entornos de Azure y otros servicios de la plataforma Microsoft. Esta combinación de opciones permitirá al BPA seleccionar la solución que mejor se ajuste a sus capacidades técnicas y financieras, o inclusive explorar alternativas análogas que considere oportunas para cubrir los mismos objetivos. La plataforma elegida deberá poder integrarse con los canales digitales actuales

del banco, asegurando que el chatbot esté disponible en la web y la aplicación móvil, de modo que pueda atender consultas de manera accesible y eficaz.

La siguiente acción consiste en estructurar la base de conocimiento del chatbot. Rojas Ahumada et al. (2023) subrayan la importancia de alimentar al chatbot con datos históricos bien definidos, organizados en formato de preguntas y respuestas. Para lograr una alta efectividad, es esencial categorizar estos datos, estableciendo un árbol de decisiones que permita al chatbot navegar entre las respuestas predefinidas de manera eficiente. Este proceso implica una curaduría minuciosa de las interacciones frecuentes, supervisada por un equipo interno que se encargue de validar la precisión de las respuestas y ajustar las variaciones en el lenguaje de acuerdo con las consultas específicas de los clientes del BPA.

Luego deberá accionarse en la configuración técnica del chatbot. Dado que Rojas Ahumada et al. (2023) no brinda detalles sobre este paso, siguiendo las recomendaciones de Ortiz-Garcés et al. (2024), el paso implica ajustar la lógica de respuesta del sistema para que reconozca palabras clave y frases que desencadenen las respuestas almacenadas en la base de conocimiento. La implementación deberá realizarse en un entorno controlado, realizando pruebas piloto en escenarios simulados, lo que permite evaluar la capacidad del chatbot para interpretar correctamente las consultas y ofrecer respuestas precisas. Según Ortiz-Garcés et al. (2024), cualquier discrepancia observada durante las pruebas debe corregirse mediante ajustes en el sistema de reglas y la ampliación de la base de datos de respuestas, garantizando así una interacción coherente y alineada con las necesidades de los usuarios.

Una vez que el chatbot ha demostrado su eficacia en el entorno de pruebas, se avanzará hacia el despliegue gradual en los canales de atención al cliente del BPA. En esta etapa, es fundamental monitorear el desempeño del chatbot en tiempo real, recopilando métricas de satisfacción del cliente y tiempos de respuesta. Rojas Ahumada et al. (2023) sugieren que el seguimiento continuo permite identificar patrones de interacción y adaptar las respuestas del chatbot en función de la retroalimentación recibida. Esta supervisión inicial debe ir acompañada de ajustes periódicos, optimizando el sistema en función de nuevas consultas o cambios en el comportamiento de los usuarios.

Finalmente, para asegurar la evolución continua del chatbot, el BPA deberá establecer un mecanismo de actualización de la base de conocimiento, incorporando datos de interacciones

recientes. Este proceso de mejora continua permitirá que el chatbot se adapte a las necesidades cambiantes de los clientes y mejore su precisión. La actualización deberá incluirse como parte de un plan de mantenimiento periódico, que garantice la estabilidad del sistema y optimice su efectividad a largo plazo, siguiendo las recomendaciones de Rojas Ahumada et al. (2023) para mantener la experiencia del usuario alineada con las expectativas de atención eficiente y satisfactoria.

4.3 Determinación de recursos necesarios

Esta sección describirá los recursos humanos y tecnológicos para ejecutar el plan objetivo presentado en esta propuesta. Si bien el BPA sabrá definir recursos parecidos (e.g. perfiles similares, un perfil asimilando responsabilidades de dos perfiles, recursos tecnológicos similares a los propuestos provenientes de otros proveedores, etc.) este inciso del trabajo refleja una guía desde la perspectiva de la organización principal como de todas las organizaciones colaboradoras involucradas en la implementación.

4.3.2 Recursos Humanos

Para la implementación de este plan de intervención, el equipo de trabajo estará compuesto por un conjunto de perfiles clave, seleccionados según la experiencia previa en proyectos de gobernanza de datos, BI e IA en el ámbito bancario. A continuación, se describen los roles esenciales:

Project Manager. El Project Manager actuará como el punto focal y coordinador principal frente a los intereses del BPA y el equipo de implementación. Su responsabilidad será asegurar que el proyecto avance según el cronograma establecido, coordinar las actividades entre los distintos equipos y facilitar la comunicación entre los actores involucrados. Este rol es crucial para la gestión de tiempos y recursos, así como para la resolución de conflictos que pudieran surgir durante la ejecución del plan.

Arquitecto Cloud. Este profesional es el encargado de definir y supervisar la infraestructura en la nube necesaria para la implementación, con un enfoque en Microsoft Fabric y Microsoft Purview (preferentemente, para evitar el costo de la curva de aprendizaje, la cual se omite como carga de costos y tiempos en el cronograma de este trabajo). Su función incluye el diseño y configuración de la arquitectura en Azure, asegurando que los recursos sean eficientes,

seguros y escalables. Además, será responsable de aplicar las mejores prácticas en el manejo de datos en la nube, garantizando la interoperabilidad entre los distintos recursos tecnológicos, y la alineación con las políticas de seguridad del banco.

Especialista en Data Governance. El Especialista en Data Governance es responsable de la configuración y mantenimiento de las políticas de gobernanza de datos en Purview. Este perfil se centra en establecer y supervisar los estándares de seguridad, calidad y accesibilidad de los datos. Entre sus tareas también se incluye la asesoría en la aplicación de las regulaciones vigentes y la supervisión de la implementación de las políticas de gobierno de datos que aseguren un uso ético y seguro de la información.

Data Analyst. El Data Analyst será el encargado de varias actividades. Por una parte, colaborará con el Especialista en Data Governance para asegurar la correcta organización y accesibilidad de los datos en el entorno de Microsoft Fabric. Por otra parte, este perfil es clave en la creación de reportes y dashboards que permiten a las áreas de negocio realizar análisis descriptivo y diagnóstico, facilitando la toma de decisiones estratégicas. Si el BPA optara por el uso de la plataforma de visualización Power BI, es importante considerar que el perfil cuente con experiencia en tal plataforma, para evitar la curva de aprendizaje, cuyo costo se omite en este trabajo en cuanto a costos y tiempo de cronograma. Si no, con aquella que el BPA efectivamente seleccione.

Data Engineer. El Data Engineer se encargará de la integración y preparación de datos provenientes de diversas fuentes (APIs, bases de datos, archivos de texto, entre otros) para su ingesta en el Data Warehouse de Microsoft Fabric. Este perfil desarrollará procesos ETL (Extract, Transform, Load) y ELT (Extract, Load, Transform), configurando pipelines en Data Factory o Dataflow que gestionen grandes volúmenes de datos de manera escalable y que soporten los requerimientos de análisis en BI e IA. Además de su competencia técnica en la manipulación de datos, el Data Engineer deberá colaborar con los Data Scientists para garantizar que los datos estén correctamente procesados y limpios, facilitando la precisión en los modelos de Machine Learning y las consultas de BI. Su experiencia en optimización de consultas y estructuras de datos complejas será esencial para reducir costos operativos y asegurar la rapidez en la recuperación de datos.

Data Scientist. Este perfil se especializará en el desarrollo e implementación de modelos predictivos, utilizando técnicas de ML y análisis estadístico. Entre sus responsabilidades, el Data

Scientist deberá diseñar, entrenar y validar los modelos de predicción que forman parte del plan de esta propuesta de intervención, asegurando la precisión y robustez del modelo para identificar probabilidades de incumplimiento y riesgos asociados. Podría utilizar lenguajes de programación como Python y R, especialmente valorados en entornos de modelado de ML, para procesar datos históricos de los clientes y evaluar patrones de comportamiento financiero. Además, será responsable de la interpretación de resultados, entregando insights claros y accionables para el equipo de negocio, que permita al BPA optimizar sus políticas de crédito. La capacidad de explicar la lógica detrás de los modelos de manera comprensible y el análisis de métricas de desempeño (como la precisión, el recall y el F1-score) serán claves para ajustar los modelos y alinearlos con los objetivos estratégicos del BPA.

Soporte IT y DevOps. Este perfil técnico es clave en la configuración inicial del entorno y en la automatización de procesos de monitoreo y gestión de los recursos en Microsoft Fabric. El profesional en Soporte IT y DevOps proveerá servicios y recursos tecnológicos (cuenta Azure, ambientes de desarrollo, licencias, microinformática, etc), asegurándose de que las soluciones implementadas estén operativas y alineadas con las políticas de seguridad y escalabilidad de la infraestructura en la nube. Además, trabajará en conjunto con los ingenieros de datos y el arquitecto cloud para facilitar la implementación de cambios y actualizaciones según sea necesario priorizando toda automatización de despliegue posible. Tendrá en cuenta tareas de CI/CD (integración y delivery continuo) y controlará el consumo de costos de los recursos de nube. En principio, para la optimización de costos se presenta el perfil en forma consolidada, aunque más adelante el BPA (o desde el principio si lo prefiere, podría diferenciarlo en dos perfiles específicos con sus especialidades correspondientes.

Punto Focal de Negocio o Product Owner (Banco). Este rol, asignado por el propio Banco, se encarga de representar los intereses y necesidades del área de negocio en cada etapa del proyecto. Este punto focal será un referente en temas de riesgo crediticio, fraude y atención al cliente, y proporcionará una comprensión detallada de los procesos y necesidades de cada área, facilitando la alineación entre las soluciones tecnológicas y los objetivos estratégicos del Banco. Dados los temas a abordar para la inclusión de IA en un BPA, se considera para fines prácticos del planteo del cronograma, que este perfil se distribuye en los siguientes “sub-perfiles”, para cada caso, a saber:

- **Analista Funcional de Riesgo** para temas de crédito,
- **Analista Funcional de Fraude**
- **Responsable del Área Comercial y Marketing** para atención al cliente es una excelente práctica.

Estos perfiles, con experiencia directa en sus áreas, pueden proporcionar insights específicos y requisitos que mejorarán la precisión y utilidad de los tableros y modelos. No obstante, se aclara como en otros casos, que el BPA puede unificar en una persona estos perfiles de acuerdo con la distribución de conocimientos y responsabilidades real.

Tester o QA (Quality Assurance): Si bien los data scientists pueden realizar pruebas iniciales de los modelos, contar con un perfil dedicado de QA para los dashboards de BI y los modelos predictivos puede asegurar que cada componente del sistema funcione de acuerdo con los requerimientos de calidad y rendimiento establecidos. Este rol puede colaborar estrechamente con el Data Scientist y el Data Analyst para verificar la precisión y coherencia de los datos, así como la experiencia de usuario en los tableros. Un QA puede detectar problemas de usabilidad, rendimiento o seguridad en los reportes de Power BI, así como revisar los modelos predictivos para garantizar su exactitud y eficacia antes de su implementación final.

Perfil de Documentación o Especialista en Conformidad y Normativa (opcional): Si bien no siempre se considera necesario, en un proyecto que incluye IA y manejo de datos financieros sensibles, un profesional de documentación o especialista en normativa puede asegurar que todos los procedimientos y procesos cumplan con las regulaciones y sean documentados adecuadamente. Este perfil puede asistir en la preparación de manuales de uso, informes técnicos y guías de cumplimiento, especialmente para garantizar la alineación con la normativa 7724 del BCRA (BCRA, 2023) u otros requisitos regulatorios locales e internacionales. A los efectos prácticos de organizar el cronograma, se lo contemplará en forma discriminada.

4.3.1 Recursos Tecnológicos

A continuación, se presentan los recursos tecnológicos esenciales para la implementación del plan de intervención propuesto. Estos recursos están organizados en función de su uso y rol dentro del proyecto.

Microsoft Fabric. La plataforma que se propone, unificada de análisis de datos que permitirá la implementación de soluciones de BI, Data Governance e Inteligencia Artificial (IA). La misma integra los recursos tecnológicos OneLake, Data Factory, Synapse, Power BI y un Data Gateway (para conexiones seguras en la transmisión de datos), lo cual facilita el manejo de datos en entornos unificados. Para el licenciamiento se propone comenzar con una capacidad de 730 hs por mes, con un espacio de OneLake de 5GB, aclarando que se deberá escalar según el crecimiento de los datos generados por las diferentes fuentes. Se considera que esta estimación garantizará el soporte para almacenamiento y procesamiento de datos de menor a gran escala.

Microsoft Purview. Para la gestión y catalogación de datos, se propone un plan con las funcionalidades de mapa de datos, escaneo y clasificación automatizados: 1 duración total del escaneo en minutos x 32 núcleos virtuales totales en todos los escaneos (para otras fuentes de datos), enriquecimiento del mapa de datos: 730 horas de conjunto de recursos avanzados, 730 horas de generación de informes, mapa de datos elástico: 1 hora de unidad de capacidad, 730 horas, aplicaciones de Microsoft Purview, catálogo de datos: servicio C0, política de datos: 0 políticas de DevOps x 730 horas, consumo de información: 0 llamadas API.

Servidor Linux para Data Lake. Se propone un servidor Linux Ubuntu de 64 bits (versión 22.04 o superior) para alojar un Data Lake en el cual se almacenarán datos crudos provenientes de distintas fuentes. Este servidor permitirá la ingesta y almacenamiento de grandes volúmenes de datos sin procesamiento, ofreciendo un recurso para análisis previo a Fabric, para optimización de costos. La configuración recomendada es de 8-16 núcleos de CPU, 32 GB de RAM y un almacenamiento SSD de 4 TB para soportar altos volúmenes de lectura y escritura. El software necesario podría ser Docker y Python 3.8 o superior para realizar operaciones ETL y scripts de integración con el Data Warehouse.

Power BI Pro. Se propone esta plataforma de visualización de datos para la generación de los tableros interactivos y reportes dinámicos. En cuanto al licenciamiento, más allá de que este software se encuentre dentro de los recursos ofrecidos por el ecosistema de Microsoft Fabric, se debe considerar el modo de licencia, la cual se recomienda que comience con usuarios individuales que desarrollen y consuman dashboards en su propia cuenta, por lo que la licencia “Power BI Pro” es una opción viable y más económica. Luego, en una curva de crecimiento más avanzada, el BPA podrá considerar la licencia “Power BI Premium” (licencia por capacidad).

