

**UNIVERSIDAD NACIONAL DEL CALLAO**  
**FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS**  
**ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS**



**“APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023”**

TESIS PARA OPTAR EL TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS

AUTORES:

ANA MARLENE ORIHUELA RAMIREZ  
LESLIE FRIDA PEREZ RAMOS  
XIMENA PIERINA OMayra VICUÑA PEÑA

Asesor:  
DRA. SALLY KARINA TORRES ALVARADO

Línea de investigación:  
INGENIERÍA Y TECNOLOGÍA

Callao, 2024

PERÚ



## Document Information

Analyzed document	TESIS - ORIHUELA_PEREZ_OMAYRA.docx (D181862423)
Submitted	2023-12-14 20:30:00 UTC+01:00
Submitted by	Unidad FIIS
Submitter email	fiis.investigacion@unac.edu.pe
Similarity	4%
Analysis address	fiis.investigacion.unac@analysis.arkund.com

## Sources included in the report

<b>SA</b>	<b>1586023205_103__MURILLO_FRANCISCO_EXAMEN_ESTADISTICA.docx</b> Document 1586023205_103__MURILLO_FRANCISCO_EXAMEN_ESTADISTICA.docx (D67564449)		4
<b>SA</b>	<b>1563606284_187__avance_de_evaluacion_proyecto_final.docx</b> Document 1563606284_187__avance_de_evaluacion_proyecto_final.docx (D54648500)		1
<b>SA</b>	<b>Universidad Nacional del Callao / Archivo 1 1A, Luyo Z, Naveda P, Castro E-Título-2022.doc.docx</b> Document Archivo 1 1A, Luyo Z, Naveda P, Castro E-Título-2022.doc..docx (D152907508) Submitted by: mepingoz@unac.edu.pe Receiver: investigacion.fcc.unac@analysis.arkund.com		1
<b>SA</b>	<b>Universidad Nacional del Callao / Archivo 1. 1A, Anchahua T, Luque C, Neira F-Titulacion-2022.doc.docx</b> Document Archivo 1. 1A, Anchahua T, Luque C, Neira F-Titulacion-2022.doc.docx (D141537222) Submitted by: mepingoz@unac.edu.pe Receiver: investigacion.fcc.unac@analysis.arkund.com		2

## Entire Document

UNIVERSIDAD NACIONAL DEL CALLAO  
FACULTAD DE INGENIERÍA INDUSTRIAL Y SISTEMAS  
ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS  
"APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023"  
TESIS PARA OPTAR EL TÍTULO EN INGENIERÍA DE SISTEMAS  
AUTORES:  
ANA MARLENE ORIHUELA RAMIREZ LESLIE FRIDA PEREZ RAMOS XIMENA PIERINA OMAIRA VICUÑA PEÑA  
Asesor: DRA. SALLY KARINA TORRES ALVARADO  
Línea de investigación: INGENIERÍA Y TECNOLOGÍA  
Callao, 2023  
PERÚ

## INFORMACIÓN BÁSICA

**FACULTAD:** FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS

**ESCUELA PROFESIONAL:** ESCUELA PROFESIONAL DE INGENIERÍA DE SISTEMAS

**TÍTULO:** “APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023”

**AUTORES:** ORIHUELA RAMIREZ, ANA MARLENE  
CÓDIGO ORCID: 0009-0001-7981-2620  
DNI: 70001369

PEREZ RAMOS, LESLIE FRIDA  
CÓDIGO ORCID: 0009-0003-5980-7001  
DNI: 74541358

VICUÑA PEÑA, XIMENA PIERINA OMayra  
CÓDIGO ORCID: 0009-0007-5837-803X  
DNI: 74240141

**ASESOR:** DRA. TORRES ALVARADO, SALLY KARINA  
CÓDIGO ORCID: 0000-0001-6657-2931  
DNI: 15724611

**LUGAR DE EJECUCIÓN:** UNA ENTIDAD FINANCIERA CON SEDE PRINCIPAL EN EL DISTRITO DE LA VICTORIA

**UNIDAD DE ANÁLISIS:** ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA

**TIPO DE INVESTIGACIÓN:** APLICADA

**ENFOQUE INVESTIGACIÓN:** CUANTITATIVO

**DISEÑO DE INVESTIGACIÓN:** EXPERIMENTAL

**TEMA OCDE:** INGENIERÍA Y TECNOLOGÍA

## HOJA DE REFERENCIA DEL JURADO Y APROBACIÓN

La presente tesis fue sustentada por los bachilleres Perez Ramos Leslie Frida, Orihuela Ramirez Ana Marlene y Vicuña Peña Ximena Pierina Omayra ante el JURADO DE SUSTENTACIÓN DE TESIS conformado por los siguientes docentes ordinarios:

