



**Abordando la fuga de clientes en la banca: un enfoque inteligente con tecnología
IA**

Abdón Felipe Vargas Rodríguez

Universidad Ean

Facultad de Ingeniería

Maestría en Inteligencia de negocios

Bogotá, Colombia

22/03/2025

**Abordando la fuga de clientes en la banca: un enfoque inteligente con tecnología
IA**

Abdón Felipe Vargas Rodríguez

Trabajo de grado presentado como requisito para optar al título de:

Magister en Inteligencia de Negocios

Director (a):

Luis Armando Cobo Campo

Modalidad:

Monografía

Universidad Ean

Facultad de Ingeniería

Maestría en Inteligencia de negocios

Bogotá, Colombia

22/03/2025

Nota de aceptación:

Firma del jurado

Firma del jurado

Firma del director del trabajo de grado

Bogotá, 22/03/2025

A mi familia, mi faro en la oscuridad, por siempre animarme a explorar nuevos horizontes. Y a mi novia, mi compañera de vida, por sus palabras de aliento que me impulsaron a alcanzar esta meta.

Agradecimientos

Agradezco profundamente a todas las personas que formaron parte de este proceso. Sus conocimientos y experiencia fueron mi brújula en este viaje. A mis seres queridos, por creer en mí y crear un ambiente propicio para el estudio y la superación. Este logro es también un reflejo de su apoyo y cariño.

Resumen

La presente monografía que se realiza como requisito de grado en la maestría de Inteligencia de Negocios de la Universidad Ean busca comprender la fuga de clientes en el sector bancario colombiano, con énfasis en la necesidad de implementar tecnologías de inteligencia artificial (IA) para mejorar la retención de clientes. Los antecedentes indican que la competencia en el sector financiero ha aumentado, lo que ha generado una mayor preocupación por la satisfacción y fidelización de los clientes.

El objetivo principal del estudio es proponer estrategias basadas en IA que permitan a las entidades bancarias reducir la tasa de abandono de clientes. Para alcanzar este objetivo se empleó una metodología que combina el análisis de información secundaria, encuestas dirigidas a clientes y modelos predictivos basados en técnicas avanzadas de inteligencia artificial, con el fin de evaluar tanto la percepción de los clientes sobre las soluciones tecnológica, como los factores determinantes del abandono.

Los resultados principales revelan que los clientes valoran positivamente la implementación de IA en aspectos como la personalización de servicios y en la mejora de la experiencia del usuario. Así mismo, los modelos predictivos desarrollados identificaron variables asociadas al abandono como la edad y el género, lo que permitió definir una serie de acciones estratégicas específicas para retener clientes con mayor riesgo de deserción. Las conclusiones sugieren que al adoptar estas tecnologías, los bancos pueden no solo mejorar la satisfacción del cliente, sino también reducir la tasa de abandono, fortalecer la fidelización y atraer nuevos clientes, consolidando así su posición en un mercado altamente competitivo.

Palabras clave: Inteligencia artificial, fidelización, percepción, tasa de abandono, satisfacción, modelos predictivos.

Abstract

This monograph, conducted as a graduation requirement for the Master's Degree in Business Intelligence at Ean University, seeks to understand customer churn in the Colombian banking sector, emphasizing the need to implement artificial intelligence (AI) technologies to improve customer retention. The background indicates that competition in the financial sector has increased, leading to greater concern regarding customer satisfaction and loyalty.

The main objective of this study is to propose AI-based strategies enabling banking institutions to reduce customer churn rates. To achieve this objective, a methodology combining secondary data analysis, customer surveys, and predictive models based on advanced artificial intelligence techniques was employed, evaluating both customer perceptions of technological solutions and factors influencing churn.

The main findings reveal that customers positively value AI implementation in aspects such as service personalization and enhanced user experience. Additionally, the predictive models developed identified variables associated with churn, such as age and gender, allowing the definition of specific strategic actions to retain customers with higher risk of attrition. The conclusions suggest that by adopting these technologies, banks can not only improve customer satisfaction but effectively reduce churn rates, strengthen customer loyalty, and attract new clients, thereby consolidating their position in a highly competitive market.

Keywords: Artificial Intelligence, loyalty, perception, churn rate, satisfaction, predictive models.

| | |
|---|----|
| ABORDANDO LA FUGA DE CLIENTES EN LA BANCA: UN ENFOQUE INTELIGENTE CON TECNOLOGÍA IA | 12 |
|---|----|

Contenido

| | |
|--|-----------|
| Lista de Figuras | 13 |
| Lista de Tablas | 14 |
| Introducción | 15 |
| Objetivos | 18 |
| <i>Objetivo general</i> | 18 |
| <i>Objetivos específicos</i> | 18 |
| Justificación | 19 |
| Marco Teórico | 21 |
| Hipótesis | 27 |
| Variables | 28 |
| Metodología | 31 |
| <i>Enfoque y alcance de la investigación</i> | 31 |
| <i>Población:</i> | 32 |
| <i>Muestra:</i> | 32 |
| <i>Instrumentos:</i> | 33 |
| <i>Técnicas para el análisis de información:</i> | 34 |
| Trabajo de Campo | 35 |
| <i>Procesamiento de los datos cualitativos:</i> | 35 |
| <i>Procesamiento de los datos cuantitativos:</i> | 39 |

| | |
|---|-----------|
| ABORDANDO LA FUGA DE CLIENTES EN LA BANCA: UN ENFOQUE INTELIGENTE CON TECNOLOGÍA IA | 13 |
| Conclusiones y Trabajo Futuro | 69 |
| Referencias | 74 |
| Anexos: | 78 |
| <i>A.Anexo. Entrevista sobre IA y retención de clientes</i> | 78 |
| <i>B.Anexo. Formato de encuestas grupo focal uso de IA.</i> | 80 |

Lista de Figuras

| | |
|--|----|
| Figura 1. <i>Análisis nube de palabras en Atlas.ti con investigaciones relacionados a la monografía.</i> | 37 |
| Figura 2. <i>Diagrama de frecuencia palabras según investigaciones seleccionadas.</i> | 38 |
| Figura 3. <i>Diagrama de redes semánticas.</i> | 39 |
| Figura 4. <i>Código en Python para conversión de variables a categóricas y creación de matriz de correlación.</i> | 41 |
| Figura 5. <i>Matriz de correlación variables seleccionadas.</i> | 41 |
| Figura 6. <i>Código en Python para entrenamiento de datos.</i> | 42 |
| Figura 7. <i>Análisis random forest para variables características y variable predictora.</i> | 43 |
| Figura 8. <i>Código en Python para entrenamiento de datos Redes Neuronales.</i> | 44 |
| Figura 9. <i>Resultados matriz de confusión, evaluación del modelo: pérdida y precisión.</i> | 45 |
| Figura 10. <i>Análisis descriptivos y exploratorios del dataset.</i> | 49 |
| Figura 11. <i>Matriz de correlación de variables seleccionadas.</i> | 50 |
| Figura 12. <i>Grafico precisión del modelo redes neuronales.</i> | 51 |
| Figura 13. <i>Resultados de entrenamiento redes neuronales.</i> | 53 |
| Figura 14. <i>Diagrama de barras según datos encuestas familiaridad con la IA.</i> | 55 |

| | |
|--|----|
| ABORDANDO LA FUGA DE CLIENTES EN LA BANCA: UN ENFOQUE INTELIGENTE CON TECNOLOGÍA IA | 14 |
| Figura 15. <i>Diagrama de barras según datos de encuesta sobre la confianza en recomendaciones de IA.</i> | 56 |
| Figura 16. <i>Diagrama de barras según datos encuesta sobre mejoras en la experiencia Bancaria de los clientes.</i> | 57 |
| Figura 17. <i>Top 5 de ventajas y desventajas más representativas para la población encuestada.</i> | 59 |
| Figura 18. <i>Diagrama de cajas y bigotes que representa el nivel de confianza en IA por género.</i> | 60 |
| Figura 19. <i>Relación entre la Edad y el nivel de confianza de los clientes en la IA.</i> | 60 |
| Figura 20. <i>Relación entre el nivel de confianza en IA por nivel educativo.</i> | 61 |

Lista de Tablas

| | Pág. |
|--|------|
| Tabla 1. <i>Criterios de factibilidad del proyecto.</i> | 20 |
| Tabla 2. <i>Definiciones y clasificación de variables de estudio.</i> | 28 |
| Tabla 3. <i>Descripción de variables dataset churn_rate</i> | 40 |
| Tabla 4. <i>Descripción de variables dataset anonimizado</i> | 48 |

Introducción

Tema de Investigación:

El presente trabajo, titulado “*Abordando la fuga de clientes en la banca: un enfoque inteligente con tecnología IA*” realizado dentro del programa de Maestría en Inteligencia de Negocios de la Universidad Ean.

Antecedentes:

El sector bancario colombiano ha experimentado un crecimiento considerable en los últimos años, impulsado por la digitalización y la competencia de nuevas instituciones financieras. No obstante, este entorno competitivo ha aumentado la preocupación por la retención de clientes, lo que ha llevado a las entidades bancarias a explorar soluciones tecnológicas avanzadas para comprender mejor las necesidades y expectativas de sus usuarios. La fuga de clientes se ha convertido en una de las principales inquietudes de la banca en Colombia, según estudios de Customer Index Value (Customer Index Value (CIV), s.f.) empresa que creó el primer índice de cercanía emocional del cliente (CIVeX). En 2019, los bancos tradicionales obtuvieron una calificación de 73 sobre 100 en este índice, reflejando factores como la insatisfacción con el servicio y la creciente oferta de productos financieros personalizados por parte de la competencia.

Dado el impacto significativo que tiene la fuga de clientes en la rentabilidad del sector, resulta crucial explorar soluciones innovadoras como la inteligencia artificial (IA) para enfrentar este desafío en el contexto colombiano. Esta monografía busca contribuir a la literatura existente analizando cómo la IA no solo puede prevenir la fuga de clientes, sino también optimizar la relación entre bancos y clientes.

Planteamiento del Problema:

Se estima que el sector bancario tiene el potencial de aumentar sus ingresos entre 200 y 340 mil millones de dólares anualmente mediante la aplicación de la Inteligencia Artificial (IA), según cifras del (McKinsey Global Institute, 2024). La IA ha cobrado relevancia en diversos sectores económicos, los datos obtenidos de una encuesta sobre tendencias tecnológicas realizada en 2023 por la empresa líder en infraestructura digital: Equinix, muestran un crecimiento significativo en la adopción de la IA en Colombia. Según esta encuesta, un alto porcentaje de empresas colombianas ya están utilizando esta tecnología en áreas clave: el 89% en operaciones de Tecnologías de la Información (TI), el 88% en el sector de comercio electrónico (e-commerce), y el 87% en temas relacionados con ciberseguridad (Nasdaq: EQIX, 2023).

En particular, desde 2011 hasta 2021, el sistema financiero colombiano ha presenciado la incorporación de entidades autorizadas por la Superintendencia Financiera de Colombia (SFC), las cuales basan sus modelos de negocio en el uso intensivo de tecnología, convirtiéndose así en competidores directos de la banca tradicional. Actualmente, en el sistema de seguro de depósitos administrado por Fogafín, hay 60 entidades financieras inscritas: 30 bancos, 6 corporaciones financieras, 16 compañías de financiamiento y 8 sociedades especializadas (Fondo de Garantías de Instituciones Financieras). Este crecimiento en la entrada de nuevas entidades en el sector financiero ha obligado a la banca colombiana a agilizar sus procesos de transformación y adaptarse rápidamente a las nuevas condiciones del mercado. Como resultado, estas instituciones están adoptando activamente tecnologías como la Inteligencia Artificial para el scoring de créditos, sistemas antifraude, atención al cliente mediante chatbots y clasificación automática de quejas. Al mismo tiempo, están incorporando la robótica para automatizar tareas operativas y permitiendo al talento humano enfocarse en labores más especializadas y estratégicas. (Castaño Gutierrez, 2021).

Sumado a lo anterior, en el año 2021 los resultados de una encuesta aplicada por el Centro Nacional de Consultoría a 5861 personas en distintas partes de Colombia afirmaron que los usuarios preferían manejar dinero en efectivo entre un (90%-80%) para los pagos mensuales de gastos internos como: servicios públicos, alimentos, vestuario, transporte, entre otros. Posteriormente (Superfinanciera, 2023), afirma que el mayor porcentaje en el uso de canales lo obtuvo el internet con el 52%, mientras que el uso de las oficinas registra un 23% y las aplicaciones un 8% aproximadamente para el año 2023, con un total acumulado de \$9.960 billones en transacciones hasta ese momento.

De ahí que la mayor parte del dinero recibido por los usuarios a través de transacciones salga casi inmediatamente para el pago de las obligaciones mencionadas anteriormente, quedando así un margen mínimo de recursos en los bancos. Esta situación afecta en gran parte el pasivo de estas entidades y limita la posibilidad de ofrecer nuevos productos de captación en el mercado. Es evidente que los usuarios prefieren manejar su dinero de forma digital, sin necesidad de disponer físicamente del efectivo y buscan productos financieros innovadores que les faciliten consultas, trámites y otros servicios informativos de manera oportuna, además que aseguren protección e integridad de sus productos contratados en dichas entidades.

En este contexto, la tasa de abandono se convierte en una métrica crítica para los bancos, ya que refleja problemas como la baja satisfacción del cliente, la competencia agresiva en el sector y la falta de productos atractivos. Comprender y analizar esta métrica permite identificar patrones de comportamiento de los usuarios, desarrollando así estrategias para fortalecer la relación con los clientes y en última instancia, incrementar los ingresos y mejorar la competitividad del sector financiero. (Lara Rubio, Liébana Cabanillas, & Martínez Fiestas, 2013)

Pregunta de investigación

¿De qué manera la banca colombiana puede mejorar la experiencia del cliente implementando la inteligencia artificial para disminuir la tasa de abandono y generar mayor retención de clientes?

Objetivos

Objetivo general

Elaborar una propuesta de estrategias que integren la inteligencia artificial en los modelos ya implementados, con el fin de reducir la tasa de abandono y mejorar la retención de clientes en la banca colombiana.

Objetivos específicos

- Reconocer las diferentes prácticas, aplicaciones IA que están realizando en bancos representativos en el sector para mejorar la experiencia de los clientes.
- Identificar patrones de referencia y características de las técnicas utilizadas por la banca colombiana en los tipos de producto de mayor preferencia de los clientes y los de mayor abandono.
- Evaluar la percepción de los clientes frente a la implementación de las IA en la adquisición de productos financieros en la banca colombiana.
- Proponer acciones estrategias basadas en los hallazgos recolectados con el fin de ser integradas al uso de inteligencia artificial, para optimizar la experiencia del cliente, reducir la tasa de abandono y potenciar la retención en la banca colombiana.