Recursos de Microsoft Azure para Modelos de IA (basados en ML). Se sugiere emplear esta plataforma en Azure Machine Learning para el desarrollo, entrenamiento e implementación de modelos predictivos. Este recurso permitirá implementar los modelos de ML. El licenciamiento considera pago por uso para instancias de entrenamiento de IA y almacenamiento de modelos. Para proyectos de larga duración, se recomienda un plan de uso flexible según las necesidades del BPA. La configuración recomendada es contar con instancias de 16 núcleos de CPU, 64 GB de RAM y almacenamiento de 500 GB SSD para entrenar y almacenar modelos predictivos. Es importante aclarar que también el BPA podría aprovechar el recurso “Servidor Linux para Data Lake” mencionado anteriormente, para emplear modelos predictivos mediante Docker.

Puestos de Trabajo (notebooks). Se consideran notebooks para cada miembro del equipo de implementación (Data Scientist, Data Engineer, Data Analyst, Especialista en Data Governance, y Soporte IT y DevOps). Se recomienda que estas computadoras cuenten con capacidad de procesamiento suficiente para manejar datos y ejecutar software especializado. La configuración mínima recomendada es que cada puesto considere CPU de 4 núcleos, 16 GB de RAM, disco SSD de 512 GB y conectividad de alta velocidad. Software adicional: Licencias de Microsoft Office, Power BI Desktop, Python, R, y acceso a Azure DevOps para la gestión del proyecto.

Licencias de Software Complementario. Esto es para el uso de herramientas de gestión y colaboración, tales como Microsoft Teams para comunicación interna y Azure DevOps para la gestión de tareas, control de versiones y despliegue continuo. Con una licencia estándar de Microsoft 365 por cada usuario, que incluye acceso a Teams y otras herramientas de productividad, además de una suscripción a Azure DevOps para la gestión integral del proyecto se cumpliría con este punto. Es importante aclarar que estas licencias no son consideradas dentro del punto 4.6.1 “Costos de Recursos Tecnológicos”, debido a que se asumen como costos hundidos dentro de paquetes globales de licencias que se asume que una entidad bancaria, por más mínima que sea, ya cuenta de antemano para la totalidad de su staff (o de otro modo, se puede resolver con herramientas open-source).

4.4 Cronograma de tareas

Manteniendo el orden y coherencia de los temas presentados en el punto 4.2 de la presente propuesta de intervención, a continuación, se materializa el plan de desarrollo por etapas del sistema de software que implementará modelos predictivos de gestión de riesgo crediticio,

detección de fraudes, atención al cliente y su comportamiento, dirigido a los BPA, de este modo, cumpliendo con el objetivo general de este trabajo.

En este punto se ha trabajado en la confección del plan de tareas, con el mayor detalle posible para que el BPA pueda administrar el proyecto a nivel de Estructura de Desglose de Trabajo (EDT), dividiendo así cada etapa en un proyecto en tareas más pequeñas y manejables.

4.4.1 Convenciones definidas para el armado del cronograma

A continuación, se presentan algunas convenciones establecidas para la elaboración de este cronograma.

En primer lugar, se utilizó Microsoft Excel para estimar las horas por tarea y perfil participante. Esto permitió obtener un desglose preciso de la participación de cada perfil y las horas propuestas para cada actividad. Este detalle se encuentra en el Anexo I.

Acto seguido, dada la cantidad de perfiles involucrados (de acuerdo con el punto 4.3.2) y la naturaleza de la estimación (Anexo I), varias tareas incluyen a múltiples perfiles en paralelo. Para facilitar la visualización de tiempos y etapas en este cronograma, se optó por simplificar la asignación de recursos en Microsoft Project, herramienta elegida para el armado del diagrama de Gantt a presentar en los puntos siguientes, mediante una entidad única denominada “Equipo,” con una capacidad del 100%. Este enfoque introduce un margen de error, ya que el camino crítico de cada perfil no se define con precisión. Sin embargo, se considera adecuado para el propósito de este trabajo, dado que cada BPA podrá ajustar el plan según sus perfiles disponibles y el número de personas por perfil (por ejemplo, un Data Scientist que tiene mayor participación en el desarrollo de modelos predictivos). Así, la duración de las tareas podría variar en función de los recursos específicos de cada institución. No obstante, es importante aclarar que el margen de error introducido se considera menor, ya que ilustra el camino crítico que tiene cada tarea, por lo tanto los tiempos de cada etapa propuesta son acordes a la naturaleza de lo que se desarrolla e implementa.

Un tercer aspecto por considerar es que, aunque las etapas 1 y 2 deben ejecutarse en orden para aplicar adecuadamente los criterios de gobernanza de datos relacionados con el cumplimiento de la normativa 7724 (BCRA, 2023), las etapas 3 a 7 podrían realizarse en un orden diferente, de acuerdo con las prioridades y disponibilidad de recursos del BPA, incluso en paralelo. Este


cronograma presenta un plan posible, adaptado a un BPA con los recursos mínimos necesarios para implementar el proyecto en un equilibrio de tiempos y costos, donde cada etapa se ejecuta de forma secuencial y sin solapamiento.

Por último, dado que Microsoft Project exige una fecha de inicio, las visualizaciones incluyen fechas, asumiendo un comienzo el 02/01/2025 para los casos que se ilustrarán en los próximos puntos. Este cronograma está diseñado para ser ajustable, permitiendo que el BPA que lo utilice pueda adaptar las fechas y el orden de ejecución según su propio plan de implementación. Modificando simplemente la fecha de inicio, el resto de las fechas se ajustará automáticamente.

4.4.2 Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos

Figura 7

Diagrama de Gantt – Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos.




Nota. Elaboración Propia en base al Plan del Proyecto.

Como se observa en la Figura 7, la estimación aproximada de la Etapa 1 conlleva unos cuatro meses de ejecución, sentando las bases necesarias para comenzar luego el camino de madurez en la gestión de datos acorde a la Etapa 2 y las posteriores implementaciones de las etapas pertinentes a IA.

4.4.3 Etapa 2: Implementación de BI

Figura 8

Diagrama de Gantt – Etapa 2: Implementación de BI.




Nota. Elaboración Propia en base al Plan del Proyecto.

Como se observa en la Figura 8, la estimación aproximada de la Etapa 2 conlleva un mes y medio de ejecución, logrando con el camino propuesto, una implementación mínima que sienta el camino de la aplicación de BI y el alcance del BPA del nivel de madurez en la gestión de datos descriptiva y analítica, previo a pasar a las próximas etapas pertinentes a IA.

4.4.4 Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio

Figura 9

Diagrama de Gantt – Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio.




Nota. Elaboración Propia en base al Plan del Proyecto.

El cronograma correspondiente a la Etapa 3 conlleva aproximadamente tres meses en total.

4.4.5 Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude

Figura 10

Diagrama de Gantt – Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude.




Nota. Elaboración Propia en base al Plan del Proyecto.

El cronograma correspondiente a la Etapa 4 conlleva aproximadamente tres meses y medio en total.

4.4.6 Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes

Figura 11

Diagrama de Gantt – Etapa 5: Implementación de Modelo Predictivo de Abandono de Clientes.




Nota. Elaboración Propia en base al Plan del Proyecto.

El cronograma correspondiente a la Etapa 5 conlleva aproximadamente tres meses en total.

4.4.7 Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros

Figura 12
Diagrama de Gantt – Etapa 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros.




Nota. Elaboración Propia en base al Plan del Proyecto.

El cronograma correspondiente a la Etapa 6 conlleva aproximadamente tres meses en total.

4.4.8 Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente

Figura 13

Diagrama de Gantt – Etapa 7: Implementación de un Chatbot para Servicio de Atención al Cliente.



Nota. Elaboración Propia en base al Plan del Proyecto.

El cronograma correspondiente a la Etapa 7 conlleva aproximadamente dos meses en total.

4.4.9 Duración total estimada del proyecto

En función de las etapas que se fueron detallando en los puntos anteriores, se estima que la duración total en meses pauta para el proyecto es de unos 20 (veinte) meses, considerando una ejecución lineal y con los recursos determinados. Como se indicó anteriormente, ante la posibilidad de que un BPA pueda modificar el paralelismo, sobre todo, de las etapas 3 a 7 o sume más recursos para paralelizar ciertas tareas, el tiempo podría ser menor.

4.5 Factores externos condicionantes

La implementación de IA en los BPA podría enfrentar una serie de factores externos que pueden condicionar su ejecución y éxito a lo largo del tiempo. Estos factores, provenientes de aspectos culturales, regulatorios, y tecnológicos, entre otros, son elementos ajenos a la gestión interna de la institución y representan desafíos adicionales a los propios de cualquier proyecto de transformación digital.

Considerar estos factores es esencial para que los BPA puedan adoptar un enfoque de IA sostenible y adaptativo. En los apartados siguientes se analizan los factores externos en mente, con el objetivo de identificar sus posibles implicancias y proponer estrategias que permitan mitigarlos de forma anticipada, asegurando así un entorno favorable para el éxito del proyecto de IA.

4.5.1 Resistencia Cultural y Temores de Privacidad

Este factor podría manifestarse tanto a nivel interno, entre los empleados del banco, como a nivel externo, en la clientela que utiliza sus servicios. La adopción de IA implica cambios en los métodos tradicionales de trabajo y la incorporación de herramientas tecnológicas que pueden percibirse como disruptivas o incluso invasivas.

Desde una perspectiva interna, la resistencia cultural, de ocurrir, podría estar motivada por la percepción de que la automatización y la digitalización reemplazarán algunas funciones realizadas actualmente por el personal. Esta preocupación probablemente generaría una actitud reticente al uso de herramientas de IA, lo que afecta directamente la efectividad de su implementación. Los empleados pueden experimentar inseguridad ante la falta de experiencia o capacitación en el manejo de estas tecnologías, lo que refuerza la necesidad de procesos de adaptación y apoyo constantes durante el despliegue del plan.

A nivel externo, la clientela de los BPA puede tener recelos ante el uso de tecnologías avanzadas para procesar su información personal y financiera. Las preocupaciones sobre la privacidad y la seguridad de los datos se vuelven prominentes, ya que muchos usuarios temen que sus datos sean utilizados sin su consentimiento o sean vulnerables a accesos no autorizados. Este aspecto es especialmente relevante en un contexto en el que la transparencia y la protección de la información son temas críticos para las instituciones financieras.

Para abordar este factor, es esencial que los BPA adopten una estrategia de comunicación clara y efectiva, que informe a sus empleados y clientes sobre los beneficios de la IA y las medidas de protección de datos implementadas para salvaguardar su privacidad. Asimismo, es necesario establecer políticas de transparencia en el tratamiento de la información y la creación de canales de feedback que permitan a los clientes expresar sus inquietudes. La capacitación continua del personal en temas de privacidad y protección de datos también contribuirá a reducir la resistencia cultural y a fomentar una adopción gradual de la tecnología.

4.5.2 Escasez de Datos para Entrenamiento de Modelos IA

Uno de los desafíos técnicos más relevantes a la hora de implementar IA por primera vez, es la probable escasez de datos de calidad y relevancia para el entrenamiento de modelos predictivos. A diferencia de las grandes entidades financieras, que cuentan con volúmenes extensivos de datos acumulados en sus sistemas, los BPA podría tener bases de datos perteneciente a los sistemas terceros de los cuales se debe alimentar, más limitadas, fragmentadas o con menor profundidad histórica. Esta falta de datos podría afectar directamente la precisión y efectividad de los modelos de IA, ya que estos dependen de una cantidad sustancial de información para identificar patrones y realizar predicciones acertadas.

Para mitigar este problema, los BPA pueden explorar estrategias de enriquecimiento de datos, como la integración de fuentes externas (por ejemplo, datos demográficos regionales y de comportamiento financiero a nivel macroeconómico) que complementen los datos propios del banco. Otra opción es implementar técnicas de aumento de datos mediante simulaciones o el uso de métodos de aprendizaje transferido, donde se aprovechan modelos entrenados en conjuntos de datos más grandes y se ajustan a las particularidades del banco. Estas soluciones no solo podrían mejorar la capacidad predictiva de los modelos, sino que también permitirían a los BPA optimizar los recursos de datos disponibles, facilitando una implementación más efectiva de las soluciones de IA en su contexto específico.

4.5.3 Disponibilidad de Personal Especializado

La disponibilidad de personal capacitado en IA y ciencia de datos es otro factor externo que influye significativamente en la implementación de IA en los BPA. La naturaleza regional de estos bancos, sumada a las limitaciones en el acceso a profesionales altamente especializados en

zonas alejadas de los centros urbanos principales, complica la contratación y retención de talento capacitado. La falta de recursos humanos en áreas como Machine Learning, ingeniería de datos y analítica avanzada puede ralentizar o incluso impedir el avance de proyectos tecnológicos.

Este problema se vería agravado en caso de resistencia de algunos BPA a flexibilizar sus políticas de trabajo remoto, una práctica cada vez más común en el sector tecnológico y que podría ofrecer soluciones para cubrir las brechas de talento en las áreas menos accesibles. Sin embargo, muchos bancos mantienen un enfoque tradicional que restringe esta modalidad, limitando las oportunidades para contratar talento ubicado en otras regiones o en el extranjero, lo cual podría mejorar la capacidad del banco para implementar IA de manera efectiva.

Para mitigar este factor, los BPA podrían considerar programas de capacitación internos y alianzas estratégicas con instituciones educativas locales que ofrezcan formación en IA y ciencia de datos, promoviendo así el desarrollo de talento en las propias regiones donde operan, además de evaluar la tercerización de algún servicio. Asimismo, una revisión de las políticas de trabajo remoto permitiría a los bancos ampliar su alcance de contratación, accediendo a un mayor número de profesionales capacitados y contribuyendo a un entorno de trabajo más inclusivo y flexible que facilite la retención de talento especializado.

4.5.3 Cambios en la Normativa del BCRA

La regulación financiera en Argentina, y particularmente la normativa emitida por el BCRA, representa un factor de gran relevancia para los proyectos de implementación de IA en los BPA. Dado que el BCRA establece normas y regulaciones de cumplimiento obligatorio en temas tecnológicos y de protección de datos, cualquier cambio en estas normativas puede alterar la dirección y el alcance del proyecto. Es posible que, durante la implementación de una solución de IA, surjan nuevas exigencias regulatorias que requieran ajustes en el sistema o cambios en los procesos operativos, lo cual introduce incertidumbre y puede aumentar los costos y el tiempo de implementación.