MG. MANUEL ABELARDO ALCÁNTARA RAMÍREZ.....PRESIDENTE

MG. ANGELINO ABAD RAMOS CHOQUEHUANCA.....SECRETARIO

MG. JESÚS JOSÉ BRINGAS ZUÑIGA.....VOCAL

ASESOR: DRA. SALLY KARINA TORRES ALVARADO

Libro N° 01

Folio N° 11

Acta N° 005-2024-I-CTT-IS

Fecha de sustentación: 6 de enero de 2024



# ACTA DE SUSTENTACIÓN

## ACTA DE SUSTENTACION POR MODALIDAD DE CICLO TALLER DE TESIS PARA LA OBTENCIÓN DEL TÍTULO PROFESIONAL DE INGENIERO DE SISTEMAS

ACTA N° 005-2024-I-CTT-IS

Siendo las 10.40 horas del día 06 de Enero del año 2024, encontrándose reunidos en el Auditorium de la FIIS, el **Dr. ENRIQUE GARCÍA TALLEDO**, en representación de la Rectora de la UNAC; el **JURADO DE SUSTENTACIÓN DE TESIS** (designado por resolución **002-2024-CF-FIIS**) de la Facultad Ingeniería Industrial y de Sistemas de la Universidad Nacional del Callao, para la evaluación de las Tesis que conllevan a la obtención del Título Profesional de **INGENIERO DE SISTEMAS**, el que se encuentra conformado por los siguientes docentes ordinarios:

<b>PRESIDENTE</b>	<b>MG. MANUEL ABELARDO ALCÁNTARA RAMÍREZ</b>
<b>SECRETARIO</b>	<b>MG. ANGELINO ABAD RAMOS CHOQUEHUANCA</b>
<b>VOCAL</b>	<b>MG. JESÚS JOSÉ BRINGAS ZÚÑIGA</b>
<b>SUPLENTE</b>	<b>MG. YESMI KATIA ORTEGA ROJAS</b>

Con el quórum reglamentario de ley y de conformidad con lo establecido por el Reglamento de Grados y Títulos vigente se dio inicio al Acto de Sustentación de la Tesis de los Bachilleres: **PEREZ RAMOS LESLIE FRIDA, ORIHUELA RAMIREZ ANA MARLENE, VICUÑA PEÑA XIMENA PIERINA OMAIRA** quienes, habiendo cumplido con los requisitos para optar el Título Profesional de **INGENIERO DE SISTEMAS**, sustentan la tesis titulada **“APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023”**, cumpliendo con la sustentación en acto público, de manera presencial.

Luego de la exposición, y de la absolución de las preguntas formuladas por el Jurado de Sustentación y efectuadas las deliberaciones pertinentes, **SE ACORDÓ:** Dar por **APROBADO** con la escala de calificación cuantitativa **(17)** y calificación cualitativa **(Muy Bueno)** a la presente tesis, conforme a lo dispuesto en el Art. 24 del Reglamento de Grados y Títulos de la UNAC, aprobado por Resolución de Consejo Universitario N° 150-2023-CU del 15 de junio del 2023.

Se dio por concluida la Sesión a las 11.10 horas del día 06 de enero del 2024.

  
.....  
MG. MANUEL ABELARDO ALCANTARA RAMÍREZ  
Presidente

  
.....  
MG. ANGELINO ABAD RAMOS CHOQUEHUANCA  
Secretario

  
.....  
MG. JESÚS JOSÉ BRINGAS ZÚÑIGA  
Vocal

  
.....  
MG. YESMI KATIA ORTEGA ROJAS  
Suplente



**INFORME N° 005-2024 – JS ICTTS**

**PARA : DR. PAUL GREGORIO PAUCAR LLANOS  
DECANO FIIS**

**DE : JURADO DE SUSTENTACIÓN DEL I CICLO TALLER DE TESIS DE INGENIERÍA DE SISTEMAS**

**ASUNTO : INFORME FAVORABLE DEL JURADO DE SUSTENTACION**

**FECHA : Callao, 06 de enero del 2024**

---

Los miembros del Jurado de Sustentación designados por **Resolución N° 002-2024-CF-FIIS** y de acuerdo al Reglamento de Grados y Títulos, aprobado por Resolución 150-2023-CU del 15 de junio de 2023 Art. 71, visto el Acta de Sustentación **N° 005-2024 – JS ICTTS** de Tesis Titulada: **“APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023”**

**Presentado por:**  
**PEREZ RAMOS LESLIE FRIDA**  
**ORIHUELA RAMIREZ ANA MARLENE**  
**VICUÑA PEÑA XIMENA PIERINA OMayRA**

Para obtener Título de Profesional de **INGENIERO DE SISTEMAS**, por modalidad de Tesis con Ciclo Taller de Tesis, habiendo obtenido nota aprobatoria de (17) diecisiete, Muy Bueno.