Justificación

En un entorno dinámico y en constante crecimiento, es crucial mantener una relación estrecha con los clientes es fundamental para asegurar la sostenibilidad financiera. Para comprender y adaptarse a las nuevas necesidades de los clientes, es necesario establecer estrategias respaldadas en datos que reflejen claramente patrones y comportamientos característicos de los usuarios, identificando así puntos claves para satisfacer esas necesidades cambiantes del mercado. Por otro lado, los bancos digitales están captando segmentos importantes de clientes gracias al uso de infraestructura en la nube y la integración avanzada de datos, lo que permite alinearse eficientemente con las últimas tendencias tecnológicas.

Sin embargo, al analizar la banca colombiana, podemos denotar que estas entidades están haciendo grandes esfuerzos para disminuir esa brecha digital y poder estar a la par de esos nuevos competidores. Tal como señala (Asobancaria, 2022), los bancos requieren adaptarse en términos de infraestructura tecnológica, migrando sus sistemas de información desde servidores físicos hacia soluciones en la nube, mejorando así el desempeño y escalabilidad en el soporte técnico que se realizan a estos. En este contexto, las herramientas BI cobran relevancia, ya que permiten visualizar la información de manera eficiente y facilitan la elaboración de reportes adaptados a las necesidades de cada área, siempre y cuando exista una estructura sólida de datos históricos que permitan soportar esos análisis estratégicos.

De acuerdo con lo mencionado anteriormente, la información que se utilice para cualquier práctica o aplicación de técnicas de IA debe estar sujeta a los criterios DAMA, aplicados en datos y segmentos claros de los clientes de cada tipo de entidad bancaria. Estos son ejes primordiales para garantizar la precisión de las estimaciones con un margen de error mínimo.

Dicho esto, la presente investigación brinda la posibilidad de comprender y analizar las estrategias implementadas por los bancos colombianos a partir de investigaciones o tesis realizadas en el sector, para retener clientes y ofrecerles productos que satisfagan sus necesidades. Desde un punto de vista investigativo y así determinar en qué medida perciben los clientes una mejora con respecto a experiencias pasadas.

Viabilidad del proyecto

Tabla 1

Criterios de factibilidad del proyecto

| Criterio | Factibilidad <i>(siendo 1 menor y 5 mayor)</i> |
|---|--|
| Acceso a la información | 5 |
| Apoyo e interés de colaboradores o aliados | 4 |
| Disponibilidad de recursos requeridos | 4 |
| Probabilidad de avance en el tiempo establecido | 4 |
| Probabilidad de continuidad o implementación de la propuesta de investigación | 5 |
| Promedio | 4.4 |

Fuente: Elaboración propia.

El acceso a la información está enmarcado por algunas instituciones que son de gran referencia en el sector financiero y en Colombia. Para este caso son Asobancaria quien representa al sector financiero y realiza ciertos tipos de programas que promueven el desarrollo del sector, así mismo el Ministerio de Tecnologías de la Información y Comunicaciones de Colombia quien está encargado a nivel nacional de todos los avances tecnológicos y que en

sus informes dan cierta información de cómo se promueven tecnológicas como: IA, IoT y generan ciertos informes en detalle que dan un visual más puntual de esos comportamientos que a veces por algunas entidades no son públicos. Por otro lado, ya están es las consultorías especializadas quienes realizan encuestas o mediciones internas dentro de este sector y han permitido captar inversiones que se hacen importantes para este aumento de tecnología y esfuerzos en acondicionar estas prácticas para poder impactar en ciertos recursos adicionales que se podrían tener en mediano o largo plazo. También se encuentran trabajos investigativos sobre bancos puntuales donde se evalúan estrategias que han implementado y los respectivos cuestionamientos que surgen de los modelos que se plantearon, considero que toda esta información es un buen insumo para partir y poder complementar durante el transcurso de esta investigación.

Marco Teórico

En la construcción del presente trabajo será necesario comprender ciertas investigaciones, adelantos y distinta información sobre las diferentes aplicaciones y análisis que se han realizado en este sector económico como es el financiero para poder implementar modelo analítico bien sea predictivo o descriptivo, los cuales permita plantear estrategias a la banca en Colombia para mantener clientes y evitar el abandono de estos.

Veamos el primer concepto clave, la inteligencia artificial es una definición que ha evolucionado durante el pasar de los años sus inicios se remontan con Alan Turing quien sobre los años 1930 planteo las bases con "prueba de Turing" en el artículo "*Computing Machinery and Intelligence*" (Turing, 1950) donde se explica un test fundamentado en cómo ese comportamiento del ser humano, puede ser recreado por maquina siendo similar a partir de ciertas situaciones. Ya para el año 1956 John McCarthy crea el lenguaje (list procesing) siendo uno de los más aplicados en este campo para manipulación de listas y estructura de datos (simbólicos) el junto con Marvin Minsky crean la conferencia de Dartmouth, lugar donde se da

inicio a encuentros para el nacimiento de la inteligencia artificial. El a su vez, es considerado el precursor de las redes neuronales artificiales y sus grandes avances se dieron con Seymour Papert quién también apoyo estos avances y dieron origen redes neuronales profundas y aprendizaje profundo.

Al revisar el documento *“Desafíos del riesgo cibernético en el sector financiero para Colombia y América Latina”* (Asobancaria, 2019) es incisivo en evidenciar esos cambios que se han dado tanto en la cultura y expectativas de esos clientes que se alinean mucho más a la tecnología y que sobre ellos empieza a girar unos nuevos propósitos.

Por otra parte, acorde con lo escrito en páginas anteriores: los desafíos y requisitos para poder implementar modelos BI y de analítica más avanzada son bajo las siguientes premisas:

1. Integración de datos: Es decir la consistencia de información tanto histórica como la real, que permita datos primordiales como lo son: demográficos, personales y económicos permitiendo así clasificar a los clientes de acuerdo con las variables descritas y con un cierto Score.
2. Análisis del comportamiento: Información primordial de transacciones en productos, estacionalidades, tasas de abandono por productos.
3. Monitoreo BI: Información en tiempo real a través de tableros con el detalle de la información respectiva de la retención de clientes, satisfacción y demás comportamientos en los segmentos.
4. Autoconsumo de información: Se deberá revisar por diferentes personas con roles específicos en datos y que acceden a este tipo de información con el fin de que cuando se detecte desviaciones se pueda hacer las correcciones necesarias.
5. Información sensible: Es necesario que se garantice la seguridad y el uso adecuado de información crítica, con accesos limitados por su alto grado de sensibilidad para el cliente (cedula, datos de contacto, ubicación, salario).

6. Dinámica constante: Capacitar y formar constantemente a las personas usuarias de información con las últimas tendencias para evitar una posible obsolescencia de conocimiento y que no se puedan migrar a tecnológicas con mayor avance. La digitalización depende de todos y es un proceso dinámico, que se alimenta entre todas las partes. (Asiedu, 2016)

Ahora bien, lo anteriormente mencionado hacer parte de lo que se debería tener planteado e identificado como partes fundamentales, para poder tener una dinámica más alineada y que de cierta forma sea más adaptativa con las nuevas circunstancias, que puedan dar en el mercado financiero que tiende a ser cada vez más cambiante. Si contrastamos esto con las nuevas tecnologías que se ofrecen para este tipo de análisis específicos en clientes, podríamos ver que algunos de los más utilizados en este sector son los siguientes:

- Inteligencia artificial (IA): Se entiende por aplicación de ciertos códigos internos que permiten a partir de ciertos patrones de comportamiento, imágenes y demás hábitos normales del ser humano, poder tratar de predecir las respuestas. Un ejemplo claro de estos son los Chatbots, que ya en algunas entidades son el primer canal de comunicación que permiten ofrecer asesoría sobre productos y gestionar PQR. En algunos de estos casos, pueden agilizar la atención de temas frecuentes basándose en interacciones con clientes anteriores (Adhikari, Aryal, & Park, 2022).

Su ventaja es que puede ayudar en la optimización de tiempos y también empleada para técnicas en detección de fraudes, al entrenar estos modelos con grandes volúmenes de información para prevenir pérdidas y posibles afectaciones en otros clientes. (Ashwini, Muddasir, & Abrar, 2023)

Cabe resaltar que su implementación tiene ciertos impactos diferenciados: a nivel de clientes internos, puede suponer reducción de cargas operativas al automatizar tareas repetitivas, aunque también puede generar resistencia al cambio y temas de adaptación. En los clientes externos, mejora la rapidez en la atención, pero plantea retos en

términos de confianza, disponibilidad del servicio e información y personalizaciones en especial para aquellos usuarios que prefieren la interacción humana.

- Machine learning: Es una técnica que depende de la IA y de la cual maneja grandes volúmenes de datos, aprende a entender las anomalías que hay en la información y puede proporcionar decisiones adecuadas con respecto a variables que puedan afectar al cliente siendo posible aplicar para mejorar los servicios en clientes como predicciones en productos de inversión y generando mejor experiencia en el cliente. (Stefanini, 2023).
- Análisis de sentimiento: Se crea a partir de la extracción de información sobre las percepciones de clientes, en algún mecanismo de información canalizado por: encuestas, redes sociales, entre otros. Sobre los productos o la satisfacción generada en atenciones anteriores o comentarios que se hayan dejado en la atención de PQR. A partir de esta información se crean correlaciones entre la información recibida de las fuentes y se empiezan a considerar palabras de mayor recurrencia entre clientes, uno de las aplicaciones es la creación de productos nuevos y la predicción de transacciones recurrentes en ciertos establecimientos. (Barba, 2023)

Ahora bien, llegando a este punto es importante mencionar que los anteriores conceptos y definiciones de cierta forma se encuentran ligadas entre sí, veamos estas definiciones un poco más macro. Revisando en la literatura podemos evidenciar que la evolución de esta técnicas y modelados de información tienen orígenes con el data mining o minería de datos según Jiawei Han (Han & Kamber, 2006) .Esta es una disciplina donde se descubren patrones validos previamente que se desconocen y que de alguna forma son útiles en conjuntos de datos, también menciona los aspectos claves y fundamentales en la minería de datos:

- Patrones: Lo define como identificaciones de relacionamiento, estructuras de gran grado de significancia de acuerdo con el análisis que se esté realizando y que algunas no son tan evidentes.
- Patrones validos: Luego de realizar ese descubrimiento inicial de patrones, se debe considerar la validez de los mismos, para garantizar consistencia en la información. A su vez, es necesario que en verdad esos patrones no hayan sido conocidos anteriormente para que en verdad sea algo diferente.
- Potencialmente útiles: En su aplicación deben aportar para la toma de decisiones empresariales o ser un marco de referencia para las posibles áreas a mejorar de acuerdo con lo detectado.

En resumen, con las definiciones de este autor podemos ver que se define como una disciplina que permite descubrir patrones validos dentro de grandes conjuntos de datos y que estos mismos aportan en decisiones o son referentes para la misma mejora del análisis que estemos realizando. Ahora bien, el libro *"Data Mining: Concepts and Techniques"* permite que pueda retomar lo que antes mencione como integracion de datos que si lo vemos desde gran detalle esta la *"limpieza y integracion"* siendo claves en las bases de datos debido a errores que por algun motivo son humanos o que puede darse por extraer información que este incompleta desde las fuentes y por ende deba tener algun tipo de remediación o de arreglo casi manual para que este correctamente. Luego se pasa al "data warehouse" (bodega de datos) donde se hace una selección de la información y se crean una serie de procesos internos para subir información a otras bases de datos bajo logicas relacionales, se almacena información de transacciones o de tipo cuantitativa en las tablas de hechos y en dimensiones todo aquello que es cualitativo y que puede ser referentes sobre:(clientes, productos, servicios, entre otros). (Han & Kamber, 2006). En este tercer paso está el data mining donde se aplican técnicas específicas que pueden ser de directamente con las combinaciones de: estadística,

machine learning, visualización BI (tableros de control o dashboard), data warehouse, en bases de datos o entre otros. Las aplicaciones ya van a estar ligadas a las condiciones de cada empresa, no necesariamente se combinan todas las técnicas. En algunos casos puede que donde se realice alguna de estas prácticas no cuente con DWH pero si puede contar con un *DataMart*, en este caso es un parte más pequeña del mencionado. Pero que se crea bajo las mismas condiciones solo que con información a un segmento más pequeño y puntual, pero tendrá menor volumen de tablas en sus relacionamientos. Complementando estos tipos de análisis con técnicas apropiadas para el objeto de esta investigación encuentro que ya hay autores que han revisado y realizado una serie de análisis aplicados para lo que es la retención de clientes además que lo consideran un éxito empresarial en marketing y gestión de relaciones (Berry & S.Linoff, 2004). De este texto se desprende el “*modelo predictivo de abandono*” se construye bajo la premisa de data histórica de clientes que abandonan la empresa y se contrasta con aquellos que aún se encuentran, se originan análisis para identificar señales de alerta manifestadas por los usuarios y que puedan desencadenar un posible abandono en los clientes actuales. Si bien el anterior es un factor importante también se encuentran otras características importantes: frecuencia de compra, el grado de satisfacción, tiempo de cliente en la empresa, entre otros. Permitiendo tomar medidas adecuadas para atacar esas preocupaciones o incertidumbres que puede tener el cliente y tratar de mejorar esa fidelización. Por otra parte, la segmentación de clientes nos define los grupos de mayores riesgos de abandono y el diseño de estrategias para estos, apoyados en incentivos personalizados, programas de algún tipo de fidelización o mejora de la experiencia en problemáticas ya identificadas con anterioridad.

En un apartado casi final, se encuentra la satisfacción de cliente donde se utilizan datos de encuestas y las distintas formas de retroalimentación que tienen las empresas hoy en día para también medir y comprender ese grado de lealtad. También se puede apreciar la insatisfacción que se genera y que desencadena en abandono o acciones correctivas para

mantener el cliente. Por su parte lo que pretenden estos autores en libro “*Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*” es a partir de la utilización de técnicas en minería de datos y análisis predictivos poder identificar, predecir y corregir el relacionamiento de clientes actuales siendo todos estos conceptos claves que se integran para poder dar solidez al presente trabajo.

Hipótesis

Partiendo de la pregunta de investigación que sustenta este trabajo, así como del marco teórico expuesto, es posible establecer, como hipótesis, las siguientes:

1. Utilizando inteligencia artificial (IA) en los procesos de atención al cliente, la banca colombiana puede apoyarse en esta tecnología para reducir la tasa de abandono de los clientes. Se espera que la capacidad de la IA para analizar grandes volúmenes de datos financieros, así como de comportamiento del cliente, permita identificar patrones de abandono potenciales con mayor precisión y anticipación. Al personalizar las interacciones con los clientes y ofrecer respuestas rápidas y efectivas a sus necesidades, la IA tiene el potencial de mejorar la satisfacción del cliente y fortalecer la relación entre el banco y sus usuarios, lo que finalmente conducirá a una mayor retención de estos.

