

Universidad de Lima
Facultad de Ingeniería
Carrera de Ingeniería de Sistemas



SISTEMA DE RECOMENDACIÓN DE PRODUCTOS FINANCIEROS PARA TELEVENTAS

Trabajo de suficiencia profesional para optar el Título Profesional de Ingeniero de
Sistemas

Joaquin Arnaldo Casanova Muchotrigo

Código 20111665

Claudia Karina Cerrillo Alvarez

Código 20122626

Asesor

Pedro Humberto Saravia Torres

Lima - Perú

Junio de 2024

**FINANCIAL PRODUCT
RECOMMENDATION SYSTEM
FOR CALL CENTER**



TABLA DE CONTENIDO

RESUMEN	vii
ABSTRACT.....	viii
CAPÍTULO I: INTRODUCCIÓN.....	1
1.1 Diagnóstico.....	1
1.1.1. Diagnóstico de necesidades.....	1
1.1.2. Definición e impacto del problema	3
1.1.3. Antecedentes de soluciones previas	6
1.2 Análisis de la necesidad, el cliente y el mercado potencial	7
1.2.1. Análisis del mercado potencial	7
1.2.2. Segmentación del mercado.....	8
1.3 Propuesta solución y su modelo de negocio.....	9
1.3.1. Justificación.....	13
CAPÍTULO II: FUNDAMENTOS TEÓRICOS.....	16
2.1 Componentes principales de un sistema de recomendación	16
2.2 Componentes del sistema de recomendación.....	17
2.3 Algoritmos de aprendizaje supervisado	17
2.3.1. Técnicas de performance de algoritmo	18
2.3.2. Algoritmos de filtrado colaborativo: memoria basada, modelo basado .	19
2.3.2.1. Filtrado basado en contenido	19
2.3.2.2. Filtrado colaborativo.....	19
2.3.2.3. Filtrado híbrido	19
2.4. Diseños de sistema de recomendación con Python	19
2.5. Machine Learning	20
2.5.1. Análisis exploratorio.....	20
2.5.2. Modelamiento	20
2.5.3. Despliegue	21
2.5.4. Monitoreo	22
2.6. Automated machine Learning.....	23
2.7. Cómo diseñar pilotos	24
2.8. Sistema de recomendación con GENAI	24

2.9. Técnicas para implementar pilotos	25
CAPÍTULO III: DEFINICIÓN DEL PROYECTO	26
3.1. Definición del proyecto	26
3.2. Objetivos del proyecto	28
3.3. Alcance del proyecto	28
3.4. Roles y responsabilidades del equipo del proyecto	29
3.5. Cronograma y riesgos iniciales del proyecto	29
3.6. Indicadores de gestión del proyecto	31
3.7. Recursos económicos.....	32
CAPÍTULO IV: DESARROLLO DEL PRODUCTO MÍNIMO VIABLE	34
4.1 Alcance del producto mínimo viable	34
4.1.1. Selección de Leads	34
4.1.2. Despliegue del MVP.....	34
4.1.3. Medición de resultados	35
4.2 Supuestos clave y técnicas de validación a nivel de clientes y de usuarios	35
4.3 Diseño del producto mínimo viable	36
4.4 Implementación y análisis de resultados del producto mínimo viable....	38
CONCLUSIONES	42
RECOMENDACIONES	43
GLOSARIO DE TÉRMINOS	44
REFERENCIAS.....	47

ÍNDICE DE TABLAS

Tabla 3. 1 Etapas de la aplicación del Boosting	26
Tabla 3. 2 Roles y responsabilidades del equipo del proyecto	29
Tabla 3. 3 Cronograma del proyecto.....	30
Tabla 3. 4 KPI's de gestión del proyecto	32
Tabla 3. 5 Recursos económicos suficientes.....	33
Tabla 4. 1 Métricas de medición de resultados.....	35
Tabla 4. 2 Resultados del MVP	39



ÍNDICE DE FIGURAS

Figura 1. 1 Promedio de ventas por canal 2023.....	1
Figura 1. 2 Histórico de los últimos seis meses de gestión de ventas telefónicas	2
Figura 1. 3 Mapa de empatía de ejecutivos del call center	4
Figura 1. 4 Lean Canvas	10
Figura 1. 5 Mapa del proceso de campañas	12
Figura 3. 1 Etapas de la aplicación del Boosting.....	27
Figura 4. 1 Interfaz de usuario realizada en el Amazon Web Services	36
Figura 4. 2 Flujograma de la interfaz de programación.....	37
Figura 4. 3 Interfaz de usuario final.....	38
Figura 4. 4 Resultados en torno a la pregunta: ¿Sientes que los datos que te brindamos fueron útiles?.....	40
Figura 4. 5 Resultados en torno a la pregunta: ¿Cómo te sentiste con la nueva plataforma?	40
Figura 4. 6 Resultados en torno a la pregunta: ¿Qué te gustaría experimentar en una nueva web para obtener información sobre los clientes?	41
Figura 4. 7 Resultados en torno a la pregunta: ¿Qué clúster de información te resultó más útil?.....	41

RESUMEN

El objetivo general del proyecto fue optimizar el proceso de ventas telefónicas de productos financieros, específicamente el producto Extracash, mediante la implementación de un sistema de recomendación basado en modelos predictivos y técnicas de aprendizaje automático. La metodología empleada incluyó entrevistas empáticas con ejecutivos de ventas telefónicas, análisis del mercado financiero, segmentación del mercado objetivo y la implementación de algoritmos de filtrado colaborativo, tanto de enfoque basado en memoria como en modelos. Tras la implementación del sistema de recomendación, se observó un aumento significativo en la efectividad de las ventas. El grupo piloto seleccionado por el sistema logró mayores ventas y tasas de conversión en comparación con el grupo control. Estos resultados destacan el potencial de las tecnologías de inteligencia artificial y análisis de datos para mejorar la eficiencia y efectividad en el proceso de ventas telefónicas en el sector financiero.

Palabras clave: Ventas telefónicas, modelo recomendador, efectividad, feedback, plataforma de gestión

ABSTRACT

The overall objective of the project was to optimise the telephone sales process for financial products, specifically the Extracash product, by implementing a recommendation system based on predictive modelling and machine learning techniques. The methodology employed included empathic interviews with telephone sales executives, analysis of the financial market, segmentation of the target market and the implementation of collaborative filtering algorithms, both memory-based and model-based approaches. Following the implementation of the recommendation system, a significant increase in sales effectiveness was observed. The pilot group selected by the system achieved higher sales and conversion rates compared to the control group. These results highlight the potential of artificial intelligence and data analytics technologies to improve the efficiency and effectiveness of the telephone sales process in the financial sector.

Keywords: Telephone sales, referral model, effectiveness, feedback, management platform.

CAPÍTULO I: INTRODUCCIÓN


1.1 Diagnóstico

1.1.1. Diagnóstico de necesidades

En un entorno altamente competitivo como el sector financiero, es crucial tener claridad sobre la contribución en ventas de cada canal. Esto permite al banco tomar decisiones comerciales informadas para adquirir nuevos clientes y fidelizar a los ya existentes.

En la empresa donde trabajamos, existe un canal que, durante más de 10 años, ha disputado consistentemente los tres primeros puestos en términos de contribución a las ventas: las ventas telefónicas. En lo que va del año 2023, este canal ha aportado un 22.7% de las ventas totales en campaña, con tan solo 250 colaboradores. Esta proporción de contribución es equivalente a la de la red de tiendas, que cuenta con 1,922 colaboradores. Es decir, las ventas telefónicas generan las mismas ventas que la red de tiendas, utilizando 7.5 veces menos personal para gestionar a los clientes y potenciales clientes. En la **Figura 1. 1** Promedio de ventas por canal 2023, se presenta la distribución de ventas por canal en el año 2023:

Figura 1. 1 Promedio de ventas por canal 2023

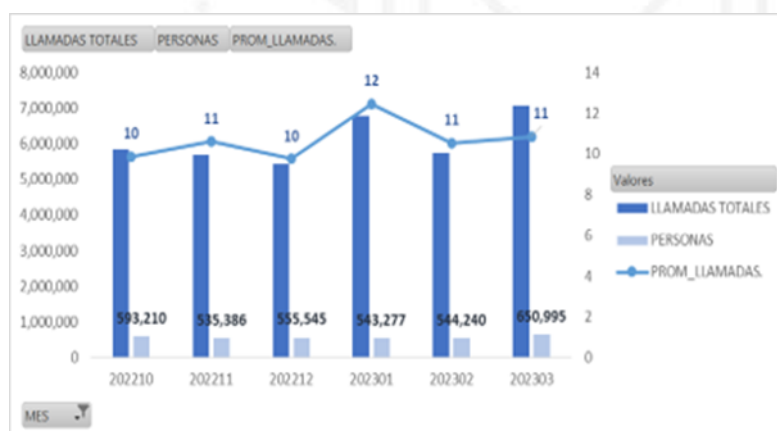


En la actualidad, este canal se encarga de gestionar 13 productos, los cuales están dirigidos a diferentes segmentos de clientes que tienen diferentes características y preferencia. Luego de generar la actualización de las campañas, este canal es de los

primeros en comenzar a gestionar las bases que reciben, para intentar tener un contacto directo con el cliente o potenciales clientes, y, de esa forma, ofrecerles de primera mano algún producto del banco, esto con la finalidad de lograr un mayor número de ventas y que cada asesor pueda llegar a su meta de venta del mes y conseguir sus comisiones por ello. Sin embargo, el canal presenta varias limitaciones en su gestión. Inicialmente, la base de datos compartida para ser contactada no está bien perfilada, ya que los leads reciben múltiples ofertas y los ejecutivos de ventas no pueden identificar qué producto ofrecer a cada persona. Esto implica que el equipo de datos del canal de ventas telefónicas deba comenzar su jornada laboral, en los días de recarga de base, aproximadamente a las 5 a.m. para limpiar y ordenar las ofertas. Estas ofertas se organizan según experiencias previas de efectividad por producto. Este proceso es el principal motivo de la falta de cierres de ventas, ya que el perfil de los leads no es el más adecuado.

Asimismo, el canal de ventas telefónicas realiza más de 6 millones de llamadas totales al mes, contactando aproximadamente a 600,000 personas. Esto implica que, en promedio, deben llamar a una persona 11 veces al mes para intentar venderle un producto. Este elevado número de intentos resulta en un porcentaje de contacto efectivo del 4%, lo que complica significativamente la gestión para los ejecutivos de ventas, como se muestra en la **Figura 1. 2** Histórico de los últimos seis meses de gestión de ventas telefónicas.

Figura 1. 2 Histórico de los últimos seis meses de gestión de ventas telefónicas



A todo lo mencionado anteriormente, hay que sumarle que los ejecutivos de ventas telefónicas trabajan con una interfaz de un aplicativo llamado “PureConnect”, la cual no brinda toda la información que necesitan para poder cerrar la venta. Este aplicativo cuenta únicamente con información general de la campaña del producto seleccionado para gestionar: nombre de la persona a la que están llamando, número de teléfono, producto

ofertado, datos demográficos y speech de venta, el cual concatena únicamente los datos mostrados. Por lo tanto, necesitamos una solución que permita segmentar mejor nuestros clientes optimizando la carga operativa del armado de perfiles y facilite la venta de los operadores a través de una plataforma más intuitiva y con información que genere valor.

1.1.2. Definición e impacto del problema

Siguiendo los pasos de la metodología de Design Thinking, realizamos entrevistas empáticas con los ejecutivos de ventas telefónicas, quienes son los representantes del banco de cara al cliente, con el propósito de comprender y conectar emocionalmente con ellos buscando entender sus experiencias, necesidades, deseos y perspectivas, para finalmente obtener insights que nos permitan identificar sus necesidades reales.

Además, tuvimos la oportunidad de reunirnos presencialmente con 31 ejecutivos de ventas telefónicas. A aquellos que no pudieron asistir a la reunión por motivos laborales, les enviamos entrevistas anónimas, solicitando que respondieran en párrafos abiertos para evitar sesgos. En total, recibimos respuestas de 13 ejecutivos adicionales, sumando así 44 ejecutivos entrevistados, lo que representa el 18% del total.

Luego de las entrevistas y respuestas obtenidas, realizamos un mapa de empatía con todo lo recolectado de los ejecutivos, el cual se muestra en la **Figura 1. 3** Mapa de empatía de ejecutivos del call center.

Figura 1. 3 Mapa de empatía de ejecutivos del call center



Como principales hallazgos tenemos:

1. ¿Qué piensan y sienten?

- a. "Preocupación por llegar a la meta".
- b. "Frustración por llamadas con clientes complicados y llamadas cortadas".
- c. "Necesitan información más precisa y personalizada que genere valor para cerrar las ventas".

2. ¿Qué ven?

- a. "Las personas no aceptan el producto ofrecido porque no es de su interés".
- b. "Muchas llamadas que no timbran, son números equivocados o cortadas".
- c. "Pocas opciones/herramientas para cerrar las ventas".

3. ¿Qué dicen y hacen?

- a. "Intentan tener una conversación empática con las personas para intentar venderles".
- b. "Registran el resultado de las llamadas con las opciones que encuentran".
- c. "Solicitan mejores bases para vender más".

4. ¿Qué oyen?

- a. "Quejas y malos tratos de clientes por constantes llamadas".
- b. "Quejas de sus compañeros por el mal perfilamiento de las bases".
- c. "Consultas sobre los beneficios extras que obtendrían las personas por aceptar el producto".

5. Esfuerzos

- a. "Gran número de llamadas para intentar contactar a una persona y venderle, lo cual se convierte en ineficiencia".
- b. "Frustración y cansancio, luego de que el cliente finalmente contestó no tener la información suficiente para vender".