Por ejemplo, una modificación en la normativa podría demandar mayor transparencia en los modelos de IA, imponiendo requisitos adicionales de exposición y trazabilidad de los algoritmos. Estos cambios pueden complicar el cumplimiento de los procesos de auditoría y

requerir que los bancos adapten o revisen las herramientas utilizadas, lo cual implica recursos adicionales para el desarrollo y cumplimiento de estas nuevas demandas.

Para gestionar este riesgo, los BPA deben mantener una estrecha vigilancia sobre las actualizaciones normativas del BCRA y diseñar sus sistemas de IA de manera flexible, de modo que puedan adaptarse a posibles modificaciones regulatorias sin comprometer su funcionalidad o efectividad.

4.6 Evaluación del Proyecto

El análisis de costos proyecta los recursos necesarios para la implementación del proyecto, abarcando tanto los costos tecnológicos como los costos de recursos humanos. A continuación, se desglosan estos costos en detalle, de los cuales es importante aclarar que están considerados por la totalidad de la ejecución del proyecto.

4.6.1 Costos de Recursos Tecnológicos

Esta sección se centra en los costos de los recursos tecnológicos proyectados para el proyecto, con un énfasis especial en los servicios de la nube de Microsoft Azure, dada su relevancia en la infraestructura del sistema. Los recursos considerados incluyen almacenamiento, procesamiento, bases de datos, servicios de inteligencia artificial y los puestos de trabajos para los perfiles participantes.

Cabe aclarar que, si bien algunos precios en las siguientes imágenes que evidencian la investigación de costos realizadas, se encuentran en pesos argentinos y otras en dólares estadounidenses, por convención, los costos que se presentarán a continuación se han trabajado todos en USD (dólares americanos), usando el tipo de cambio general oficial en pesos cotizado en noviembre 2024, de \$1017 (sin inclusión de impuestos).

En primer lugar, a continuación, mediante la Tabla 4 se visualiza la cotización proyectada mediante el sitio de Microsoft Azure que ofrece la calculadora de precios según recursos a proyectar (Microsoft, s.f.-g). Una observación a tener en cuenta sobre dicha proyección es que los costos proyectados se basan en estimaciones iniciales basadas en el alcance del proyecto propuesto y los recursos descritos. Sin embargo, estos costos pueden aumentar en función del crecimiento en el volumen de usuarios, la demanda de datos y el consumo de recursos en Azure. A medida que

evolucionen los casos de uso y aumente el consumo de la plataforma, los valores podrán ajustarse para reflejar el uso acumulativo de recursos adicionales.

Tabla 4

Costos de recursos Azure considerados para la propuesta de intervención

Servicio	Tipo	Región	Descripción	Costo Mensual (USD)
Analysis	Microsoft Fabric - Power BI	East US	Power BI Pro License: USD 10 per user per month	\$ 10,00
Analysis	Microsoft Fabric	East US	F2, 2 Capacity units x 730 Hours, OneLake storage 5,000 GB	\$ 392,80
Compute	App Service	West US	Basic Tier; 2 B1 (1 Core(s), 1.75 GB RAM, 10 GB Storage) x 730 Hours; Windows OS; 0 SNI SSL Connections; 0 IP SSL Connections; 0 Custom Domains; 0 Standard SLL Certificates; 0 Wildcard SSL Certificates	\$ 109,50
Analytics	Microsoft Purview	East US	Microsoft Purview Data Map, Automated Scanning and Classification: 1 Total scan duration in minute x 32 Total vCores across scans (For other data sources), Data Map Enrichment: 730 Advanced Resources Set hours, 730 Report Generation Hours, Elastic Data Map: 1 Capacity Unit hour, 730 hours, Microsoft Purview Applications, Data Catalog: C0 Service, Data Policy: 0 DevOps Policies x 730 Hours, Insight Consumption: 0 API calls	\$ 1.052,27
Analytics	Azure Machine Learning	East US 2	1 D3 v2 (4 Core(s), 14 GB RAM) x 730 Hours, Pay as you go	\$ 167,17
Analytics	Azure AI Bot Service	West US	Free Tier	\$ -
Notebook	Puesto de Trabajo Físico	N/A	Notebook Hp Intel Core I5 1235u 15dy5885 16gb 512gb Ssd Pcie Nvme Windows 11 Home 15.6	\$
Total				\$ 1.731,74

Nota. Elaboración Propia, adaptado de Microsoft (s.f.-g).

Figura 14

Cotización a través de la calculadora de costos de servicios Microsoft Azure

The screenshot displays the Microsoft Azure Pricing Calculator interface. The browser address bar shows the URL: azure.microsoft.com/en-us/pricing/calculator/?ef_id=_k_Cj0KCQjwvpy5BhDTARIsAHSil.... The page title is "Your Estimate".

The main content area lists several services with their respective configurations and costs:

Service	Configuration	Upfront	Monthly
Microsoft Purview	Microsoft Purview Data Map, Automated Scanning ...	\$0.00	\$1,052.27
Azure Machine Learning	1 D3 v2 (4 Core(s), 14 GB RAM) x 730 Hours, Pay as ...	\$0.00	\$167.17
Microsoft Fabric	F2, 2 Capacity units x 730 Hours, OneLake storage 5...	\$0.00	\$392.80
Azure AI Bot Service	Free Tier	\$0.00	\$0.00

Below the table, the "Azure AI Bot Service" section is expanded, showing configuration options:

- Region:** West US
- Tier:** Free

The "Standard Channels" section indicates "Unlimited messages included." The "Premium Channels" section indicates "10,000 messages included."

The "Support" section shows "SUPPORT: Basic (Included)" with a cost of \$0.00.

The "Select your program/offer" section shows "LICENSING PROGRAM: Microsoft Customer Agreement (MCA)" with a link to [Log in to see your Azure agreement pricing.](#)

At the bottom, there is a checkbox for "Show Dev/Test Pricing" which is currently unchecked.

Nota. Cotización generada utilizando la calculadora de Microsoft Azure (Microsoft, s.f.-g).

En segundo lugar, a continuación, se visualiza en la Tabla 5 la cotización proyectada de puestos de trabajos requeridos para los perfiles que participan del proyecto. Principalmente los puestos estimados se basan, en un primer grupo, en notebooks con capacidades para un grupo de funcionales y gestión, con características de procesamiento y memoria I5 y 16 GB respectivamente. Y en un segundo grupo, notebooks con capacidades para un grupo de desarrollo y soporte de infraestructura, con características de procesamiento y memoria I7 y 32 GB respectivamente.

Tabla 5*Costos de puestos de trabajo para la propuesta de intervención*

Sevicio	Tipo	Descripción	Cantidad	Costo Total (USD)
Notebook	Puesto de Trabajo Físico: Project Manager, Especialista en Data Governance, Punto Focal por 3, Tester, Perfil doc+Especialista en conformidad y normativa.	Notebook Hp Intel Core I5 1235u 15dy5885 16gb 512gb Ssd Pcie Nvme Windows 11 Home 15.6	7	\$ 7.999,11
	Puesto de Trabajo Físico Arquitecto Cloud, Data Analyst, Data Engineer, Data Scientist, Soporte IT y DevOps	Notebook Hp New Elite I7 32gb 1tb Ssd	5	\$ 8.704,47
Total				\$ 16.703,58

Nota. Elaboración Propia, adaptado de Microsoft (s.f.-g).

Los recursos obtenidos se buscaron en el sitio Mercado Libre (s.f.), no obstante es un ejemplo a modo referencia y el BPA podrá buscar los puestos de trabajo (notebooks o pc) con características técnicas similares a las presentadas. A los efectos de llegar a la relación de precio entre los costos que se observan en la Tabla 5 y la Figura 15 que se encuentra a continuación, los precios en pesos argentinos visualizados en la Figura 15, fueron convertidos a dólares, de los cuales se le dedujo el 10.5% de IVA y se lo multiplicó por la cantidad de puestos indicados en la columna “Cantidad” de la Tabla 5.

Figura 15*Cotización de Puestos de Trabajo en Mercado Libre*






[Ver más productos marca HP](#)
 Nuevo | +25 vendidos 
**Notebook Hp Intel Core i5 1235u
15dy5885 16gb 512gb Ssd Pcie
Nvme Windows 11 Home 15.6
Gráficos Intel Iris Xe Color Blue
And Grey**
 4.0 ★★★★★ (7)
~~\$ 2.023.499~~
\$ 1.298.499 35% OFF
 Mismo precio en 18 cuotas de \$ 72.138⁸³
[Ver los medios de pago](#)
 Capacidad: **16 GB RAM | 512 GB SSD**

16 GB RAM 512 GB SSD	24 GB RAM 1 TB SSD	24 GB RAM 512 GB SSD
---------------------------	-------------------------	---------------------------

Computación > Notebooks y Accesorios > Notebooks > Notebook Hp

[Vender uno igual](#) | [Compe](#)




 Nuevo | +25 vendidos 
**Notebook Hp New Elite i7
32gb 1tb Ssd Pantalla Táctil**
 4.8 ★★★★★ (10)
~~\$ 2.198.000~~
\$ 1.978.200 10% OFF
 en 6 cuotas de \$ 458.250⁰³
[Ver los medios de pago](#)
 Llega gratis entre el miércoles y el jueves
[Más formas de entrega](#)
 Color: Plateado
 Stock disponible
 Cantidad: 1 unidad ▼ (+50 disponibles)
[Comprar ahora](#)

Nota. Cotización generada utilizando Mercado Libre (s.f.).

4.6.2 Costos de Recursos Humanos

La implementación del proyecto requiere de un equipo especializado, proyectado en el tiempo para cumplir con los plazos y objetivos establecidos. La Tabla 6 detalla los costos asociados a los recursos humanos, considerando los perfiles indicados en el punto 4.3.2 de la presente propuesta de intervención.

Cabe aclarar que la proyección de horas estimadas es presentada en detalle, discriminada por Etapa e incluso por tarea en el Anexo I de la presente propuesta, por lo que, el BPA que siga esta guía podría estimar incluso, los costos por etapa.

Tabla 6

Costos de recursos humanos proyectados según las horas estimadas del proyecto

Rol	Costo Mensual (USD)	Proyección según hs estimadas	Costo Total Estimado para el proyecto (USD)
Project Manager	4000	564	\$ 14.100,00
Arquitecto Cloud	3500	148	\$ 3.237,50
Especialista en Data Governance	3500	180	\$ 3.937,50
Data Analyst	2200	648	\$ 8.910,00
Data Engineer	2500	456	\$ 7.125,00
Data Scientist	2700	974	\$ 16.436,25
Soporte IT/DevOps	2500	192	\$ 3.000,00
Analista Funcional de Riesgo (Punto Focal 1)	2200	48	\$ 660,00
Analista Funcional de Fraude (Punto Focal 2)	2500	46	\$ 718,75
Responsable Area Comercial y Marketing (Punto Focal 3)	2700	100	\$ 1.687,50
Tester	2000	202	\$ 2.525,00
Documentador/Conformidad y Normativa	2000	164	\$ 2.050,00
Total			\$ 64.387,50

Nota. Elaboración Propia.

4.6.3 Resumen de Costos Totales del Proyecto

Para brindar una perspectiva global del presupuesto requerido, a continuación, se presenta la Tabla 7 consolidada con los costos totales estimados del proyecto. Dicha tabla resume tanto los costos de los recursos tecnológicos como los de los recursos humanos, proyectados a lo largo de

la implementación, de acuerdo con la duración estipulada en el punto 4.4.9 de la presente propuesta de intervención.

Tabla 7

Costos total de implementación de la propuesta de intervención

Categoría	Detalle	Costo Total de Implementación del proyecto (USD)	
Recursos Tecnológicos	Servicios en Azure (almacenamiento, procesamiento, bases de datos, IA)	\$	34.634,72
Recursos Tecnológicos	Recursos físicos (notebooks)	\$	16.703,58
Recursos Humanos	Perfiles aplicados según punto 4.3.2 de la propuesta de intervención	\$	64.387,50
Total		\$	115.725,80

Nota. Elaboración Propia.

Se debe recalcar que estos costos corresponden a la implementación completa del proyecto, de acuerdo con lo estipulado en el punto 4.4 de la presente propuesta. A partir de su implementación, deberán considerarse los costos mensuales, ya sea de los recursos tecnológicos de la infraestructura de Microsoft (s.f.-g.), sueldos mensuales de recursos que continúen trabajando sobre el mantenimiento de los modelos aplicados, nuevos desarrollos etc.

4.6.4 Matriz FODA de la propuesta de intervención

A modo conclusión para la evaluación del proyecto, más allá de la vertical de costos analizada para su evaluación, en este punto se presenta un análisis FODA (Fortalezas, Oportunidades, Debilidades y Amenazas). Desde esta perspectiva, se presenta una evaluación de los factores internos y externos que pueden influir en el desarrollo y éxito del proyecto de implementación de IA en los BPA.

En primer lugar, se detallan las principales **fortalezas** identificadas.

Optimización de Procesos. La implementación de IA facilita la automatización de tareas operativas, logrando una reducción de costos y una mejora en la eficiencia de los procesos internos.

Mejora en la Toma de Decisiones. La utilización de modelos predictivos permite tomar decisiones basadas en datos, optimizando la gestión de riesgos y la detección de fraudes.

Personalización de Servicios. La IA permite adaptar los servicios a las necesidades individuales de los clientes, incrementando la satisfacción y promoviendo la retención.

Infraestructura Escalable. La elección de plataformas como Azure garantiza que la infraestructura pueda crecer de acuerdo con las necesidades y el ritmo de adopción de IA en el banco.

En segundo lugar, se exponen las principales **oportunidades** identificadas.

Innovación y Competitividad. La adopción de IA representa una oportunidad para que los BPA compitan con bancos digitales y fintechs que ya aplican tecnología avanzada.

Inclusión Financiera. La IA facilita la expansión de servicios hacia sectores menos bancarizados y zonas geográficas aisladas, promoviendo la inclusión.