2. La implementación efectiva de sistemas de inteligencia artificial en la banca colombiana conduciría a una mejora sustancial en la experiencia del cliente. Se espera que, al aprovechar las capacidades de la IA para personalizar las interacciones, sea posible ofrecer recomendaciones relevantes y automatizar procesos, de manera que la banca pueda proporcionar una experiencia más fluida y satisfactoria para sus clientes. Al reducir la fricción en los procesos bancarios, anticipar las necesidades del cliente y ofrecer soluciones proactivas, la IA puede contribuir a generar un mayor grado de confianza y lealtad en los clientes,

resultando en una disminución de la tasa de abandono y un aumento en la retención a largo plazo.

Variables

Tabla 2.

Definiciones y clasificación de variables de estudio.

| Variable | Def. conceptual | Def. Operacional | Clasificación de variable |
|--|---|---|--|
| Implementación de la inteligencia artificial (IA) en los bancos colombianos | Esta variable se refiere al grado en que la banca colombiana ha integrado sistemas de IA en sus procesos de atención al cliente. | Recolectar indicadores de uso de herramientas de IA implementadas, la cobertura de IA en diferentes etapas del proceso de atención al cliente y la sofisticación de los algoritmos utilizados en la banca colombiana. | Variable de tipo Independiente: la variable de implementación de la inteligencia artificial (IA) se considera independiente debido a que es la variable que se manipula o controla directamente como parte de este estudio. Ello, debido a que la banca colombiana tiene la capacidad de decidir si implementa o no sistemas de IA en sus procesos de atención al cliente. |
| | Esta variable podría medirse mediante indicadores como el número de herramientas de IA implementadas, la cobertura de IA en diferentes etapas del | | |

| | | | |
|---|--|---|--|
| <p>proceso de atención al cliente y la sofisticación de los algoritmos utilizados en la banca nacional.</p> | <p>Esta variable representa el porcentaje de clientes que han dejado de utilizar los servicios de la banca colombiana en un período de tiempo determinado.</p> | <p>La medición de esta variable está condicionada al uso de datos históricos de abandono de clientes y comparándolos antes y después de la implementación de la IA.</p> | <p>Variable de tipo independiente: La tasa de abandono de clientes se clasifica como una variable independiente en esta investigación porque es una medida que puede ser influenciada o manipulada por la implementación de la inteligencia artificial (IA) en los procesos de atención al cliente de la banca colombiana. Cuando se introduce la IA, se espera que afecte la forma en que los clientes interactúan con el banco y, por lo tanto, su</p> |
|---|--|---|--|

| | | | |
|-----------------------------|---|---|--|
| | | | propensión a abandonar los servicios ofrecidos. |
| | | La medición de esta variable depende de indicadores como el tiempo medio de respuesta a las consultas de los clientes, el número de transacciones procesadas por unidad de tiempo y los costos operativos asociados con la implementación de la IA. | Variable de tipo independiente: La eficiencia operativa se clasifica como una variable independiente en este estudio. La implementación de la inteligencia artificial (IA) en la banca colombiana puede tener un impacto en la eficiencia operativa al automatizar procesos, reducir errores y optimizar recursos. Por lo tanto, la eficiencia operativa puede ser influenciada por la introducción de sistemas de IA en los procesos bancarios. |
| Eficiencia operativa | Hace referencia a la capacidad de la banca colombiana para realizar sus operaciones de manera eficiente y rentable, frente a la que incorpora procesos de IA en sus procesos. | | |

Metodología

Enfoque y alcance de la investigación

Esta investigación adopta un enfoque cualitativo, centrado en el análisis de casos de estudio documentados en informes anuales de bancos, publicaciones especializadas y estudios de consultoras, con el fin de examinar cómo las tecnologías de IA se están utilizando en áreas clave del sector bancario. Se prestará especial atención a la aplicación de la IA en la atención al cliente, la personalización de servicios, la detección de fraudes y la automatización de procesos. Se destacarán aquellas iniciativas que hayan reportado resultados significativos en términos de mejora de la satisfacción del cliente y aumento de la eficiencia operativa.

Además, la investigación incluirá un análisis descriptivo de datos extraídos de informes sectoriales y bases de datos públicas que documenten los patrones de preferencia y abandono de productos financieros en la banca colombiana. Este análisis permitirá identificar cuáles son los productos financieros más populares entre los clientes y aquellos que presentan las mayores tasas de abandono. Se explorarán las características de estos productos y las técnicas de IA que se han implementado para su gestión, con el objetivo de detectar tendencias y patrones que revelen cómo la IA está influyendo en las decisiones de los clientes y la dinámica de abandono y retención de productos bancarios.

El enfoque combinado de análisis cualitativo y descriptivo proporcionará una visión integral sobre el impacto de la IA en el comportamiento de los usuarios y en la operatividad del sistema bancario, aportando valiosa información sobre las oportunidades y desafíos que enfrenta el sector en la adopción de estas tecnologías.

Población:

1. Bancos y entidades financieras en Colombia que están adoptando tecnologías de Inteligencia Artificial (IA) en áreas clave como la atención al cliente, personalización de servicios, detección de fraudes y automatización de procesos.
2. Clientes de productos financieros en Colombia, que forman parte de los patrones de preferencia y abandono de productos bancarios, documentados en informes sectoriales y bases de datos públicas.

Muestra:

Para seleccionar la muestra dentro de esta población, se podrían considerar los siguientes criterios:

1. Bancos y entidades financieras específicas: Se seleccionarán aquellos bancos que hayan reportado en sus informes anuales o en estudios de consultoras el uso de IA en áreas clave. Esto podría incluir tanto bancos tradicionales como nuevas entidades tecnológicas (fintech) autorizadas por la Superintendencia Financiera de Colombia. La muestra podría incluir a los principales bancos del país, basándose en su cuota de mercado y nivel de adopción tecnológica.
2. Estudios de caso documentados: La muestra de casos incluirá aquellos bancos que, además de adoptar IA, hayan documentado mejoras específicas en satisfacción del cliente y eficiencia operativa, permitiendo analizar resultados concretos.
3. Datos de clientes: En cuanto a los clientes, la muestra incluirá información de bases de datos públicas y estudios sectoriales que reporten patrones de comportamiento en cuanto a la preferencia y abandono de productos financieros, representando una diversidad de perfiles de usuarios (por ejemplo, usuarios de productos digitales vs. tradicionales, edades, tipos de productos financieros).

Instrumentos:

De acuerdo con el enfoque cualitativa de la investigación y el análisis descriptivo propuesto, los instrumentos de recolección de datos serían los siguientes:

- Recolección de datos cualitativos:

1. Análisis documental:

- Informes anuales de bancos: Se utilizarán para extraer información sobre la implementación de IA, mejoras en satisfacción del cliente, eficiencia operativa, y otros resultados relevantes. Estos informes proporcionarán un panorama detallado de las iniciativas tecnológicas en los bancos seleccionados.
- Publicaciones especializadas: Se revisarán artículos y reportajes en medios del sector financiero y tecnológico que documenten casos de uso de IA en bancos. Estas publicaciones aportarán información complementaria sobre el impacto de estas tecnologías en el sector.
- Estudios de consultoras: Se utilizarán informes de consultoras internacionales (como McKinsey, PwC, Deloitte) para obtener datos sobre las tendencias globales y locales en la adopción de IA y su impacto en áreas clave de los bancos colombianos.

2. Estudios de caso:

- Casos documentados: Se analizarán casos de bancos que hayan implementado con éxito soluciones de IA, proporcionando evidencia detallada sobre cómo estas tecnologías han mejorado áreas como la atención al cliente y la detección de fraudes. Los estudios de caso permitirán entender las prácticas específicas y los resultados alcanzados.

- Instrumentos para el análisis descriptivo:

1. Bases de datos públicas:

- Datos sectoriales: Se utilizarán bases de datos de instituciones como la Superintendencia Financiera de Colombia y Fogafín, que documentan el comportamiento del mercado bancario, la adopción de productos financieros, y las tasas de abandono. Estos datos permitirán realizar un análisis cuantitativo-descriptivo sobre la preferencia y abandono de productos financieros.
2. Informes de estudios sectoriales:
- Encuestas y estudios de comportamiento del cliente: Se emplearán resultados de encuestas o estudios realizados por entidades como el Centro Nacional de Consultoría, que documentan las preferencias de los clientes en cuanto a productos financieros y canales de uso (banca digital, oficinas físicas, etc.). Estos informes serán clave para identificar patrones de preferencia y abandono.

Técnicas para el análisis de información:

Software de análisis cualitativo (como NVivo o Atlas.ti): Se utilizará para organizar, codificar y analizar el contenido de los informes, estudios de caso y documentos relevantes. Este software permitirá extraer temas recurrentes y analizar los resultados de manera sistemática.

Herramientas de análisis descriptivo (como Excel o Python): Para el análisis descriptivo de los datos cuantitativos obtenidos de las bases de datos públicas y los informes sectoriales, permitiendo identificar tendencias, patrones y comportamientos en la adopción y abandono de productos financieros.

Estos instrumentos proporcionarán una base sólida para realizar tanto el análisis cualitativo de los casos de estudio como el análisis descriptivo de los datos sectoriales.

Trabajo de Campo

Con el objetivo de obtener una comprensión profunda y contextualizada de la problemática, se llevó a cabo una revisión exhaustiva de la literatura académica y sectorial. Se priorizaron investigaciones y estudios relacionados con la tasa de churn, la inteligencia artificial en el sector bancario, modelos de retención y aplicaciones de IA en este ámbito.

Adicionalmente, se complementó la información con datos cuantitativos provenientes de fuentes externas, anonimizadas y comparables con el contexto colombiano, para enriquecer el análisis y validar los hallazgos.

Procesamiento de los datos cualitativos:

- Ideas iniciales data cualitativa:

1. Data Mining Approach to Predict Business Sectors in Banking (Rafiqul & Ahsan, 2015)

Data Mining: Un proceso clave para analizar datos de clientes en el sector bancario.

Decision Trees: Uso de árboles de decisión para crear modelos predictivos.

Customer Retention & Churn: El análisis de la retención de clientes y la predicción de abandono.

Loan Disbursement: Determinación de los sectores más prometedores para otorgar préstamos.

Risk Categorization: Clasificación de sectores de clientes según el riesgo.

Weka Software: Comparación del modelo con resultados obtenidos usando Weka.

Prospective Sectors: Sectores como Retail, Wholesale, y Rice/Flower Mills identificados como prometedores.

2. Application of AI in the Banking Sector (Documento sobre IA en banca) (Buha & Bjegovic, 2023)

Artificial Intelligence (AI): Su aplicación en procesos bancarios.

Chatbots: Implementación de asistentes virtuales como "REA" para interactuar con los clientes.

Customer Service: Mejora en la interacción con clientes a través de tecnologías digitales.

Digital Banking: Digitalización completa de los procesos bancarios.

Security: Protección de la información, con mención a estándares como ISO 27001.

Machine Learning & Neural Networks: Uso de redes neuronales y aprendizaje automático para mejorar la eficiencia.

Cybersecurity: Protección frente a ataques como malware y DDoS.

3. IDB Paper (Desarrollo en el contexto de IA y economía) (Eslava, Maffioli, & Meléndez):

Artificial Intelligence for Development: Impacto de la IA en economías emergentes.

Economic Growth: Cómo la IA y las tecnologías avanzadas promueven el crecimiento económico.

Innovation in Finance: Adopción de IA en servicios financieros para mejorar la competitividad.

Skill Development: Necesidad de desarrollar habilidades tecnológicas en la fuerza laboral.

4. Inteligencia Artificial en los Servicios Financieros (Fernández, 2019):

Inteligencia artificial (IA) es un conjunto de teorías y algoritmos que permiten a los sistemas informáticos realizar tareas que normalmente requieren inteligencia humana (e.g. percepción visual, reconocimiento de voz, interpretación de textos).

Machine learning: La mayoría de las aplicaciones actuales pertenecen al campo del aprendizaje automático donde los algoritmos mejoran automáticamente a medida que se les alimenta con más datos.

- Aplicaciones:

Automatización de procesos y toma de decisiones.

Mejora en la detección de fraudes y control de lavado de dinero.

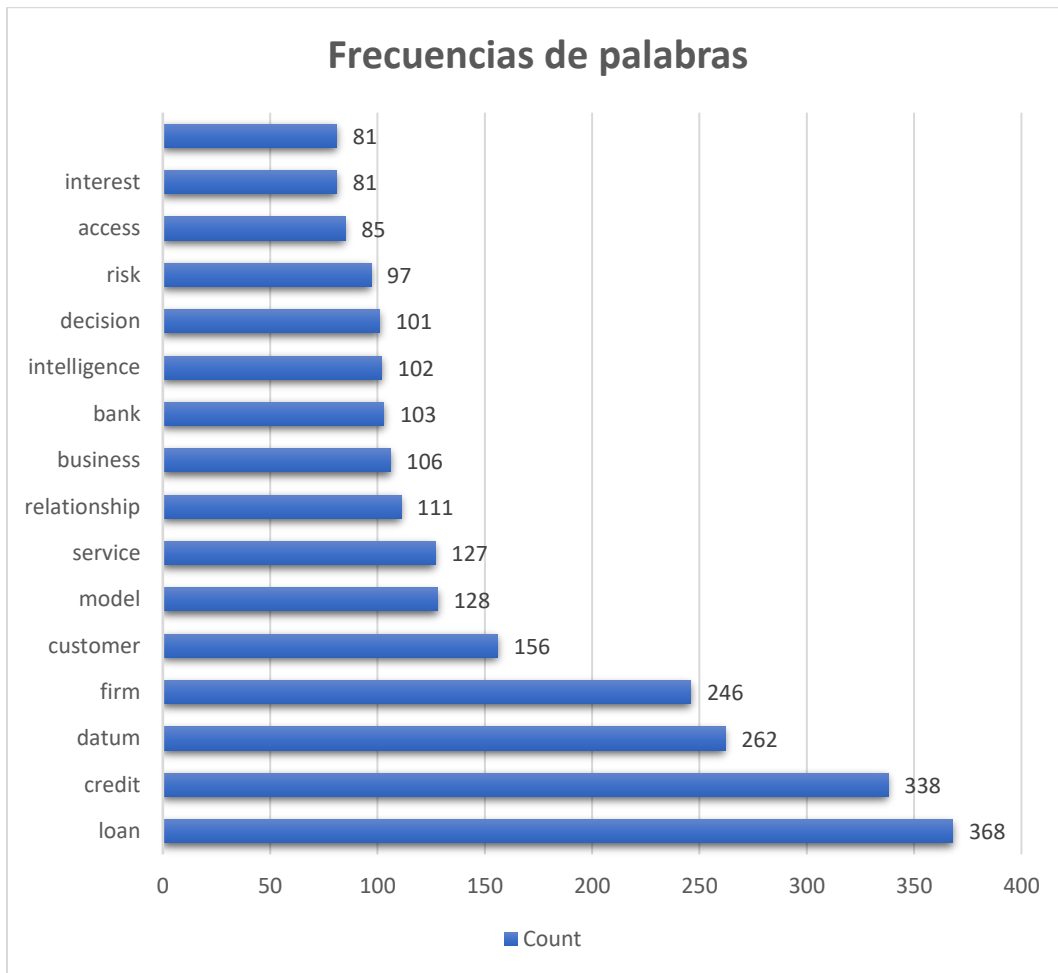
Personalización de productos y servicios financiero

5. Soluciones de Inteligencia de Negocios en Banca (Radmehr & Bazmara, 2017):

La inteligencia de negocios (BI) incluye arquitecturas, herramientas y metodologías utilizadas para analizar datos y apoyar la toma de decisiones. Se utiliza en aplicaciones como gestión de riesgos, prevención de fraudes y optimización de procesos comerciales

Figura 2

Diagrama de frecuencia palabras según investigaciones seleccionadas.