En tal sentido, los miembros del Jurado de Sustentación informan que no existe observación alguna a dicha Tesis por lo que se da la **CONFORMIDAD**, lo cual se debe comunicar a los interesados.

Sin otro particular reiteramos los sentimientos y estima personal.

MG. MANUEL ABELARDO ALCÁNTARA RAMÍREZ  
Presidente

MG. ANGELINO ABAD RAMOS CHOQUEHUANCA  
Secretario

MG. JESÚS JOSÉ BRINCAS ZÚÑIGA  
Vocal

MG. YESMI KATHIA ORTEGA ROJAS  
Suplente

## **DEDICATORIA**

El siguiente trabajo de tesis está dedicado a todas las personas que nos han apoyado y han hecho que el trabajo se realice con éxito en especial a nuestros padres y a aquellos que nos abrieron las puertas y nos compartieron sus conocimientos.



## ÍNDICE

INTRODUCCIÓN .....	7
I. PLANTEAMIENTO DEL PROBLEMA.....	8
1.1. Descripción de la realidad problemática.....	8
1.2. Formulación del problema.....	10
1.2.1. Problema General:.....	10
1.2.2. Problemas Específicos: .....	10
1.3. Objetivos.....	10
1.3.1. Objetivo General:.....	10
1.3.2. Objetivos Específicos:.....	10
1.4. Justificación.....	10
1.5. Limitantes de investigación.....	11
1.5.1. Limitación Espacial .....	11
1.5.2. Limitante Temporal .....	11
1.5.3. Limitante Conceptual .....	11
II. MARCO TEÓRICO.....	12
2.1. Antecedentes.....	12
2.1.1. Internacionales .....	12
2.1.2. Nacionales.....	15
2.2. Bases teóricas.....	17
2.2.1. Inteligencia artificial.....	17
2.2.2. Machine learning.....	19
2.2.3. Aprendizaje supervisado.....	20
2.2.4. Aprendizaje no supervisado.....	20
2.2.5. Algoritmos KNN .....	20

2.2.6.	Banca .....	21
2.2.7.	Ventas digitales. ....	21
2.2.8.	Convenios corporativos .....	21
2.3.	Marco conceptual. ....	22
2.3.1.	Crédito bancario. ....	22
2.4.	Definición de términos básicos. ....	22
III.	HIPÓTESIS Y VARIABLES. ....	26
3.1.	Hipótesis. ....	26
3.1.1.	Hipótesis general .....	26
3.1.2.	Hipótesis específicas .....	26
3.2.	Operacionalización de variables. ....	26
3.2.1.	Modelo de machine learning .....	26
3.2.2.	Ventas digitales .....	26
IV.	METODOLOGÍA DEL PROYECTO. ....	28
4.1.	Diseño metodológico. ....	28
4.2.	Métodos de investigación. ....	28
4.3.	Población y muestra. ....	28
4.3.1.	Población.....	29
4.3.2.	Muestra.....	29
4.4.	Lugar de estudio y periodo desarrollado.....	29
4.5.	Técnicas e instrumentos para la recolección de la información. ....	29
4.6.	Análisis y procesamiento de datos. ....	30
4.7.	Aspectos éticos en investigación.....	32
V.	RESULTADOS. ....	33
5.1.	Modelo K-NN.....	33
5.2.	Resultados descriptivos.....	39

5.3. Resultados inferenciales. ....	43
VI. DISCUSIÓN DE RESULTADOS.....	50
6.1. Contrastación y demostración de la hipótesis con los resultados. ....	50
6.2. Contrastación de los resultados con otros estudios similares.....	50
6.3. Responsabilidad ética de acuerdo a los reglamentos vigentes.....	51
VII. CONCLUSIONES.....	53
VIII. RECOMENDACIONES.....	54
IX. REFERENCIAS BIBLIOGRÁFICAS.....	55
ANEXOS:.....	60
Anexo 1: Matriz de consistencia.....	60
Anexo 2: Instrumentos validados .....	61
Anexo 3: Base de Datos .....	69
Anexo 4: Declaración Jurada de autenticidad de datos.....	74

## ÍNDICE DE TABLAS

Tabla 1: Operacionalización de las variables .....	27
Tabla 2: Cálculo de calificación de expertos.....	31
Tabla 3: Clientes que aceptaron o no aceptaron un crédito.....	39
Tabla 4: Fuentes por las que fueron captados los clientes potenciales .....	39
Tabla 5: Clientes potenciales con campaña vigente .....	40
Tabla 6: Segmentación de clientes potenciales por región .....	41
Tabla 7: Segmentación de clientes potenciales por familia por convenio .....	42
Tabla 8: Prueba de normalidad de ventas digitales .....	45
Tabla 9: Prueba de normalidad de clientes potenciales y montos desembolsados .....	46
Tabla 10: Estadística de la muestra .....	47
Tabla 11: Prueba T-student para ventas digitales .....	48
Tabla 12: Prueba T-student para clientes potenciales .....	48
Tabla 13: Prueba T-student para montos desembolsados .....	49
Tabla 14: Encuesta de variable dependiente.....	69
Tabla 15: Ficha de Registro – Antes de la implementación .....	70
Tabla 16: Ficha de Registro – Después de la implementación .....	72