En base a estos hallazgos planteamos los siguientes point of view (POV) de los ejecutivos que nos dieron pie para plantear nuestra solución:

- a. PoV1: Los ejecutivos de ventas telefónicas desean gestionar adecuadamente a los

clientes para alcanzar sus metas mensuales y recibir sus bonificaciones. Sin embargo, los leads a los que llaman no están bien perfilados, ya que no aceptan los productos porque no los necesitan o no les interesan. Estas llamadas infructuosas les quitan tiempo valioso de gestión diaria.

- b. PoV2: Los ejecutivos de ventas telefónicas quieren cerrar la venta lo más pronto posible, dado el gran esfuerzo que tienen que hacer para contactar a las personas y que ellas contesten; sin embargo, una vez logrado el contacto con la persona, la información que actualmente se les muestra en su aplicativo de ventas es muy genérica por producto, lo cual no permite dar una oferta personalizada con todos los beneficios.

1.1.3. Antecedentes de soluciones previas

En el trabajo realizado por Ke et al. (2023), plasmado en su libro *Product Offer and Pricing Personalization in Retail Banking*, se aprovecharon las nuevas capacidades de los modelos de recomendación para cambiar el enfoque de los bancos minoristas. En lugar de generar ofertas genéricas, los bancos ahora pueden centrarse en los clientes y brindarles ofertas que realmente cubran sus necesidades.

La solución que brindaron fue la personalización de ofertas y tasas, para ello desarrollaron modelos que incluyen el análisis del flujo de fondos, modelos de respuesta y agrupamiento de segmentación, y medición de la vida útil del cliente. Los datos sobre el uso del producto y los patrones de transacción respaldan la segmentación de clientes, lo que permite anticipar sus necesidades futuras y activar ventas adicionales y comunicaciones personalizadas. Una estrategia de marketing personalizada puede brindar muchos beneficios a la banca minorista, incluida una mayor retención de clientes, una mayor participación de la cartera, rentabilidad de ventas por cliente y satisfacción del cliente.

El proyecto mencionado previamente se centra en la creación de modelos que permitan personalizar de manera más efectiva las ofertas ofrecidas a los clientes. En contraste, nuestro enfoque implica el desarrollo de un sistema de recomendación de las mejores ofertas para los clientes finales a través del canal de ventas telefónicas. Además de proporcionarle al canal una base de datos de mayor calidad, también le brindamos una plataforma donde pueden acceder a esta información, junto con datos relevantes de los clientes, con el objetivo de mejorar su discurso de ventas y lograr la venta final de manera

más efectiva.

Así también, Song et al. (2021) presentaron un estudio con el fin de introducir un sistema de entrenamiento innovador llamado SmartSales, diseñado específicamente para mejorar la capacitación de representantes de ventas telefónicas en empresas. Utilizando inteligencia artificial como su motor principal, SmartSales buscó recopilar información valiosa de los diálogos de ventas entre clientes y vendedores experimentados para proporcionar un enfoque efectivo en el desarrollo de habilidades para vendedores jóvenes. Para lograr esto, se recopilaron datos de conversaciones reales de ventas y se utilizaron algoritmos de procesamiento de lenguaje natural para analizar y extraer patrones y técnicas efectivas utilizadas por vendedores experimentados. Estos datos se utilizaron para generar contenido de capacitación personalizado para vendedores novatos, proporcionando un enfoque práctico y orientado a resultados en el proceso de formación. Se logró recopilar una cantidad significativa de datos de conversaciones de ventas reales, y los algoritmos de inteligencia artificial demostraron ser efectivos en la identificación de patrones y estrategias exitosas utilizadas por vendedores experimentados. Además, la generación de contenido de capacitación personalizado mostró mejoras tangibles en las habilidades de venta de los representantes más jóvenes, lo que se reflejó en un aumento en la eficiencia y el rendimiento de las ventas.

En conclusión, SmartSales representó una herramienta poderosa y eficiente para mejorar la formación de representantes de ventas telefónicas en empresas. La capacidad de aprovechar la inteligencia artificial para analizar y sintetizar el conocimiento acumulado en las interacciones de ventas demostró ser altamente efectiva en el desarrollo de habilidades de venta. Esto no solo benefició a las empresas al mejorar la productividad y eficiencia de sus equipos de ventas, sino que también contribuyó a una experiencia de compra mejorada para los clientes al contar con vendedores más capacitados y profesionales.

1.2 Análisis de la necesidad, el cliente y el mercado potencial

1.2.1. Análisis del mercado potencial

El sector financiero ha experimentado un crecimiento constante en los últimos años, y los bancos están cada vez más interesados en mejorar la experiencia del cliente y aumentar la eficiencia operativa a través de soluciones innovadoras.

Los avances tecnológicos y la disponibilidad de datos permiten un mejor análisis

y comprensión del comportamiento del cliente, lo que permite la implementación de modelos de recomendación más precisa y relevante. Esto brinda al banco la capacidad de ofrecer productos financieros adecuados a las necesidades de cada cliente, lo que puede aumentar la satisfacción del cliente, fomentar la fidelidad y mejorar los resultados financieros del banco.

Aprovechando esta oportunidad, el banco tiene la posibilidad de fortalecer su posición en el mercado al mejorar la forma en que gestiona los leads en sus canales. En el caso de las ventas telefónicas, sabemos que, en promedio, un operador debe realizar 11 intentos de llamada para tratar de vender un producto a una persona. Considerando que solo se logra establecer contacto efectivo en aproximadamente el 4% de los casos y se obtiene una aceptación del 16%, nuestra propuesta busca aumentar tanto el porcentaje de contactos efectivos como el de aceptación. De esta manera, lograríamos que la gestión del ejecutivo sea más eficiente al reducir el número de llamadas realizadas y aumentar las ventas, lo que resultaría en mayores beneficios para el banco.

1.2.2. Segmentación del mercado

Luego de realizar una user persona y un mapa de empatía, encontramos que, en nuestro segmento de mercado objetivo, hay un grupo de personas diverso, el cual presenta diferentes características demográficas y socioeconómicas. A continuación, listamos las principales características encontradas para definir el perfil de los trabajadores de ventas telefónicas.

a. Edad: La mayoría de los colaboradores están en una edad del rango de 18 a 33 años, con excepciones de algunos colaboradores que tienen 36 años, que son los más antiguos a nivel de tiempo de trabajo en el canal, con aproximadamente 10 años.

b. Formación académica: Un 50% de los ejecutivos de call center cuentan con estudios técnicos, mientras que un 44% tienen únicamente estudios secundarios, lo cual puede generar dificultades al manejar el léxico y los tecnicismos de los productos al momento de ofrecerlos a los clientes.

c. Carga de trabajo excesiva: La carga de trabajo excesiva que afecta la calidad de vida de los ejecutivos; lo cual repercute en frustraciones y en el desempeño de cara a la gestión con los clientes finales.

d. Falta de conocimiento del cliente: Los ejecutivos gestionan de la misma forma a todos

los clientes, lo cual dificulta el establecimiento de una conexión empática, que es crucial para poder cerrar la venta y tener una personalización en la llamada.

e. Poca capacidad de responder consultas: Sin tener un conocimiento detallado de los productos a ofrecer y un escaso conocimiento de los clientes, les es muy complicado responder consultas más específicas sobre los productos que ofrecen, y, en la mayoría de los casos, dejan a los clientes con dudas.

Como se mencionó previamente, este canal es sumamente importante de cara a la contribución de venta para el banco, sin embargo, presenta un alto porcentaje de fluctuación de personal, el cual es de un 22% y los motivos principales son: la poca efectividad al cerrar la venta y la poca información de los productos a ofrecer, ambos puntos generan mucha frustración en el equipo.

Tomando en cuenta lo mencionado anteriormente, el canal de ventas telefónicas actualmente gestiona 13 productos, cada uno con diferentes lógicas comerciales, ofertas y estrategias de venta. En muchos casos, debido a la combinación incorrecta de productos causada por un mal perfilamiento y la capacitación de los ejecutivos, se pierden oportunidades de venta. Por lo tanto, es crucial proporcionar herramientas adicionales que faciliten el cierre de ventas, así como ofrecer soporte en línea continuo a los ejecutivos para asegurar el éxito en las ventas.

1.3 Propuesta solución y su modelo de negocio

Después de realizar encuestas, mapas de empatía y points of view con los ejecutivos de ventas telefónicas, hemos identificado sus necesidades y determinado que la solución más efectiva será un aplicativo web. Este aplicativo mostrará información proveniente de un modelo recomendador que sugiere el mejor producto para cada lead, considerando tanto las necesidades históricas del cliente como la rentabilidad para el banco. Además de presentar la recomendación de producto óptima, el aplicativo proporcionará al ejecutivo de ventas telefónicas información valiosa organizada en clusters. Esto permitirá al ejecutivo contar con herramientas adicionales para mejorar su capacidad de cierre de ventas y optimizar su discurso actual, el cual, según nos han indicado, es demasiado genérico. Adjuntamos en la **Figura 1. 4** Lean Canvas el modelo Lean Canvas para ilustrar mejor nuestra propuesta de valor para los ejecutivos de ventas telefónicas.

Figura 1. 4 Lean Canvas

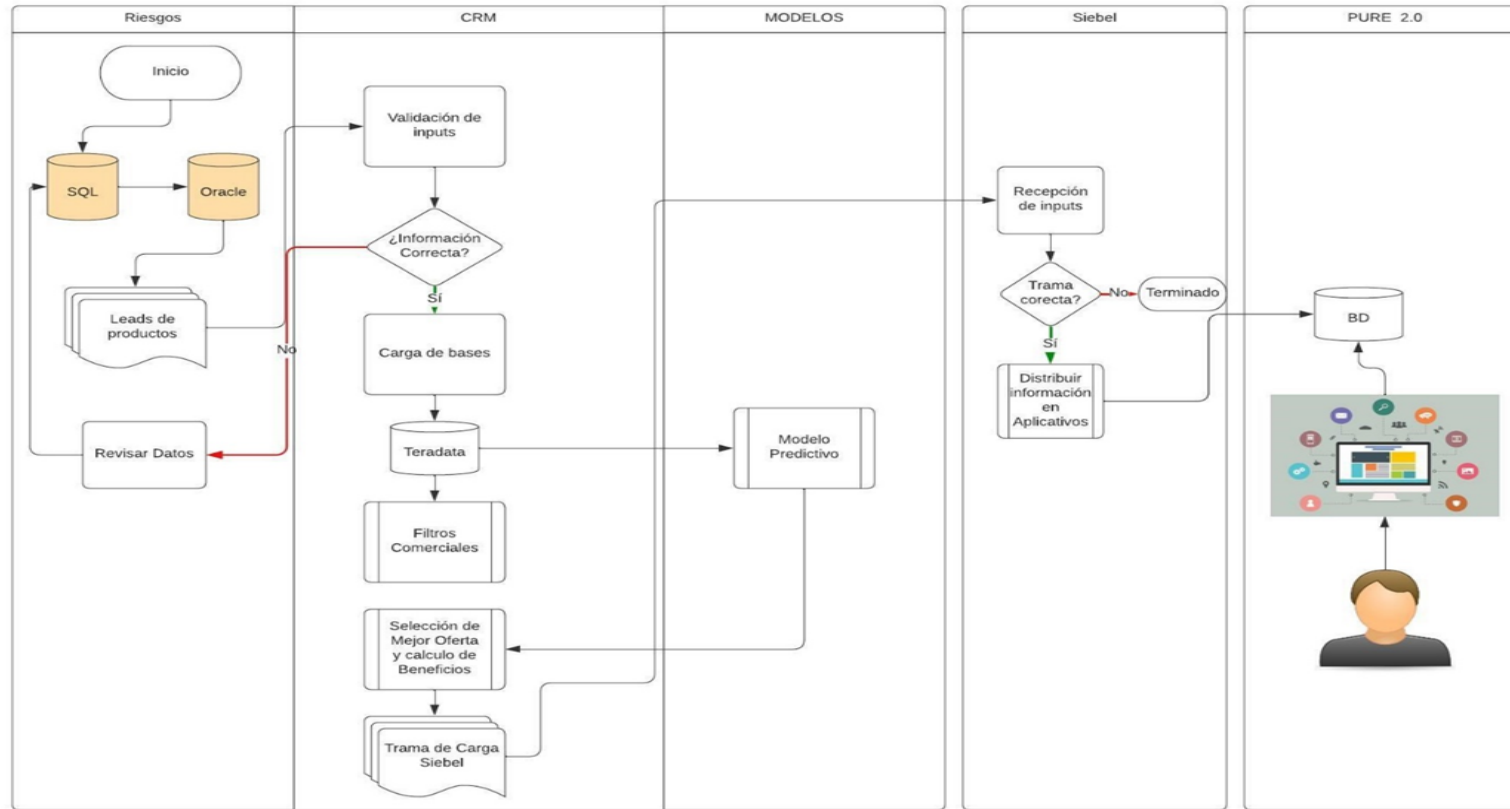
Problema	Solución	Unique value proposition	Unfair advantage	Customers
<ul style="list-style-type: none"> - Poca información disponible de beneficios del producto o perfil de la persona para cerrar la venta. - Las bases que llegan al canal de ventas telefónicas no están bien perfiladas, hay presencia de mucho rechazo a la oferta. - Mucho esfuerzo (intentos de llamada) para contactar y venderle un producto a un cliente 	<ul style="list-style-type: none"> - La organización de datos en clusters optimiza el proceso de ventas al permitir a los ejecutivos personalizar estrategias y utilizar técnicas de aprendizaje automático para mejorar la conversión y rentabilidad. - Mostrar el mejor producto a ofrecer al cliente, en términos de necesidad del cliente y rentabilidad para el banco. <div style="border: 1px solid black; padding: 2px; margin-top: 5px;"> <p style="text-align: center; margin: 0;">Key metrics</p> <ul style="list-style-type: none"> - Incremento en la efectividad de venta. - Incremento en la aceptación de los productos. - Mejora del NPS. </div>	<p>El sistema de recomendación de productos financieros optimiza las ventas telefónicas mediante el uso de un modelo avanzando que personaliza ofertas basadas en las necesidades específicas del cliente y maximiza la rentabilidad para el banco. Proporciona a los ejecutivos clusters de información detallada para cerrar ventas de manera eficiente y directa, mejorando la satisfacción del cliente y aumentando la tasa de cierre de ventas.</p>	<p>El aspecto único es su capacidad para personalizar ofertas, según las necesidades del cliente y optimizar la rentabilidad para el banco. A diferencia de otros sistemas, nuestro aplicativo web proporciona clusters de información detallada que permite a los ejecutivos cerrar ventas de manera más eficiente y directa, mejorando la percepción del cliente y la rentabilidad del banco simultáneamente.</p> <div style="border: 1px solid black; padding: 2px; margin-top: 5px;"> <p style="text-align: center; margin: 0;">Channels</p> <p style="margin: 0;">Ventas telefónicas</p> </div>	<p>Trabajos del canal televentas con:</p> <ul style="list-style-type: none"> - Frustraciones constantes por las bases que gestionan. - Frustraciones por la poca información de venta. - Deseos de cerrar ventas de forma eficiente para alcanzar sus objetivos de ventas y tener sus comisiones.
Cost structure		Revenue streams		
<p>Costo en creación del aplicativo web + implementación del modelo recomendador.</p>		<ul style="list-style-type: none"> - Incremento de ventas. - Incremento en la rentabilidad. - Mejora en el NPS. 		