Apoyo Gubernamental y Regulatorio. La alineación del proyecto con políticas de innovación y digitalización bancaria puede facilitar la obtención de apoyo de reguladores o cámaras en las que se encuentren registrados los BPA (como ABAPPRA).

Transformación Digital en el Sector. El proyecto está en sintonía con la tendencia de digitalización del sector financiero en Argentina, lo que puede generar sinergias y apoyos para futuras innovaciones.

En tercer lugar, se plantean las **debilidades** que puede presentar el proyecto.

Limitación de Recursos Financieros. Los BPA enfrentan dificultades para asignar recursos financieros considerables de acuerdo con otras prioridades regionales, lo que podría afectar la escala y sostenibilidad del proyecto de IA.

Falta de Personal Especializado. La disponibilidad de talento en IA es limitada en ciertas regiones, y la resistencia a permitir el trabajo remoto dificulta el reclutamiento y retención de expertos.

Dependencia de Proveedores de Servicios Cloud. El uso de infraestructura en la nube, como Azure, conllevaría una dependencia que podría influir en los costos y la disponibilidad del

servicio. Esto puede ser una debilidad si internamente no se hace un control adecuado del consumo de costos de la plataforma Azure.

Escasez de Datos para Entrenamiento de Modelos IA. La calidad y cantidad de datos históricos podrían ser limitadas, lo que puede disminuir la efectividad inicial de los modelos de IA. Es un punto débil para aquel BPA que se encuentre en esta condición de datos.

Por último, las **amenazas** posibles se presentan a continuación.

Resistencia Cultural y Temores de Privacidad. La implementación de IA podría enfrentar resistencia tanto de empleados como de clientes, quienes pueden tener preocupaciones sobre privacidad y desconocimiento de las tecnologías.

Cambios en la Normativa del BCRA. Las actualizaciones regulatorias del BCRA podrían requerir ajustes en el proyecto, afectando los plazos y aumentando los costos de cumplimiento.

Competencia con Fintechs. Las fintechs y grandes bancos, que ya han avanzado en la adopción de IA, representan una amenaza competitiva si los BPA no logran adoptar tecnología rápidamente.

Ciberseguridad y Riesgos Asociados. La mayor exposición a la tecnología de IA puede incrementar los riesgos de ciberseguridad, afectando la confianza de los clientes y la reputación de los BPA.

Conclusiones

La adopción de IA mediante una implementación gradual por etapas es una solución factible y alcanzable, incluso frente a las barreras económicas, organizativas y regulatorias que caracterizan a los BPA. Un plan de implementación desagregado por cada etapa marca un camino viable hacia ese objetivo, evitando que la idea de implementar IA sea percibida por un BPA como un proyecto inalcanzable o inmanejable. Cada etapa se encuentra diseñada para ofrecer resultados medibles por medio de modelos predictivos, en plazos razonables y priorizando casos de uso relevantes para la industria financiera.

La implementación de IA en el sector bancario es, sin duda, una necesidad estratégica. La transformación digital y el uso de IA para optimizar la gestión del riesgo crediticio, la detección de fraudes y la mejora en la experiencia del cliente constituyen respuestas concretas a las problemáticas que enfrentan los BPA en términos de competitividad y eficiencia operativa. Además, es la base inicial a partir de la cual las entidades pueden escalar hacia la aplicación de otros casos de negocio más complejos, gestionados mediante IA. La competencia con instituciones financieras de mayor envergadura y con capacidad de innovación tecnológica, es un factor determinante para los BPA, los cuales necesitan, cada vez más, desarrollar capacidades que les permitan responder a un mercado cambiante y altamente competitivo. En este sentido, la IA se presenta como una herramienta estratégica que no solo incrementa la eficiencia operativa, sino que también aporta valor en términos de calidad de servicio y toma de decisiones informadas, dos elementos esenciales para asegurar la sostenibilidad y crecimiento de los BPA en el largo plazo.

Uno de los desafíos más evidentes en este contexto es la correcta gestión de la información. En tal sentido, aquellos BPA que implementen IA podrán superar este desafío, contando con la ventaja competitiva de poder transformar sus datos en insumos estratégicos para la toma de decisiones. La capacidad de los modelos predictivos para anticipar el riesgo crediticio, detectar patrones de fraude y analizar el comportamiento de los clientes permite que las instituciones no solo se adapten al entorno actual, sino que se anticipen a él. Sin embargo, para que las tecnologías basadas en IA tengan un impacto efectivo, es crucial que los BPA desarrollen políticas de gestión de la información que optimicen el almacenamiento, procesamiento y acceso a los datos. Sin una infraestructura de datos sólida, los beneficios de la IA se verán limitados y, en última instancia, podrían comprometer el éxito de la implementación. Por tal motivo resulta necesaria la aplicación

de una infraestructura de gestión de datos que garantice la gobernanza de los mismos, exigiendo compromiso de la organización y el desarrollo de una cultura de gestión del dato.

Otro aspecto importante por considerar es la flexibilidad y escalabilidad del enfoque propuesto. El plan indica un orden, detalla modelos y recursos tecnológicos aplicables, pero también posibilita a los BPA alternar tecnologías a su realidad organizativa y ajustarlas según los resultados y necesidades que vayan surgiendo. Por ejemplo, la selección de tecnologías soportadas sobre otros proveedores o la alternancia en el orden de las etapas de aplicación de modelos predictivos a los casos de negocio abordados es factible. Por otra parte, este enfoque además de ser flexible es escalable en el sentido de que prioriza aplicaciones iniciales sencillas, asegurando una integración sostenible en un contexto de recursos limitados, fomentando la capacidad de aprendizaje y adaptación de los BPA, elementos clave para su éxito a largo plazo.

El plan se sustenta en la consolidación de la literatura existente, tomando como referencia estudios previos en la aplicación de modelos predictivos de IA en la banca. A partir de casos concretos de implementación de IA para la gestión de riesgo crediticio, detección de fraudes y mejora de la experiencia del cliente, se materializa la configuración de una guía práctica y adaptada a la realidad de los BPA. Aprovecha los modelos y metodologías analizados en la literatura para construir una hoja de ruta aplicable a la realidad local. Los ejemplos y experiencias compartidos por los autores citados en el análisis de los diversos modelos considerados han demostrado la efectividad de IA en la predicción de casos de riesgos y en la optimización de procesos. Estos estudios ejemplifican cómo los modelos de IA no solo pueden mejorar la toma de decisiones, sino también pueden transformar la interacción con los clientes y reducir los costos operativos, permitiendo a los BPA ofrecer servicios competitivos y de calidad.

En conclusión, los BPA cuentan con la referencia de un plan sólido y con recursos posibles para implementar un camino gradual, factible y con resultados evidenciables en plazos cortos a medianos. Este aporte en su camino hacia la innovación y la eficiencia, más allá de los modelos predictivos específicamente tratados, subraya que la transformación digital mediante IA es posible, necesaria y alcanzable, lejos de percibirse como un lujo o una aspiración lejana. Mediante la implementación de IA en procesos críticos y su alineación con las necesidades estratégicas de los BPA, las entidades de este tipo pueden consolidarse como actores clave en el desarrollo económico

y social de sus regiones, fomentando una banca más inclusiva, eficiente y adaptada a los desafíos del siglo XXI.

Líneas Futuras de Trabajo

A partir de la implementación de IA en los BPA bajo el plan de intervención propuesto, se plantean posibilidades de expansión y profundización de este proyecto. Las líneas futuras de trabajo buscan abordar algunas limitaciones y complementar el plan, de forma que se amplíe el impacto de la IA, mejorando tanto la precisión de los modelos implementados como la eficiencia general de la institución. Estas propuestas son una invitación a la exploración continua de los temas abordados, reconociendo que la implementación inicial es solo el comienzo de un proceso de transformación digital que requiere de ajustes, adaptaciones y nuevas innovaciones para maximizar sus beneficios.

Ampliación de los Modelos Predictivos. Una de las líneas futuras más prometedoras es la ampliación de los modelos predictivos iniciales. Una vez que los modelos actuales (focalizados en riesgo crediticio, detección de fraude y gestión del cliente) estén estabilizados y demuestren su efectividad, los BPA podrían expandir el uso de la IA hacia nuevas áreas de predicción. Entre estas áreas, destaca la predicción de la reactivación de clientes cuando el abandono ya ha ocurrido, la predicción de mora, la recomendación de inversiones, mejor colocación de promociones o incluso, casos de negocio en donde apliquen otras verticales de IA, como por ejemplo la vigilancia perimetral o el control de contratos firmados, mediante “Computer Vision”. Estas aplicaciones adicionales de IA potenciarían la competitividad y capacidad de respuesta de los BPA, consolidándolos como actores dinámicos en un mercado financiero altamente competitivo.

Automatización Avanzada. Con la consolidación del sistema de IA, otra línea de trabajo a considerar es la expansión de la automatización a procesos adicionales, permitiendo que los BPA logren una mayor eficiencia operativa y una mejor experiencia para el cliente. En este sentido, podrían evolucionarse los chatbots y asistentes virtuales con capacidad de manejar tareas más complejas, como la gestión de reclamos y sugerencias o la atención personalizada a clientes de alto valor. Estos sistemas, basados en Generative IA, más avanzados, facilitarían interacciones automatizadas que mejoren continuamente la experiencia del cliente y liberen recursos humanos para tareas de mayor valor estratégico.

Profundización en el Uso de Tableros de BI. A medida que la infraestructura de datos de los BPA se fortalezca, la creación y el desarrollo de tableros de BI adicionales pueden proporcionar una visión integral del rendimiento y de las áreas de oportunidad. Estos tableros ofrecerían

visualizaciones detalladas y en tiempo real de los datos generados por los modelos de IA, facilitando el seguimiento y evaluación continua de los resultados. Entre los casos adicionales, podría incorporarse la medición de la satisfacción del cliente, la eficacia de las campañas de marketing y el rendimiento de productos financieros. El objetivo de estos tableros sería optimizar la toma de decisiones a nivel directivo, contribuyendo al desarrollo de una cultura organizacional orientada al análisis de datos y a la mejora continua de los servicios.

Análisis de Retorno de Inversión (ROI). El análisis del retorno de inversión (ROI) es una línea de trabajo que permitirá evaluar la sostenibilidad y rentabilidad de esta intervención. Una vez implementada la IA, será necesario contar con métricas que cuantifiquen el beneficio económico de la inversión. Este análisis incluiría el cálculo de costos presentados en el punto 4.6, pudiendo a partir de los mismos desarrollarse un plan de negocios que proyecte los ingresos potenciales generados por la mejora en la eficiencia, la reducción de fraudes y la retención de clientes, entre otros factores. Un enfoque estructurado en la evaluación de ROI permitirá ajustar la estrategia de inversión y justificar futuros desarrollos de IA en los BPA.

Estudio de Factibilidad para Aplicación en Otras Entidades. Finalmente, otra línea de trabajo por considerar es el estudio de la factibilidad de aplicar este plan de intervención en entidades similares a los BPA, como startups financieras, fintech locales, o entidades financieras no bancarias de alcance regional. Estas instituciones comparten características estructurales y desafíos regulatorios que hacen que el plan desarrollado para los BPA pueda ser relevante para sus contextos. Un análisis comparativo podría identificar las adaptaciones necesarias para implementar esta propuesta en otros tipos de organizaciones, aprovechando los beneficios de la IA en la gestión de riesgos, la experiencia del cliente y la eficiencia operativa. Esto plantearía la posibilidad de replicar los logros obtenidos en los BPA en un espectro más amplio de entidades financieras, contribuyendo a la evolución del ecosistema financiero a nivel regional.

Anexo I

El presente Anexo I complementa al punto el punto 4.4 de la propuesta de intervención, con un mayor detalle que justifica al diagrama de Gantt de cada etapa. A continuación, se muestra el detalle de las estimaciones realizadas, los datos que deben ingresarse a partir de estas estimaciones en el software encargado de administrar la planificación del proyecto y generar el respectivo Gantt.

Las siguientes tablas detallan las estimaciones de cada perfil, por cada etapa y cada tarea:

Tabla 8

Referencias Perfil – Columna titulada en tablas de estimaciones

Perfil	Denominación de columna en tabla de estimaciones (Tablas 9 a 16)
Project Manager	(A)
Arquitecto Cloud	(B)
Especialista en Data Governance	(C)
Data Analyst	(D)
Data Engineer	(E)
Data Scientist	(F)
Soporte IT/DevOps	(G)
Analista Funcional de Riesgo (Punto Focal 1)	(H)
Analista Funcional de Fraude (Punto Focal 2)	(I)
Responsable Área Comercial y Marketing (Punto Focal 3)	(J)
Tester	(K)
Documentador/Conformidad y Normativa	(L)

Nota. Elaboración Propia

Tabla 9*Estimación de Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos**Centralizado y Gobernanza de Datos*

Nombre de Tarea	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)	Totales
As Is													
Workshops	4	2	20	16	2							4	48
Identificación y definición de la situación actual	4	2	8	8	2		2					2	28
To Be													
Definición del modelo aspiracional	4	4	12	8	2	2	4						36
Definición ficha resumen de iniciativas	4				2			2	2	2		2	14
Conceptualización caso de uso	4	2	4	2		2		2	2	2		4	24
Identificación de dependencias	4	2	4	2			2					2	16
Categorización y priorización de iniciativas	4		4					2	2	2		2	16
Mapa de hoja de ruta	4		4									2	10
Implementación - Aplicación de Microsoft Fabric y Microsoft Purview													
Preparación del entorno y configuración inicial	4	20		2	2		20				2		50
Definir y asignar roles específicos	4	8	4	4			2				4	2	28
Implementación de herramientas de gestión de datos	4	8	8	8	4		16				4	2	54
Configuración de políticas y controles automáticos	4		4	24	4		2				4		42
Configuración de procesos de calidad de datos	4		8	16	2		2				4	2	38
Implementación de procesos de gestión de metadatos	4		8	32	2								46
Integración de los sistemas con la nueva estructura de gobierno	4	4	4	24	16		4						56
Pruebas de los procesos y validación de controles	4	2	2	8	2		2				24		44
Capacitación a usuarios clave en herramientas y procesos	4		8	8						2		4	26
Ajustes finales y puesta en producción	4	4	8	24	8		8				16		72
Revisión de resultados y optimización	4	2	2	2			2						12
Consolidación de Documentación	4	2	8	8	2							24	48