## ÍNDICE DE FIGURAS

Figura 1:Definiciones de inteligencia artificial .....	18
Figura 2: Pasos en Aprendizaje de Máquina .....	19
Figura 3: Importación de librerías .....	33
Figura 4:Carga de datos.....	34
Figura 5: Visualización previa de los datos.....	34
Figura 6: Limpieza de datos .....	34
Figura 7: Tipos de datos.....	35
Figura 8: Tamaño de la data .....	35
Figura 9: División de datos .....	35
Figura 10: Clasificando con el modelo KNN .....	36
Figura 11: Métricas del modelo .....	36
Figura 12: Precisión del modelo .....	36
Figura 13: Validando el mejor hiperparámetro.....	37
Figura 14: Valores con el hiperparametro 3.....	37
Figura 15: Métricas con el hiperparámetro igual a 3.....	38
Figura 16: Correlación entre las variables del modelo .....	38
Figura 17 Fuentes por las que fueron captados los clientes potenciales .....	40
Figura 18: Clientes potenciales con campaña vigente.....	41
Figura 19: Segmentación de clientes potenciales por región.....	42
Figura 20:Segmentación de clientes potenciales por familia por convenio .....	43

## RESUMEN

Las ventas digitales son el futuro de cada compañía alrededor del mundo y los bancos peruanos saben de la importancia de este tema. Una de las principales fuentes de ingreso del sector bancario es el otorgamiento de créditos. Siendo los canales de venta digitales los que proactivamente los ofrecen, permitiendo captar clientes de forma eficiente.

Sin embargo, el rendimiento del banco podría ser mucho mejor. El presente trabajo propone al área de ventas digitales por convenio la elaboración de un modelo predictivo con técnicas de machine learning que permita conocer los factores que impactan en el número de ventas de crédito que se realizan, con el fin de agilizar la toma de decisiones frente a estrategias de venta y mejorar la planificación de recursos para incrementar el número de créditos otorgados.

Además, para la construcción del modelo se utilizó la técnica de machine learning de clasificación k-NN, los datos utilizados para el entrenamiento son de clientes a los que se les ofreció un crédito durante el mes de agosto del 2023. Los datos recopilados son de un total de 2461 clientes, siendo 1,844 clasificados como 'Aceptaron' y 617 clasificados como 'No Aceptaron'. Los resultados en la primera simulación tuvieron una precisión de 96.14%.

**PALABRAS CLAVES:** Machine learning, Aprendizaje supervisado, ventas digitales, Créditos y Leads.

## **ABSTRACT**

Digital sales are the future of every company around the world, and Peruvian banks know the importance of this issue. One of the main sources of income for the banking sector is the granting of credit. Being the digital sales channels that proactively offer them, allowing to attract customers efficiently.

However, the performance of the bank could be much better. The present work proposes to the area of digital sales by agreement the elaboration of a predictive model with machine learning techniques that allows knowing the factors that impact the number of credit sales that are made, in order to expedite decision making in front of sales strategies and improve resource planning to increase the number of credits granted by agreement.

In addition, k-NN classification machine learning technique was used to build the model. The data used is from clients who were offered a loan during the month of August 2023. The data collected is from a total of 2,461 clients, with 1,844 classified as 'Accepted' and 617 classified as 'Not Accepted'. The results in the first simulation had an accuracy of 96.14%.

**KEY WORDS:** Machine learning, Supervised learning, digital sales, Credits and Leads.

## INTRODUCCIÓN

Situándonos en los acontecimientos recientes, la evolución digital y el marketing han tenido un cambio impactante, las industrias dejaron de utilizar los medios digitales solamente como mecanismos de comunicación, en su lugar se han convertido en una herramienta de adquisición de mercado con potencial de ventas.

Las primeras en incursionar en el esquema de ventas online fueron las compañías de e-commerce, pero con el paso del tiempo diferentes sectores se han sumado a este modelo. Luego de los recientes eventos generados por la pandemia del Covid-19, muchas personas y organizaciones fueron afectadas negativamente a nivel económico, además que restringieron a las personas dentro de sus viviendas lo que las llevó a tener una vida a través de las pantallas de sus celulares y computadores. Tal fue el impacto, que a partir del 2020 las compañías que nunca priorizaron la transformación de sus modelos de ventas tuvieron que adaptarse rápidamente a la nueva tendencia de compra de productos y servicios a través de Internet. Siendo el sector bancario uno más de los afectados.