Tal como se muestra en el Canvas presentado, nuestra propuesta ataca directamente los principales dolores, inquietudes y necesidades que presentaban los ejecutivos de ventas telefónicas, y les ayuda a realizar su trabajo de forma eficiente y enfocada en resultados.

En la **Figura 1. 5** Mapa del proceso de campañas hemos elaborado un diagrama de flujo del proceso final de carga de campañas hacia el canal de ventas telefónicas. Este diagrama muestra claramente las etapas en las que nuestra solución interactúa, detallando cómo se comparte la información con el canal.



Figura 1.5 Mapa del proceso de campañas



Como se puede observar, todo comienza en el área de riesgos con la generación de leads y la evaluación de todas las posibles ofertas a las que una persona puede calificar. Estas ofertas por producto se comparten en archivos planos .txt con el equipo de CRM, que verifica la corrección de la información antes de iniciar el proceso de carga de bases mediante Hadoop hacia Teradata. Una vez cargada la información, se ejecutan filtros comerciales y, simultáneamente, los datos se comparten con el equipo de modelos. En este punto, nuestro modelo recomendador del mejor producto se ejecuta y actualiza, utilizando como inputs todas las ofertas proporcionadas por el área de riesgos.

Una vez completada la actualización, los resultados se devuelven al equipo de CRM, que finaliza la etapa del proceso de carga al generar el archivo en formato adecuado para Siebel, el CRM del banco. Este archivo está disponible para que el equipo de ventas telefónicas lo gestione. Finalmente, Siebel valida la trama y, si es correcta, la información se pone a disposición del equipo de ventas telefónicas a través de nuestra aplicación web.

1.3.1. Justificación

La investigación se basa en una combinación de teorías y conceptos que son fundamentales en el campo de la personalización de servicios, la inteligencia artificial (IA) y el análisis de datos. En primer lugar, la teoría de la personalización sostiene que adaptar las recomendaciones de productos financieros según las necesidades y preferencias específicas de cada cliente puede tener un impacto significativo en la satisfacción del cliente y en el éxito de las estrategias de ventas. Al ofrecer productos que son más relevantes y útiles para cada cliente en particular, se mejora la experiencia del cliente y se aumenta la probabilidad de realizar una venta efectiva (Consoli, 2010).

La inteligencia artificial desempeña un papel crucial en este contexto, ya que permite desarrollar algoritmos y modelos predictivos que analizan grandes cantidades de datos para identificar patrones de comportamiento de los clientes. Estos modelos pueden tener en cuenta diversos factores, como el historial de compras, las preferencias declaradas, la actividad en línea y otros datos relevantes, para generar recomendaciones personalizadas en tiempo real durante una llamada de televenta. La IA también puede mejorar la precisión de las recomendaciones a medida que se recopila más información sobre el cliente y se perfeccionan los modelos de análisis de datos (Rocha, 2023).

El análisis de datos es otro componente clave, ya que proporciona la base para la generación de recomendaciones personalizadas. Al recopilar y analizar datos de clientes, como transacciones anteriores, comportamientos de navegación en línea, interacciones en redes sociales y más, se pueden identificar tendencias y preferencias que informan las recomendaciones de productos (Velásquez y Alejandro, 2023). Esto no solo ayuda a impulsar las ventas al ofrecer productos relevantes, sino que también contribuye a mejorar la fidelización de los clientes al demostrar un entendimiento profundo de sus necesidades y deseos.

El enfoque metodológico propuesto se basa en la utilización del algoritmo de aprendizaje supervisado Boosting. Este algoritmo ha sido seleccionado debido a sus características que se ajustan de manera óptima a las necesidades específicas del proyecto. Boosting es conocido en el ámbito del aprendizaje automático por su capacidad para construir modelos predictivos de alta precisión a partir de conjuntos de datos complejos. Una de las principales ventajas de Boosting radica en su habilidad para mejorar la precisión de las predicciones a medida que ajusta y refina el modelo en iteraciones sucesivas (Pozuelo et al., 2018). Esto significa que el modelo de recomendación de productos financieros podrá aprender de manera continua y mejorar su capacidad para generar recomendaciones personalizadas a medida que se recopilan más datos y se obtiene retroalimentación sobre la efectividad de las recomendaciones.

Otra característica clave de Boosting es su capacidad para manejar conjuntos de datos desbalanceados, lo cual es común en el ámbito de las ventas telefónicas donde puede haber una gran variabilidad en los perfiles de clientes y en los patrones de comportamiento. El algoritmo de Boosting puede adaptarse eficazmente a estas variaciones y generar recomendaciones precisas, incluso en situaciones donde los datos disponibles pueden ser limitados o sesgados. Además, Boosting es conocido por su capacidad para reducir el sobreajuste (overfitting) y mejorar la generalización del modelo, lo que garantiza que las recomendaciones generadas sean relevantes y útiles para una amplia gama de clientes y situaciones (Pozuelo et al., 2018).

La implementación práctica del sistema conlleva beneficios significativos tanto para las instituciones financieras como para sus clientes. En primer lugar, a nivel operativo, el sistema de recomendación personalizada mejora la eficiencia de las ventas telefónicas al optimizar el proceso de selección de productos. Al utilizar algoritmos avanzados, el sistema puede analizar rápidamente el historial de transacciones, las

preferencias declaradas, el comportamiento de navegación en línea y otros datos relevantes para ofrecer recomendaciones precisas y relevantes durante las llamadas de ventas. Esto reduce el tiempo necesario para realizar cada venta y aumenta la efectividad al presentar productos que son más propensos a ser aceptados por el cliente.

Además, la personalización de las recomendaciones aumenta la probabilidad de conversión de ventas, ya que los clientes son más propensos a comprar productos que se ajustan a sus necesidades y preferencias específicas. Esto se traduce en un aumento en las tasas de conversión y, en última instancia, en un incremento en los ingresos para la institución financiera.

Por otro lado, desde la perspectiva del cliente, la implementación de un sistema de recomendación de productos financieros mejora significativamente la experiencia del cliente. Al recibir recomendaciones personalizadas que reflejan sus intereses y objetivos financieros, los clientes se sienten valorados y comprendidos, lo que contribuye a fortalecer la relación cliente-institución financiera. Además, al ofrecer productos financieros que son más relevantes y útiles para cada cliente, se aumenta la satisfacción del cliente y se fomenta la fidelización a largo plazo.

CAPÍTULO II: FUNDAMENTOS TEÓRICOS

2.1 Componentes principales de un sistema de recomendación

Los sistemas de recomendación (SR) son herramientas diseñadas para facilitar la toma de decisiones del usuario al filtrar información relevante según sus necesidades (García y Gil, 2015). Estos sistemas tienen como función elegir y organizar la información conforme a las necesidades del usuario, siendo particularmente útiles cuando la cantidad de información disponible es demasiado extensa para que el usuario la explore individualmente (Ramírez, 2018). Se ha comprobado que los SR mejoran el proceso de toma de decisiones y su calidad en situaciones donde el usuario no cuenta con conocimiento personal o experiencia suficiente sobre las opciones disponibles (Pathak et al., 2010), una situación comprensible debido al volumen masivo de información generado en la actualidad (Resnick et al., 1997).

De manera formal, un SR se define como una función que proporciona una lista de ítems ordenados según su utilidad para el usuario. Estos sistemas se enmarcan en el campo de la inteligencia artificial, centrándose en evaluar la relevancia de elementos desconocidos para el usuario. Su objetivo principal es abordar la sobrecarga de información al ofrecer información sintetizada que sea útil para la toma de decisiones. En un SR, las entidades clave son los usuarios y los objetos (Bron y Mar, 2022). Los usuarios utilizan el sistema para recibir recomendaciones sobre objetos desconocidos o para proporcionar recomendaciones sobre objetos que ya conocen. Los objetos, por su parte, son los elementos susceptibles de ser recomendados, y se definen como los indicadores identificados para la evaluación de proyectos almacenados en una base de datos para su análisis posterior (Lugo, 2012).

En términos generales, los sistemas de recomendación se componen de tres elementos clave: los datos de entrada proporcionados por el usuario al sistema para generar una recomendación; el algoritmo de recomendación que fusiona los datos almacenados previamente con la información ingresada por el usuario para generar las recomendaciones; y la base de datos que contiene toda la información almacenada en el sistema antes de iniciar el proceso de recomendación (Bron y Mar, 2022).

2.2 Componentes del sistema de recomendación

Los sistemas de recomendación suelen constar de tres partes principales (Bron y Mar, 2022):

- Datos de entrada: Información que el usuario comparte con el sistema para que este pueda generar una recomendación.
- Algoritmo de recomendación: Proceso mediante el cual se fusionan los datos almacenados previamente en el sistema con los datos de entrada proporcionados por el usuario, con el fin de generar las recomendaciones. La base de datos engloba toda la información almacenada en el sistema antes de iniciar el proceso de recomendación.
- Datos de entrada: Proporcionados por el usuario, el algoritmo de recomendación que utiliza tanto estos datos como la información almacenada previamente, y la base de datos que contiene toda la información del sistema antes de generar recomendaciones. Estos datos de entrada pueden ser de varios tipos, incluyendo:
 - o Valoraciones de los usuarios.
 - o Datos demográficos como edad o género.
 - o Datos de contenido obtenidos a partir de análisis textual de objetos, y ejemplos iniciales de objetos de interés del usuario.

A partir de estas entradas, se aplican diferentes tipos de algoritmos de recomendación para generar recomendaciones, que pueden presentarse como una lista de objetos útiles para el usuario o como explicaciones asociadas a cada indicador de la lista de recomendaciones (Bron y Mar, 2022).

Las técnicas utilizadas para llevar a cabo estas recomendaciones varían significativamente en términos de la información requerida y los procesos necesarios (Tintarev y Masthoff, 2007).

2.3 Algoritmos de aprendizaje supervisado

Los algoritmos de aprendizaje supervisado son estrategias que combinan múltiples modelos para mejorar el rendimiento utilizando el conocimiento colectivo, aplicables tanto a problemas de clasificación como de estimación de valor. Las dos técnicas

principales son Bagging y Boosting (Universidad Politécnica de Madrid, 2021).

- Bagging: Los modelos se entrenan en paralelo y se combinan sus predicciones para obtener una predicción final.
- Boosting: Los modelos se entrenan secuencialmente, y cada modelo intenta corregir los errores del modelo anterior.

Algunos métodos ensemble ampliamente utilizados incluyen:

- Random Forest: Es un algoritmo de bagging que crea múltiples árboles de decisión en paralelo y combina sus predicciones para obtener resultados más precisos y estables (Universidad Politécnica de Madrid, 2021).
- Gradient Boosting Machines (GBM): Este método, como sugiere su nombre, es un algoritmo de boosting. Utiliza árboles secuenciales para corregir los errores del árbol anterior, enfocándose en mejorar la velocidad y el rendimiento del modelo. Una implementación específica es XGBoost, que busca mejorar la velocidad y eficiencia del modelo (Universidad Politécnica de Madrid, 2021).
- AdaBoost: Similar al método anterior, AdaBoost difiere en cómo cada árbol corrige los errores del anterior. En cada iteración, actualiza las ponderaciones de las observaciones según los errores cometidos, dando mayor peso a las observaciones mal clasificadas por el modelo anterior (Universidad Politécnica de Madrid, 2021).

2.3.1. Técnicas de performance de algoritmo

Al evaluar el rendimiento de un algoritmo, se deben considerar la simplicidad y la eficiencia en el uso de recursos, especialmente el tiempo de ejecución. Aunque la simplicidad a menudo se subestima en favor de la eficiencia, es clave para facilitar la verificación, análisis de eficiencia y mantenimiento del código. La eficiencia en el uso de recursos se mide en términos de espacio y tiempo, influenciada por factores como la naturaleza de los datos de entrada, la calidad del código, la velocidad del procesador y la complejidad intrínseca del algoritmo. Se pueden realizar estudios teóricos y reales para estimar y medir el tiempo de ejecución, lo que permite comparar distintas implementaciones del algoritmo y seleccionar la más adecuada en función del tamaño de

la entrada y las limitaciones de recursos (Universidad de Málaga, 2000).