Nota. Elaboración Propia

Tabla 10*Estimación de Etapa 2: Implementación de BI*

Nombre de Tarea	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)	Totales
Configuración de Power BI dentro de Microsoft Fabric	4	2		2			4						12
Desarrollo y configuración de tableros en Power BI													
Conexión con Data Warehouse	4			4	2								10
Configuración de actualizaciones automáticas	4			8	2		2						16
Organización y clasificación de tableros	4	2		4			4						14
Configuración de permisos y seguridad	4	2	4				2						12
Desarrollo de Tableros Específicos													
Tablero de Segmentación de Clientes y Perfilado	4			32	8		2				12	4	62
Tablero de Análisis de Riesgo Crediticio	4			32	8		2				12	4	62
Capacitación y soporte para usuarios de BI													
Entrenamiento a usuarios clave	4			4				2		2			12
Creación de guías y manuales de uso	4		2	2								8	16

Nota. Elaboración Propia

Tabla 11*Estimación de Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio*

Nombre de Tarea	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)	Totales
Fase 1: Business Understanding													
Comprender el problema del riesgo crediticio	4			2		2		4					12
Definir objetivos de negocio para la gestión del riesgo	4					4		4					12
Definir objetivos específicos del proyecto de riesgo crediticio	4			2		4		4					14
Fase 2: Data Understanding													
Recopilar datos históricos y relevantes de riesgo crediticio	4		2	8	8	4		4					30
Describir y documentar las características de los datos de crédito	4			4	4	4		4				4	24
Explorar los datos para detectar patrones iniciales de riesgo	4			4	2	8		4					22
Verificar la calidad y consistencia de los datos recolectados	4		2	4	8	4	4	2					28
Fase 3: Data Preparation													
Seleccionar datos específicos para entrenamiento y prueba	4			4	4	12							24
Limpiar datos eliminando errores y valores atípicos	4			4	8	12							28
Crear nuevas variables derivadas para enriquecer el análisis	4			4	4	12							24
Integrar datos de múltiples fuentes	4	2	2		8	12	4						32
Formatear los datos para que sean compatibles con el modelo	4			4	4	12							24
Fase 4: Modeling													
Seleccionar técnicas de modelado adecuadas	4			4	4	12							24
Crear un modelo inicial de comprobación y aceptación	4			4	4	16							28
Generar diferentes versiones del modelo para evaluación	4			4	4	16							28
Evaluar los modelos en función de precisión y efectividad	4			4	4	16							28
Fase 5: Evaluation													
Revisar y ajustar el modelo seleccionado	4			4	4	12					8		32
Evaluar los resultados y ajustar según sea necesario	4			4	4	12		8			8		40

Fase 6: Deployment										
Entrenar y validar el modelo final en el entorno del BPA	4	2				8	16	4		34
Preparar y documentar el código fuente del modelo final	4					4	4		2	14
Documentar lecciones aprendidas	4		2	2	2	2		2	2	18
Revisión y ajuste final de la base de conocimiento	4	2	2	2	2	4			8	24
Capacitación a usuarios clave en el modelo de riesgo crediticio	4			2		4		2	2	14
Monitoreo inicial y ajustes del modelo en producción	4	2		8	4	32		2	8	62

Nota. Elaboración Propia

Tabla 12

Estimación de Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude

Nombre de Tarea	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)	Totales
Fase 1: Business Understanding													
Comprender el problema del fraude	4			2		2			4				12
Definir objetivos de negocio para la detección de fraude	4					4			4				12
Definir objetivos específicos del proyecto de detección de fraude	4			2		4			4				14
Fase 2: Data Understanding													
Recopilar datos históricos de fraude	4		2	8	8	4			4				30
Describir y documentar las características de los datos de fraude	4			4	4	4			4			2	22
Explorar los datos para detectar patrones de fraude	4			4	2	8			4				22
Verificar la calidad y consistencia de los datos de fraude	4		2	4	8	4	4		2				28
Fase 3: Data Preparation													
Seleccionar datos específicos para entrenamiento y prueba	4			4	4	12							24
Limpiar datos eliminando errores y valores atípicos	4			4	8	12							28

Crear nuevas variables derivadas para enriquecer el análisis	4			4	4	12					24
Integrar datos de múltiples fuentes	4	2	2		8	12	4				32
Formatear los datos para compatibilidad con el modelo	4			4	4	12					24
Fase 4: Modeling											
Seleccionar técnicas de modelado para fraude	4			4	4	16					28
Crear un modelo inicial de comprobación y aceptación	4			4	4	16					28
Generar versiones del modelo para evaluación	4			4	4	16					28
Evaluar los modelos en función de precisión y efectividad	4			4	4	16					28
Fase 5: Evaluation											
Revisar y ajustar el modelo seleccionado	4			4	4	12			8		32
Evaluar resultados para garantizar que cumpla con los objetivos de precisión y control de falsos positivos	4			4	4	12		8	8		40
Fase 6: Deployment											
Entrenar y validar el modelo final en el entorno del BPA	4	2			8	16	4				34
Preparar y documentar el código fuente del modelo final	4				4	4			2		14
Documentar lecciones aprendidas	4		2	2	2	2		2	2	2	18
Revisión y ajuste final de la base de conocimiento	4	2	2	2	2	4			8		24
Capacitación a usuarios clave en el modelo de fraude	4			2		4		2		2	14
Monitoreo inicial y ajustes del modelo en producción	4	2		8	4	32		2	8	2	62

Nota. Elaboración Propia

Tabla 13*Estimación de Etapa 5: Implementación de Modelo Predictivo de Churn (Abandono de Cliente)*

Nombre de Tarea	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)	Totales
Fase 1: Business Understanding													0
Comprender el problema del churn en el contexto del BPA	4			2		2				4			12
Definir objetivos de negocio para la retención de clientes	4					4				4			12
Definir objetivos específicos del proyecto de predicción de abandono	4			2		4				4			14
Fase 2: Data Understanding													0
Recopilar datos históricos de clientes y actividades (ej., interacciones, historial de compras)	4		2	8	8	4	4			4			34
Describir las características de los datos de comportamiento y satisfacción del cliente	4			4	4	4				4		2	22
Explorar patrones de comportamiento que indiquen intención de abandono	4			4		8				4			20
Verificar la calidad y consistencia de los datos de clientes	4		2	4	8	4	4						26
Fase 3: Data Preparation													0
Seleccionar variables clave para el análisis de churn (ej., frecuencia de interacción, valor de compra)	4			4	4	8							20
Limpiar datos, eliminando registros incompletos o inconsistentes	4			4	8	8							24
Crear variables adicionales, como la segmentación del cliente o puntajes de lealtad	4			4	4	8							20
Integrar datos de múltiples fuentes, incluyendo CRM y canales de soporte	4	2	2		8	8	4						28
Formatear los datos para que sean compatibles con el modelado predictivo	4			4	4	8							20
Fase 4: Modeling													0
Seleccionar técnicas de modelado para el análisis de churn (ej., regresión logística, redes neuronales)	4			4	4	12							24

Generar modelos iniciales de prueba con foco en la precisión y el recall	4			4	4	12					24
Evaluar múltiples versiones del modelo para elegir la más precisa	4			4	4	12					24
Optimizar el modelo para minimizar errores en la predicción de abandono	4			4	4	12					24
Fase 5: Evaluation											0
Revisar y ajustar el modelo seleccionado en función de la efectividad en retención	4			4	4	12					24
Evaluar resultados para garantizar que el modelo cumpla con los objetivos de precisión y alcance	4	2	2		8	12	4				32
Fase 6: Deployment											0
Implementar el modelo final en el entorno del BPA para análisis continuo	4				4	4			2		14
Preparar y documentar el código fuente del modelo final de churn	4		2			2			2		10
Documentar lecciones aprendidas y pasos a seguir para optimizar la retención de clientes	4		2	2	2	2		2	2	2	18
Revisión y ajuste final de la base de conocimiento	4	2	2	2	2	4				8	24
Capacitación a usuarios clave en el modelo de churn	4			2		4		2		2	14
Monitoreo inicial y ajustes del modelo en producción	4	2		8	4	32		2	8	2	62

Nota. Elaboración Propia

Seleccionar técnicas de modelado, como filtrado colaborativo o sistemas basados en contenido	4			4	4	12					24
Generar modelos de recomendación iniciales y probar diferentes enfoques	4			4	4	12					24
Evaluar los modelos en términos de precisión y relevancia de las recomendaciones	4			4	4	12					24
Optimizar el modelo para mejorar la personalización y reducir recomendaciones irrelevantes	4			4	4	12					24
Fase 5: Evaluation											
Revisar y ajustar el modelo de recomendación en función de la satisfacción del cliente	4			4	4	12					24
Evaluar la efectividad del modelo para asegurar que cumple los objetivos de personalización	4	2	2		8	12	4				32
Fase 6: Deployment											
Implementar el modelo final en el entorno del BPA para recomendaciones en tiempo real	4				4	4			2		14
Documentar el código fuente del modelo final de recomendación personalizada	4		2			2			2		10
Documentar las lecciones aprendidas y establecer un plan de mejora continua para la personalización	4		2	2	2	2		2	2	2	18
Revisión y ajuste final de la base de conocimiento	4	2	2	2	2	4			8		24
Capacitación a usuarios clave en el modelo de recomendación de productos	4			2		4		2		2	14
Monitoreo inicial y ajustes del modelo en producción	4	2		8	4	32		2	8	2	62

Nota. Elaboración Propia

Configurar la lógica de respuesta del chatbot para reconocer palabras clave y activar respuestas adecuadas desde la base de conocimiento	4	4		4		8	2		4	2	28
Realizar pruebas piloto en un entorno controlado para evaluar y ajustar la precisión del chatbot	4	2		4		8	4		16	4	42
Ajustar las reglas y ampliar la base de datos de respuestas en caso de discrepancias o errores detectados durante las pruebas	4			4		8			4		20
Despliegue y Monitoreo Inicial											0
Desplegar el chatbot gradualmente en los canales de atención al cliente del BPA	4		2	2	2	4	16		4		34
Monitorear en tiempo real el desempeño del chatbot, recolectando métricas de satisfacción del cliente y tiempos de respuesta	4	2				4	2		2	4	18
Realizar ajustes periódicos basados en la retroalimentación de los usuarios y las métricas recopiladas	4	2		4	2	16	2		8		38
Mantenimiento y Mejora Continua											0
Establecer un mecanismo de actualización de la base de conocimiento, integrando datos de interacciones recientes	4			2		4			4	8	22
Implementar un plan de mantenimiento periódico para optimizar la precisión y efectividad del chatbot a largo plazo	4	4		2	2	8	4		2		26

Nota. Elaboración Propia

Las horas distribuidas en las tablas detalladas anteriormente, se consolidan en los totales que se indican a continuación en la Tabla 16.

Tabla 16*Cuadro total de estimaciones por Etapa y Perfil*

ETAPA	Suma de Totales	(A)	(B)	(C)	(D)	(E)	(F)	(G)	(H)	(I)	(J)	(K)	(L)
1	708	80	62	120	196	50	4	66	6	6	8	58	52
2	216	36	6	6	88	20		16	2		2	24	16
3	620	96	8	10	78	94	236	12	40			26	20
4	622	96	8	10	78	94	240	12		40		26	18
5	546	96	8	14	74	88	190	16			30	10	20
6	546	96	8	14	74	88	190	16			30	10	20
7	464	64	48	6	60	22	114	54			30	48	18
Total general	3722	564	148	180	648	456	974	192	48	46	100	202	164

Nota. Elaboración Propia

A continuación, en la Tabla 17 se describe la carga de información que, a partir de este detalle de estimaciones debe ingresarse en un sistema que corresponda a la gestión de la planificación del Project, tal como puede ser Microsoft Project u otro producto similar. Cabe aclarar que los datos que deben ingresarse son los correspondientes a la columna Nombre de Tarea, Trabajo y Recurso. La columna Duración y Fecha se calculan automáticamente, considerando la fecha de inicio que se configuró previamente para el proyecto. Para esta propuesta de intervención se ha generado el Recurso “Equipo” representando a todo el equipo de acuerdo con lo justificado en el punto 4.4.1. Debe tenerse en cuenta que el BPA podrá cargar en dicha columna los recursos específicos que considere, a partir de conocer los perfiles y el criterio de asignación a configurar en la planificación. Por último, las filas resaltadas indican hitos del proyecto.