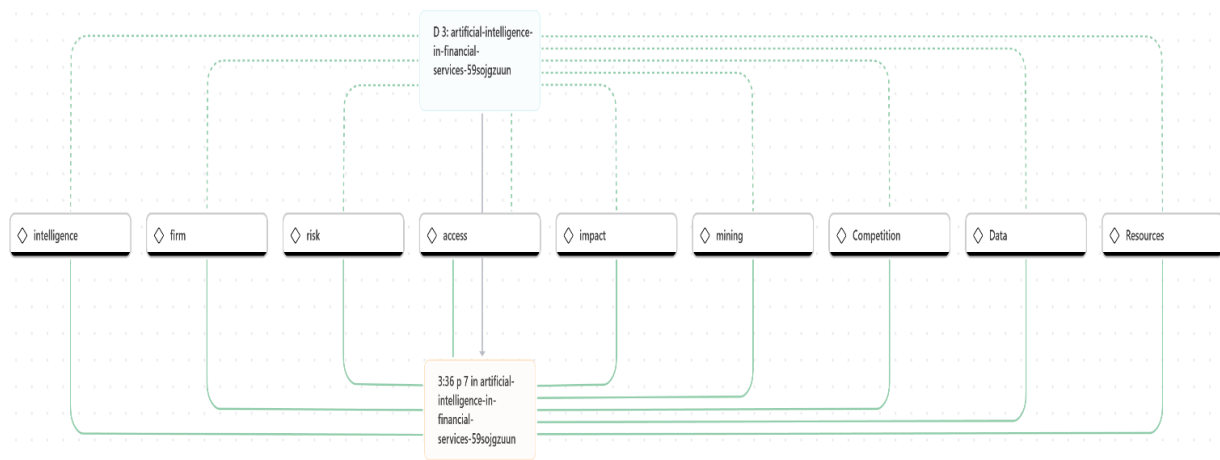


Fuente: Elaboración propia en Excel según reporte de Atlas.ti.

A partir de la información anterior, se busca empezar a relacionar conceptos entre las diferentes investigaciones que se están analizando con el paso de codificación cualitativa en el cual se toma de referencia las exploraciones ya realizadas y se depuran o se crean condiciones para aquellas palabras que puedan ser similares en cuanto a concepto o aplicación. Se realiza la elaboración del diagrama de redes semánticas:

Figura 3

Diagrama de redes semánticas



Fuente: Elaboración propia en Atlas.ti.

Conclusión del diagrama:

El análisis cualitativo con Atlas.ti evidencio un fuerte énfasis en los conceptos de "inteligencia artificial" está fuertemente conectado con otros conceptos como: "service", "data", "virtual bank", "modelling", "customer churn" y "data mining". Esto sugiere que la IA desempeña un papel importante en la percepción del cliente y en su decisión de abandonar o permanecer en las entidades financieras. Para validar estas tendencias, se analizarán dos conjuntos de datos donde se apliquen modelos de aprendizaje automático y sus respectivos modelado en los datos.

Procesamiento de los datos cuantitativos:

- Análisis 1: Con el propósito de entender el fenómeno de la fuga de clientes en el sector bancario, se analizaron los datos provenientes del dataset "Customer-Churn-Records.csv" (Radheshyam), que cuenta con información detallada sobre 10.000 clientes. En este análisis, se pretende identificar variables determinantes para una posterior creación de estrategias basadas en IA que mitiguen esta problemática:

Tabla 3

Descripción de variables dataset churn_rate

| Campo | Descripción |
|---------------------------|---|
| Rownumber | Código de registro de fila |
| CustomerId | Código identificador de cliente |
| Surname | Apellido de cliente |
| CreditScore | Puntuación crediticia de cada cliente |
| Geography | Ubicación del cliente |
| Gender | Genero de cada cliente |
| Age | Edad de cada cliente |
| Tenure | Tiempo de antigüedad del cliente en el banco |
| Balance | Saldo total de productos del cliente |
| NumOfProducts | Cantidad de productos que tiene el cliente |
| HasCrCard | Marca de clientes que tienen tarjeta de crédito. |
| IsActiveMember | Marca de cliente activo |
| EstimatedSalary | Ingresos de cada cliente |
| Exited: | Marca de cliente por abandono |
| Complain | Marca de cliente si tiene quejas |
| Satisfaction Score | Calificación del cliente de acuerdo con resolución de queja |
| Card Type | Tipo de tarjeta de crédito del cliente |
| Points Earned | Puntos acumulados por el uso de la tarjeta |

Fuente: Elaboración propia

Se llevó a cabo un proceso de limpieza y validación de los datos eliminando valores faltantes o inconsistentes, seguido de una selección de variables claves con potencial

predictivo del abandono, especialmente están relacionadas a características y financieras del cliente. Luego de esto, las variables fueron convertidas a categóricas para facilitar el análisis correlacional y predictivo, con el fin de identificar relaciones iniciales que orienten el modelo predictivo posterior.

Figura 4

Código en Python para conversión de variables a categóricas y creación de matriz de correlación.

```

▶ # Utilizar pandas.get_dummies() para convertir columnas categóricas en numéricas
df_encoded = pd.get_dummies(df_selected, drop_first=True)
# Calcular la matriz de correlación
corr_matrix_encoded = df_encoded.corr()
print('Correlation Matrix (Encoded):')
print(corr_matrix_encoded)

```


↔ Correlation Matrix (Encoded):

| | CreditScore | Age | EstimatedSalary | Exited | Gender_Male |
|-----------------|-------------|-----------|-----------------|-----------|-------------|
| CreditScore | 1.000000 | -0.003965 | -0.001384 | -0.026771 | -0.002857 |
| Age | -0.003965 | 1.000000 | -0.007201 | 0.285296 | -0.027544 |
| EstimatedSalary | -0.001384 | -0.007201 | 1.000000 | 0.012490 | -0.008112 |
| Exited | -0.026771 | 0.285296 | 0.012490 | 1.000000 | -0.106267 |
| Gender_Male | -0.002857 | -0.027544 | -0.008112 | -0.106267 | 1.000000 |

Fuente: Elaboración propia en Collab-Python

Figura 5

Matriz de correlación variables seleccionadas



Fuente: Elaboración propia en Collab-Python

Resultados de la matriz de correlación:

Edad y Exited: Hay una correlación positiva débil (0.29) entre la edad y la variable "Exited" (la cual nos indica si un cliente se ha ido). Esto podría indicar que los clientes de mayor edad tienen una mayor probabilidad de abandonar.

Las demás variables: No muestran correlaciones significativas entre sí. Esto significa que no hay una relación lineal fuerte entre el puntaje de crédito, el género y las otras variables.

La edad parece ser un factor relevante. Se podrían realizar análisis más profundos para entender mejor cómo la edad influye en el comportamiento de los clientes.

La variable "Exited" es el objetivo principal. Se podrían construir modelos predictivos para intentar predecir qué clientes tienen más probabilidades de abandonar el banco.

Con el fin de profundizar en el análisis, se recreo un modelo predictor con la misma data seleccionada del punto anterior con el fin de utilizar la variable de predicción "Exited" y dividiendo los datos para entrenamiento en una relación (70-30).

Figura 6

Código en Python para entrenamiento de datos

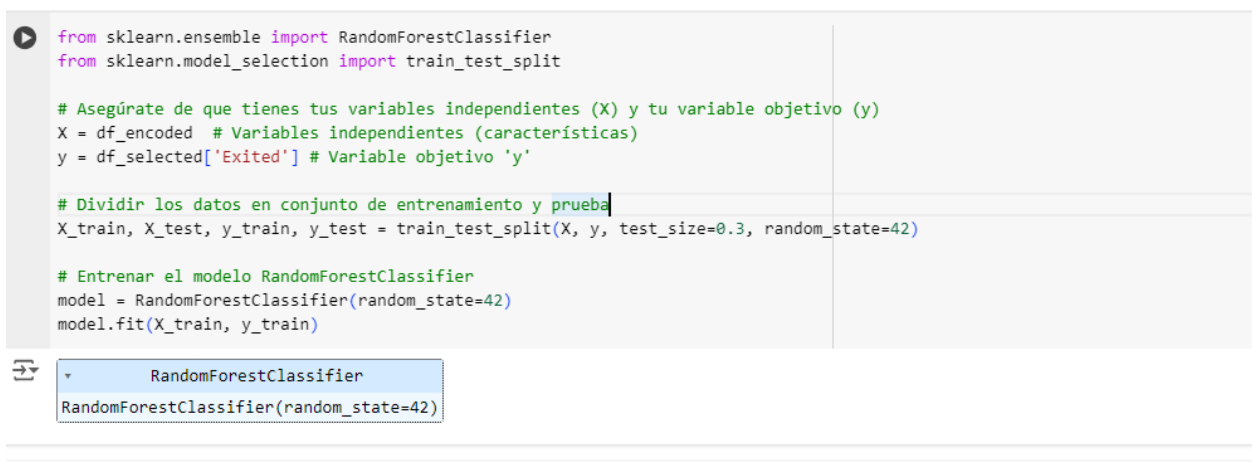
```

from sklearn.ensemble import RandomForestClassifier
from sklearn.model_selection import train_test_split

# Asegúrate de que tienes tus variables independientes (X) y tu variable objetivo (y)
X = df_encoded # Variables independientes (características)
y = df_selected['Exited'] # Variable objetivo 'y'

# Dividir los datos en conjunto de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=42)

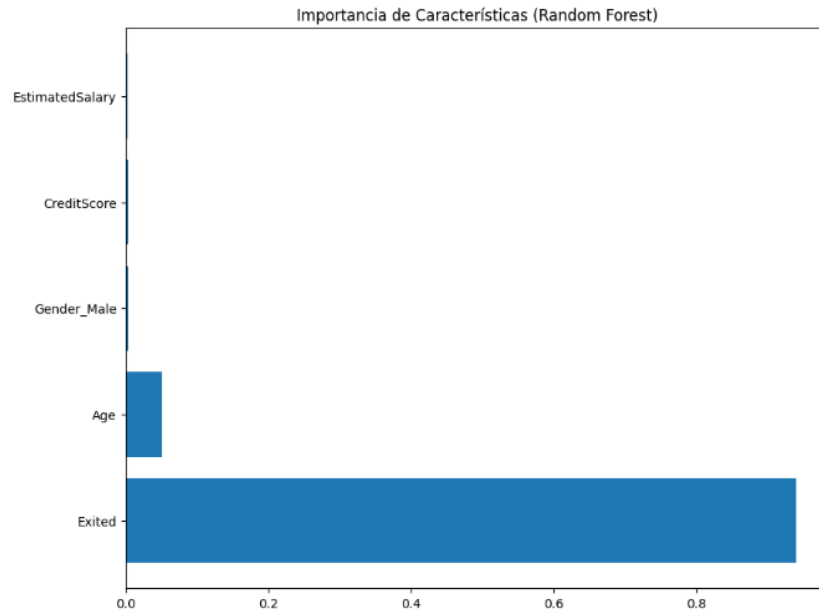
# Entrenar el modelo RandomForestClassifier
model = RandomForestClassifier(random_state=42)
model.fit(X_train, y_train)
    
```



Fuente: Elaboración propia en Collab-Python

Figura 7

Análisis random forest para variables características y variable predictora



Elaboración propia en Collab-Python

De acuerdo con el análisis random forest teniendo como variable objetivo Exited, se puede apreciar que las variables con las que mayor se relaciona son age, gender_Male. Age tiene una importancia en el modelo: Es la segunda variable más importante. Esto sugiere que la edad de los individuos tiene un impacto significativo en la variable objetivo (Exited), lo que confirma lo que se observó en la matriz de correlación.

Las demás variables tienen poca importancia: Las variables "CreditScore", "EstimatedSalary" y "Gender_Male" tienen una importancia muy baja, lo que indica que su influencia en la variable objetivo es mínima.

- Conclusiones de random forest y matriz de correlación:

El modelo ha aprendido a predecir "Exited" basándose principalmente en sí misma y en las demás variables seleccionadas. Sin embargo, se denota que la edad es un factor relevante: Confirma lo observado en la matriz de correlación.