2.3.2. Algoritmos de filtrado colaborativo: memoria basada, modelo basado

Los sistemas de recomendación, según Valenzuela et al. (2021), han dado origen a métodos de filtrado que incluyen lo siguiente:

2.3.2.1. Filtrado basado en contenido

Este enfoque utiliza las características de los contenidos previamente evaluados por el usuario para generar recomendaciones similares a los elementos que le han gustado (Walid, 2017).

2.3.2.2. Filtrado colaborativo

Aquí se construye una matriz con las predilecciones de los usuarios y se contrastan para encontrar similitudes en sus perfiles. Este método busca coincidencias entre los usuarios para predecir sus gustos y hacer recomendaciones personalizadas (Mathew et al., 2016).

- **Técnicas basadas en memoria:** Estas técnicas consideran las calificaciones previas del usuario para buscar vecinos con gustos similares. Pueden ser basadas en usuarios o en elementos, dependiendo de la aplicación y la estabilidad de la lista de elementos (Isinkaye et al., 2015).
- **Técnicas basadas en modelos:** Este enfoque utiliza calificaciones anteriores para crear un modelo que mejore el rendimiento del filtrado colaborativo. Esto se puede conseguir a través de métodos de aprendizaje automático o utilizando técnicas de minería de datos. (Isinkaye et al., 2015).

2.3.2.3. Filtrado híbrido

Combina diferentes técnicas de recomendación para optimizar el sistema y ofrecer recomendaciones más precisas y efectivas (Isinkaye et al., 2015).

2.4. Diseños de sistema de recomendación con Python

Según Challenger et al. (2014), los lenguajes de programación son esenciales para construir programas. Python ha ido creciendo en popularidad en comunidades como la de software libre, la ciencia y la educación, debido a su facilidad de uso y su eficacia para abordar problemas actuales de manera efectiva, ofreciendo una amplia gama de características para la programación orientada a objetos, imperativa y funcional, lo que

lo convierte en un lenguaje multiparadigma (Kuchling, 1988).

En suma, Python es considerado un lenguaje de alto nivel gracias a sus estructuras de datos integradas, que permiten realizar tareas complejas de manera legible y eficiente en pocas líneas de código. Su amplia selección de librerías especializadas en sistemas de recomendación, como Pandas, NumPy y scikit-learn, junto con una gran comunidad de desarrolladores y recursos en línea, hacen que sea una elección ideal. Además, su integración con otras tecnologías y su simple sintaxis lo convierten en una herramienta poderosa y flexible para el desarrollo de proyectos en diversos ámbitos (Huang, 2023).

2.5. Machine Learning

El aprendizaje automático, o Machine Learning, es una rama de la informática que surgió del estudio del reconocimiento de patrones y la teoría del aprendizaje computacional dentro del campo de la inteligencia artificial. Su enfoque radica en la exploración y desarrollo de algoritmos capaces de aprender y realizar predicciones a partir de datos (Vera et al., 2015). Estos algoritmos construyen modelos basados en ejemplos e insumos para hacer predicciones o tomar decisiones (Bishop, 2006), en contraste con seguir estrictamente instrucciones estáticas de un programa.

2.5.1. Análisis exploratorio

Abarca un conjunto de técnicas estadísticas cuya meta es investigar, explicar y resumir la naturaleza de los datos, así como entender las conexiones entre las variables clave para lograr una comprensión profunda del conjunto de datos. A pesar de las características específicas de los datos o los análisis posteriores que se realicen, el análisis exploratorio ofrece varias ventajas fundamentales.

Al examinar detalladamente los datos, se pueden detectar posibles errores, como datos ingresados incorrectamente, valores faltantes o variables mal codificadas. También permite identificar valores atípicos, evaluar correlaciones entre variables y determinar si hay redundancias. Además, proporciona un análisis descriptivo mediante gráficos y resúmenes que resaltan los aspectos más relevantes de los datos (Red España, 2021).

2.5.2. Modelamiento

El modelado se refiere a la representación de fenómenos de interés de una forma que facilite un análisis más profundo del fenómeno en cuestión (Bender, 2002). En diversas industrias, como la alimentaria, eléctrica y química, se han utilizado modelos

para diseñar equipos. Ejemplos de estos incluyen intercambiadores de calor, hornos y condensadores, elementos cruciales para controlar la temperatura en procedimientos específicos, y que se desarrollan a partir de ecuaciones relacionadas con la transferencia de calor y la convección (Shang, 2010). En este marco, los modelos se prueban para evaluar su comportamiento frente a nuevas condiciones, proporcionando resultados variables. Aquellos modelos que reflejan de manera precisa el fenómeno de interés se utilizan para entender su comportamiento. Si un modelo no ofrece el resultado esperado, se puede rediseñar sin tener que empezar desde cero, lo que optimiza la efectividad del proceso. Este ciclo puede repetirse hasta lograr un resultado satisfactorio (Allaire, 2007)

Los modelos permiten obtener un conocimiento más profundo sobre los fenómenos y prever su comportamiento ante diversas condiciones. De esta forma, se utilizan con diversos objetivos, como predecir resultados al modificar las condiciones iniciales o determinar las condiciones necesarias para alcanzar los resultados deseados. Dado que los modelos no están limitados a un área específica, existe una amplia variedad de ellos (Frigg y Hartmann, 2020).

Los modelos matemáticos, en adelante referidos simplemente como "modelos", son definidos por Bender (2002) como "una construcción matemática abstracta y simplificada relacionada con una porción de la realidad, diseñada para un propósito específico". La principal ventaja de este tipo de modelos radica en que emplean expresiones matemáticas exactas, universales y fácilmente modificables. Su implementación se puede lograr mediante diversos teoremas y/o tecnologías enfocadas en la realización de cálculos matemáticos. En la ingeniería de procesos, los modelos se han utilizado de forma rutinaria desde principios del siglo 20 para el diseño de equipos (Valadi y Siarry, 2014).

2.5.3. Despliegue

El desarrollo de nuevas versiones de modelos predictivos implica su posterior implementación en el entorno de producción, reemplazando los modelos previamente utilizados. Este proceso requiere una planificación detallada y una estrategia bien definida. Los modelos predictivos pueden funcionar bajo dos modalidades principales:

- En tiempo real: los modelos diseñados para operar en tiempo real están destinados a procesar solicitudes provenientes de usuarios finales o sistemas automatizados, generando predicciones basadas en datos de entrada específicos. Por lo tanto, el

modelo debe ejecutarse y proporcionar una respuesta en el menor tiempo posible (Valderrama, 2021).

- Por lotes: estos modelos están configurados para producir predicciones sobre un conjunto amplio de datos de manera periódica, siguiendo una frecuencia establecida. A diferencia de los modelos en tiempo real, no procesan solicitudes inmediatas, sino que se ejecutan solo durante el tiempo necesario para completar el análisis de los datos del lote (Valderrama, 2021).

En el proceso de actualización de versiones, es crucial minimizar cualquier interrupción en el servicio, especialmente para los modelos que operan en tiempo real. Además, se debe realizar una validación final, evaluando el desempeño del modelo al ejecutarse con datos reales del entorno de producción (Valderrama, 2021).

Dentro de las estrategias de despliegue más utilizadas, se destacan dos enfoques principales:

- Canary deployments: en este enfoque, la nueva versión del modelo se implementa junto a la versión actual en el entorno de producción. Luego, se dirige una pequeña porción de la carga de trabajo al modelo actualizado (Fernandez, 2020). Esto permite verificar la estabilidad y precisión de la nueva versión con datos reales. Una vez validado, toda la carga de trabajo se redirige al nuevo modelo y el modelo anterior es retirado.
- Blue-green deployments: en este caso, al igual que el enfoque anterior, el modelo nuevo se despliega junto al antiguo en el entorno de producción. No obstante, en lugar de distribuir la carga de trabajo, ambas versiones procesan los datos simultáneamente. El modelo nuevo registra sus resultados en una colección de predicciones de validación, los cuales pueden ser revisados. Una vez validado su correcto funcionamiento, los resultados se trasladan a la colección de predicciones estándar de producción y el modelo antiguo se elimina (Red Hat, 2019).

2.5.4. Monitoreo

Se compone de sistemas para seguir, observar y supervisar los riesgos potenciales de peligro, lo que conduce a la creación de indicadores apropiadamente definidos (Marín y Pineda, 2019). En un sistema de Machine Learning, es esencial considerar que el desempeño del modelo puede deteriorarse con el tiempo debido a cambios en los datos y la necesidad de reentrenar el modelo. Después de implementar el modelo, es crucial llevar

a cabo revisiones periódicas para garantizar su correcto funcionamiento en producción. El monitoreo del modelo implica verificar patrones de datos consistentes y establecer alertas para identificar discrepancias en los datos de entrada en comparación con el esquema esperado. También se debe vigilar la estabilidad numérica del modelo y configurar alertas para detectar valores no válidos, como NaNs o infinitos.

Además, es fundamental supervisar la calidad de los datos utilizados para entrenar el modelo y evitar sesgos. Otro aspecto importante es evaluar la pérdida de precisión del modelo en datos en tiempo real. Además, es necesario realizar auditorías de las acciones de los usuarios para recopilar métricas de éxito y evaluar si el modelo está logrando los resultados deseados. Por ejemplo, en un sistema de recomendación de productos, se puede rastrear la tasa de conversión cuando los usuarios compran los productos sugeridos como medida de éxito. Otros elementos a monitorear incluyen la duración del modelo en producción y su equidad, asegurándose de analizar las entradas y salidas del modelo en relación con variables sensibles como la raza, el género o la edad para evitar sesgos (Santamaría, 2022).

2.6. Automated machine Learning

El creciente interés se centra en modelos de aprendizaje automático sofisticados que cuentan con una alta cantidad de hiperparámetros, como los sistemas de aprendizaje automático automatizado (AutoML) y las redes neuronales profundas (Feurer y Hutter, 2019).

En ese sentido, AutoML es un campo en crecimiento que busca automatizar la creación de modelos de aprendizaje automático. Su propósito es incrementar la productividad y la eficiencia al reducir la repetición de tareas ineficientes asociadas con el proceso de aplicar el aprendizaje automático. Durante mucho tiempo, se ha investigado cómo desarrollar modelos de alta calidad de manera efectiva, minimizando la intervención humana en las etapas que van desde el preprocesamiento de datos hasta la selección y ajuste de algoritmos (Salehin et al., 2024).

En suma, el Automated Machine Learning (AutoML) es un enfoque que automatiza gran parte del proceso de construcción de modelos de aprendizaje automático. Esto incluye la sistematización del análisis y tratamiento de datos previos, la creación de un espacio de búsqueda de modelos y parámetros, así como la automatización de técnicas de interpretabilidad. Los sistemas AutoML se basan en dos componentes principales: el

optimizador, que genera y actualiza combinaciones de parámetros dentro de los límites definidos, y el evaluador, que mide el rendimiento de las opciones propuestas y puede influir en la estrategia de búsqueda. Existen diferentes técnicas de optimización, como búsqueda en cuadrícula, búsqueda aleatoria, algoritmos evolutivos o metaaprendizaje. El reto radica en incluir conocimientos previos y desarrollar sistemas que cubran todo el proceso de construcción de modelos. Aunque hay margen de mejora, los sistemas AutoML han alcanzado un nivel de desarrollo que les permite competir e incluso superar a los expertos humanos en aprendizaje automático, siendo una herramienta esencial para los científicos de datos (Management Solutions, 2020).

2.7. Cómo diseñar pilotos

El A/B testing implica comparar una página de control con una o más variaciones que contienen una diferencia significativa en un elemento específico. Después de un periodo determinado o un número de visitas, se evalúan los resultados para determinar cómo afectó el cambio a los resultados. Aunque el término A/B testing es comúnmente utilizado, en realidad puede incluir más de dos variaciones (A/B/C/D, etc.), siendo una forma más precisa referirse a estas pruebas como A/B/n o Split Test cuando hay múltiples variaciones. Cada visitante ve una versión diferente de la página, y se miden las conversiones de cada conjunto de visitantes, permitiendo probar distintas versiones de texto, imágenes, diseños, funcionalidades, entre otros elementos, para optimizar la eficacia de la página o plataforma (Data Science Association, 2020).

2.8. Sistema de recomendación con GENAI

Una inteligencia artificial generativa, conocida como GenAI en la terminología estándar, es un tipo de IA que emplea aprendizaje automático para generar respuestas a partir de las preguntas que se le hacen. Se nutre constantemente de datos para entrenarse, lo que permite que sus respuestas mejoren con el tiempo. Además, puede ser utilizada por varios usuarios al mismo tiempo, sin importar su ubicación, y se adapta a las necesidades de cada uno de ellos (Universidad Carlos III de Madrid, 2023). En ese sentido. Es una disciplina en constante evolución dentro de la inteligencia artificial, cuyo objetivo es crear sistemas capaces de replicar cualquier tarea intelectual realizada por los humanos, pero de forma más rápida, eficiente y tomando en cuenta una mayor cantidad de variables. A diferencia de la inteligencia artificial convencional, que se centra en resolver problemas específicos, la inteligencia artificial general (AGI) busca crear sistemas que puedan

aprender y ajustarse a cualquier tarea intelectual, sin importar su nivel de complejidad (IA+Iguar, 2024).