Tabla 17*Detalle complementario de datos a trasladar al sistema de gestión de planificación del proyecto*

ID	Nombre de Tarea	Trabajo	Duración	Comienzo	Fin	Predecesoras	Nombre de los Recursos
1	Proyecto Implementación IA en un BPA	3.722 horas	445 días?	02/01/2025	16/09/2026		
2	Etapas 1: Diagnóstico Inicial, Implementación de Repositorio de Datos	708 horas	88,5 días?	02/01/2025	06/05/2025		

Centralizado y Gobernanza de Datos							
3	As Is	76 horas	9,5 días?	02/01/2025	15/01/2025		
4	Workshops	48 horas	6 días?	02/01/2025	09/01/2025		Equipo
5	Identificación y definición de la situación actual	28 horas	3,5 días?	10/01/2025	15/01/2025	4	Equipo
6	To Be	116 horas	14,5 días?	15/01/2025	04/02/2025	3	
7	Definición del modelo aspiracional	36 horas	4,5 días?	15/01/2025	21/01/2025		Equipo
8	Definición ficha resumen de iniciativas	14 horas	1,75 días?	22/01/2025	23/01/2025	7	Equipo
9	Conceptualización caso de uso	24 horas	3 días?	23/01/2025	28/01/2025	8	Equipo
10	Identificación de dependencias	16 horas	2 días?	28/01/2025	30/01/2025	9	Equipo
11	Categorización y priorización de iniciativas	16 horas	2 días?	30/01/2025	03/02/2025	10	Equipo
12	Mapa de hoja de ruta	10 horas	1,25 días?	03/02/2025	04/02/2025	11	Equipo
13	Implementación - Aplicación de Microsoft Fabric y Microsoft Purview	516 horas	64,5 días?	05/02/2025	06/05/2025	6	
14	Preparación del entorno y configuración inicial	50 horas	6,25 días?	05/02/2025	13/02/2025		Equipo
15	Definir y asignar roles específicos	28 horas	3,5 días?	13/02/2025	18/02/2025	14	Equipo
16	Implementación de herramientas de gestión de datos	54 horas	6,75 días?	18/02/2025	27/02/2025	15	Equipo
17	Configuración de políticas y controles automáticos	42 horas	5,25 días?	27/02/2025	06/03/2025	16	Equipo
18	Configuración de procesos de calidad de datos	38 horas	4,75 días?	06/03/2025	13/03/2025	17	Equipo
19	Implementación de procesos de gestión de metadatos	46 horas	5,75 días?	13/03/2025	21/03/2025	18	Equipo
20	Integración de los sistemas con la nueva estructura de gobierno	56 horas	7 días?	21/03/2025	01/04/2025	19	Equipo
21	Pruebas de los procesos y validación de controles	44 horas	5,5 días?	01/04/2025	08/04/2025	20	Equipo
22	Capacitación a usuarios clave en herramientas y procesos	26 horas	3,25 días?	08/04/2025	11/04/2025	21	Equipo
23	Ajustes finales y puesta en producción	72 horas	9 días?	14/04/2025	24/04/2025	22	Equipo
24	Revisión de resultados y optimización	12 horas	1,5 días?	25/04/2025	28/04/2025	23	Equipo
25	Consolidación de Documentación	48 horas	6 días?	28/04/2025	06/05/2025	24	Equipo
26	Etapla 2: Implementación de BI	216 horas	27 días?	06/05/2025	12/06/2025	2	
27	Configuración de Power BI dentro de Microsoft Fabric	12 horas	1,5 días?	06/05/2025	07/05/2025		Equipo
28	Desarrollo y configuración de tableros en Power BI	52 horas	6,5 días?	08/05/2025	16/05/2025	27	

29	Conexión con Data Warehouse	10 horas	1,25 días?	08/05/2025	09/05/2025		Equipo
30	Configuración de actualizaciones automáticas	16 horas	2 días?	09/05/2025	13/05/2025	29	Equipo
31	Organización y clasificación de tableros	14 horas	1,75 días?	13/05/2025	14/05/2025	30	Equipo
32	Configuración de permisos y seguridad	12 horas	1,5 días?	15/05/2025	16/05/2025	31	Equipo
33	Desarrollo de Tableros Específicos	124 horas	15,5 días?	16/05/2025	06/06/2025	28	
34	Tablero de Segmentación de Clientes y Perfilado	62 horas	7,75 días?	16/05/2025	28/05/2025		Equipo
35	Tablero de Análisis de Riesgo Crediticio	62 horas	7,75 días?	28/05/2025	06/06/2025	34	Equipo
36	Capacitación y soporte para usuarios de visualizaciones BI	28 horas	3,5 días?	09/06/2025	12/06/2025	33	
37	Entrenamiento a usuarios clave	12 horas	1,5 días?	09/06/2025	10/06/2025		Equipo
38	Creación de guías y manuales de uso	16 horas	2 días?	10/06/2025	12/06/2025	37	Equipo
39	Etap 3: Implementación de Modelo Predictivo de Riesgo Crediticio	620 horas	68,5 días?	12/06/2025	16/09/2025	26	
40	Fase 1: Business Understanding	38 horas	4,75 días?	12/06/2025	19/06/2025		
41	Comprender el problema del riesgo crediticio	12 horas	1,5 días?	12/06/2025	13/06/2025		Equipo
42	Definir objetivos de negocio para la gestión del riesgo	12 horas	1,5 días?	16/06/2025	17/06/2025	41	Equipo
43	Definir objetivos específicos del proyecto de riesgo crediticio	14 horas	1,75 días?	17/06/2025	19/06/2025	42	Equipo
44	Fase 2: Data Understanding	104 horas	10,25 días?	19/06/2025	03/07/2025	40	
45	Recopilar datos históricos y relevantes de riesgo crediticio	30 horas	1 día?	19/06/2025	20/06/2025		
46	Describir y documentar las características de los datos de crédito	24 horas	3 días?	20/06/2025	25/06/2025	45	Equipo
47	Explorar los datos para detectar patrones iniciales de riesgo	22 horas	2,75 días?	25/06/2025	27/06/2025	46	Equipo
48	Verificar la calidad y consistencia de los datos recolectados	28 horas	3,5 días?	30/06/2025	03/07/2025	47	Equipo
49	Fase 3: Data Preparation	132 horas	16,5 días?	03/07/2025	25/07/2025	44	
50	Seleccionar datos específicos para entrenamiento y prueba	24 horas	3 días?	03/07/2025	08/07/2025		Equipo
51	Limpiar datos eliminando errores y valores atípicos	28 horas	3,5 días?	08/07/2025	11/07/2025	50	Equipo
52	Crear nuevas variables derivadas para enriquecer el análisis	24 horas	3 días?	14/07/2025	16/07/2025	51	Equipo
53	Integrar datos de múltiples fuentes (ej., datos	32 horas	4 días?	17/07/2025	22/07/2025	52	Equipo

	financieros y demográficos)						
54	Formatear los datos para que sean compatibles con el modelo	24 horas	3 días?	23/07/2025	25/07/2025	53	Equipo
55	Fase 4: Modeling	108 horas	13,5 días?	28/07/2025	14/08/2025	49	
56	Seleccionar técnicas de modelado adecuadas (ej., regresión logística, Random Forest)	24 horas	3 días?	28/07/2025	30/07/2025		Equipo
57	Crear un modelo inicial de comprobación y aceptación	28 horas	3,5 días?	31/07/2025	05/08/2025	56	Equipo
58	Generar diferentes versiones del modelo para evaluación	28 horas	3,5 días?	05/08/2025	08/08/2025	57	Equipo
59	Evaluar los modelos en función de precisión y efectividad para identificar el mejor	28 horas	3,5 días?	11/08/2025	14/08/2025	58	Equipo
60	Fase 5: Evaluation	72 horas	6 días?	14/08/2025	22/08/2025	55	
61	Revisar y ajustar el modelo seleccionado según criterios de desempeño	32 horas	1 día?	14/08/2025	15/08/2025		
62	Evaluar los resultados y ajustar según sea necesario	40 horas	5 días?	15/08/2025	22/08/2025	61	Equipo
63	Fase 6: Deployment	166 horas	17,5 días?	22/08/2025	16/09/2025	60	
64	Entrenar y validar el modelo final en el entorno del BPA	34 horas	1 día?	22/08/2025	25/08/2025		
65	Preparar y documentar el código fuente del modelo final	14 horas	1,75 días?	25/08/2025	27/08/2025	64	Equipo
66	Documentar lecciones aprendidas y formalizar los pasos para el uso del modelo	18 horas	2,25 días?	27/08/2025	29/08/2025	65	Equipo
67	Revisión y ajuste final de la base de conocimiento	24 horas	3 días?	29/08/2025	03/09/2025	66	Equipo
68	Capacitación a usuarios clave en el modelo de riesgo crediticio	14 horas	1,75 días?	03/09/2025	05/09/2025	67	Equipo
69	Monitoreo inicial y ajustes del modelo en producción	62 horas	7,75 días?	05/09/2025	16/09/2025	68	Equipo
70	Etapas 4: Implementación de Modelo Predictivo de Detección de Fraude	622 horas	77,75 días?	17/09/2025	02/01/2026	39	
71	Fase 1: Business Understanding	38 horas	4,75 días?	17/09/2025	23/09/2025		
72	Comprender el problema de fraude en transacciones financieras	12 horas	1,5 días?	17/09/2025	18/09/2025		Equipo
73	Definir objetivos de negocio enfocados en la reducción de actividades fraudulentas	12 horas	1,5 días?	18/09/2025	19/09/2025	72	Equipo
74	Definir objetivos específicos del proyecto de detección de fraude	14 horas	1,75 días?	22/09/2025	23/09/2025	73	Equipo

75	Fase 2: Data Understanding	102 horas	12,75 días?	23/09/2025	10/10/2025	71	
76	Recopilar datos históricos de transacciones, incluyendo etiquetados de fraude	30 horas	3,75 días?	23/09/2025	29/09/2025		Equipo
77	Describir las características de los datos, como transacciones inusuales y patrones atípicos	22 horas	2,75 días?	29/09/2025	02/10/2025	76	Equipo
78	Explorar los datos en busca de indicadores de fraude (ej., frecuencia, monto)	22 horas	2,75 días?	02/10/2025	06/10/2025	77	Equipo
79	Verificar y validar la calidad de los datos para evitar sesgos en el modelo	28 horas	3,5 días?	07/10/2025	10/10/2025	78	Equipo
80	Fase 3: Data Preparation	132 horas	16,5 días?	10/10/2025	03/11/2025	75	
81	Seleccionar datos relevantes para la detección de fraude (ej., frecuencia de transacción, geolocalización)	24 horas	3 días?	10/10/2025	15/10/2025		Equipo
82	Limpiar datos para eliminar inconsistencias o valores atípicos irrelevantes	28 horas	3,5 días?	15/10/2025	20/10/2025	81	Equipo
83	Crear variables adicionales, como puntuaciones de riesgo para actividades inusuales	24 horas	3 días?	21/10/2025	23/10/2025	82	Equipo
84	Integrar datos de múltiples fuentes (ej., datos de cliente, históricos de transacciones)	32 horas	4 días?	24/10/2025	29/10/2025	83	Equipo
85	Formatear los datos para que sean compatibles con las herramientas de modelado	24 horas	3 días?	30/10/2025	03/11/2025	84	Equipo
86	Fase 4: Modeling	112 horas	14 días?	04/11/2025	21/11/2025	80	
87	Seleccionar técnicas de modelado específicas para detección de fraude (ej., árboles de decisión, redes neuronales)	28 horas	3,5 días?	04/11/2025	07/11/2025		Equipo
88	Crear modelos iniciales de comprobación, con énfasis en la precisión para minimizar falsos positivos	28 horas	3,5 días?	07/11/2025	12/11/2025	87	Equipo
89	Generar y probar diferentes versiones del modelo para evaluar su rendimiento	28 horas	3,5 días?	13/11/2025	18/11/2025	88	Equipo
90	Evaluar los modelos utilizando métricas de precisión y sensibilidad para seleccionar el óptimo	28 horas	3,5 días?	18/11/2025	21/11/2025	89	Equipo
91	Fase 5: Evaluation	72 horas	9 días?	24/11/2025	04/12/2025	86	

92	Revisar el modelo seleccionado, ajustándolo en función de su efectividad en detectar fraudes	32 horas	4 días?	24/11/2025	27/11/2025		Equipo
93	Evaluar resultados para garantizar que cumpla con los objetivos de precisión y control de falsos positivos	40 horas	5 días?	28/11/2025	04/12/2025	92	Equipo
94	Fase 6: Deployment	166 horas	20,75 días?	05/12/2025	02/01/2026	91	
95	Entrenar y validar el modelo final en un entorno operativo para el BPA	34 horas	4,25 días?	05/12/2025	11/12/2025		Equipo
96	Preparar el código fuente del modelo final y documentar su uso	14 horas	1,75 días?	11/12/2025	12/12/2025	95	Equipo
97	Documentar las lecciones aprendidas y establecer pasos para el monitoreo continuo de fraude	18 horas	2,25 días?	15/12/2025	17/12/2025	96	Equipo
98	Revisión y ajuste final de la base de conocimiento	24 horas	3 días?	17/12/2025	22/12/2025	97	Equipo
99	Capacitación a usuarios clave en el modelo de fraude	14 horas	1,75 días?	22/12/2025	23/12/2025	98	Equipo
100	Monitoreo inicial y ajustes del modelo en producción	62 horas	7,75 días?	24/12/2025	02/01/2026	99	Equipo
101	Etap 5: Implementación de Modelo Predictivo de Abandono de Clientes	546 horas	68,25 días?	02/01/2026	08/04/2026	70	
102	Fase 1: Business Understanding	38 horas	4,75 días?	02/01/2026	09/01/2026		
103	Comprender el problema del churn en el contexto del BPA	12 horas	1,5 días?	02/01/2026	06/01/2026		Equipo
104	Definir objetivos de negocio para la retención de clientes	12 horas	1,5 días?	06/01/2026	07/01/2026	103	Equipo
105	Definir objetivos específicos del proyecto de predicción de abandono	14 horas	1,75 días?	07/01/2026	09/01/2026	104	Equipo
106	Fase 2: Data Understanding	102 horas	12,75 días?	09/01/2026	28/01/2026	102	
107	Recopilar datos históricos de clientes y actividades (ej., interacciones, historial de compras)	34 horas	4,25 días?	09/01/2026	15/01/2026		Equipo
108	Describir las características de los datos de comportamiento y satisfacción del cliente	22 horas	2,75 días?	15/01/2026	20/01/2026	107	Equipo
109	Explorar patrones de comportamiento que indiquen intención de abandono	20 horas	2,5 días?	20/01/2026	22/01/2026	108	Equipo
110	Verificar la calidad y consistencia de los datos de clientes	26 horas	3,25 días?	23/01/2026	28/01/2026	109	Equipo
111	Fase 3: Data Preparation	112 horas	14 días?	28/01/2026	17/02/2026	106	