Anteriormente los bancos se caracterizaban por su tradicional forma de operar, dedicaban la mayor parte de sus recursos en la apertura de nuevas oficinas, que les permitiera estar más cerca de sus clientes para brindarles una mejor atención y ofrecerles los productos casi a la mano. En la actualidad la realidad es diferente, por medio de una aplicación móvil el banco les ofrece a sus clientes la mejor atención, le permite al cliente realizar numerosas operaciones y ofrecer sus productos financieros desde el celular o un computador.



## **I. PLANTEAMIENTO DEL PROBLEMA.**

### **1.1. Descripción de la realidad problemática.**

Ante la llegada del covid en el año 2019 todas nuestras vidas se vieron afectadas, a pesar que la mayoría de las empresas han realizado con éxito la transición a las operaciones en línea, es probable que el impacto de la pandemia no se limite únicamente a las operaciones comerciales sino también a la nueva cultura digital que ha repercutido en la cultura del consumidor.

Según (Caillaux, 2020), la crisis del covid 19 aceleró la transformación digital del ecosistema empresarial a nivel global. Con una creciente importancia del Big data y los servicios en la nube, las organizaciones han visto la forma de ahorrar costos, innovar, optimizar procesos y rentabilizar lo invertido en esas tecnologías mediante el desarrollo rápido de aplicaciones, el lanzamiento de call centers en la nube o la creación de dashboards virtuales con datos claves sobre sus ventas.

Además, en el estudio (The Impact of COVID-19 on Consumers: Preparing for Digital Sales, 2020) desarrollado por Rau Yuli Kim concluyó que las dos motivaciones dominantes para comprar en tiendas físicas en lugar de hacerlo en línea son las posesiones inmediatas y las interacciones sociales, mientras que las compras en línea tienden a ser sustancialmente más cómodas y económicas, ofreciendo una mayor flexibilidad en cuanto a tiempo, ubicación y variedad de productos. Por su lado los bancos tampoco se han quedado atrás porque empezaron a implementar la venta de productos que lo puedes encontrar tanto en las oficinas físicas o los medios digitales.

La evolución del sector financiero en diversos países dio como inicio la aparición de las fintech que según (Núñez Gonzáles, y otros, 2019) son definidas como “empresas que ofrecen productos y servicios financieros teniendo como soporte la innovación tecnológica”; las fintech contribuyeron a que las financieras tradicionales también empezaran a hacer uso de los servicios de teléfonos móviles e internet.

Actualmente en el Perú las formas de financiamiento son muy largas ya

que conlleva hacer uso de múltiples documentaciones por lo que causa mucha insatisfacción en los usuarios, según estudios sobre la innovación y tecnología en los servicios financieros en Perú.

En el artículo de (Chavez Muñoz, y otros, 2019) donde nos presenta los factores que influyen en el uso de la tecnología con respecto a los pagos móviles en negocios minoristas de Lima metropolitana. Se destaca el rol fundamental de los teléfonos celulares como canales para hacer transacciones electrónicas a nivel mundial. El estudio concluye que existen diversas variables a tener en cuenta respecto del empleo de los pagos móviles en esta clase de negocios: la actitud para el uso, la presencia de condiciones facilitadoras, el nivel de control percibido y el riesgo percibido por el usuario.

Asimismo, según (Araujo Mesias, y otros, 2022) tras realizar un análisis de los clientes del sistema financiero de Lima Metropolitana concluyó que los usuarios toman más en cuenta los beneficios de los aplicativos móviles que es un medio digital para realizar sus operaciones en línea. En la actualidad los bancos son dueños de diversas aplicaciones móviles buscando facilitar el acceso al servicio financiero de sus diversos productos y también son usados como medios para promocionar nuevos productos financieros, siendo el servicio financiero con mayor riesgo el del préstamo, pero así mismo es el que genera mayor cantidad de ingresos para una entidad bancaria.

Se define un préstamo bancario a una forma de financiamiento en el cual sigue un proceso de proveer capital financiero de terceros a un prestatario lo que genera que este usuario consiga capital que le ayudará en sus inversiones. A pesar de ello, al adquirir un préstamo existen diferentes tipos de riesgo que el prestatario debe tomar en cuenta porque puede conllevar a un endeudamiento cíclico.

Actualmente existen diferentes medios para poder solicitar este producto, sin embargo, la cantidad de efectividad que genera un banco del Perú a través de estos medios digitales no es el esperado. En el presente proyecto evaluaremos las formas de poder incrementar la

efectividad y conversión de estas ventas digitales a un banco del Perú.

## **1.2. Formulación del problema.**

### **1.2.1. Problema General:**

- a. ¿De qué manera la implementación de un modelo de Machine Learning incrementará las ventas digitales en el área de convenios de una entidad financiera del Perú?