2.9. Técnicas para implementar pilotos

Los nuevos sistemas a implementarse se evalúan inicialmente en una sección específica de la organización antes de su implementación en toda la empresa, lo que resulta en un enfoque menos costoso en comparación con el método paralelo. Aunque este enfoque conlleva un riesgo mayor, este riesgo es manejable al estar restringido a áreas específicas y no afectar a toda la empresa (Maida y Pacienza, 2015).

La prueba de software es un proceso esencial que implica ejecutar un sistema bajo condiciones específicas para detectar fallos y evaluar su desempeño. Este proceso se realiza a diferentes niveles, comenzando por las pruebas de unidad para revisar componentes individuales, pasando por las pruebas de integración y sistema hasta llegar a las pruebas alfa y beta, que involucran al cliente en entornos controlados y de producción respectivamente. Las técnicas de prueba incluyen la caja blanca, que analiza el código a nivel interno, y la caja negra, que se enfoca en los aspectos funcionales del software, ambas buscando garantizar la eficiencia y calidad del sistema

CAPÍTULO III: DEFINICIÓN DEL PROYECTO

3.1. Definición del proyecto

Para esta fase, se implementaron algoritmos de filtrado colaborativo, incluyendo el enfoque de memoria basada y el modelo basado, para identificar a los clientes que podrían ser asignados a ventas telefónicas. Estos algoritmos evaluaron el puntaje de recomendación de productos financieros y aplicaron criterios de ordenamiento para seleccionar a los clientes de mayor potencial de conversión.

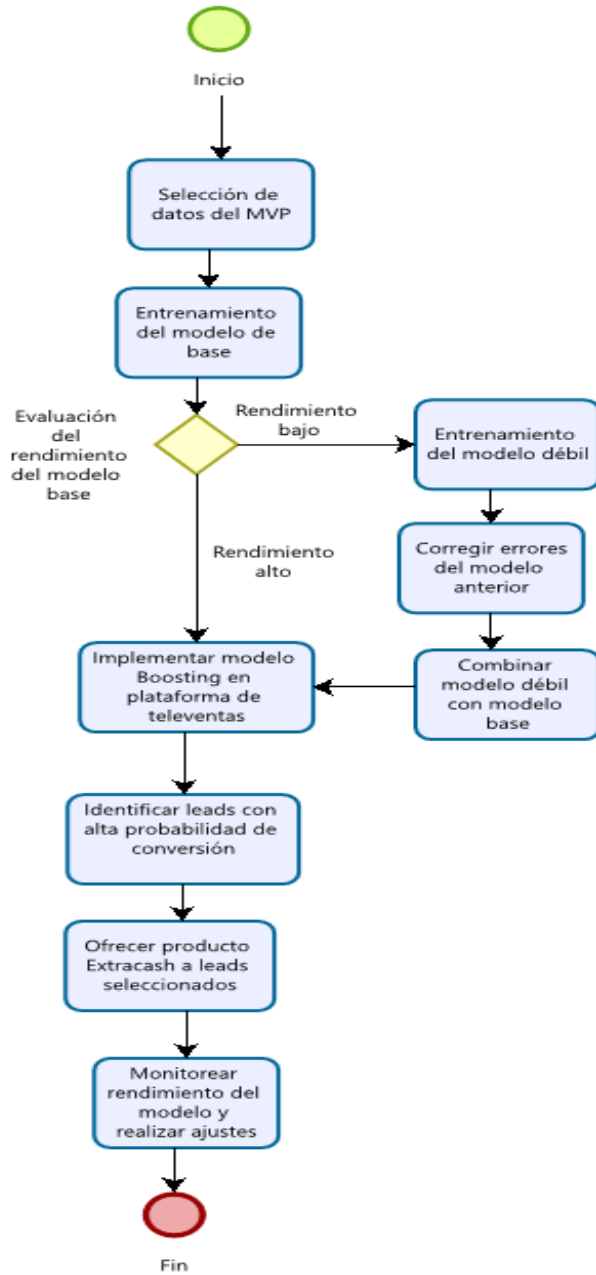
En este contexto, se ha utilizado la técnica del Boosting, un enfoque de combinación de modelos propuesto por Schapire en 1990, cuyo propósito es aumentar la capacidad predictiva de los métodos de aprendizaje estadístico con alta variabilidad, como árboles. Se construyen secuencialmente clasificadores "débiles", y cada uno se basa en la información de los anteriores. Se seleccionan instancias mal clasificadas para entrenar el siguiente clasificador, lo que puede llevar al sobreajuste. La idea central es que la combinación de clasificadores débiles puede compensar las limitaciones individuales, generando un clasificador más efectivo (Pérez, 2018). La técnica se aplicó en base a las siguientes etapas (ver **Tabla 3. 1** Etapas de la aplicación del Boosting):

Tabla 3. 1 Etapas de la aplicación del Boosting

Etapas	Descripción
1. Selección de datos	Utilizar los datos del MVP como conjunto de entrenamiento inicial. Incluir tanto las características de los leads como los resultados de las ventas (conversión, desembolso, etc.).
2. Entrenamiento del modelo de base	Entrenar un modelo de aprendizaje automático inicial, como un árbol de decisión o regresión logística, utilizando los datos del MVP. Evaluar el rendimiento del modelo base en términos de precisión y error.
3. Entrenamiento de modelos débiles	Entrenar secuencialmente una serie de modelos débiles utilizando el mismo conjunto de datos. Cada modelo débil debe enfocarse en corregir los errores del modelo anterior. Se pueden utilizar diferentes algoritmos para entrenar los modelos débiles, como árboles de decisión, reglas de asociación o redes neuronales.
4. Combinación de modelos	Combinar las predicciones de los modelos débiles utilizando un algoritmo de ponderación. El algoritmo de ponderación asigna mayor peso a los modelos débiles con mayor precisión. El modelo final es un conjunto de modelos débiles que, en conjunto, tiene un mejor rendimiento que cualquier modelo individual.
5. Implementación del modelo Boosting	Implementar el modelo Boosting en la plataforma de ventas telefónicas para la toma de decisiones. Utilizar el modelo para identificar a los leads con mayor probabilidad de conversión y ofrecerles el producto Extracash. Monitorear el rendimiento del modelo y realizar ajustes según sea necesario.

En la **Figura 3.1** Etapas de la aplicación del Boosting, se muestra el flujo de proceso de la implementación:

Figura 3.1 Etapas de la aplicación del Boosting



3.2. Objetivos del proyecto

Objetivo general

- Optimizar el proceso de ventas telefónicas de productos financieros, específicamente el producto Extracash, mediante la implementación de un sistema de recomendación basado en modelos predictivos y el uso de técnicas de aprendizaje automático.

Objetivos específicos

- Desarrollar un sistema de recomendación de productos financieros basado en modelos predictivos que utilicen información histórica de clientes y leads.
- Integrar el sistema de recomendación en el canal de ventas telefónicas para identificar leads con mayor probabilidad de aceptar el producto Extracash.
- Evaluar la efectividad del sistema de recomendación mediante la comparación de resultados entre un grupo piloto seleccionado por el sistema y un grupo control seleccionado por reglas comerciales tradicionales.
- Mejorar la tasa de aceptación del producto Extracash en el grupo piloto, con el objetivo de alcanzar un aumento significativo en las ventas, la efectividad y el desembolso en comparación con el grupo control.
- Recopilar feedback y opiniones de los colaboradores de ventas telefónicas sobre la experiencia con la nueva plataforma y utilizar esta información para realizar ajustes y mejoras continuas en el sistema de recomendación y en las estrategias de venta mediante la formulación de una propuesta de valor.

3.3. Alcance del proyecto

El alcance del proyecto abarcó la identificación del producto para el MVP, la selección de clientes para la televenta basados en puntajes y reglas comerciales, la creación de una nueva plataforma de gestión para los ejecutivos de televenta, la realización de un piloto de 15 días, y la medición de resultados y encuestas posgestión.

3.4. Roles y responsabilidades del equipo del proyecto

Tabla 3. 2 Roles y responsabilidades del equipo del proyecto

Rol	Responsabilidades
Investigador 1	<ul style="list-style-type: none">- Desarrollar el sistema de recomendación de productos financieros basado en modelos predictivos.- Integrar el sistema de recomendación en el canal de ventas telefónicas para identificar leads potenciales.- Coordinar con el equipo de desarrollo para la implementación técnica del sistema de recomendación.- Evaluar la efectividad del sistema y realizar ajustes basados en los resultados obtenidos.
Investigador 2	<ul style="list-style-type: none">- Recolectar y analizar información histórica de clientes y leads para la construcción de modelos predictivos.- Validar y mejorar la precisión y fiabilidad de los modelos predictivos utilizados en el sistema.- Supervisar la integración del sistema de recomendación en el canal de ventas telefónicas.- Recopilar feedback de los colaboradores de ventas telefónicas y realizar ajustes en base a sus opiniones.

3.5. Cronograma y riesgos iniciales del proyecto

El cronograma del proyecto incluyó la identificación del producto, selección de clientes, creación de la plataforma, piloto de 15 días, medición de resultados y encuestas post gestión, ver **Tabla 3. 3** Cronograma del proyecto.

Tabla 3. 3 Cronograma del proyecto

Etapa	Actividades	Duración estimada
Planificación	Definición de objetivos y alcance del proyecto.	1 semana
	Revisión y aprobación del plan de trabajo.	1 semana
Investigación preliminar	Recopilación de información histórica de clientes y leads.	2 semanas
	Análisis exploratorio de datos para identificar patrones y tendencias.	2 semanas
Desarrollo de modelos	Diseño y construcción de modelos predictivos basados en Machine Learning.	4 semanas
	Validación de la precisión y fiabilidad de los modelos.	2 semanas
Implementación del sistema	Integración del sistema de recomendación en el canal de ventas telefónicas.	3 semanas
	Capacitación del equipo de ventas telefónicas sobre el uso del sistema.	1 semana
Pruebas y ajustes	Realización de pruebas de funcionamiento y rendimiento del sistema.	2 semanas
	Recopilación de feedback del equipo de ventas telefónicas y ajustes en el sistema.	1 semana
Evaluación y optimización	Evaluación de la efectividad del sistema en términos de ventas y desempeño.	2 semanas
	Implementación de mejoras y optimizaciones en el sistema de recomendación.	2 semanas
Monitoreo y mantenimiento	Establecimiento de métricas de seguimiento y monitoreo continuo del sistema.	Permanente
	Mantenimiento y actualización regular del sistema de acuerdo a las necesidades identificadas.	Permanente

Los riesgos iniciales identificados se detallan a continuación:

- **Complejidad de los modelos:** Los modelos de recomendación basados en Machine Learning pueden ser complejos de diseñar e implementar, lo que podría llevar a retrasos en el desarrollo y dificultades en la integración con el canal de ventas telefónicas.
- **Calidad de los datos:** La calidad de los datos históricos de clientes y leads puede afectar la precisión de los modelos de recomendación. Problemas como datos incompletos, ruidosos o sesgados podrían comprometer la efectividad del sistema.
- **Capacitación del personal:** La capacitación del equipo de ventas telefónicas en el uso del nuevo sistema podría enfrentar desafíos, como resistencia al cambio, falta de familiaridad con la tecnología o dificultades en la interpretación de las recomendaciones.
- **Integración tecnológica:** La integración del sistema de recomendación con los

sistemas existentes en el canal de ventas telefónicas puede enfrentar obstáculos técnicos, como incompatibilidad de plataformas, falta de API adecuadas o problemas de escalabilidad.

- **Evaluación de resultados:** La evaluación precisa de los resultados del sistema puede ser un desafío, especialmente al medir el impacto en las ventas y la efectividad de las recomendaciones. La falta de métricas claras o indicadores relevantes podría dificultar la evaluación.
- **Seguridad de datos:** La seguridad y privacidad de los datos de clientes y leads son fundamentales. Riesgos como fugas de información, accesos no autorizados o brechas de seguridad podrían comprometer la confianza en el sistema y la reputación de la empresa.
- **Adopción del sistema:** La aceptación y adopción del nuevo sistema por parte del equipo de ventas telefónicas y otros stakeholders puede ser un riesgo. Resistencia al cambio, falta de comprensión de los beneficios o percepciones negativas podrían afectar la implementación exitosa.
- **Competencia y mercado:** Cambios en el mercado financiero, acciones de la competencia o fluctuaciones económicas pueden impactar la efectividad del sistema de recomendación y sus resultados esperados.
- **Gestión de expectativas:** Las expectativas excesivamente altas o poco realistas sobre los resultados del sistema podrían generar frustración si no se alcanzan rápidamente, afectando la motivación y compromiso del equipo.
- **Presupuesto y recursos:** Limitaciones en el presupuesto asignado, falta de recursos humanos o técnicos adecuados podrían limitar la capacidad de desarrollo y la calidad del sistema implementado.