112	Seleccionar variables clave para el análisis de churn (ej., frecuencia de interacción, valor de compra)	20 horas	2,5 días?	28/01/2026	30/01/2026		Equipo
113	Limpiar datos, eliminando registros incompletos o inconsistentes	24 horas	3 días?	30/01/2026	04/02/2026	112	Equipo
114	Crear variables adicionales, como la segmentación del cliente o puntajes de lealtad	20 horas	2,5 días?	04/02/2026	09/02/2026	113	Equipo
115	Integrar datos de múltiples fuentes, incluyendo CRM y canales de soporte	28 horas	3,5 días?	09/02/2026	12/02/2026	114	Equipo
116	Formatear los datos para que sean compatibles con el modelado predictivo	20 horas	2,5 días?	12/02/2026	17/02/2026	115	Equipo
117	Fase 4: Modeling	96 horas	12 días?	17/02/2026	05/03/2026	111	
118	Seleccionar técnicas de modelado para el análisis de churn (ej., regresión logística, redes neuronales)	24 horas	3 días?	17/02/2026	20/02/2026		Equipo
119	Generar modelos iniciales de prueba con foco en la precisión y el recall	24 horas	3 días?	20/02/2026	25/02/2026	118	Equipo
120	Evaluar múltiples versiones del modelo para elegir la más precisa	24 horas	3 días?	25/02/2026	02/03/2026	119	Equipo
121	Optimizar el modelo para minimizar errores en la predicción de abandono	24 horas	3 días?	02/03/2026	05/03/2026	120	Equipo
122	Fase 5: Evaluation	56 horas	7 días?	05/03/2026	16/03/2026	117	
123	Revisar y ajustar el modelo seleccionado en función de la efectividad en retención	24 horas	3 días?	05/03/2026	10/03/2026		Equipo
124	Evaluar resultados para garantizar que el modelo cumpla con los objetivos de precisión y alcance	32 horas	4 días?	10/03/2026	16/03/2026	123	Equipo
125	Fase 6: Deployment	142 horas	17,75 días?	16/03/2026	08/04/2026	122	
126	Implementar el modelo final en el entorno del BPA para análisis continuo	14 horas	1,75 días?	16/03/2026	17/03/2026		Equipo
127	Preparar y documentar el código fuente del modelo final de churn	10 horas	1,25 días?	18/03/2026	19/03/2026	126	Equipo
128	Documentar lecciones aprendidas y pasos a seguir para optimizar la retención de clientes	18 horas	2,25 días?	19/03/2026	23/03/2026	127	Equipo
129	Revisión y ajuste final de la base de conocimiento	24 horas	3 días?	23/03/2026	26/03/2026	128	Equipo
130	Capacitación a usuarios clave en el modelo de churn	14 horas	1,75 días?	26/03/2026	30/03/2026	129	Equipo
131	Monitoreo inicial y ajustes del modelo en producción	62 horas	7,75 días?	30/03/2026	08/04/2026	130	Equipo

132	Etapla 6: Implementación de Modelo Predictivo de Recomendación Personalizada de Productos Financieros	546 horas	68,25 días?	09/04/2026	14/07/2026	101	
133	Fase 1: Business Understanding	38 horas	4,75 días?	09/04/2026	15/04/2026		
134	Comprender la necesidad de recomendaciones personalizadas en el BPA	12 horas	1,5 días?	09/04/2026	10/04/2026		Equipo
135	Definir objetivos de negocio para aumentar la adopción de productos financieros	12 horas	1,5 días?	10/04/2026	13/04/2026	134	Equipo
136	Definir objetivos específicos del proyecto de recomendación personalizada	14 horas	1,75 días?	14/04/2026	15/04/2026	135	Equipo
137	Fase 2: Data Understanding	102 horas	12,75 días?	15/04/2026	04/05/2026	133	
138	Recopilar datos históricos de clientes y productos financieros adquiridos	34 horas	4,25 días?	15/04/2026	21/04/2026		Equipo
139	Describir las características de los datos de consumo de productos financieros	22 horas	2,75 días?	22/04/2026	24/04/2026	138	Equipo
140	Explorar patrones de preferencia y comportamiento de los clientes	20 horas	2,5 días?	24/04/2026	29/04/2026	139	Equipo
141	Verificar la calidad y consistencia de los datos para evitar sesgos	26 horas	3,25 días?	29/04/2026	04/05/2026	140	Equipo
142	Fase 3: Data Preparation	112 horas	14 días?	04/05/2026	22/05/2026	137	
143	Seleccionar variables clave, como el historial de compras y la segmentación de clientes	20 horas	2,5 días?	04/05/2026	06/05/2026		Equipo
144	Limpiar datos para eliminar errores y valores atípicos	24 horas	3 días?	07/05/2026	11/05/2026	143	Equipo
145	Crear nuevas variables, como el puntaje de afinidad del cliente hacia productos específicos	20 horas	2,5 días?	12/05/2026	14/05/2026	144	Equipo
146	Integrar datos de múltiples fuentes, incluyendo CRM y perfiles financieros	28 horas	3,5 días?	14/05/2026	19/05/2026	145	Equipo
147	Formatear los datos para que sean compatibles con las herramientas de modelado	20 horas	2,5 días?	20/05/2026	22/05/2026	146	Equipo
148	Fase 4: Modeling	96 horas	12 días?	22/05/2026	09/06/2026	142	
149	Seleccionar técnicas de modelado, como filtrado colaborativo o sistemas basados en contenido	24 horas	3 días?	22/05/2026	27/05/2026		Equipo
150	Generar modelos de recomendación iniciales y probar diferentes enfoques	24 horas	3 días?	27/05/2026	01/06/2026	149	Equipo

151	Evaluar los modelos en términos de precisión y relevancia de las recomendaciones	24 horas	3 días?	01/06/2026	04/06/2026	150	Equipo
152	Optimizar el modelo para mejorar la personalización y reducir recomendaciones irrelevantes	24 horas	3 días?	04/06/2026	09/06/2026	151	Equipo
153	Fase 5: Evaluation	56 horas	7 días?	09/06/2026	18/06/2026	148	
154	Revisar y ajustar el modelo de recomendación en función de la satisfacción del cliente	24 horas	3 días?	09/06/2026	12/06/2026		Equipo
155	Evaluar la efectividad del modelo para asegurar que cumple los objetivos de personalización	32 horas	4 días?	12/06/2026	18/06/2026	154	Equipo
156	Fase 6: Deployment	142 horas	17,75 días?	18/06/2026	14/07/2026	153	
157	Implementar el modelo final en el entorno del BPA para recomendaciones en tiempo real	14 horas	1,75 días?	18/06/2026	22/06/2026		Equipo
158	Documentar el código fuente del modelo final de recomendación personalizada	10 horas	1,25 días?	22/06/2026	23/06/2026	157	Equipo
159	Documentar las lecciones aprendidas y establecer un plan de mejora continua para la personalización	18 horas	2,25 días?	23/06/2026	25/06/2026	158	Equipo
160	Revisión y ajuste final de la base de conocimiento	24 horas	3 días?	25/06/2026	30/06/2026	159	Equipo
161	Capacitación a usuarios clave en el modelo de recomendación de productos	14 horas	1,75 días?	30/06/2026	02/07/2026	160	Equipo
162	Monitoreo inicial y ajustes del modelo en producción	62 horas	7,75 días?	02/07/2026	14/07/2026	161	Equipo
163	Etapla 7: Implementación de un Chatbot para Servicio de Atención al Cliente	464 horas	46,75 días?	14/07/2026	16/09/2026	132	
164	Planificación y Definición de Objetivos	54 horas	6,75 días?	14/07/2026	22/07/2026		
165	Definir los objetivos específicos del chatbot para atención básica de clientes, centrándose en preguntas frecuentes	18 horas	2,25 días?	14/07/2026	16/07/2026		Equipo
166	Identificar consultas iniciales de bajo nivel (ej., saldos, horarios de operación, ubicación de sucursales) en base a datos históricos de interacciones	18 horas	2,25 días?	16/07/2026	20/07/2026	165	Equipo
167	Desarrollar una base de conocimiento preliminar con preguntas y respuestas estándar	18 horas	2,25 días?	20/07/2026	22/07/2026	166	Equipo

168	Selección de Plataforma	94 horas	4,5 días?	23/07/2026	29/07/2026	164	
169	Evaluar herramientas open-source (ej., Rasa, Botpress) o servicios de Microsoft (ej., Azure AI Bot Service) según la capacidad técnica y financiera del BPA	66 horas	1 día?	23/07/2026	23/07/2026		
170	Asegurar la compatibilidad de la plataforma seleccionada con los canales digitales del BPA, como la web y la aplicación móvil	28 horas	3,5 días?	24/07/2026	29/07/2026	169	Equipo
171	Diseño y Estructuración de la Base de Conocimiento	88 horas	7 días?	29/07/2026	07/08/2026	168	
172	Curar y categorizar datos históricos de atención al cliente en un formato de preguntas y respuestas organizado	40 horas	1 día?	29/07/2026	30/07/2026		
173	Establecer un árbol de decisiones que permita al chatbot responder de manera eficiente y coherente	14 horas	1,75 días?	30/07/2026	03/08/2026	172	Equipo
174	Validar la precisión de las respuestas y adaptar el lenguaje de acuerdo con las consultas específicas de los clientes del BPA	34 horas	4,25 días?	03/08/2026	07/08/2026	173	Equipo
175	Configuración Técnica y Pruebas	90 horas	11,25 días?	07/08/2026	24/08/2026	171	
176	Configurar la lógica de respuesta del chatbot para reconocer palabras clave y activar respuestas adecuadas desde la base de conocimiento	28 horas	3,5 días?	07/08/2026	12/08/2026		Equipo
177	Realizar pruebas piloto en un entorno controlado para evaluar y ajustar la precisión del chatbot	42 horas	5,25 días?	13/08/2026	20/08/2026	176	Equipo
178	Ajustar las reglas y ampliar la base de datos de respuestas en caso de discrepancias o errores detectados durante las pruebas	20 horas	2,5 días?	20/08/2026	24/08/2026	177	Equipo
179	Despliegue y Monitoreo Inicial	90 horas	11,25 días?	24/08/2026	08/09/2026	175	
180	Desplegar el chatbot gradualmente en los canales de atención al cliente del BPA	34 horas	4,25 días?	24/08/2026	28/08/2026		Equipo
181	Monitorear en tiempo real el desempeño del chatbot, recolectando métricas de satisfacción del cliente y tiempos de respuesta	18 horas	2,25 días?	31/08/2026	02/09/2026	180	Equipo

182	Realizar ajustes periódicos basados en la retroalimentación de los usuarios y las métricas recopiladas	38 horas	4,75 días?	02/09/2026	08/09/2026	181	Equipo
183	Mantenimiento y Mejora Continua	48 horas	6 días?	09/09/2026	16/09/2026	179	
184	Establecer un mecanismo de actualización de la base de conocimiento, integrando datos de interacciones recientes	22 horas	2,75 días?	09/09/2026	11/09/2026		Equipo
185	Implementar un plan de mantenimiento periódico para optimizar la precisión y efectividad del chatbot a largo plazo	26 horas	3,25 días?	11/09/2026	16/09/2026	184	Equipo

Nota. Elaboración Propia

Acrónimos

ABAPPRA: Asociación de Bancos Públicos y Privados de la República Argentina.

ANN: Redes neuronales artificiales.

BCRA: Banco Central de la República Argentina.

BDT: Bagged Decision Trees

BI: Business Intelligence

BPA: Bancos Provinciales Argentinos.

ByMA: Bolsas y Mercados Argentinos.

CI/CD: Integración y delivery continuo.

CRISP-DM: Cross-Industry Standard Process for Data Mining.

CX: Experiencia del Cliente

ELT: Extract, Load and Transform

ETL: Extract, Transform and Load

FODA: Fortalezas, Oportunidades, Debilidades y Amenazas

GNN: Redes Neuronales de Grafos

IA: Inteligencia Artificial.

ML: Machine Learning

NLP: Procesamiento del Lenguaje Natural.

RFM: Recencia, Frecuencia y Valor Monetario

Referencias

- Adiguzel, Z., Aslan, B., y Sonmez Cakir, F. (2023). *Examination of the Strategic Vision of Banks in Digitalization and the Effects of Innovation on Performance and Artificial Intelligence Perception*. *Universidad & Empresa Journal*, 25(44), 1-29.
<https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.12023>
- Asociación de Bancos Públicos y Privados de la República Argentina. (8 de julio de 2024). *Conclusiones de la agenda de trabajo del 3° Congreso Federal Bancario ABAPRA*.
<https://abappra.org.ar/comunicados>
- Banco Central de la República Argentina. (2023). *Comunicación "A" 7724 - Requisitos mínimos para la gestión y control de los riesgos de tecnología y seguridad de la información*.
<https://www.bcra.gob.ar/pdfs/comytexord/A7724.pdf>
- Banco Central de la República Argentina. (s.f.-a). *Nómina de entidades financieras*. Banco Central de la República Argentina. Recuperado el 02 de septiembre de 2024
https://www.bcra.gob.ar/SistemasFinancierosYdePagos/Sistema_financiero_nomina_de_entidades.asp?bco=AAA00&tipo=1
- Banco Central de la República Argentina. (s.f.-b). *Nómina de entidades privadas*. Banco Central de la República Argentina. Recuperado el 02 de septiembre de 2024
https://www.bcra.gob.ar/SistemasFinancierosYdePagos/Sistema_financiero_nomina_de_entidades.asp?bco=AAA20&tipo=3
- Banco Central de la República Argentina. (s.f.-c). *Nómina de entidades públicas*. Banco Central de la República Argentina. Recuperado el 02 de septiembre de 2024
https://www.bcra.gob.ar/SistemasFinancierosYdePagos/Sistema_financiero_nomina_de_entidades.asp?bco=AAA10&tipo=2
- Banco Central de la República Argentina. (s.f.-d). *Ranking de activos por entidades financieras*. Banco Central de la República Argentina. Recuperado el 02 de septiembre de 2024
<https://www.bcra.gob.ar/SistemasFinancierosYdePagos/Activos.asp>

- Banco de la Provincia de Buenos Aires. (s.f.). *El asistente virtual de Banco Provincia ya resuelve el 70% de las consultas*. Banco Provincia. Recuperado el 10 de octubre de 2024
<https://www.bancoprovincia.com.ar/Noticias/MasNoticias/el-asistente-vitual-de-banco-provincia-ya-resuelve-el-70-de-las-consultas-1348>
- Banco de la República. (2019). *Modelo de Gobierno y Gestión de Información en el Banco de la República*. Centro de Estudios Monetarios Latinoamericanos (CEMLA).
<https://www.cemla.org/actividades/2019-final/2019-09-gestion-documental/2019-09-gestion-documental-banrep.pdf>
- BDO Argentina. (16 de marzo de 2023). *Análisis de los nuevos requisitos para la gestión y control de los riesgos: Com. A 7724 BCRA*. BDO Argentina
[https://www.bdoargentina.com/es-ar/novedades/2023/analisis-de-los-nuevos-requisitos-para-la-gestion-y-control-de-los-riesgos-\(com-a%E2%80%9D-7724-bcra\)](https://www.bdoargentina.com/es-ar/novedades/2023/analisis-de-los-nuevos-requisitos-para-la-gestion-y-control-de-los-riesgos-(com-a%E2%80%9D-7724-bcra))
- Botpress (s.f.). *La plataforma completa para agentes de IA*. Botpress. Recuperado el 02 de noviembre de 2024
<https://botpress.com/es>
- Brito, J. B. G., Bucco, G. B., Heldt, R. et al. (2024). *A framework to improve churn prediction performance in retail banking*. Financial Innovation, 10(17).
<https://doi.org/10.1186/s40854-023-00558-3>
- Broby, D. (2022). *Financial Machine Learning and Applications in the Banking Sector*. Journal of Financial Data Science, 2(4), 50-65.
<https://doi.org/10.1016/j.jfds.2022.01.007>
- Capurro Behr, V. (2023). *Sistema de Recomendación de Productos Bancarios utilizando Técnicas de Machine Learning y Deep Learning [MÁSTER EN BIG DATA Y ANÁLISIS AVANZADO DE DATOS]*. UNIVERSIDAD PONTIFICIA COMILLAS. ESCUELA TÉCNICA SUPERIOR DE INGENIERÍA (ICAI), Madrid - España.
<https://repositorio.comillas.edu/xmlui/handle/11531/78543>
- Castillo Abarca, Loreto, Vega Zepeda, Vianca, & Meneses Villegas, Claudio. (2020). *Alineando el ciclo de vida de un proyecto con un modelo de madurez BI: una propuesta para la etapa de análisis preliminar*. Ingeniare. Revista chilena de ingeniería, 28(4), 629-644.