### **1.2.2. Problemas Específicos:**

- a. ¿De qué manera la implementación de un modelo de Machine Learning incrementará los clientes potenciales en el área de convenios de una entidad financiera del Perú?
- b. ¿De qué manera la implementación de un modelo de Machine Learning incrementará los montos desembolsados en el área de convenios de una entidad financiera del Perú?

## **1.3. Objetivos.**

### **1.3.1. Objetivo General:**

- a. Determinar el incremento de las ventas digitales en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning.

### **1.3.2. Objetivos Específicos:**

- a. Determinar el incremento de los clientes potenciales en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning.
- b. Determinar el incremento de los montos desembolsados en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning.

## **1.4. Justificación.**

En los últimos años en el Perú la digitalización se convirtió en una necesidad tanto para las entidades financieras como para sus clientes es por ello que los bancos enfocaron sus esfuerzos y recursos en sus canales digitales, cambiaron la forma de atención al cliente por chats

automatizados, correos personalizados y aplicaciones web - móviles donde se brinda la información de sus diferentes productos.

Enfocarse en las ventas digitales en la actualidad apoyaría en la toma de decisiones y ejecución de estrategias para incrementar el número de créditos otorgados; por lo tanto, el presente trabajo aplica un modelo predictivo con técnicas de machine learning que se adapte a las necesidades de predicción y comportamiento de las variables con una base de datos limpia con la información del cliente que nos permita identificar las variables que más influyen en su decisión de compra según el modelo.

## **1.5. Limitantes de investigación.**

### **1.5.1. Limitación Espacial**

En este caso, el presente trabajo de investigación se centra en el área de ventas por convenio de una entidad financiera, la información es alimentada por todas las agencias a nivel nacional a través de canales digitales.

### **1.5.2. Limitante Temporal**

Los datos fueron recolectados en el periodo del mes de agosto del 2023. La información de la venta digital por convenios es proporcionada por una entidad financiera con sede principal en La Victoria.

### **1.5.3. Limitante Conceptual**

La investigación implementará un modelo predictivo con técnicas de machine learning con el fin de predecir si un cliente aceptará un crédito a través de los canales digitales.

## **II. MARCO TEÓRICO.**

### **2.1. Antecedentes.**

#### **2.1.1. Internacionales**

Según la investigación, (Quintero Acuña, 2023) sustentó la tesis con el título “Aplicación de machine learning a un modelo tradicional de prevención y detección de fraude en entidad financiera proyectado periodos trimestrales” en la Universidad de La Salle – Colombia. El objetivo principal de esta investigación fue analizar cómo una entidad financiera puede optimizar efectivamente su desempeño mediante la aplicación de machine learning. El enfoque de la investigación fue cuantitativo-descriptivo, siendo de tipo no experimental y transversal, teniendo como población/muestra a la entidad financiera.

Los resultados obtenidos indican que el machine learning proporciona una mayor capacidad para gestionar y procesar datos con características anómalas, lo que contribuye significativamente a mejorar el rendimiento y la precisión en la detección de fraudes.

Según (Suarez Ramirez, 2022) sustenta en su “Investigación sobre el estado actual de las ventas digitales y la percepción de los colaboradores del banco BBVA” en la Universidad de Bogotá, que el área de mercadeo del Banco BBVA utiliza diferentes canales digitales para la comunicación con sus clientes. Utilizando diferentes estrategias de comunicación para atraer y fidelizar nuevos clientes. El objetivo del trabajo es identificar acciones para aumentar las ventas digitales de los productos del banco BBVA por medio de los diferentes canales digitales a nivel nacional. La investigación tiene un enfoque cualitativo – descriptivo, teniendo como propósito la identificación del estatus actual de los productos digitales de la banca, así como posibles iniciativas y estrategias que puedan aumentar las ventas digitales. Se llevarán a cabo 3 entrevistas en profundidad a personas que se

seleccionaron por su alto conocimiento y experiencia en el área. Sobre el resultado de la investigación, según los colaboradores del BBVA el banco debería enfocarse en la mejora de procesos internos y aprovechamiento de las herramientas de medición digital en lugar de motivar nuevas iniciativas.

Según (Troncoso Ponce, 2022) sustenta su investigación “Transformación digital a nivel corporativo mediante la realización de proyectos basados en analytics y machine learning” en la Universidad de Chile. El objetivo del trabajo consiste en diseñar e implementar 3 proyectos de transformación digital basados en analítica y machine learning, que generen mejoras en procesos financieros de las gerencias de finanzas de Falabella S.A. y sus unidades de negocios, aportando de esta manera en la transformación digital de la compañía. La investigación tiene un enfoque cuantitativo, donde se evalúan los elementos de rentabilidad y eficiencia, además del enfoque cualitativo en el rediseño de procesos o elementos estratégicos de la organización. El presente trabajo ha tomado en consideración metodologías como el KDD, SEMMA o CRISP-DM de proyecto de ciencia de datos para definir las mejores prácticas. Como conclusión se logró obtener que los resultados analíticos de proyectos de transformación digital logran mejoras en los procesos financieros y aportan en la transformación analítica de la empresa.