3.6. Indicadores de gestión del proyecto

Los indicadores de gestión del proyecto fueron la efectividad en la selección de clientes para televenta, la mejora en la gestión de los ejecutivos de televenta con la nueva plataforma, la tasa de conversión de ventas durante el piloto, y la satisfacción de los ejecutivos con las herramientas proporcionadas. En la **Tabla 3. 4** KPI's de gestión del proyecto se detalla a continuación:

Tabla 3. 4 KPI's de gestión del proyecto

KPI	Descripción	Interpretación
Tasa de conversión de leads a ventas	Porcentaje de leads que se convierten en ventas del producto Extracash.	Una tasa de conversión elevada sugiere que el sistema de recomendación está reconociendo y priorizando prospectos con alta probabilidad de compra, lo que optimiza la eficiencia del equipo de ventas.
Aumento en la tasa de aceptación	Comparación de la tasa de aceptación del producto antes y después del sistema.	Un aumento en la tasa de aceptación sugiere que el sistema de recomendación está logrando identificar mejor a los clientes interesados y está alineando la oferta del producto con sus necesidades.
Incremento en la efectividad de las ventas	Aumento en el número de ventas exitosas del producto Extracash.	Un incremento en este KPI indica que el sistema de recomendación está mejorando la capacidad del equipo de ventas para cerrar ventas, posiblemente mediante una mejor segmentación y priorización de leads.
Desembolso promedio por cliente	Monto promedio desembolsado por cliente que acepta el producto Extracash.	Un aumento en el desembolso promedio por cliente puede indicar que el sistema de recomendación está identificando clientes con mayor capacidad o disposición para tomar productos financieros de mayor valor.
Porcentaje de mejora en resultados	Diferencia porcentual entre los resultados del grupo piloto y el grupo control.	Un porcentaje positivo indica que el sistema de recomendación está teniendo un impacto favorable en las ventas y efectividad, demostrando su valor frente a las prácticas tradicionales.
Satisfacción del equipo de ventas telefónicas	Evaluación de la satisfacción y percepción del equipo sobre la nueva plataforma.	Alta satisfacción sugiere que el equipo encuentra la plataforma útil, fácil de usar y efectiva en mejorar sus resultados de ventas, lo cual es crucial para la adopción y éxito del sistema.
Retención de clientes	Porcentaje de clientes que continúan utilizando el producto en el tiempo.	Alta retención indica que los clientes están satisfechos con el producto, lo cual puede ser resultado de una mejor alineación inicial entre las necesidades del cliente y el producto ofrecido, gracias al sistema de recomendación.
Tiempo promedio de conversión	Tiempo promedio desde que un lead es identificado hasta que realiza la compra.	Un tiempo de conversión más corto sugiere que el sistema de recomendación está ayudando a identificar leads más calificados y que los procesos de venta se están volviendo más eficientes y efectivos.

3.7. Recursos económicos

Los recursos económicos necesarios para el proyecto incluyeron presupuesto para el desarrollo de la plataforma, costos de selección de clientes, gastos operativos durante el piloto, y recursos para la medición de resultados y encuestas posgestión. Estos recursos son fundamentales para garantizar el éxito y la efectividad del proyecto de recomendación de productos financieros para ventas telefónicas. A continuación, en la **Tabla 3. 5** Recursos económicos suficientes, la cual hace referencia a los recursos económicos:

Tabla 3. 5 Recursos económicos suficientes

Recurso	Descripción	Monto tentativo
Inversión en tecnología	- Desarrollo del sistema de recomendación basado en modelos predictivos.	S/. 100,000.00
	- Adquisición o mejora de infraestructura de hardware y software para implementar y mantener el sistema.	S/. 20,000.00
	- Licencias de software y herramientas de análisis de datos.	S/. 15,000.00
Recursos humanos	- Salarios y honorarios para el equipo de investigación y desarrollo del sistema.	S/. 50,000.00
	- Posibles contrataciones de personal especializado en aprendizaje automático y análisis de datos.	Variable
	- Capacitación y formación continua para el equipo técnico y de ventas telefónicas.	S/. 5,000.00
Gastos operativos	- Costos asociados con la recolección, almacenamiento y procesamiento de datos de clientes y leads.	S/. 35,000.00
	- Gastos de ventas telefónicas, incluyendo comunicaciones, servicios telefónicos y de internet.	S/. 20,000.00
	- Publicidad y promoción del producto Extracash a través del canal de ventas telefónicas.	S/. 70,000.00
	- Costos de investigación de mercado y análisis de competencia.	S/. 50,000.00
Investigación y evaluación	- Gastos relacionados con la evaluación de la efectividad del sistema de recomendación y la comparación de resultados entre grupos piloto y control.	S/. 10,000.00
	- Recursos para realizar ajustes y mejoras en el sistema de recomendación basados en el feedback de los colaboradores y resultados obtenidos.	Variable
Mejoras continuas y mantenimiento	- Mantenimiento regular de la infraestructura tecnológica y actualización de software.	S/. 50,000.00
Reservas para contingencias	- Fondos destinados a imprevistos y situaciones no planificadas que puedan surgir durante la implementación y operación del proyecto.	S/. 15,000.00

Si bien la implementación del sistema de recomendación requiere el uso de algunas herramientas como el acceso a productos de Amazon Web Services, o alguna herramienta de Interfaz de Programación de Aplicaciones, estas fueron suministradas por la entidad.

CAPÍTULO IV: DESARROLLO DEL PRODUCTO MÍNIMO VIABLE

4.1 Alcance del producto mínimo viable

4.1.1. Selección de Leads

Contamos con una base de prueba de 32 mil leads aleatorios, la cual se dividió la base en 50% de leads piloto y 50% control, mientras que el piloto se gestionó durante una semana.

4.1.2. Despliegue del MVP

Conexión con base de datos

Se emplearon servicios de Amazon Web Services (AWS), haciendo uso de la interfaz de Amazon Athena como gestor de datos para llevar a cabo consultas y análisis sobre la información que estaba almacenada en un repositorio de datos en Amazon S3, cuyas evidencias se muestran en la **Figura 4. 1** Interfaz de usuario realizada en el Amazon Web Services Este repositorio, que es un servicio de almacenamiento en la nube de AWS, actúa como un data lake que almacena y organiza de manera eficiente todos los archivos y datos necesarios para el sistema de recomendación.

Desarrollo de la interfaz de programación

Implicó dividir la funcionalidad de la aplicación en pequeños servicios independientes que se comunican entre sí a través de interfaces bien definidas. Cada microservicio se enfocó en realizar una tarea específica, lo que permite una mayor modularidad y flexibilidad en el desarrollo. Esto facilitaría la integración de nuevos servicios y la colaboración entre equipos de desarrollo, ya que cada microservicio tiene su propio ciclo de vida y puede ser desarrollado, probado y desplegado de manera independiente.

Integración con plataforma de ventas telefónicas

Cada microservicio pudo integrarse de manera independiente con la plataforma de ventas telefónicas a través de sus propias interfaces de programación. Estos microservicios se comunican con la plataforma de ventas telefónicas utilizando protocolos estándar HTTP/HTTPS. Además, al separar las funcionalidades en microservicios, se reduce el impacto de fallos o caídas en una parte de la plataforma, ya que los demás microservicios pueden continuar funcionando de manera independiente y seguir procesando el flujo de

trabajo de las ventas telefónicas sin interrupciones significativas. Esto mejora la disponibilidad y la resiliencia del sistema en su conjunto.

4.1.3. Medición de resultados

Se estableció un plan integral para medir el rendimiento del sistema de recomendación, este plan permitió evaluar con precisión el impacto del sistema y se identificaron oportunidades de mejora.

A continuación, se visualiza la **Tabla 4. 1** Métricas de medición de resultados. que hace referencia a las métricas de medición de resultados:

Tabla 4. 1 Métricas de medición de resultados

Categoría	Métricas de medición de resultados
Conversión y efectividad	Porcentaje de conversión de leads (CE)
	Porcentaje de aceptación
	Porcentaje de efectividad de ventas
Rentabilidad y finanzas	Desembolso total
	Satisfacción con la plataforma
Experiencia del usuario y satisfacción	Facilidad de uso
	Utilidad percibida de los datos brindados
	Preferencias para futuras mejoras en la plataforma

4.2 Supuestos clave y técnicas de validación a nivel de clientes y de usuarios

Algunos de los supuestos clave que se identificaron incluyeron la efectividad del modelo recomendador en la selección de leads para el grupo piloto, la capacidad de la nueva plataforma para mejorar la experiencia del usuario de ventas telefónicas y la relevancia de los clústeres de información proporcionados.

Para validar estos supuestos, se implementaron varias técnicas, como entrevistas en profundidad con los usuarios de la plataforma para comprender sus necesidades y expectativas con mayor detalle. Además, se realizaron pruebas A/B para comparar diferentes versiones de la plataforma y medir su impacto en la tasa de conversión, la aceptación del producto y la efectividad en las ventas. También se recopiló feedback continuo a través de encuestas y análisis de datos para identificar áreas de mejora y optimización en la plataforma.

4.3 Diseño del producto mínimo viable

Conexión con base de datos:

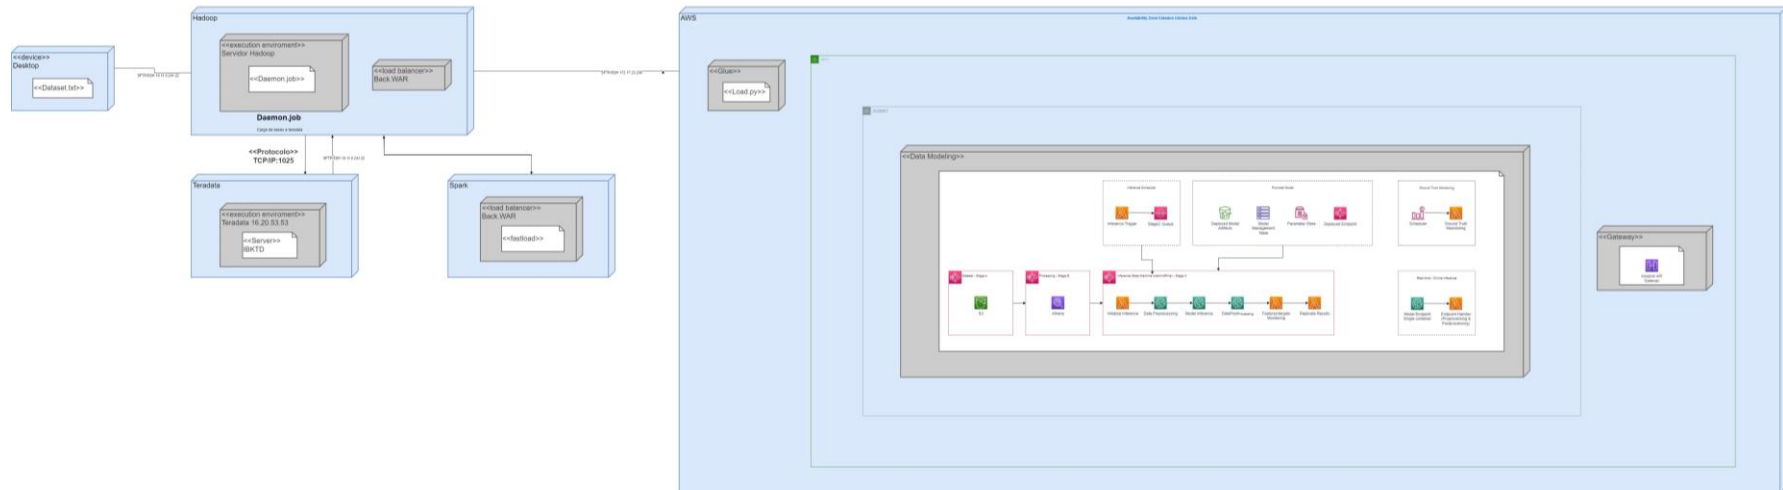
Figura 4. 1 Interfaz de usuario realizada en el Amazon Web Services

The screenshot displays the Amazon Athena Query Editor interface. On the left, there are sections for 'Data' (with 'Data source' set to 'AwsDataCatalog' and 'Database' set to 'e_perm_aws') and 'Tables and views' (listing various tables like 'adqc', 'advocate_user_md1', etc.). The main area shows a SQL query in a dark editor, with the current line highlighted. Below the editor are buttons for 'Run', 'Explain', 'Cancel', 'Clear', and 'Create'. The 'Query results' section shows a 'Completed' status with performance metrics: 'Time in queue: 97 ms', 'Run time: 2.555 sec', and 'Data scanned: 4.34 MB'. Below this, a table of results is displayed with columns for row number, 'codmes', 'tipdoc', 'coddoc', 'puntuacion', 'modelo', 'fec_replic a', 'grupo_aje', 'score', 'orden', and two 'variable' columns. The results table contains 4 rows of data.