Figura 8

Código en Python para entrenamiento de datos Redes Neuronales

```
# Copiar los datos para el preprocesamiento
df = df.copy()

# Paso 2: Codificar variables categóricas (Geography y Gender)
label_encoder = LabelEncoder()
df["Gender"] = label_encoder.fit_transform(df["Gender"]) # 0: Female, 1: Male
df = pd.get_dummies(df, columns=["Geography", "Card Type"], drop_first=True)

# Paso 3: Dividir en características (X) y variable objetivo (y)
X = df.drop("Exited", axis=1)
y = df["Exited"]

# Paso 4: Escalado de las características
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

# Paso 5: Dividir en conjuntos de entrenamiento y prueba
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.2, random_state=42, stratify=y)

# Revisar las dimensiones de los conjuntos resultantes
X_train.shape, X_test.shape, y_train.shape, y_test.shape

((8000, 17), (2000, 17), (8000,), (2000,))
```


Fuente: Elaboración propia en Collab-Python

Figura 9

Resultados matriz de confusión, evaluación del modelo: perdida y precisión.

```
# Evaluación del modelo
loss, accuracy = model.evaluate(X_test, y_test, verbose=0)
print(f"Loss: {loss:.4f}, Accuracy: {accuracy:.4f}")

/usr/local/lib/python3.10/dist-packages/keras/src/layers/core/dense.py:87: UserWarning: Do not pass an `input_shape`/`input_dim`
super().__init__(activity_regularizer=activity_regularizer, **kwargs)
Epoch 1/100
250/250 ----- 2s 2ms/step - accuracy: 0.8637 - loss: 0.3241 - val_accuracy: 0.9985 - val_loss: 0.0130
Epoch 2/100
250/250 ----- 0s 2ms/step - accuracy: 0.9981 - loss: 0.0218 - val_accuracy: 0.9985 - val_loss: 0.0116
Epoch 3/100
250/250 ----- 1s 2ms/step - accuracy: 0.9987 - loss: 0.0103 - val_accuracy: 0.9985 - val_loss: 0.0128
Epoch 4/100
250/250 ----- 1s 2ms/step - accuracy: 0.9995 - loss: 0.0060 - val_accuracy: 0.9985 - val_loss: 0.0132
Epoch 5/100
250/250 ----- 1s 2ms/step - accuracy: 0.9983 - loss: 0.0141 - val_accuracy: 0.9985 - val_loss: 0.0139
Epoch 6/100
250/250 ----- 1s 2ms/step - accuracy: 0.9983 - loss: 0.0104 - val_accuracy: 0.9985 - val_loss: 0.0140
Epoch 7/100
250/250 ----- 1s 2ms/step - accuracy: 0.9989 - loss: 0.0077 - val_accuracy: 0.9985 - val_loss: 0.0140
Epoch 8/100
250/250 ----- 1s 2ms/step - accuracy: 0.9986 - loss: 0.0069 - val_accuracy: 0.9985 - val_loss: 0.0149
Epoch 9/100
250/250 ----- 0s 2ms/step - accuracy: 0.9981 - loss: 0.0099 - val_accuracy: 0.9985 - val_loss: 0.0158
Epoch 10/100
250/250 ----- 1s 2ms/step - accuracy: 0.9989 - loss: 0.0059 - val_accuracy: 0.9985 - val_loss: 0.0155
Epoch 11/100
250/250 ----- 1s 2ms/step - accuracy: 0.9981 - loss: 0.0117 - val_accuracy: 0.9985 - val_loss: 0.0171
Epoch 12/100
250/250 ----- 1s 2ms/step - accuracy: 0.9980 - loss: 0.0086 - val_accuracy: 0.9985 - val_loss: 0.0180
Loss: 0.0116, Accuracy: 0.9985
```



Fuente: Elaboración propia en Collab-Python

➤ **Entrenamiento y Validación**

Observaciones del entrenamiento:

Precisión:

En el conjunto de entrenamiento, el modelo alcanzó una precisión del 99.85% (accuracy), lo cual indica que el modelo clasifica correctamente casi todos los datos durante el entrenamiento.

En el conjunto de validación, la precisión validada fue de 99.85%, consistente con la precisión del entrenamiento, lo que muestra que el modelo generaliza bien y no hay señales evidentes de sobreajuste.

Pérdida:

La pérdida (loss) disminuyó rápidamente en las primeras épocas hasta estabilizarse en un valor bajo (~0.0086 en validación), lo que es característico de un modelo bien optimizado.

Interpretación de los Resultados de la matriz de confusión:

- Verdaderos Positivos (VP): 1591 instancias fueron correctamente clasificadas como "Retenidos". Esto indica que el modelo es muy bueno a la hora de identificar a los clientes que se quedarán.
- Verdaderos Negativos (VN): 406 instancias fueron correctamente clasificadas como "Abandonados". Esto significa que el modelo también tiene un buen desempeño al identificar a los clientes que se irán.
- Falsos Positivos (FP): 1 instancia fue incorrectamente clasificada como "Abandonado" cuando en realidad se quedó. Este tipo de error puede ser costoso si se toman acciones basadas en esta predicción errónea.
- Falsos Negativos (FN): 2 instancias fueron incorrectamente clasificadas como "Retenidos" cuando en realidad se fueron. Este tipo de error también puede ser problemático, ya que se pierden oportunidades de tomar acciones para retener a estos clientes.

Métricas de Evaluación

Para tener una evaluación más cuantitativa del desempeño del modelo, podemos calcular diversas métricas a partir de la matriz de confusión:

- **Precisión:** La proporción de predicciones positivas que fueron correctas. En este caso, la precisión para la clase "Abandonado" sería muy baja debido a la cantidad de falsos positivos. Sin embargo, la precisión para la clase "Retenido" es muy alta.
- **Recall o Sensibilidad:** La proporción de instancias positivas que fueron correctamente identificadas. El recall para la clase "Abandonado" es relativamente bajo, lo que indica que el modelo no está capturando a todos los clientes que se van.
- **Especificidad:** La proporción de instancias negativas que fueron correctamente identificadas. La especificidad para la clase "Retenido" es muy alta.

F1-score: Una medida que combina precisión y recall. Un F1-score alto indica un buen equilibrio entre ambas métricas.

Consideraciones Adicionales:

- **Desbalance de clases:** Si una clase tiene muchas más instancias que otra (desbalance de clases), las métricas de evaluación pueden ser engañosas. En este caso, parece haber un desbalance entre las clases "Retenido" y "Abandonado", lo que podría afectar la interpretación de los resultados.
- **Costo de los errores:** El costo asociado a cada tipo de error (falso positivo, falso negativo) debe ser considerado al evaluar el modelo. Para este caso, si el costo de perder un cliente es muy alto, se podría priorizar maximizar el recall.
- **Umbral de clasificación:** Es utilizado para determinar si una instancia pertenece a una clase u otra puede afectar los resultados. Ajustar este umbral puede ayudar a mejorar el desempeño del modelo para un problema específico.

Conclusiones Preliminares

Basado en la matriz de confusión proporcionada, el modelo de red neuronal aplicado al primer dataset mostro una muy buena precisión identificando a los clientes que se quedarán (alta precisión y especificidad para la clase "Retenido"). Sin embargo, el modelo tiene dificultades para identificar a los clientes que pueden abandonar (bajo recall para la clase "Abandonado"). Ante los resultados anteriores, el siguiente paso consiste en evaluar el segundo conjunto de datos, esta vez anonimizado y proveniente directamente de clientes en Colombia, para poder contrastar el comportamiento de los modelos y ver qué variables sociodemográficas inciden en la decisión de abandono.

- **Análisis 2:** Para este análisis se toma información real con ciertos datos anonimizados de clientes en entidad financiera, teniendo un total de registros de 6266 y la data tiene campos importantes que aportan al entendimiento de la fuga de clientes. En la tabla 4 se puede observar la descripción del dataset utilizado:

Tabla 4

Descripción de variables dataset anonimizado


| Campo | Descripción |
|---------------------------------|---|
| Cant_calculado | Cantidad total de productos de los clientes |
| Estado | Marcación de vigencia del cliente |
| Genero | Genero de cada cliente |
| Ingresos Mensuales total | Monto de ingreso en millones de pesos de los clientes |
| Rango de edad cliente | Rangos de edades de los clientes en la entidad |

Fuente: Elaboración propia

Análisis exploratorio de los datos:

Figura 10

Análisis descriptivos y exploratorios del dataset.




Fuente: Elaboración propia.

En la figura 10 se observan gráficos exploratorios que permiten identificar la distribución y características claves de acuerdo con las variables de interés analizadas. En cuanto a la gráfica circular permite visualizar la proporción de clientes activos e inactivos, mientras que el histograma muestra la concentración de clientes por rangos de edad, en las siguientes secciones se profundizara sobre que factores influyen en la fuga de clientes.

Figura 11

Matriz de correlación de variables seleccionadas.



Fuente: Elaboración propia.

Resultados de la matriz de correlación:

- Cant_calculado vs Género c:

Se debe hacer una revisión del conjunto de datos, ya que se está evidenciando en estas dos variables igualdad, y la causal puede ser algún error en los datos.

- Cant_calculado vs Ingresos Mensuales Total:

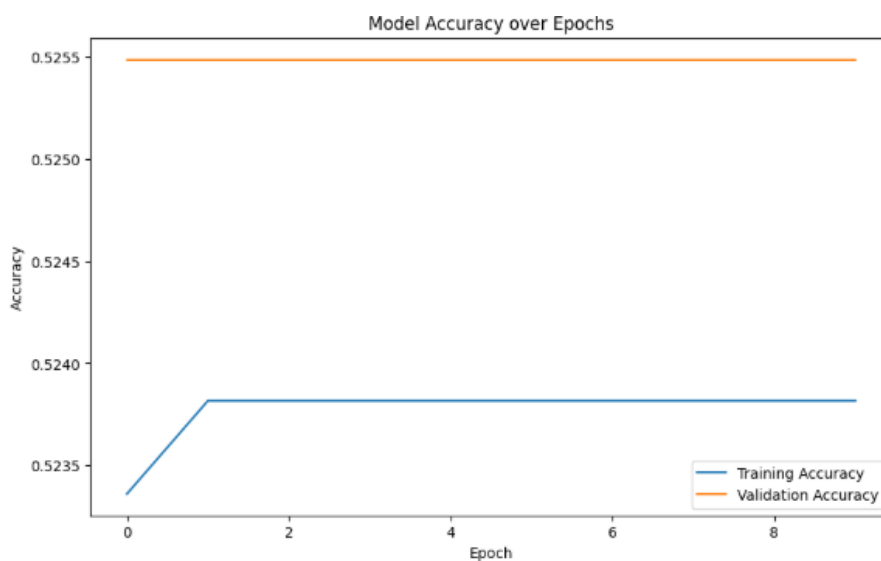
La correlación es 0.71, lo que indica una correlación positiva fuerte entre estas dos variables. Esto significa que a medida que aumentan los "Ingresos Mensuales Total", también lo hace "Cant_calculado" es decir que a medida que los clientes tienen un mayor ingreso los bancos ofrecen una mayor cantidad de productos.

- Género c vs Ingresos Mensuales Total:

La correlación es 0.70, lo que también indica una correlación positiva fuerte entre "Género c" e "Ingresos Mensuales Total". Esto implica que hay una relación entre la variable categórica "Género" y los ingresos, pero la naturaleza de esta correlación debería interpretarse con precaución sin embargo la conversión de género a binario puede haber afectado este análisis por lo que será necesario replantear otro tipo de análisis.

Figura 12

Gráfico precisión del modelo redes neuronales.



[30]: "Test Accuracy: 0.5182"

Fuente: Elaboración propia.

A continuación, procederemos a desarrollar un modelo basado en redes neuronales, ajustando y experimentando con diferentes cantidades de épocas. La variable objetivo de este análisis es el estado del cliente.

El gráfico muestra que la precisión del modelo (accuracy) tanto en el conjunto de entrenamiento como en el de validación no está mejorando durante las épocas. Además, el resultado indica que la precisión del conjunto de prueba es de aproximadamente **0.5182**, lo que sugiere que el modelo tiene un rendimiento bajo.

Se plantean una serie de acciones para poder mejorar la precisión del modelo y que permita un análisis más detallado, siendo estas las siguientes:

- ❖ Agregar más capas densas y técnicas de regularización:
- ❖ Incluir más capas densas adicionales y aplicar Batch Normalization para estabilizar el proceso de aprendizaje.
- ❖ Mantenemos Dropout con el objetivo de reducir el sobreajuste.
- ❖ Ajustar hiperparámetros:
- ❖ Reducir la tasa de aprendizaje del optimizador Adam para lograr una convergencia mas estable.
- ❖ Aumentar el número de épocas e implementar callbacks (EarlyStopping y ModelCheckpoint) para optimizar la gestión del entrenamiento.
- ❖ Visualización mejorada:
- ❖ Generamos gráficos más claros y precisos que faciliten la interpretación del comportamiento del modelo respecto a la precisión y perdida.

Diferencias clave respecto al modelo inicial:


- ❖ Más capacidad del modelo: El incremento en capas y neuronas, proporciona una mayor capacidad para aprender patrones complejos en los datos.
- ❖ Regularización adicional: La combinación de Batch Normalization y Dropout ayudan a prevenir el sobreajuste.
- ❖ Tasa de aprendizaje ajustada: Una tasa de aprendizaje más bajo permite un aprendizaje más estable y robusto.

- ❖ Uso de Callbacks: Herramientas como EarlyStopping y ModelCheckpoint optimizan el entrenamiento, permitiendo detenerlo oportunamente si no hay mejoras significativas y guardando el mejor modelo.

A continuación, en la siguiente figura se evidencia los resultados obtenidos a partir de las mejoras descritas, las cuales buscan mejorar significativamente el desempeño del modelo, especialmente en la precisión y la estabilidad, en contraste con el modelo inicial.

Figura 13

Resultados de entrenamiento redes neuronales



Fuente: Elaboración propia.

Precisión:

- La precisión del conjunto de entrenamiento y del conjunto de validación se muestran relativamente estables a lo largo de las épocas, con valores que fluctúan alrededor de 0.525.

- La similitud de ambas curvas indica que el modelo no está sobre ajustando los datos de entrenamiento. Es decir, no está memorizando los datos sino que esta generalizado adecuadamente

Pérdida:

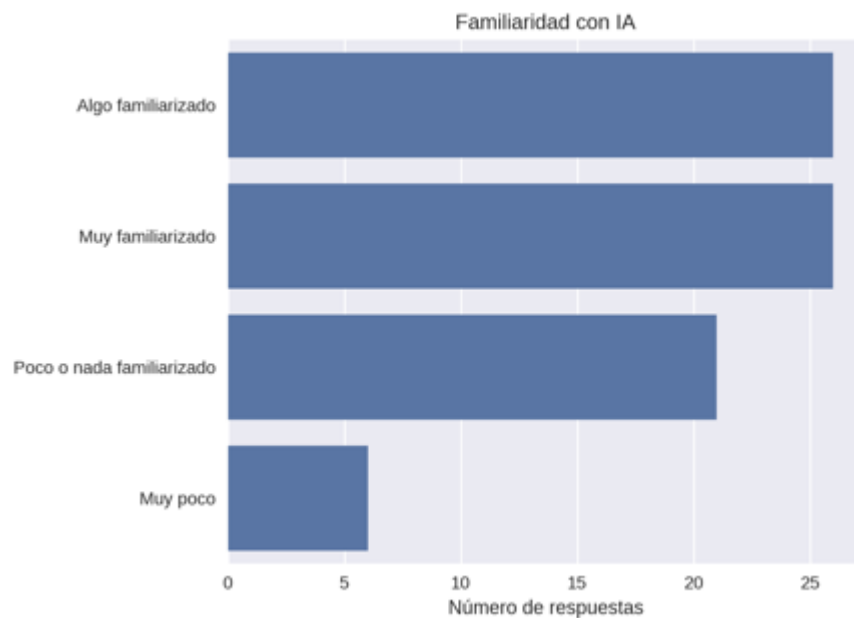
- La pérdida del conjunto de entrenamiento muestra una disminución leve seguida de una estabilización en las épocas posteriores.
- De manera similar, la pérdida en el conjunto de validación se mantiene relativamente estable, con valores cercanos a los de entrenamiento.

Estos resultados sugieren que las mejores realizadas ha favorecido el comportamiento del modelo siendo más robusto y estable.

- ❖ **Análisis 3:** Se llevaron a cabo 80 encuestas (**anexo 2 encuestas grupo focal**) dirigidas a un grupo focal de usuarios del sector financiero en Colombia, compuesto por personas entre 27 y 50 años. Estas encuestas tuvieron como objetivo explorar diversas percepciones relacionadas con el conocimiento de la inteligencia artificial, su uso en los servicios bancarios y los niveles de confianza asociados. Además, se analizaron factores clave que influyen en la relación y percepción de los clientes respecto a estas tecnologías emergentes implementadas en la banca.

