

Facundo Villanueva

fvillanueva@gyf.com.ar

GYF Inteligencia Digital y UAI- Universidad Abierta Interamericana

APLICACIÓN DE INTELIGENCIA ARTIFICIAL EN EL ECOSISTEMA DE BANCOS PROVINCIALES ARGENTINOS

Resumen

El presente artículo resulta una propuesta de intervención en el campo profesional centrada en la aplicación de Inteligencia Artificial (IA) en el Ecosistema de Bancos Provinciales Argentinos (BPA). Se trata de 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 y la detección del fraude.

Finalmente, se elaboró un plan de desarrollo que facilita una transición ordenada hacia el uso de IA, mejorando la eficiencia operativa y fomentando una innovación tecnológica para este ecosistema. Palabras clave: bancos provinciales argentinos, industria financiera, inteligencia artificial

APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE ARGENTINEAN PROVINCIAL BANKS ECOSYSTEM

Abstract

This article is a proposal for intervention in the professional field focused on the application of Artificial Intelligence (AI) in the Ecosystem of Argentinean Provincial Banks (BPA). It is a phased development plan of a software system that allows these entities, through a gradual implementation, to incorporate AI in credit risk management and fraud detection.

Finally, a development plan was drawn up to facilitate an orderly transition to the use of AI, improving operational efficiency and fostering technological innovation for this ecosystem.

Keywords: Argentine provincial banks, financial industry, artificial intelligence

1. Planteo del problema

Los BPA deben competir con instituciones financieras locales, con grandes bancos y con Fintech que ofrecen servicios innovadores y altamente personalizados. En este contexto, es necesario e inevitable que estas entidades deban contar con una forma de soportarse en

tecnologías como IA, fundamentales para mantenerse competitivos y de este modo poder progresar.

El desafío que se plantea en la presente investigación es cómo los BPA pueden mejorar su eficiencia operativa y calidad de servicio reforzando su competitividad, mediante la

implementación de tecnologías de Inteligencia Artificial (IA).

2. Marco institucional

El marco institucional de este trabajo se centra 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. Si bien se desconoce si alguna ya se encuentra embarcada en casos 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 resultar útil, ya sea para realizar ajustes, para alinear estrategias, revisarlas o directamente considerar en forma completa el plan propuesto.

Cabe aclarar que, para el presente 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 esta entidad posee una infraestructura tecnológica de gran escala debido a su tamaño según nivel de activos informado por el BCRA (s.f.)

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.

3. Objetivo general

El objetivo general del presente 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 y detección de fraudes y su comportamiento, dirigido a los Bancos Provinciales Argentinos.

3.1 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 y detección de fraudes 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.

4. 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 a la mejora en la calidad del servicio 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.

5. Marco teórico

5.1 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.).

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.

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 et al. (2023), indican 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 relación, los BPA, con menores recursos frente a otras entidades financieras (BCRA, s.f.), se ven forzados a adoptar estas tecnologías para poder ofrecer servicios competitivos y optimizar sus procesos internos.

5.2 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 integren 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 ciber incidentes (Escobar, 2023, p. 8).

5.3 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.

Existen ciertas características del federalismo que pueden contribuir a resultados regresivos. Tres de estas 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 3er Congreso Federal Bancario de la Asociación de Bancos Públicos y Privados de la República Argentina (ABAPRA), 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 Fintech 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 [ABAPRA], 2024). Asimismo, se indica en las conclusiones que *“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.”* (ABAPRA, 2024, párrafo 1).

5.4 IA aplicada en gestión de riesgo crediticio

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.

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.

5.5 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.

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.

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).

5.6 Inteligencia Artificial

5.6.1 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).

5.7 Concepto de aprendizaje automático o Machine Learning

El 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.

5.8 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 Yáñez (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 Yáñez, 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.

5.9 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 puedan 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
- Comprensión de los Datos
- Preparación de los Datos
- Modelado
- Evaluación
- Despliegue

6. 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).

6.1 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 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).

7. Consideraciones previas a la implementación de IA para los Bancos Provinciales Argentinos

Los conceptos fundamentales sobre IA, ML y los casos de aplicación abordados en esta propuesta de intervención son indispensables, pero los BPA deben complementarlos con otras temáticas 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.

8. En 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).

9. Propuesta de intervención

Se propone el diseño de un plan de implementación por etapas de un sistema de software que utiliza modelos predictivos de inteligencia artificial (IA) para gestionar el riesgo crediticio y detectar fraudes, 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 hace mención de cada etapa.

- Etapa 1: Diagnóstico Inicial, Implementación de Repositorio de Datos Centralizado y Gobernanza de Datos
- Evaluación de la Infraestructura y Capacidad Organizacional (As Is)
 - Definición del Modelo de Gobernanza de Datos (To Be)
 - Aplicación de Microsoft Fabric y Microsoft Purview (Implementación)
- Etapa 2: Implementación de BI

- Evaluación de la Infraestructura y Capacidad Organizacional (As Is)
- Definición del Modelo de Gobernanza de Datos (To Be)
- Aplicación de Microsoft Fabric y Microsoft Purview (Implementación)
- Etapa 3: Implementación de Modelo Predictivo de Riesgo Crediticio
- Etapa 4: Implementación de Modelo Predictivo de Detección de Fraude

Recursos Humanos

- Project Manager
- Arquitecto Cloud
- Especialista en Data Governance
- Data Analyst
- Data Engineer
- Data Scientist
- Soporte IT y DevOps
- Punto Focal de Negocio o Product Owner (Banco)
- Tester o QA (Quality Assurance)
- Perfil de Documentación o Especialista en Conformidad y Normativa (opcional)

Recursos Tecnológicos

- Microsoft Fabric
- Microsoft Purview
- Servidor Linux para Data Lake
- Power BI Pro
- Recursos de Microsoft Azure para Modelos de IA (basados en ML)
- Puestos de Trabajo (notebooks)
- Licencias de Software Complementario

10. 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 pautada para el proyecto es de unos 12 (doce) 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 y 4 o sume más recursos para paralelizar ciertas tareas, el tiempo podría ser menor.

11. 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 algunos factores externos, 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.

11.1 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 afectaría 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 mostrarse reticente 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.

11.2 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 podrían tener bases de datos pertenecientes a los sistemas terceros de los cuales se deben 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.

11.3 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.

11.4 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 implicaría 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.

12. Matriz FODA de la propuesta de intervención

A modo de conclusión para la evaluación del proyecto, se presenta un análisis FODA (Fortalezas, Oportunidades, Debilidades y Amenazas). Desde esta perspectiva, se efectuó 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 Fintech 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 ABAPRA).

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 dicha plataforma.

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.

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 Fintech. Las Fintech 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.

13. 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.

1. Referencias bibliográficas

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>

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.uosario.edu.u.co/empresa/a.12023>

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.). *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>

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>

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.

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.academica.org/escobards/71>

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>

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>

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>

Villanueva, F. (2024). *Aplicación de inteligencia artificial en el ecosistema de bancos provinciales argentinos* (Tesis de licenciatura, Universidad Abierta Interamericana).

<https://repositorio.uai.edu.ar/items/e306fb1a-8d1a-43a6-a9bb-8a6e9b50a171>

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>