<https://dx.doi.org/10.4067/S0718-33052020000400629>

Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., y Wirth, R. (2000). *CRISP-DM 1.0: Step-by-step data mining guide*. SPSS Inc.

Cuesta, C., Ruesta, M., Tuesta, D., y Urbiola, P. (2015). *La transformación digital de la banca*.
https://www.researchgate.net/profile/David-Tuesta/publication/291357543_La_transformacion_digital_de_la_banca/links/56a2cbf708aee24c585fce4/La-transformacion-digital-de-la-banca.pdf

Domingos, P. (2015). *The Master Algorithm: How the Quest for the Ultimate Learning Machine Will Remake Our World*. Basic Books.

Escobar, D. S. (2023). *Análisis de los cambios en los controles tecnológicos de la Comunicación A 7724 del BCRA en las entidades financieras. XXXV Jornadas Profesionales de Contabilidad, Auditoría y de Gestión y Costos*. CGCE, Buenos Aires.
<https://www.aacademica.org/escobards/71>

Fitzgerald, M., Kruschwitz, N., Bonnet, D., y Welch, M. (2013). *Embracing Digital Technology: A New Strategic Imperative*. MIT Sloan Management Review, 55(1), 1-13.
<https://emergenceweb.com/blog/wp-content/uploads/2013/10/embracing-digital-technology.pdf>

Gartner. (s.f.). *What Is Data and Analytics: Everything You Need to Know [What are core data and analytics techniques?]*. Gartner. Recuperado el 21 de septiembre de 2024
<https://www.gartner.com/en/topics/data-and-analytics>

Gervasoni, C. (2024). Federalismo regresivo: Tensiones entre distribución territorial e interpersonal del ingreso en la Argentina. *Estudios Digital*, (51), 13–27.
<https://doi.org/10.31050/re.vi51.44504>

González-Rossano, J., y Borja-González, A. M. (2023). *Crédito hipotecario: un modelo predictivo de discriminación de riesgo*. *Revista Venezolana de Gerencia: RVG*, ISSN-e 2477-9423, ISSN 1315-9984, Vol. 28, N°. 104, 2023, págs. 1566-1583
<https://dialnet.unirioja.es/servlet/articulo?codigo=9142789>

- Gutiérrez, N., Alvado, C., Fioretti, F. y Ielmini, S. (2022). *La baja utilización de tecnología blockchain e inteligencia artificial en los bancos argentinos*. In XVIII Simposio Regional de Investigación Contable (La Plata, 17 y 18 de noviembre de 2022). <https://sedici.unlp.edu.ar/handle/10915/149805>
- Helkkula, A., Kelleher, C., y Pihlstrom, M. (2012). *Characterizing value as an experience: Implications for researchers and managers*. Journal of Service Research, 15(1), 59–75. <https://doi.org/10.1177/1094670511426897>
- Homburg, C., Jozić, D., y Kuehnl, C. (2015). *Customer experience management: Toward implementing an evolving marketing concept*. Journal of the Academy of Marketing Science, 45(3), 377–401. <https://doi.org/10.1007/s11747-015-0460-7>
- Kokins, G., Straujuma, A., & Lapina, I. (2021). *The role of consumer and customer journeys in customer experience-driven and open innovation*. Journal of Open Innovation: Technology, Market, and Complexity, 7(3), 185. <https://doi.org/10.3390/joitmc7030185>
- Laxminarayana, K., Sikha, V., Somepalli, S (2024). *Finding the Right Data Analytics Platform for Your Enterprise*. International Journal of Science and Research (IJSR), ISSN: 2319-7064, Volume 13 Issue 7 <http://dx.doi.org/10.21275/SR24724111547>
- Lemon, K. N., y Verhoef, P. C. (2016). *Understanding customer experience throughout the customer journey*. Journal of Marketing, 80(6), 69–96. <https://doi.org/10.1509/jm.15.0420>
- Leiva Tames, L. A., Calvo Campos, B., y Alban Conejo Navarro, F. (2020). *Inteligencia artificial para la transformación digital en la toma de decisiones*. Revista de la Facultad de Ingenierías y Tecnologías de Información y Comunicación, 4(1), 15-20. <https://revistas.ulatina.ac.cr/index.php/tecnologiavital/article/view/337>

Li, T. y Song, J. (2024). *Deep Learning-Powered Financial Product Recommendation System in Banks: Integration of Transformer and Transfer Learning*. Journal of Organizational and End User Computing (JOEUC), 36(1), 1-29.

<http://doi.org/10.4018/JOEUC.343257>

Lugo, M. (2021). *La transformación digital como herramienta clave para mitigar los efectos de la pandemia y producir un impacto positivo en el desarrollo productivo de América Latina*. Propuesta Educativa, 2(56), 71-76.

<https://www.redalyc.org/journal/4030/403070017008/>

Mayor Lupo, J. (2023). *Aplicación de modelos predictivos para cálculo de probabilidad de churn en importante entidad bancaria*. [Tesis de maestría. Universidad Torcuato Di Tella]. Repositorio Digital Universidad Torcuato Di Tella

<https://repositorio.utdt.edu/handle/20.500.13098/12104>

Medina Reyes, J., Castro Pérez J., Aké, S. (2024). *Credit risk management analysis: An application of fuzzy theory to forecast the probability of default in a financial institution*. Contaduría y administración, ISSN 0186-1042, ISSN-e 2448-8410, Vol. 69, N°. 1, 2024, págs. 180-211

<https://dialnet.unirioja.es/servlet/articulo?codigo=9355294>

Mercado Libre. (s.f.). *Mercado Libre Argentina*. Recuperado el 26 de octubre de 2024

<https://www.mercadolibre.com.ar/>

Microsoft. (s.f.-a). *Govern data in Microsoft Fabric with Purview*. Microsoft Learn. Recuperado el 26 de octubre de 2024

<https://learn.microsoft.com/en-us/training/modules/fabric-data-governance-purview/>

Microsoft. (s.f.-b). *Implement a data warehouse with Microsoft Fabric*. Microsoft Learn. Recuperado el 26 de octubre de 2024

<https://learn.microsoft.com/en-us/training/paths/work-with-data-warehouses-using-microsoft-fabric/>

Microsoft. (s.f.-c). *Microsoft Fabric documentation*. Microsoft Learn. Recuperado el 26 de octubre de 2024

<https://learn.microsoft.com/en-us/fabric/>

Microsoft. (s.f.-d). *Microsoft Fabric governance documentation*. Microsoft Learn. Recuperado el 26 de octubre de 2024

<https://learn.microsoft.com/en-us/fabric/governance/>

Microsoft. (s.f.-e). *Microsoft Purview*. Microsoft Learn. Recuperado el 27 de octubre de 2024

<https://learn.microsoft.com/en-us/purview/>

Microsoft. (s.f.-f). *Tutorial: Fabric para usuarios de Power BI*. Microsoft Learn. Recuperado el 27 de octubre de 2024

<https://learn.microsoft.com/es-es/power-bi/fundamentals/fabric-get-started>

Microsoft. (s.f.-g). *Pricing calculator*. Microsoft Azure. Recuperado el 10 de noviembre de 2024

<https://azure.microsoft.com/en-us/pricing/calculator/>

Microsoft. (s.f.-h). *Azure AI Bot Service*. Microsoft Corporation. Recuperado el 02 de noviembre de 2024

<https://azure.microsoft.com/en-us/products/ai-services/ai-bot-service/>

Microsoft. (s.f.-i). *Power BI: Descubre cómo tomar decisiones informadas*. Microsoft. Recuperado el 10 de noviembre de 2024

<https://www.microsoft.com/es-es/power-platform/products/power-bi>

Mytnyk, B., Tkachyk, O., Shakhovska, N., Fedushko, S. y Syerov, Y. (2023). *Application of artificial intelligence for fraudulent banking operations recognition*. Big Data and Cognitive Computing, 7(2), 93.

<https://doi.org/10.3390/bdcc7020093>

Noreen, U., Shafique, A., Ahmed, Z. y Ashfaq, M. (2023). *Banking 4.0: Artificial Intelligence (AI) in Banking Industry & Consumer's Perspective*. Sustainability, 15(4), 3682.

<https://doi.org/10.3390/su15043682>

Noriega, J.P., Rivera, L.A., Herrera, J.A. *Machine Learning for Credit Risk Prediction: A Systematic Literature Review*. Data 2023, 8, 169.

<https://doi.org/10.3390/data8110169>

- Olujimi, P.A., Ade-Ibijola, A. *NLP techniques for automating responses to customer queries: a systematic review*. *Discov Artif Intell* 3, 20 (2023).
<https://doi.org/10.1007/s44163-023-00065-5>
- Rasa. (s.f.). *Rasa: Open source conversational AI*. Rasa Technologies Inc. Recuperado el 02 de noviembre de 2024
<https://rasa.com/>
- Reyes-Sarmiento, T. P. (2022). *Modelo de optimización de procesos bancarios o financieros para agilizar procedimientos relacionados mediante Business Intelligence*. Universidad Politécnica Salesiana.
<http://dspace.ups.edu.ec/handle/123456789/23337>
- Rivera, M. M., Toro, E., Vidaurre, W. E., Urbina, M. F., & Chapoñan, E. (2021). *Gestión de riesgo crediticio para afrontar la morosidad bancaria*. *TZHOECOEN*, 13(1), 70-78.
<https://doi.org/10.26495/tzh.v13i1.1873>
- Rojas Ahumada, K. A., López Zavaleta, V. y Mendoza de los Santos, A. C. (2023). *El impacto de la Inteligencia Artificial en la mejora de la atención al cliente: Una revisión sistémica*. *Innovación Y Software*, 4(2), 201-222.
<https://doi.org/10.48168/innosoft.s12.a90>
- Russell, S., Norvig, P. (2010). *Artificial Intelligence: A Modern Approach* (3ª ed.). Pearson.
- Sohail O, Sharma P, Shailender S, Shawn M, Kairavi B. (2021). *AI Transforming the Future of Banking*. Deloitte.
https://www2.deloitte.com/content/dam/Deloitte/us/Documents/process-and-operations/us-ai-transforming-future-of-banking.pdf?trk=public_post_comment-text
- Tames, L. A. L., Campos, B. C., y Navarro, F. A. C. (2020). *Inteligencia artificial para la transformación digital en toma de decisiones*. *Tecnología Vital*, 1(7).
<https://revistas.ulatina.ac.cr/index.php/tecnologiavital/article/view/337>

Tana Pilacuán, A. I., y Viteri Orozco, A. C. (2024). *Creación de un modelo predictivo basado en inteligencia artificial para la evaluación de riesgo crediticio* (Master's thesis, Quito: Universidad de las Américas, 2024).

<https://dspace.udla.edu.ec/bitstream/33000/16606/1/UDLA-EC-TMINCD-2024-16.pdf>

Tekouabou, S. C. K., Gherghina, Ș. C., Touluni, H., Mata, P. N., & Martins, J. M. (2022). *Towards explainable Machine Learning for bank churn prediction using data balancing and ensemble-based methods*. *Mathematics*, 10(14), 2379.

<https://doi.org/10.3390/math10142379>

Toluwani B. (2024) *AI-Based Fraud Detection in Banking and Financial Services*. *International Journal of Enhanced Research in Science, Technology & Engineering* ISSN: 2319-7463, Vol. 13 Issue 7, July-2024, Impact Factor: 8.375

https://erpublications.com/uploaded_files/download/toluwani-babatunde-adeyeri-usa_yYsRZ.pdf

Vanini, P., Rossi, S., Zvizdic, E. y Domenig, T. *Online payment fraud: from anomaly detection to risk management*. *Financ Innov* 9, 66 (2023).

<https://doi.org/10.1186/s40854-023-00470-w>

Verhoef, P.C., Broekhuizen, T.L., Bart, Y., Bhattacharya, A., Qi Dong, J., Fabian, N.E., y Haenlein, M. (2021). *Digital transformation: A multidisciplinary reflection and research agenda*. *Journal of Business Research*.

<https://doi.org/10.1016/j.jbusres.2019.09.022>

Vizuite Chancay, J. L. y Ayala Bolaños, M. (2024). *Uso de Power BI en la toma de decisiones empresariales*. *Revista Latinoamericana de Investigación Social*, 7(1), 1-25.

<https://repositorio.lasalle.mx/handle/lasalle/2894>

Zapata Yáñez, R (2024). *Modelos predictivos para la gestión de riesgo de crédito: aplicación de Random Forest y árboles de decisión (Tesis de maestría)*. Universidad de las Américas, Quito.

<https://dspace.udla.edu.ec/handle/33000/16218>