Figura 14

Diagrama de barras según datos encuestas familiaridad con la IA.



Fuente: Elaboración propia.

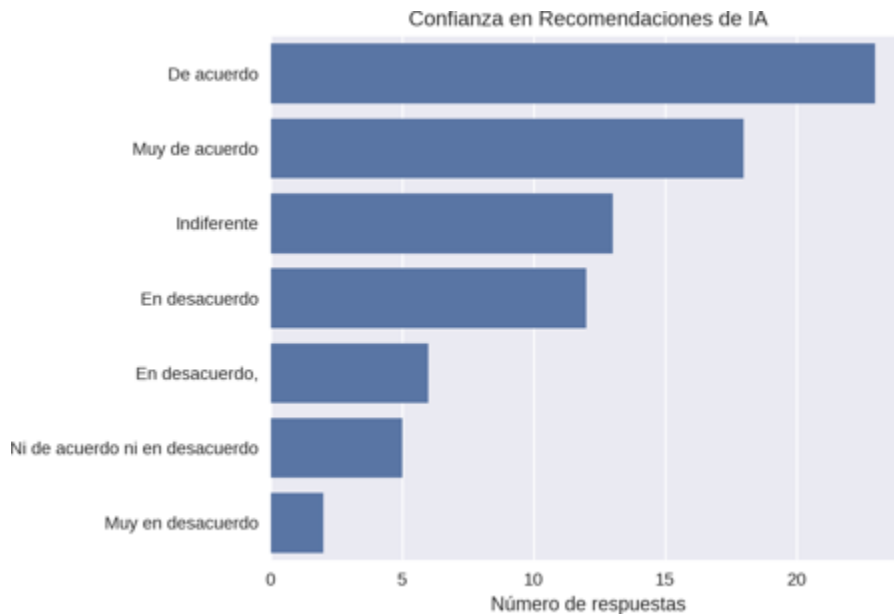
Familiaridad con la Inteligencia Artificial (IA):

La mayoría de los encuestados están "Algo familiarizados" o "Muy familiarizados" con la IA, sumando aproximadamente 50 personas, estos resultados son obtenidos de la pregunta ¿En qué medida está familiarizado con el concepto de inteligencia artificial?.

Sin embargo, una cantidad considerable cerca de 30 personas, indicó estar "Poco o nada familiarizados" o "Muy poco" familiarizados con la IA, lo que revela un nivel de conocimiento desigual entre los usuarios, esto puede darse a que muchos de los usuarios son población que desconocen este tipo de conceptos y a veces por parte de las entidades son poco evidenciadas esta serie de conceptos o definiciones para sus usuarios.

Figura 15

Diagrama de barras según datos de encuesta sobre la confianza en recomendaciones de IA.



Fuente: Elaboración propia.

Percepción de mejora en la experiencia bancaria:

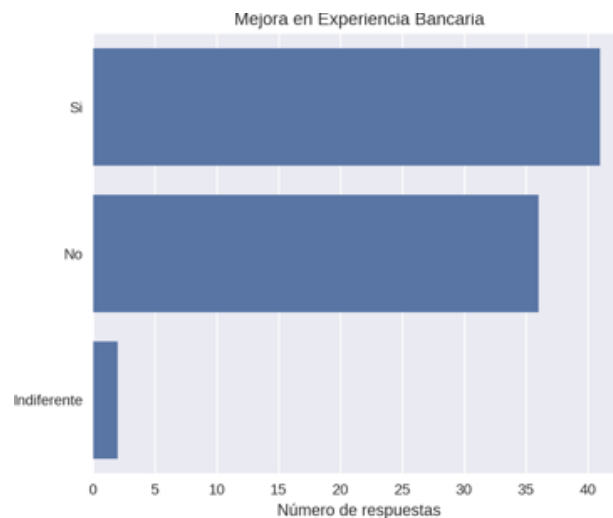
Según los resultados obtenidos de las encuestas cerca de 40 usuarios señalaron haber experimentado mejoras en su experiencia bancaria gracias al uso de tecnologías de inteligencia artificial, mientras que alrededor de 30 manifestaron no haber notado cambios significativos.

Al profundizar en estos resultados se identificó que los clientes con mayor familiaridad y confianza previa en tecnologías digitales tienden a reportar más ventajas derivadas del uso de IA en comparación con clientes menos familiarizados. Así mismo, usuarios de grupos de edad más jóvenes manifestaron una percepción más positiva frente a la IA debido a la comodidad y rapidez asociadas a canales digitales. Por otro lado, los clientes que manifestaron no notar

mejoras generalmente señalaron preferir la interacción presencial, indicando una menor adaptación o resistencia inicial al uso de soluciones tecnológicas automatizadas.

Figura 16

Diagrama de barras según datos encuesta sobre mejoras en la experiencia Bancaria de los clientes.



Fuente: Elaboración propia.

Confianza en las recomendaciones de IA:

La confianza en las recomendaciones es alta, con la mayoría de los encuestados posicionándose en "De acuerdo" y "Muy de acuerdo" (alrededor de 40 personas).

Sin embargo, existe un grupo significativo que manifiesta niveles de desconfianza, ya sea "En desacuerdo" o "Muy en desacuerdo" (aproximadamente 20 personas), indicando que la IA aún enfrenta barreras en la aceptación completa por parte de los usuarios siendo estos que aún no les ha generado gran confianza el uso de inteligencia artificial en este medio y que además es una tecnología que requiere un mayor control para poder asegurar una mejor confianza en sus usuarios.

Ventajas de la Inteligencia Artificial (IA) en la banca:

❖ Disponibilidad 24/7:

Esta ventaja está relacionada con la capacidad de la IA para operar de manera ininterrumpida, permitiendo a los usuarios acceder a servicios bancarios en cualquier momento. Es particularmente útil para consultas rápidas, transferencias y resolución de problemas fuera del horario laboral.

❖ Personalización:

Se refiere a la capacidad de la IA para adaptar sus servicios a las necesidades específicas de cada cliente. Esto puede incluir recomendaciones de productos financieros personalizados, gestión de presupuestos y asesoramiento automatizado.

Reducción de errores humanos:

Al automatizar procesos, la IA puede minimizar errores en transacciones, cálculos o procesamiento de datos, lo que refuerza la confianza de los usuarios en los sistemas bancarios.

❖ Rapidez en la atención:

La IA permite respuestas inmediatas a consultas mediante chatbots o sistemas automatizados, mejorando la experiencia del cliente al reducir los tiempos de espera.

Disponibilidad general:

Aunque menos destacada, esta ventaja refuerza el acceso constante y confiable a los servicios bancarios mediante IA.

Desventajas de la Inteligencia Artificial (IA) en la banca:

❖ Respuestas genéricas:

Los usuarios perciben que las respuestas proporcionadas por sistemas de IA suelen ser poco específicas, lo que puede resultar frustrante cuando se busca resolver problemas complejos o situaciones únicas.

❖ **Fallas técnicas:**

Las interrupciones en el funcionamiento de los sistemas de IA, debido a errores de software o problemas de conectividad, pueden generar desconfianza y dependencia excesiva de las soluciones manuales.

❖ **Falta de interacción humana:**

La ausencia de empatía y comprensión emocional en la interacción con sistemas de IA puede dificultar la resolución de problemas sensibles o generar una percepción de desconexión por parte de los clientes.

❖ **Respuestas incoherentes o confusas:**


En ciertos casos, los sistemas de IA pueden proporcionar respuestas que no son relevantes o que no abordan adecuadamente las consultas, lo que disminuye la confianza en su efectividad.

Relación entre ventajas y desventajas:

Las ventajas están estrechamente ligadas a la eficiencia operativa, accesibilidad y precisión que ofrece la IA, mientras que las desventajas surgen principalmente por limitaciones en la capacidad de la IA para emular la interacción humana y ofrecer soluciones personalizadas a problemas complejos.

Figura 17

Top 5 de ventajas y desventajas más representativas para la población encuestada.



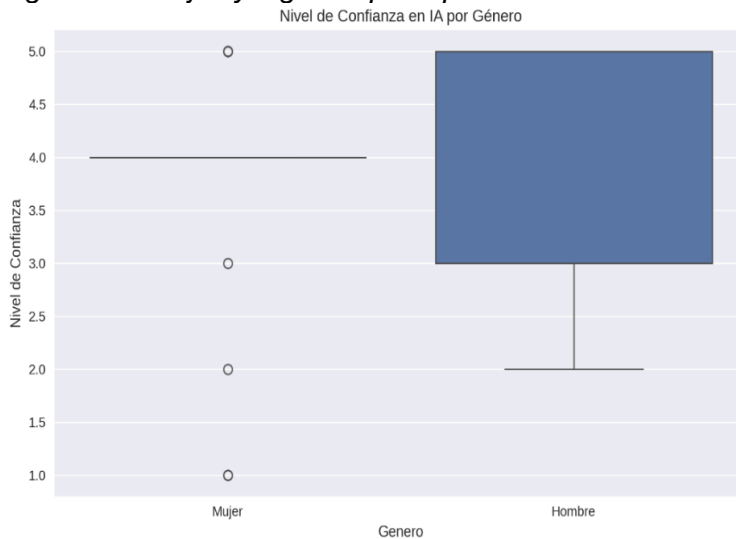
Fuente: Elaboración propia.

- Para mitigar las desventajas, sería fundamental mejorar los algoritmos para proporcionar respuestas más específicas y robustas, además de combinar la IA con atención humana en casos más delicados.

Ahora veremos los análisis según variables seleccionadas: genero, edad y nivel educativo.

Figura 18

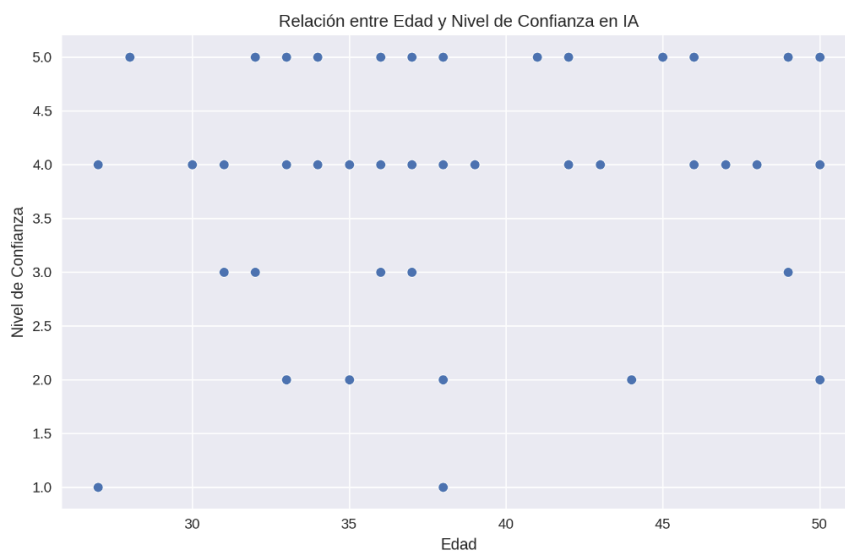
Diagrama de cajas y bigotes que representa el nivel de confianza en IA por género.



Fuente: Elaboración propia.

Figura 19

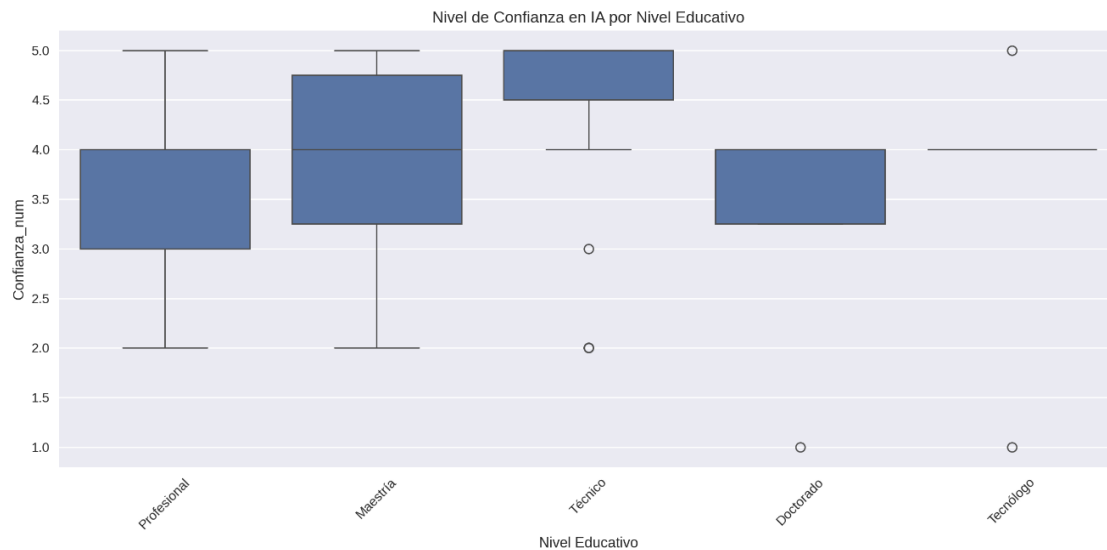
Relación entre la Edad y el nivel de confianza de los clientes en la IA



Fuente: Elaboración propia.

Figura 20

Relación entre el nivel de confianza en IA por nivel educativo



Fuente: Elaboración propia.

Hallazgos principales:

- ❖ La correlación entre edad y confianza en IA es muy baja (0.10), sugiriendo que la edad no es un factor determinante.
- ❖ Los hombres muestran una confianza ligeramente mayor (media 4.0) que las mujeres (media 3.82).
- ❖ Por nivel educativo, los técnicos muestran la mayor confianza (media 4.37), seguidos por tecnólogos (3.87).

Acciones estratégicas para implementar según información recopilada:

1. Mejorar la familiaridad con la IA

Acciones:

- ❖ Programas educativos para clientes: Implementar campañas de comunicación que expliquen qué es la IA, sus beneficios en la banca y cómo puede mejorar su experiencia financiera. Esto puede incluir videos explicativos, seminarios web y guías interactivas.
- ❖ Demostraciones prácticas: Crear tutoriales en línea o en las sucursales donde los clientes puedan interactuar con las funciones de IA, como chatbots o sistemas de recomendación personalizados.
- ❖ Gamificación: Diseñar aplicaciones que utilicen juegos o desafíos interactivos para enseñar a los usuarios cómo usar la IA en sus operaciones bancarias, dando recomendaciones y usos adecuados con el fin de llegar a los distintos tipos de clientes y segmentos que tienen los bancos.