Así mismo tenemos la tesis de (Francés Monedero, 2020) titulada “Impacto del Machine learning en el sistema financiero” en la Universidad Pontificia Comillas de Madrid. Se enfoca en el aprendizaje automático como la disciplina más prevalente de la inteligencia artificial en el sector financiero actual. El objetivo principal de este trabajo es introducir el aprendizaje automático y explorar su repercusión en el sistema financiero. Para alcanzar dicho propósito, se emplea una metodología inductiva, donde la

pregunta de investigación se centra en comprender el impacto del Machine Learning en el sistema financiero. La recopilación de datos se realiza a través de un análisis cualitativo de fuentes secundarias externas mediante la web research y la lectura individual de textos como libros, revistas y artículos. El estudio concluye que la aplicación del Machine Learning transformará de manera positiva el sector financiero, al permitir que los profesionales optimicen su tiempo y colaboren con las máquinas para realizar tareas monótonas.

Por su lado (Urrego Álvarez, y otros, 2021) sustentó en su tesis “Transformación Digital de la Banca: Modelo basado en Machine Learning para la clasificación de transacciones bancarias realizadas a través de PSE” en la Institución Universitaria Tecnológico de Antioquia en Medellín, Colombia. La investigación se centró en el desarrollo de un modelo supervisado de Machine learning mediante el Procesamiento de Lenguaje Natural, con el objetivo principal de clasificar transacciones bancarias realizadas a través de PSE, con el propósito de facilitar el análisis de las finanzas personales en el sector bancario. La metodología empleada involucró un análisis inductivo-deductivo, que permite utilizar premisas específicas para llegar a conclusiones generales y viceversa. Para llevar a cabo la propuesta, se siguieron las fases de la metodología CRISP-DM. Como resultado, se logró desarrollar un modelo óptimo de Machine Learning que ofreció una solución efectiva al problema de clasificación planteado en la investigación.

De igual manera, (Martínez Guzmán, 2022) sustentó la tesis con título “Propuesta de implementación de un canal de ventas digitales para una compañía de banca basado en Bogotá, Colombia” en la Universidad de Palermo, Argentina. Teniendo como población al personal del comité comercial y a los datos de ventas. La investigación busca definir el proceso de

implementación de canales de ventas digitales para una compañía de banca basados en el mercado colombiano. Considerando los resultados obtenidos se llega a la conclusión que el proceso de implementación de los canales digitales es práctico y de fácil implementación. Se considera esta investigación de tipo aplicada- experimental. Teniendo como dimensiones a nivel cualitativo las entrevistas al comité comercial de manera simultánea para tener conclusiones no sesgadas y a nivel cuantitativo los datos de ventas actuales obtenidos del área de innovación. Y en los indicadores: KPI (indicador clave de rendimiento) y OKR (objetivos y resultado clave). El aporte que brindó este trabajo de investigación ayudó a dar fortaleza a la propuesta de enfoque en las ventas digitales de una entidad financiera.

### **2.1.2. Nacionales**

Según la tesis de título “Aplicación de técnicas de Machine Learning para predecir el número de ventas de créditos en el sector bancario” para ESAN, sustentada por (Rodríguez Villanueva, y otros, 2023) nos dice que en el sector bancario la principal fuente de ingreso son los créditos otorgados. El presente trabajo propone al área de telemarketing de una entidad bancaria usar técnicas de machine learning para la elaboración de un modelo predictivo que permita conocer el número de ventas de crédito con la finalidad de agilizar la toma de decisiones frente a nuevas estrategias o mejoras en las ventas. El enfoque formulado para esta investigación es cuantitativo. Además, para la construcción del modelo se utilizaron técnicas de machine learning de clasificación k-NN y SVM, los datos utilizados son de clientes a los que se les ofreció un crédito entre enero y febrero del año 2023. Los resultados en la primera simulación tuvieron una precisión de 61.68% y 68.41% respectivamente. Dada la dispersión de los datos se realizó la normalización para la



segunda simulación la cual resultó con una precisión de 91.12% para k-NN y 93.85% para SVM siendo este último la mejor técnica de predicción.