#	codmes	tipdoc	coddoc	puntuacion	modelo	fec_replic a	grupo_aje	score	orden	variable 1	variable 2
1	202107	1	2E34B7192AA718DD605339D103C19222745D0A1C8375E42121FB583824DF941	0.0007091922297847595	EC	20210626	5		143986		
2	202107	1	4CC5540937141C4DFDEB042ED6B1FEF8EDCC172B85CEA3CD8617AA6DA17601F0	0.000021252998677720	EC	20210626	10		544520		
3	202107	1	D969D32863B4133552753C86CDA4E1E0F2A57804EA049A9EAFE78AA03997F57E	0.000048679499087502	EC	20210626	9		308262		
4	202107	1	B778C59899024A30FBC3A2B48B52C66F2FA48A1C80D20DD6BF0FA4F118E6F57	0.006962043997432109	EC	20210626	2		34947		

Desarrollo de la interfaz de programación

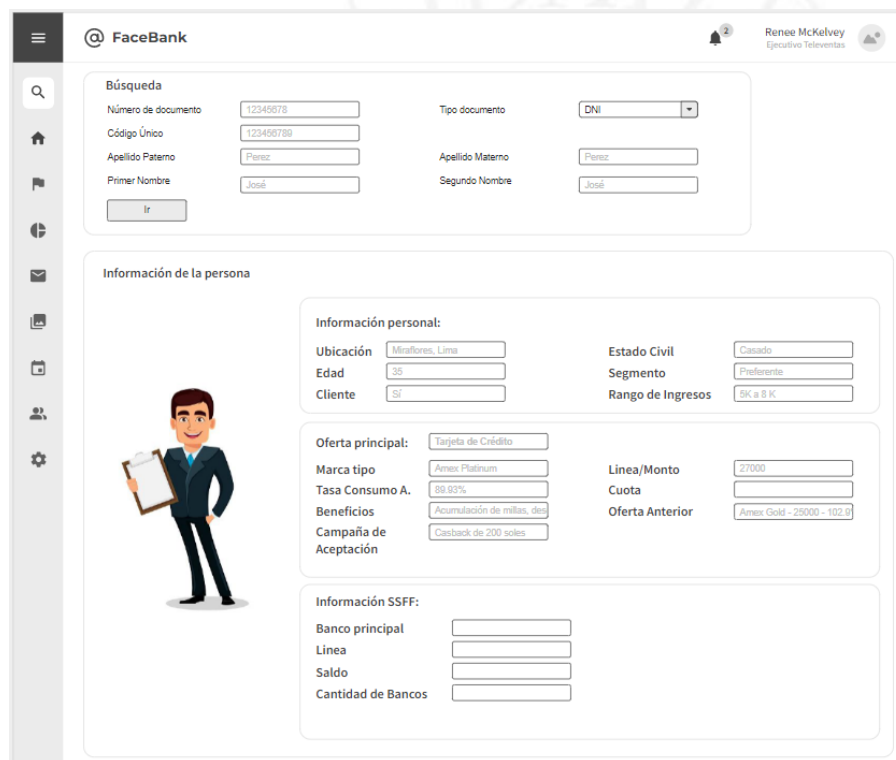
Figura 4. 2 Flujo de la interfaz de programación



Integración con plataforma de ventas telefónicas

Implicó la implementación de un algoritmo de recomendación del mejor producto centrado en la rentabilidad del banco, integrado en una interfaz web amigable. Esta herramienta recopila información relevante sobre las personas, permitiendo que los ejecutivos de ventas telefónicas potencien su speech de ventas con datos precisos y actualizados. La plataforma, véase **Figura 4. 3** Interfaz de usuario final, muestra la mejor oferta personalizada para cada cliente, *maximizando así las oportunidades de venta y la satisfacción del cliente.*

Figura 4. 3 Interfaz de usuario final



The screenshot displays the 'FaceBank' user interface. At the top, there is a search bar and a user profile for 'Renee McKelvey, Ejecutivo Telemarketing'. Below this is a search form with fields for 'Número de documento' (12345678), 'Tipo documento' (DNI), 'Código Único' (123456789), 'Apellido Paterno' (Perez), 'Apellido Materno' (Perez), 'Primer Nombre' (José), and 'Segundo Nombre' (José). An 'Ir' button is located below the search fields.

The main section is titled 'Información de la persona' and features a cartoon illustration of a man in a suit holding a clipboard. To the right of the illustration are several form sections:

- Información personal:** Includes fields for 'Ubicación' (Miraflores, Lima), 'Estado Civil' (Casado), 'Edad' (35), 'Segmento' (Preferente), 'Cliente' (Sí), and 'Rango de Ingresos' (5K a 8 K).
- Oferta principal:** Includes fields for 'Tarjeta de Crédito' (Amex Platinum), 'Linea/Monto' (27000), 'Marca tipo' (Amex Platinum), 'Tasa Consumo A.' (88.83%), 'Cuota', 'Beneficios' (Acumulación de millas, des.), 'Oferta Anterior' (Amex Gold - 25000 - 102.8), and 'Campaña de Aceptación' (Cashback de 200 soles).
- Información SSFF:** Includes fields for 'Banco principal', 'Linea', 'Saldo', and 'Cantidad de Bancos'.

4.4 Implementación y análisis de resultados del producto mínimo viable

Luego del despliegue de nuestro MVP en donde tomamos una base de 32,000 leads aleatorios del producto Extracash y formamos el grupo control con un 50% y 50% piloto, siendo este último grupo seleccionado en base al output de nuestro modelo recomendador del mejor producto, es decir, a aquellos que nuestro modelo indicaba que se le debería de ofrecer un Extracash, hicimos una medición de resultados, luego de una semana de gestión del canal de ventas telefónicas, y estos fueron los resultados obtenidos, véase

Tabla 4. 2 Resultados del MVP.

Tabla 4. 2 Resultados del MVP


	PILOTO	CONTROL
Base total	16000	16000
Gestionado	8240	6206
Venta	3049	2482
%CE	37%	37%
% Aceptación	1.41%	0.35%
% efectividad	0.73%	0.14%
Desembolso	4.3 MM	423 K

Como se puede observar, luego de una semana de gestión, el grupo piloto hizo 116 ventas comparadas con las 22 ventas del grupo control, el cual fue seleccionado con las reglas comerciales vigentes hasta ese momento, además de ello, los resultados fueron los esperados según lo descrito en el Lean Canvas, entre ellos están:

- 4 veces más aceptación del producto.
- 5 veces más efectividad en las ventas.
- 10 veces más desembolso.

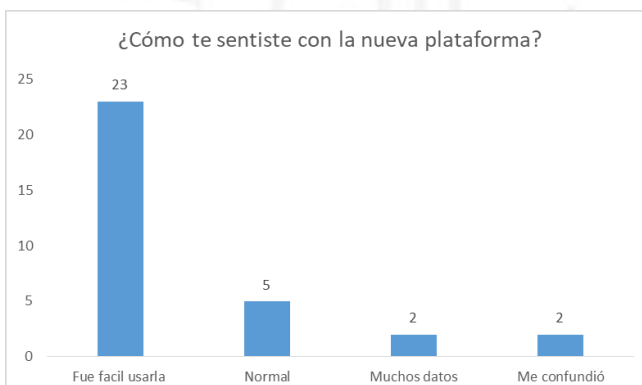
Además de los resultados mostrados, realizamos una encuesta a los mismos colaboradores de ventas telefónicas que pudieron asistir a la reunión presencial que realizamos en la etapa inicial, para entender sus opiniones basadas en la experiencia con nuestra nueva plataforma, y a continuación, en la **Figura 4. 4** Resultados en torno a la pregunta: ¿Sientes que los datos que te brindamos fueron útiles?, se presentan los resultados:

Figura 4. 4 Resultados en torno a la pregunta: *¿Sientes que los datos que te brindamos fueron útiles?*




Los resultados mostraron que 27 encuestados afirmaron sentir que los datos brindados fueron útiles, 3 más o menos, y 2 rechazaron la afirmación previa.

Figura 4. 5 Resultados en torno a la pregunta: *¿Cómo te sentiste con la nueva plataforma?*




En la **Figura 4. 5** Resultados en torno a la pregunta: *¿Cómo te sentiste con la nueva plataforma?*, los resultados mostraron que 23 encuestados afirmaron que fue fácil usar la nueva plataforma, 5 asumieron que la facilidad fue normal, 2 usuarios afirmaron que en la nueva plataforma se procesaban muchos datos, y 2 usuarios también reportaron haberse sentido confundidos.

Figura 4. 6 Resultados en torno a la pregunta: *¿Qué te gustaría experimentar en una nueva web para obtener información sobre los clientes?*



En la **Figura 4. 6** Resultados en torno a la pregunta: *¿Qué te gustaría experimentar en una nueva web para obtener información sobre los clientes?*, los resultados mostraron que a 17 usuarios les gustaría tener acceso fácil y rápido a otras campañas de los clientes para ventas en combo, a 13 usuarios les gustaría acceder a información detallada sobre las interacciones anteriores con los clientes, mientras que a 2 usuarios les gustaría tener herramientas de seguimiento y recordatorio de actividades.

Figura 4. 7 Resultados en torno a la pregunta: *¿Qué clúster de información te resultó más útil?*



En la **Figura 4. 7** Resultados en torno a la pregunta: *¿Qué clúster de información te resultó más útil?*, los resultados mostraron que 7 usuarios asumieron que el clúster de información personal les resultó más útil, a 20 usuarios les resultó más útil el de los beneficios del producto, mientras que a 5 les resultó más útil la información de SSFF-Competencia.

CONCLUSIONES

- El despliegue exitoso del MVP del sistema de recomendación basado en modelos predictivos para el producto ha demostrado una optimización significativa en el proceso de ventas telefónicas de productos financieros. La implementación de técnicas de aprendizaje automático ha llevado a mejoras sustanciales en la efectividad de ventas, la aceptación del producto y el desembolso, consolidando así la eficacia del sistema de recomendación en mejorar la operación de ventas telefónicas.
- El desarrollo e implementación del sistema de recomendación basado en modelos predictivos ha permitido utilizar información histórica de clientes y leads de manera efectiva. Esto ha contribuido directamente a la mejora en la segmentación de leads y la identificación de oportunidades de venta más relevantes, apoyando así la optimización del proceso de ventas.
- La integración exitosa del sistema de recomendación en el canal de ventas telefónicas ha permitido identificar leads con mayor probabilidad de aceptar el producto de manera eficiente. Esta integración ha optimizado el enfoque de ventas, mejorando la calidad de las interacciones con los leads y aumentando la tasa de conversión.
- La evaluación de la efectividad del sistema de recomendación, mediante la comparación de resultados entre el grupo piloto y el grupo control, ha demostrado claramente el impacto positivo del sistema en las ventas y el desempeño financiero. El análisis ha validado la importancia y el valor añadido del sistema de recomendación en el proceso de ventas telefónicas.
- La mejora significativa en la tasa de aceptación del producto en el grupo piloto, junto con el aumento notable en las ventas, la efectividad y el desembolso, reflejan el éxito en la consecución de este objetivo específico. El sistema de recomendación ha logrado impulsar resultados tangibles y positivos en la estrategia de ventas de la empresa.
- La recopilación de feedback y opiniones de los colaboradores de ventas telefónicas ha sido fundamental para identificar áreas de mejora y realizar ajustes continuos en la plataforma y en las estrategias de venta. Este proceso de retroalimentación ha contribuido significativamente a la evolución y optimización continua del sistema de recomendación y del proceso de ventas en general.

RECOMENDACIONES

Proporcionar capacitación continua al área comercial sobre el uso óptimo del sistema de recomendación y las mejores prácticas en la interacción con leads identificados por el sistema. Esto garantizará que el equipo esté actualizado con las últimas funcionalidades y estrategias de ventas.

Además, se sugiere continuar mejorando y ajustando los algoritmos de recomendación basados en modelos predictivos. Esto implica analizar regularmente los datos y retroalimentación recopilados para identificar patrones emergentes y optimizar la precisión de las recomendaciones.

En adición a ello, se sugiere implementar estrategias de segmentación más personalizadas respaldada de información del comportamiento financiero y las preferencias del cliente. Utilizar datos históricos y en tiempo real para ofrecer recomendaciones altamente relevantes y adaptadas a las necesidades específicas de cada cliente.

También es factible utilizar el feedback y las opiniones recopiladas de los colaboradores de ventas telefónicas para impulsar mejoras continuas en la plataforma de recomendación y en las estrategias de venta. Esto puede incluir ajustes en la interfaz de usuario, la incorporación de nuevas funcionalidades y la optimización de procesos.

Así mismo, se sugiere mantener un monitoreo constante de las métricas clave de rendimiento, como la tasa de conversión, la aceptación del producto y el desembolso. Utilizar estos datos para identificar áreas de oportunidad, detectar posibles problemas y tomar decisiones informadas para optimizar el proceso de ventas.

Por último, se recomienda promover la colaboración entre equipos de ventas, marketing y análisis de datos para maximizar el potencial del sistema de recomendación. Esto implica compartir información y estrategias para alinear esfuerzos en la generación de leads, la personalización de las recomendaciones y la mejora continua de la experiencia del cliente.

GLOSARIO DE TÉRMINOS

- **A/B testing:** Método de prueba en el que se comparan dos versiones de algo (como una página web, una aplicación, etc.) para determinar cuál tiene un mejor rendimiento en función de un objetivo específico (Rodríguez et al., 2024).
- **AdaBoost:** Algoritmo de aprendizaje automático que se utiliza para mejorar el rendimiento de modelos de clasificación débiles al asignarles pesos y prioridades diferentes durante el proceso de entrenamiento (Ramírez, 2018).
- **AutoML:** Automatización de Machine Learning, que consiste en utilizar herramientas y algoritmos para automatizar el proceso de creación y entrenamiento de modelos de aprendizaje automático, sin necesidad de intervención humana directa en cada paso (Tableau A Salesforce Company, 2019).
- **Bagging:** Técnica de ensamblaje en Machine Learning donde se crean múltiples modelos independientes y se combinan sus predicciones para mejorar la precisión y generalización del modelo final (Hoff, 2020).
- **Boosting:** Otra técnica de ensamblaje en Machine Learning que se enfoca en mejorar modelos débiles mediante la construcción secuencial de modelos, asignando más peso a los casos mal clasificados para corregir errores (Tableau A Salesforce Company, 2019).
- **CRM (Customer Relationship Management):** Sistema que ayuda a gestionar las interacciones con clientes actuales y potenciales, facilitando la gestión de relaciones, ventas, marketing y servicio al cliente (Alhamad, 2022).
- **Design Thinking:** Enfoque centrado en el usuario para resolver problemas complejos de manera creativa, basado en la colaboración, la empatía y la experimentación (Universidad de Málaga, 2000).
- **GenAI:** Generación de soluciones o ideas mediante la utilización de algoritmos y técnicas de inteligencia artificial (Crompton & Song, 2020).
- **Gradient Boosting Machines (GBM):** Algoritmo de aprendizaje automático que utiliza el enfoque de boosting para mejorar modelos de manera secuencial, minimizando errores en cada iteración (Pozuelo et al., 2018).