2. Incrementar la percepción de mejora en la experiencia bancaria

Acciones:

- ❖ Personalización avanzada: Implementar IA que analice los datos del cliente para ofrecer recomendaciones financieras personalizadas, como presupuestos, planes de ahorro o inversiones.
- ❖ Optimización del autoservicio: Ampliar las capacidades de los chatbots para resolver consultas complejas, haciendo que sean más específicos y funcionales.
- ❖ Experiencias híbridas: Combinar la interacción de IA con agentes humanos en casos sensibles o más complejos, garantizando una experiencia integral y empática.

- ❖ Atención proactiva: Utilizar IA predictiva para identificar problemas recurrentes o potenciales (como posibles cobros duplicados) y ofrecer soluciones antes de que el cliente lo solicite.

3. Aumentar la confianza en la IA

Acciones:

- ❖ Transparencia en las operaciones: Explicar cómo la IA toma decisiones, asegurando que los clientes entiendan el proceso detrás de las recomendaciones y las operaciones automatizadas.
- ❖ Garantías de seguridad: Reforzar las políticas de protección de datos y destacarlas en las comunicaciones con los clientes para tranquilizarlos sobre la privacidad y seguridad de su información.
- ❖ Retroalimentación del cliente: Habilitar mecanismos que permitan a los clientes calificar y comentar las recomendaciones y servicios proporcionados por la IA. Esto generará confianza al mostrar que sus opiniones son tomadas en cuenta para mejorar.
- ❖ Certificaciones y auditorías: Certificar los sistemas de IA con estándares reconocidos para asegurar su confiabilidad y efectividad, y comunicar estos logros a los usuarios.

4. Potenciar las ventajas y mitigar las desventajas de la IA

Acciones:

Estrategias para las ventajas:

- Ampliar la disponibilidad 24/7 mediante sistemas redundantes que garanticen un servicio ininterrumpido.

- Seguir desarrollando funcionalidades de personalización que permitan a los usuarios adaptar los servicios bancarios a sus necesidades específicas.

Estrategias contra las desventajas:

- Respuestas genéricas: Entrenar a los sistemas de IA con un mayor volumen de datos reales para mejorar la especificidad y la relevancia de las respuestas.
- Fallas técnicas: Implementar protocolos robustos de contingencia y soporte técnico rápido para reducir interrupciones en los servicios de IA.
- Falta de interacción humana: Ofrecer la opción de contactar a un agente humano en cualquier punto de interacción con la IA, especialmente en situaciones emocionales o complejas.

5. Segmentar estrategias según perfiles de clientes

Acciones:

- Adaptar las experiencias: Diseñar estrategias diferenciadas según el nivel de familiaridad de los clientes con la tecnología. Por ejemplo:
- Clientes poco familiarizados: Ofrecer atención más guiada y con opciones más simples.
- Clientes familiarizados: Brindar acceso a funciones avanzadas y más personalizadas.
- Beneficios personalizados: Ofrecer incentivos específicos para retener clientes según sus hábitos financieros, como descuentos en productos financieros basados en sus patrones de uso.

6. Reducir la tasa de abandono y potenciar la retención

Acciones:

- Alertas personalizadas: Implementar sistemas de notificación proactivos que informen sobre oportunidades financieras, fechas de pago, o posibles problemas en sus cuentas.
- Loyalty programs basados en IA: Crear programas de fidelización personalizados donde la IA sugiera recompensas alineadas con las preferencias y necesidades de cada cliente.
- Análisis predictivo del abandono: Utilizar algoritmos de machine learning para identificar clientes en riesgo de abandonar la institución y aplicar estrategias preventivas, como ofertas personalizadas o llamadas de seguimiento.
- Asistencia constante: Hacer que la IA sea el primer punto de contacto para resolver problemas rápidos y canalizar a agentes humanos en casos críticos.

7. Monitoreo y mejora continua

Acciones:

- Análisis de datos en tiempo real: Usar herramientas de análisis de big data para monitorear constantemente la experiencia del cliente y ajustar las estrategias según sea necesario.
- Encuestas post-interacción: Solicitar retroalimentación inmediata después de cada interacción con sistemas de IA para identificar áreas de mejora.
- Pruebas A/B: Implementar mejoras en los servicios de IA de manera experimental en grupos específicos para evaluar su impacto antes de un lanzamiento generalizado.

8. Resultados esperados:

- Mayor confianza en el uso de la IA en servicios bancarios.
- Reducción de la tasa de abandono mediante una experiencia más personalizada y transparente.
- Retención mejorada gracias a la atención proactiva y soluciones centradas en el cliente.
- Incremento en la percepción positiva de la tecnología al abordar sus desventajas de manera tangible.
- Estas estrategias permitirán a los bancos colombianos maximizar el impacto de la inteligencia artificial en la relación con sus clientes, consolidando su competitividad en el mercado.

Discusión

1. Limitaciones del Acceso a Datos y Muestras Representativas

La obtención de datos relevantes en el sector bancario puede estar restringida debido a la confidencialidad y la seguridad de los datos. Esto limita el alcance y precisión de los análisis, ya que algunos datos críticos no son accesibles para investigadores externos o no se pueden verificar independientemente (Radmehr & Bazmara, 2017). Además, la selección de los bancos en la muestra puede sesgar los resultados, dado que no todos los bancos o fintechs tienen el mismo nivel de adopción tecnológica, lo cual limita la generalización de los hallazgos a toda la industria bancaria colombiana (Castaño Gutierrez, 2021).

2. Dependencia en Datos Secundarios

La investigación se basa en gran medida en datos secundarios provenientes de informes de entidades bancarias, bases de datos públicas, estudio o análisis académicos realizados referentes a los temas de esta investigación. Esta dependencia puede limitar la validez, ya que

los datos recopilados pueden no reflejar en su totalidad las necesidades y percepciones de los clientes actuales o contener sesgos de fuente, dado que estas instituciones podrían tener intereses específicos en mostrar resultados positivos sobre el uso de la inteligencia artificial (IA) o se encuentran en fases tempranas de estos tipos de aplicaciones (McKinsey Global Institute, 2024). La falta de datos primarios limita la capacidad de corroborar los resultados obtenidos y a su vez la falta de informes por parte de organizaciones que permitan obtener más detalle sobre la data que se encuentra sobre este sector y que afecte directamente la retención de clientes.

3. Desafíos en la Medición de Variables Complejas

La complejidad inherente a la tasa de abandono de clientes hace que sea difícil medir y controlar todas las variables que afectan su comportamiento (Berry & S.Linoff, 2004). Factores contextuales como la situación económica, cambios regulatorios o incluso crisis específicas, como pandemias, influyen en la fidelización de los clientes y pueden no estar plenamente reflejados en las métricas utilizadas en el análisis. Además, la falta de una estandarización en la forma de medir la satisfacción del cliente entre instituciones puede introducir inconsistencias (Adhikari, Aryal, & Park, 2022)

4. Limitaciones de los Modelos de IA y Machine Learning

Los modelos predictivos utilizados en la investigación, como el algoritmo de random forest, presentan limitaciones en su capacidad para prever comportamientos humanos complejos (Han & Kamber, 2006). Los resultados del modelo dependen en gran medida de la calidad de los datos de entrenamiento, y cualquier sesgo o error en estos datos puede llevar a predicciones inexactas (Ashwini, Muddasir, & Abrar, 2023). Además, estos modelos carecen de adaptabilidad a cambios rápidos en el mercado, lo cual afecta su validez a largo plazo.

5. Falta de Evaluación Directa de Percepciones del Cliente

Aunque la investigación analiza las tasas de abandono y la satisfacción del cliente, no parece contar con datos cualitativos obtenidos directamente de los clientes sobre sus percepciones en relación con la IA (Buha & Bjegovic, 2023). Esta falta de perspectiva directa de

los usuarios puede limitar la comprensión de los factores emocionales y de experiencia que influyen su retención o abandono, haciendo que los resultados sean menos completos y dificultando la identificación de soluciones prácticas desde el punto de vista del cliente.

6. Impacto de Factores Externos en la Retención de Clientes

Factores externos, como el incremento de la competencia de fintechs y cambios en la política monetaria, afectan significativamente la retención de clientes en el sector bancario. Estos factores pueden sesgar los resultados de la investigación, ya que no se pueden controlar completamente en el análisis y pueden influir en la percepción del cliente sobre la IA y otros servicios tecnológicos en la banca (Centro Nacional de consultoría, 2021). Este tipo de variables no siempre se incluyen en los modelos predictivos, lo cual limita la precisión de los resultados.

7. Limitaciones Éticas y de Privacidad en el Uso de IA

El uso de IA en la banca plantea preocupaciones éticas y de privacidad, especialmente en la recopilación y procesamiento de datos personales de clientes. Esto puede limitar el alcance de la implementación de estas tecnologías y afectar la validez de los resultados, ya que los modelos de IA pueden no tener acceso a todos los datos necesarios debido a restricciones regulatorias (Sánchez Torres & Carvajal Sierra, 2015). Además, los clientes pueden percibir el uso de IA como invasivo, lo que podría impactar negativamente en la retención de clientes en vez de mejorarla.

8. Posible Sesgo en las Conclusiones y Recomendaciones

Dado el enfoque en bancos que ya han implementado IA, puede haber un sesgo hacia la demostración de efectos positivos, ya que las instituciones seleccionadas pueden haber tenido más recursos para lograr resultados favorables (Eslava, Maffioli, & Meléndez). Las conclusiones, por tanto, podrían no ser aplicables a instituciones más pequeñas o aquellas con menor grado de adopción tecnológica. Este sesgo de selección también limita la posibilidad de generalizar los hallazgos a todos los sectores de la banca.

El presente estudio se propuso analizar cómo la inteligencia artificial puede transformar la experiencia del cliente en el sector bancario colombiano y en consecuencia, reducir la tasa de abandono y aumentar la retención de clientes. A través de la revisión de las prácticas de bancos, la identificación de patrones en los productos más y menos exitosos, y la evaluación de la percepción de los clientes, se logró identificar una serie de oportunidades y desafíos en la implementación de la IA. Los hallazgos de esta investigación permitieron formular una serie de recomendaciones estratégicas para que las entidades financieras colombianas puedan optimizar el uso de la inteligencia artificial y fortalecer su relación con los clientes.

Conclusiones y Trabajo Futuro

La investigación permite resaltar el papel transformador de la inteligencia artificial (IA), evidenciado tanto en el análisis cualitativo como cuantitativo, en el sector bancario colombiano, particularmente en la mejora de la experiencia del cliente. Estos resultados están directamente alineados con los objetivos específicos planteados inicialmente:

- En relación con el primer objetivo específico, que buscó reconocer prácticas exitosas de IA en bancos representativos, se identificaron diversas iniciativas implementadas por entidades referentes que han logrado personalizar servicios, predecir necesidades de los clientes, optimizar la atención mediante asistentes virtuales y detectar fraudes de manera proactiva. Estas prácticas han facilitado interacciones más fluidas, alineadas con las expectativas actuales de los usuarios.
- En cuanto al segundo objetivo específico, orientado a identificar patrones y variables que influyen en el abandono de clientes, los modelos predictivos realizados permitieron evidenciar factores críticos como: la edad, el género y el nivel de ingresos, tienen una clara influencia en la decisión de permanencia o abandono del cliente. No obstante, cabe destacar que ciertas limitaciones asociadas a la calidad y disponibilidad de datos

restringieron parcialmente la robustez de estos modelos predictivos, subrayando así la importancia futura de contar con fuentes de información más completas para fortalecer estas predicciones.

- Respecto al tercer objetivo específico, que buscó evaluar la percepción de los clientes frente a la implementación de IA en la adquisición de productos financieros, se aplicaron encuestas directas a usuarios del sector financiero colombiano, explorando aspectos relacionados con familiaridad, confianza, percepción de personalización y valoración de la experiencia mejorada por la IA. Los resultados indicaron que, aunque la mayoría de usuarios valora positivamente aspectos como rapidez y precisión en soluciones inteligentes, también se observó que los cohortes con mayor edad son más sensibles en la atención personalizada. Sin embargo, un número considerable manifestó preocupaciones sobre privacidad y ausencia de interacción humana. No obstante, una limitación identificada fue la imposibilidad de correlacionar directamente estas percepciones con comportamientos reales posteriores (abandono o fidelización), debido a restricciones de disponibilidad de datos integrados. Esto representa una oportunidad clave para futuras investigaciones.

Con base en estos hallazgos y alineados con los objetivos específicos mencionados, se proponen estrategias concretas para optimizar la experiencia del cliente, fortalecer la retención, y captar nuevos usuarios en la banca colombiana mediante el uso de la IA. Entre estas estrategias se destacan:

- Fomentar la familiaridad con la tecnología: Implementar programas educativos y herramientas intuitivas que faciliten la adaptación del usuario a la IA en especial para aquellos segmentos con mayor desconfianza o poco familiarizados con la tecnología.

- Personalizar la experiencia del usuario: Aprovechar los modelos predictivos para ofrecer productos y servicios altamente personalizados y ajustados a las necesidades específicas de cada cliente.
- Brindar atención proactiva: Implementar un modelo predictivo impulsado por IA que permitan identificar alertas con posibles patrones o comportamientos relacionado al abandono. La identificación anticipada permitirá crear acciones de ofertas dirigidas o personalizadas, para evitar abandonos potenciales.
- Combinar inteligentemente IA y atención humana: Balancear soluciones automatizadas con atención humana en situaciones complejas o emocionalmente delicadas para mejorar la confianza y aceptación por parte de los clientes.
- Mitigar riesgos: Establecer protocolos robustos de protección de datos y manejo de contingencias técnicas para fortalecer la confianza en los sistemas automatizados.
- Segmentar estratégicamente las acciones: Aplicar estrategias diferenciadas según las variables identificadas en los modelos predictivos (edad, género, familiaridad tecnológica) para maximizar la efectividad de las iniciativas.
- Monitorear continuamente: Tener métricas establecidas como indicadores o gráficos que permitan evidenciar periódicamente el comportamiento de los clientes inactivos o desvinculados.

Estas iniciativas buscan no solo consolidar la confianza del cliente actual, sino también potenciar la capacidad del sector bancario para atraer nuevos usuarios, mejorando su posición competitiva en un mercado altamente digitalizado y competitivo.

Recomendaciones para Trabajo Futuro

Investigación Longitudinal sobre el Impacto de la IA en la Retención de Clientes

Una posible investigación futura podría abordar un estudio longitudinal para evaluar los efectos de la IA en la retención de clientes en un período más extenso. Esto permitiría analizar si las mejoras en la retención se mantienen en el tiempo y si las técnicas de IA pueden adaptarse a cambios de comportamiento del cliente, especialmente en un sector tan dinámico como el bancario.

Análisis de la Eficiencia Comparativa de Diferentes Algoritmos de IA

Sería valioso realizar estudios comparativos entre diferentes modelos de IA, como redes neuronales y algoritmos de clustering, para identificar cuáles son los más efectivos en predecir comportamientos de abandono. Esta investigación podría identificar mejoras en la precisión de los modelos, optimizando la implementación de IA para cada banco en función de sus necesidades.