- **IA (Inteligencia Artificial):** Campo de la informática que se enfoca en crear sistemas capaces de realizar tareas que normalmente requieren inteligencia humana, como el aprendizaje automático, el procesamiento del lenguaje natural, la visión por computadora, entre otros (IA+Iguar, 2024).
- **Leads:** Individuos o empresas que muestran interés en un producto o servicio y que han proporcionado información de contacto, siendo prospectos potenciales para convertirse en clientes (Siddiqui et al., 2021).
- **Machine Learning:** Subcampo de la inteligencia artificial que se centra en el desarrollo de algoritmos y modelos que pueden aprender de datos y realizar predicciones o tomar decisiones sin ser programados explícitamente para cada tarea (Rodríguez et al., 2024).
- **MVP (Minimum Viable Product):** Versión mínima y funcional de un producto o servicio que se desarrolla con el propósito de obtener retroalimentación rápida de los usuarios y validar la viabilidad del concepto (Ore et al., 2021).
- **NaNs:** Representación de valores faltantes o nulos en datos, utilizada en análisis de datos para indicar que no hay información disponible para un determinado punto de datos (Narváez, 2023).
- **Overfitting:** Problema en el aprendizaje automático donde un modelo se ajusta demasiado a los datos de entrenamiento, perdiendo capacidad de generalización y generando predicciones menos precisas en nuevos datos (Rodríguez et al., 2024).
- **PureConnect:** Plataforma de software de gestión de experiencia del cliente (CX) que proporciona soluciones integradas para la administración de interacciones, la automatización de procesos y la mejora de la satisfacción del cliente (Shahbaznezhad et al., 2022).
- **Random Forest:** Algoritmo de aprendizaje automático que crea múltiples árboles de decisión y combina sus resultados para mejorar la precisión y la generalización del modelo (Universidad de Málaga, 2000).
- **Sistemas de Recomendación (SR):** Tecnologías y algoritmos que analizan datos de usuarios y productos para predecir y recomendar elementos de interés para los usuarios, comúnmente utilizados en plataformas de comercio electrónico, streaming de contenido, entre otros (Universidad de Málaga, 2000) .

- **Speech de Venta:** Discurso o presentación estructurada y persuasiva utilizada por los vendedores para comunicar y promover un producto o servicio a los clientes potenciales (Monferrer Tirado, 2013).



REFERENCIAS

- Alhamad, I. A. (2022). The Role of Emotional Marketing and eWOM in Sustaining Competitive Advantage in the Digital Era: A Dynamic Capabilities-Based Strategic Framework. *Revista Amazonia Investiga*, 11(51), 281–290. <https://doi.org/10.34069/AI/2022.51.03.28>
- Allaire, G. (2007). *Numerical Analysis and Optimization*. Oxford University Press Inc.
- Bender, E. (2002). *An Introduction to Mathematical Modeling*. John Wiley & Sons, Inc. All. <https://doi.org/10.2307/3009653>
- Bishop, C. (2006). *A Review of Pattern Recognition and Machine Learning*. Springer Science+Business Media. <https://doi.org/10.53759/7669/jmc202404020>
- Bron, B., & Mar, O. (2022). Sistemas de recomendación para la toma de decisiones. Estado del arte. *UNESUM-Ciencias: Revista Científica Multidisciplinaria*, 6(1), 149–164.
- Challenger, I., Díaz, Y., & Becerra, R. (2014). El lenguaje de programación Python. *Revista Ciencias Holguín*, 20(2), 1–13.
- Consoli, D. (2010). A New Concept of Marketing: The Emotional Marketing. *BRAND. Broad Research in Accounting, Negotiation, and Distribution*, 1(1), 1–8.
- Crompton, H., & Song, D. (2020). El potencial de la inteligencia artificial en la educación superior. *Revista Virtual Universidad Católica Del Norte*, 62. <https://doi.org/https://doi.org/10.35575/rvucn.n62a1>
- Data Science Association. (2020). *The Ultimate Guide to A / B*. unbounce.
- Fernandez, T. (2020). *What Is Canary Deployment?* Semaphore.
- Feurer, M., & Hutter, F. (2019). Automated Machine Learning. Methods, Systems, Challenges. In *Automated Machine Learning. Methods, Systems, Challenges* (pp. 3–33). Springer.
- Frigg, R., & Hartmann, S. (2020). Models in Science. In *Stanford Encyclopedia of Philosophy*. Department of Philosophy, Stanford University.
- García, F., & Gil, A. (2015). *Personalización de Sistemas de Recomendación*. Universidad de Salamanca.
- Hoff, E. (2020). *Language Development*. Cengage Learning Editores.
- Huang, J. (2023). *Desarrollo de un sistema de reomendación para una empresa de servicios online*. Trabajo de fin de grado, Universitat de Barcelona.
- IA+Igual. (2024). *Glosario IA en RR . HH*. IA+IGUAL.
- Isinkaye, F., Folajami, Y., & Ojokoh, B. (2015). Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, 16, 261–273. <https://doi.org/10.1016/j.eij.2015.06.005>
- Ke, W., Johannes, R., & Shah, R. (2023). Product Offer and Pricing Personalization in Retail Banking. In *Encyclopedia of Data Science and Machine Learning* (pp. 1952–1963). Springer.
- Kuchling, A. (1988). Interview with Guido van Rossum. *Linux Journal*.
- Lugo, J. (2012). *Modelo para el control de la ejecución de proyectos basado en indicadores y lógica borrosa* [Trabajo final presentado en opción al título de Máster en Gestión de Proyectos Informáticos, Universidad de las Ciencias Informáticas]. <https://doi.org/10.13140/2.1.1523.5362>
- Maida, E., & Pacienza, J. (2015). *Metodologías de desarrollo de software*. Biblioteca Digital de la Universidad Católica Argentina.
- Management Solutions. (2020). *Auto Machine Learning , towards model automation*. Management Solutions.

- Marín, D., & Pineda, I. (2019). *Modelo predictivo Machine Learning aplicado a análisis de datos Hidrometeorológicos para un SAT en Represas*. Tesis de Titulación, Universidad Tecnológica del Perú.
- Mathew, P., Kuriakose, B., & Hegde, V. (2016). Book Recommendation System through Content Based and Collaborative Filtering Method. *2016 International Conference on Data Mining and Advanced Computing*, 47–52.
- Monferrer Tirado, D. (2013). Fundamentos del Marketing. (1ª ed.) Castellón de la Plana, España. In *Universitat Jaume I*. <https://repositori.uji.es/xmlui/bitstream/handle/10234/49394/s74.pdf>
- Narváez, C. (2023). *Usabilidad en Software ERP: Revisión Sistemática de la Literatura* [Trabajo de titulación previo a la obtención del grado de Ingeniero de Sistema y Telemática, Universidad del Azuay]. <https://dspace.uazuay.edu.ec/bitstream/datos/12872/1/18399.pdf>
- Ore, H., Aldana, W., Salazar, C., & Pantoja, L. (2021). Benchmarking como herramienta gerencial en las empresas: Revisión bibliográfica. *Llamkasun*, 2(2), 54–65. <https://doi.org/10.47797/llamkasun.v2i2.41>
- Pathak, B., Garfinkel, R., Gopal, R., Venkatesan, R., & Yin, F. (2010). Empirical Analysis of the Impact of Recommender Systems on Sales. *Journal of Management Information Systems*, 27(2), 159–188. <https://doi.org/10.2753/MIS0742-1222270205>
- Pérez, M. (2018). *Técnicas Boosting*. Trabajo de Fin de Grado, Universidad de Sevilla.
- Pozuelo, J., Martínez, J., & Carmona, P. (2018). Análisis de la utilidad del algoritmo Gradient Boosting Machine (GBM) en la predicción del fracaso empresarial. *Revista Española de Financiación y Contabilidad*, 00(00), 1–26. <https://doi.org/10.1080/02102412.2018.1442039>
- Ramírez, C. (2018). Algoritmo SVD aplicado a los sistemas de recomendación en el comercio. *Tecnología, Investigación y Academia*, 6(1), 18–27.
- Red España. (2021). Guía práctica de introducción al Análisis Exploratorio de Datos. In *Iniciativa aporta*. Iniciativa aporta.
- Red Hat. (2019). *What is blue green deployment?*
- Resnick, P., Varian, H., & Editors, G. (1997). Recommender Systems. *Communications of the ACM*, 40(3), 56–58. <https://doi.org/10.1145/245108.245121>
- Rocha, A. R. (2023). *Marketing 5.0, inteligencia artificial y análisis predictivo en el sector de la moda*. Trabajo de Fin de Grado, Universidade da Coruña.
- Rodríguez, Á., Rodríguez, F., Collaguazo, D., & Rodríguez, J. (2024). Diferencias y Aplicaciones de Big Data, Inteligencia Artificial, Machine Learning y Deep Learning. *Dominio de Las Ciencias*, 10(3). <https://dominiodelasciencias.com/ojs/index.php/es/article/view/3966>
- Salehin, I., Islam, S., Saha, P., & Noman, S. M. (2024). AutoML : A Systematic Review on Automated Machine Learning with Neural Architecture Search. *Journal of Information and Intelligence* 2, 2, 52–81. <https://doi.org/10.1016/j.jiixd.2023.10.002>
- Santamaría, M. (2022). *Machine Learning Operations (MLOps): contexto actual y tendencias futuras*. Trabajo Fin de Estudios, Universidad de la Rioja.
- Shahbaznezhad, H., Dolan, R., & Rashidirad, M. (2022). El papel del formato y la plataforma de contenido de las redes sociales en el comportamiento de interacción de los usuarios. *Revista de Marketing Interactivo*, 53(1). <https://journals.sagepub.com/doi/abs/10.1016/j.intmar.2020.05.001?journalCode=jnma>
- Shang, D.-Y. (2010). *Theory of Heat Transfer with Forced Convection Film Flows*.

- Springer Science & Business Media.
- Siddiqui, M. S., Siddiqui, U. A., Khan, M. A., Alkandi, I. G., Saxena, A. K., & Siddiqui, J. H. (2021). Creating Electronic Word of Mouth Credibility through Social Networking Sites and Determining Its Impact on Brand Image and Online Purchase Intentions in India. *Journal of Theoretical and Applied Electronic Commerce Research*, 16(4), 1008–1024. <https://doi.org/10.3390/jtaer16040057>
- Song, Y., Zhao, X., Jiang, D., Huang, X., Zhao, W., Xu, Q., Chi, R., & Yang, Q. (2021). SmartSales: An AI-Powered Telemarketing Coaching System in FinTech. *MM '21: Proceedings of the 29th ACM International Conference on Multimedia*, 2774–2776.
- Tableau A Salesforce Company. (2019). *Tendencias de Inteligencia de Negocios*. <https://www.tableau.com/es-es/reports/business-intelligence-trends/machine-learning>
- Tintarev, N., & Masthoff, J. (2007). A Survey of Explanations in Recommender Systems. *2007 IEEE 23rd International Conference on Data Engineering Workshop*, 801–810.
- Universidad Carlos III de Madrid. (2023). *Recomendaciones para la docencia con inteligencias artificiales generativas*. UC3M DIGITAL. <https://e-archivo.uc3m.es/rest/api/core/bitstreams/456229c0-3670-4198-b86d-ff2762a3e1f9/content>
- Universidad de Málaga. (2000). *Técnicas de Diseño de Algoritmos*. <http://www.lcc.uma.es/~av/Libro/>
- Universidad Politécnica de Madrid. (2021). *Algoritmos de Machine Learning*. Management Solutions. <https://blogs.upm.es/catedra-idanae/wp-content/uploads/sites/698/2021/04/Idanae-1T21.pdf>
- Valadi, J., & Siarry, P. (2014). *Applications of Metaheuristics in Process Engineering*. Springer International Publishing. <https://link.springer.com/book/10.1007/978-3-319-06508-3>
- Valderrama, P. (2021). *Mlops para el desarrollo y puesta en producción de modelos de machine learning* [Tesis de Grado, Universidad de Málaga]. <https://riuma.uma.es/xmlui/handle/10630/23550>
- Valenzuela, G., Cruz, Y., & Díaz, C. (2021). Desarrollo de una aplicación web progresiva para la recomendación de películas y libros mediante la técnica de filtrado colaborativo. *Revista CIES – ISSN-e 2216-0167*, 12(1), 139–150.
- Velásquez, A. A. G., & Alejandro, S. (2023). *Insighlytic: una herramienta de analítica web e inteligencia artificial* [Trabajo Fin de Máster, Universitat Politècnica de València]. <https://riunet.upv.es/handle/10251/198002>
- Vera, J., Ocsa, A., & Villalba, K. (2015). Modelo de sistema de recomendación de Objetos de Aprendizaje en dispositivos móviles, caso: Desarrollo del pensamiento computacional. *Nuevas Ideas En Informática Educativa*, 5(1), 730–734.
- Walid, E. (2017). *Un sistema de recomendación basado en perfiles generados por agrupamiento y asociaciones* [Trabajo de fin de máster, Universitat Politècnica de València]. <https://riunet.upv.es/handle/10251/94049>


9% Similitud general

El total combinado de todas las coincidencias, incluidas las fuentes superpuestas, para ca...

Filtrado desde el informe

- ▶ Bibliografía
- ▶ Texto citado

Fuentes principales

- 8%  Fuentes de Internet
- 1%  Publicaciones
- 4%  Trabajos entregados (trabajos del estudiante)

Marcas de integridad

N.º de alertas de integridad para revisión

No se han detectado manipulaciones de texto sospechosas.

Los algoritmos de nuestro sistema analizan un documento en profundidad para buscar inconsistencias que permitirían distinguirlo de una entrega normal. Si advertimos algo extraño, lo marcamos como una alerta para que pueda revisarlo.

Una marca de alerta no es necesariamente un indicador de problemas. Sin embargo, recomendamos que preste atención y la revise.