Estudio de Percepción y Satisfacción del Cliente en Relación con la IA

Se podría plantear una investigación que recoja datos cualitativos de los clientes para evaluar cómo perciben la personalización y la automatización en sus interacciones bancarias. Este análisis permitiría diseñar estrategias de IA centradas en la experiencia del cliente, promoviendo una relación más positiva y de mayor confianza con los bancos.

Exploración de Estrategias Éticas y Regulatorias en la Implementación de IA

A futuro, sería conveniente investigar cómo los bancos pueden implementar IA de manera ética y conforme a la normativa de privacidad. Esto incluiría el desarrollo de protocolos de transparencia y políticas de privacidad para que los clientes puedan entender y confiar en el uso de sus datos personales en los sistemas de IA del banco.

Evaluación de la Adaptabilidad de los Modelos de IA a Cambios del Mercado

Investigar la capacidad de los modelos de IA para adaptarse a factores externos, como las fluctuaciones económicas o los cambios en las preferencias de los clientes, que puedan afectar la retención. Esto ayudaría a asegurar que la IA pueda seguir siendo útil en escenarios cambiantes y ofrecer recomendaciones adaptativas según las condiciones del mercado.

Evaluar la correlación entre percepción y comportamiento real de los clientes

Se recomienda que futuros estudios integren métodos de análisis cuantitativo que permitan establecer correlaciones claras entre la percepción de los clientes respecto a la implementación de inteligencia artificial y su comportamiento real posterior, especialmente en términos de abandono o fidelización efectiva. Para lograrlo, sería necesario acceder a información longitudinal que combine datos cualitativos (encuestas de percepción) con registros cuantitativos del comportamiento del cliente (uso de productos, abandono real, fidelización), lo cual permitirá validar empíricamente la influencia real de la percepción sobre las decisiones efectivas de los clientes en el sector bancario.

Referencias

Adhikari, R. P., Aryal, T., & Park, G. (2022). *Impact of artificial intelligence on comercial bank's ATM. Farabi Journal of Social Sciences*, 32-38.

<https://doi.org/10.26577/FJSS.2022.v8.i2.06>

Ashwini, T. G., Muddasir Ahmed Khan, N., & Hussain, A. (2023,15 de mayo). Impact of Artificial Intelligence in banking Sector. *REST Journal on Banking, Accounting and Business*, 51-55. <https://doi.org/10.46632/jbab/2/3/7>

Asiedu, E. (2016). A Study of use and impact of market segmentation practices on bank performance: With special reference to commercial banks in Colombia. Neiva, Huila, Colombia. Recuperado de <https://www.hilarispublisher.com/open-access/a-study-of-use-and-impact-of-market-segmentation-practices-onbank-performance-with-special-reference-to-commercial-banks-incolombi-2167-0234-1000162.pdf>

Asobancaria. (2019). *Desafios-del-riesgo-cibernetico-en-el-sector-financiero-para-Colombia-y-America-Latina*. Organization of American States. Recuperado de: <https://www.oas.org/es/sms/cicte/docs/Desafios-del-riesgo-cibernetico-en-el-sector-financiero-para-Colombia-y-America-Latina.pdf>

Asobancaria. (2022). *La reinención financiera en la era digital*. Recuperado de https://asobancaria.com/wp-content/uploads/La_reinencion_financiera_en_la_era_digital-2022.pdf

Asobancaria. (2023, 15 de mayo). *Inteligencia artificial en la banca*. Recuperado de <https://asobancaria.com/ws/semanas-economicas/1376-BE.pdf>

Barba, Ó. (2023, 11 de julio). La relación entre el análisis del sentimiento y la predicción del mercado financiero. Recuperado de: <https://coinscrapfinance.com/es/banking-innovation/analisis-de-sentimiento-prediccion-mercado-financiero/>

Berry, M. J., & S. Linoff, G. (2004). *Data mining techniques: For marketing, sales, and customer relationship management*. Wiley.

Bran-Guevara, J., Hernández-Ávila, L. F., & McAllister-Harker, D. (2022). *Servicios Financieros Digitales en Colombia: Una caracterización y análisis de riesgos*. Banco de la República:

Recuperado de:

https://repositorio.banrep.gov.co/bitstream/handle/20.500.12134/10274/be_1193.pdf

Buha, V., & Bjegovic, M. (January de 2023). *Application of artificial intelligence in the banking sector*. <https://doi.org/10.5937/bezbednost2301087B>

Castaño Gutierrez, J. (2021, 26 de Noviembre). *Transformación digital y evolución de la industria financiera*. Superintendente Financiera de Colombia:

<https://www.superfinanciera.gov.co/loader.php?lServicio=Tools2&lTipo=descargas&lFuncion=descargar&lIdFile=1057055>

Castañón, H., & Subero, C. (2020). *Transformación digital de los servicios financieros Centrarse en la experiencia del cliente*. KPMG. Recuperado de

https://assets.kpmg.com/content/dam/kpmg/cr/pdf/DE-transformacion-servicios-financieros_2020.pdf

Centro Nacional de consultoría. (2021). *El salto digital: Evidencias de una nueva era*. Banca de las oportunidades. Recuperado de

<https://www.bancadelasoportunidades.gov.co/sites/default/files/2021-04/CNC%20AD%202021%20AHORA%20BCO.pdf>

CIV. (s.f.). *Primer estudio que incluye la banca tradicional y los segmentos de microcrédito y banca retail del país: Satisfacción de los clientes y experiencia emocional*. Bogotá.

Recuperado de

<https://www.civ.com.co/sites/default/files/EI%20ranking%20de%20la%20satisfacci%C3%B3n%20de%20los%20clientes%20de%20la%20banca%20en%20Colombia%202019.pdf>

- Eslava, M., Maffioli, A., & Meléndez, M. (s.f.). *Second-tier government banks and access to credit*. Washington. Recuperado de https://www.researchgate.net/publication/235712830_Second-tier_Government_Banks_and_Access_to_Credit_Micro-Evidence_from_Colombia
- Fernández, A. (2019, 29 de marzo). *Artificial intelligence in financial*. SSRN. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3366846
- Fondo de Garantías de Instituciones Financieras [Fogafín]. (s.f.). *Entidades inscritas*. Recuperado de <https://www.fogafin.gov.co/que-es-el-seguro-de-depositos/entidades-inscritas>
- Han, J., & Kamber, M. (2006). *Data Mining: Concepts and Techniques*. Morgan Kaufmann Publishers.
- Lara Rubio, J., Liébana Cabanillas, F. J., & Martínez Fiestas, M. (2013). *Lealtad bancaria y la medida del riesgo de abandono*. Harvard Deusto Business Research.
- McKinsey Global Institute. (2024, 22 de marzo). Generative AI is transforming financial services, offering opportunities for efficiency and innovation. As banks race to deploy gen AI, the right operating model can help unlock its potential. Recuperado de <https://www.mckinsey.com/industries/financial-services/our-insights/scaling-gen-ai-in-banking-choosing-the-best-operating-model>
- Mndebele, S., & Mayayise, T. (2023). The Issues, Challenges and impacts of implementing machine learning in the financial services sector. *EPiC Series in Education Science*, 31-46. <https://doi.org/10.29007/6sn7>
- Nasdaq: EQIX. (2023, 14 de junio). *Más del 88% de los responsables de TI en Colombia afirman que ya utilizan la inteligencia artificial (IA) para operaciones de e-commerce y ciberseguridad*. Recuperado de <https://www.equinix.lat/newsroom/press-releases/2023/06/m-s-del-88-de-los-responsables-de-ti-en-colombia-afirman-que-ya-utilizan-la-inteligencia-artificial-ia-para-operaciones-de-e-commerce-y-ciberseguridad>

Radheshyam, K. (s.f.). *Bank Customer Churn. Bank Customer Data for Customer Churn*

Kaggle. Recuperado de <https://www.kaggle.com/datasets/radheshyamkollipara/bank-customer-churn>

Radmehr, E., & Bazmara, M. (2017). A survey on business intelligence solutions in banking industry and big data applications. *International Journal of Mechatronics*.

Recuperado de

https://www.researchgate.net/publication/313578177_A_Survey_on_Business_Intelligence_Solutions_in_Banking_Industry_and_Big_Data_Applications

Rafiqul, I., & Ahsan, H. (March de 2015). A data mining approach to predict prospective business sectors for lending in retail banking using decision tree. Bangladesh.

Recuperado de

https://www.researchgate.net/publication/224603702_A_data_mining_approach_to_strategy_prediction

Sánchez Torres, J., & Carvajal Sierra, F. (2015, agosto). *Measurement on usage of the internet banking in Colombia*. *Journal of Internet Banking and Commerce*.

<https://doi.org/10.4172/1204-5357.1000105>

Stefanini. (2023, 18 de julio). *Machine Learning: Ventajas para bancos e instituciones*

financieras. Recuperado de <https://stefanini.com/es/tendencias/articulos/machine-learning-ventajas-para-bancos-e-instituciones-financieras>

Superfinanciera. (2023). *Transacciones por canales y puntos de atención*. Recuperado de

<https://www.superfinanciera.gov.co/powerbi/reportes/507/487/>

Turing, A. (1950). I.—Computing machinery and intelligence. *Mind*, 59(236), 433-460.

<https://doi.org/10.1093/mind/LIX.236.433>

Anexos:

A. Anexo. Entrevista sobre IA y retención de clientes

El uso de inteligencia artificial en la banca, especialmente para mejorar la retención de clientes, representa un avance significativo, pero debe evaluarse en un contexto amplio. Desde el punto de vista de admisión de riesgos, la IA ofrece ventajas indiscutibles: permite identificar patrones de comportamiento que antes eran invisibles, anticiparse a posibles abandonos y ajustar estrategias para fortalecer la relación banco-cliente. Sin embargo, su aplicación no está exenta de riesgos y desafíos.

Por un lado, está la capacidad de la IA para procesar grandes volúmenes de datos y personalizar servicios. Esto no solo mejora la experiencia del cliente, sino que también permite a los bancos optimizar sus recursos al priorizar aquellos clientes con mayor riesgo de abandonar o con un alto valor estratégico. Esta eficiencia es atractiva y, en muchos casos, necesaria en un mercado competitivo.

Sin embargo, desde una perspectiva ética y profesional, la IA puede generar decisiones automatizadas que, aunque eficientes, podrían resultar cuestionables. Un algoritmo, por ejemplo, podría identificar que ciertos perfiles demográficos están asociados a un mayor riesgo de abandono o incumplimiento, lo que podría llevar a una segmentación que roce la discriminación. Esto plantea preguntas importantes: ¿es ético priorizar clientes basándose únicamente en patrones estadísticos? ¿Cómo aseguramos que estas decisiones sean transparentes y no afecten la equidad de acceso a los servicios?

Otro punto crítico es la dependencia de datos. Los modelos de IA son tan buenos como la calidad de los datos con los que trabajan. Si existen sesgos en los datos históricos, la IA puede amplificarlos, reproduciendo desigualdades o generando resultados inexactos. Además, el manejo de datos sensibles conlleva riesgos en términos de privacidad y confianza del cliente, lo que podría tener implicaciones legales y reputacionales.

En mi experiencia, la IA debe ser vista como una herramienta complementaria, no como un reemplazo del juicio humano. Si bien puede facilitar la toma de decisiones, siempre debe haber un control humano que evalúe los resultados y garantice que se ajusten a los valores éticos y las normativas. Implementar IA sin estos controles podría poner en riesgo no solo la relación con los clientes, sino también la estabilidad del banco frente a posibles sanciones regulatorias.



Rafael Fernando Chinchilla Mesa

Admisión CIB - Profesional Senior

rafaelfernando.chinchilla@bbva.com

Global Risk Management - Carrera 9 No 72 - 21 Piso 4 Bogotá D.C.

B. Anexo. Formato de encuestas grupo focal uso de IA.

Encuestas grupo focal uso de IA-

El propósito de esta encuesta es recopilar información representativa sobre los diversos usos y aplicaciones actuales de la inteligencia artificial (IA) en el sector bancario en Colombia. Los datos recolectados serán utilizados exclusivamente con fines académicos.

Su participación es completamente voluntaria y se realizará únicamente si usted está de acuerdo. Agradecemos su tiempo y disposición para contribuir a este estudio.

* Indica que la pregunta es obligatoria.

Datos Demográficos



1. Edad *

2. Genero *

Marca solo un óvalo.

Hombre

Mujer

Otros: _____

3. Nivel Educativo *

Marca solo un óvalo.

Bachiller

Técnico

Tecnólogo

Profesional

Maestría

Otros: _____

4. Ocupación *

Marca solo un óvalo.

Estudiante universitario

Empleado

Independiente

5. ¿Cuánto tiempo hace que está utilizando servicios de banca digital? *

Marca solo un óvalo.

- Menos de 1 año
- 1 Año
- 2 Años
- 3 Años

Percepción de la IA en la Banca

6. ¿Con qué frecuencia utiliza los servicios de banca digital? *

Marca solo un óvalo.

- Semanal
- Mensual
- Diaria

7. ¿En qué medida está familiarizado con el concepto de inteligencia artificial? *

Marca solo un óvalo.

- Algo familiarizado
- Poco o nada familiarizado
- Muy familiarizado
- Muy poco

8. ¿Ha utilizado chatbots o asistentes virtuales en otros servicios? *

Marca solo un óvalo.

- Sí
- No
- Tal vez

9. ¿Conoce los beneficios de la IA en la atención o prestación de sus servicios bancarios que tiene actualmente? (Si/No) ¿Cuáles? *

10. ¿Qué tan fácil le resulta utilizar los servicios de banca digital que utilizan inteligencia artificial (CHATBOT)? *

Marca solo un óvalo.

- Muy fácil
- Fácil
- Ni fácil ni difícil
- Difícil

11. ¿Confía en las recomendaciones de productos financieros que le brinda la inteligencia artificial? *

Marca solo un óvalo.

- Muy de acuerdo
- De acuerdo
- Ni de acuerdo ni en desacuerdo
- En desacuerdo,
- Muy en desacuerdo

12. ¿Cree que la inteligencia artificial ha mejorado su experiencia bancaria en general? *

Marca solo un óvalo.

- Si
- No
- Indiferente

13. ¿Cuáles son las principales ventajas que percibe en el uso de la inteligencia artificial en la banca? *

14. ¿Cuáles son las principales desventajas que percibe en el uso de la inteligencia artificial en la banca? *

15. ¿Qué tan importante es para usted la interacción humana en sus relaciones con el banco? *

Marca solo un óvalo.

- Muy importante
- Importante
- Ni importante ni poco importante
- Poco importante
- Nada importante

16. ¿Recomendaría los servicios de banca digital de su banco a un amigo o familiar? *

Marca solo un óvalo.

- Si
- No
- Tal vez

17. ¿Ha tenido alguna experiencia negativa al utilizar los servicios de banca digital con inteligencia artificial? *

Marca solo un óvalo.

- Sí
- No