De igual forma (Barrueta Meza, y otros, 2018) en su tesis titulada “Modelo de análisis predictivo para determinar clientes con tendencia a la deserción en bancos peruanos” para la UPC fundamenta la importancia de los bancos en el país y el impacto en las diferentes clases sociales. Este proyecto tiene como objetivo la implementación de un Modelo de Análisis Predictivo que determine la tendencia de deserción en los clientes, con el objetivo de apoyar a la toma de decisiones para las estrategias de retención y fidelización. Los datos recopilados son de un total de 20,000 clientes, siendo 1,764 clasificados como ‘Desertores’ y 18,236 clasificados como ‘No Desertores’. Se determinó que el algoritmo más preciso era el R-K-Means logrando una precisión del 93.20% en la prueba de validación. El árbol R-CNR y la red neuronal R-NNet tenían precisiones de validación de 92.5% y 87.3% respectivamente.

Así mismo tenemos en la tesis de título “Optimización del Margen Comercial de Préstamos de Consumo: Algoritmo de Optimización con Machine Learning” sustentada por (Azabache La Torre, 2019) para la ESAN, se refiere a que entidades bancarias no son ajenas al impacto de la transformación digital, en los últimos años en el Perú ha crecido la competencia en la banca reduciendo los márgenes de ganancia para los bancos. En este proyecto se busca diseñar un algoritmo utilizando técnicas de Machine Learning que permita diseñar estrategias de pricing permitiendo maximizar el margen comercial de los créditos bancarios basándose en el perfil de los clientes. Los datos utilizados son de 3 meses del año 2019 de créditos otorgados por un banco. Se realizó un algoritmo de inteligencia artificial, el cual logró incrementar las colocaciones de los créditos de consumo en 33

millones con un margen de utilidad de 5.1 millones adicionales. Por lo tanto, se puede afirmar que los bancos pueden aumentar sus márgenes de ganancia utilizando algoritmos de Inteligencia artificial para la gestión de pricing para la identificación de la disposición a pagar de sus clientes.

Según la investigación de (Rodríguez Condezo, 2022) sustentó la tesis con el título “Machine learning y su incidencia en la gestión comercial en una entidad financiera, Lima 2022” en la Universidad César Vallejo-Lima. El propósito central de la investigación fue determinar la influencia del Machine Learning en la gestión comercial de una entidad financiera durante el año 2022. El enfoque metodológico utilizado fue cuantitativo, de tipo básico y correlacional, con un diseño no experimental. La población objetivo consistió en 120 trabajadores del área comercial de negocios de una entidad financiera ubicada en Lima, se emplearon cuestionarios como instrumento de recolección de datos, y los resultados obtenidos en la hipótesis general revelaron un coeficiente de correlación de Pearson entre las dos variables de 12.347. se determinó un valor de estimación de 1.250, con un valor de p 0.000, que resultó ser inferior a 0.05, confirmando la significativa incidencia entre la variable Machine Learning y la variable gestión comercial, en consecuencia, se rechazó la hipótesis nula y se aceptó la hipótesis propuesta por el investigador.

## **2.2. Bases teóricas.**

### **2.2.1. Inteligencia artificial.**

El concepto de inteligencia artificial sigue siendo hasta hoy complejo de precisar, si bien en la actualidad muchas organizaciones la utilizan para agilizar la toma de decisiones a partir de simular el pensamiento humano. Como mencionan (Hurwitz, y otros, 2018) esta tecnología ya es aplicada en

diferentes campos desde servicio al cliente hasta detección de fraudes, entre otros.

En su libro (Russell, y otros, 2008) plantean cuatro enfoques de definición para la inteligencia artificial. A continuación, se detalla las bases de los cuatro enfoques con más detalle.

*Figura 1:Definiciones de inteligencia artificial*

<b>Sistemas que piensan como humanos</b>	<b>Sistemas que piensan racionalmente</b>
«El nuevo y excitante esfuerzo de hacer que los computadores piensen... máquinas con mentes, en el más amplio sentido literal». (Haugeland, 1985) «[La automatización de] actividades que vinculamos con procesos de pensamiento humano, actividades como la toma de decisiones, resolución de problemas, aprendizaje...» (Bellman, 1978)	«El estudio de las facultades mentales mediante el uso de modelos computacionales». (Charniak y McDermott, 1985) «El estudio de los cálculos que hacen posible percibir, razonar y actuar». (Winston, 1992)
<b>Sistemas que actúan como humanos</b>	<b>Sistemas que actúan racionalmente</b>
«El arte de desarrollar máquinas con capacidad para realizar funciones que cuando son realizadas por personas requieren de inteligencia». (Kurzweil, 1990) «El estudio de cómo lograr que los computadores realicen tareas que, por el momento, los humanos hacen mejor». (Rich y Knight, 1991)	«La Inteligencia Computacional es el estudio del diseño de agentes inteligentes». (Poole <i>et al.</i> , 1998) «IA... está relacionada con conductas inteligentes en artefactos». (Nilsson, 1998)

Fuente: (Russell, y otros, 2008 pág. 2)

Se interpreta del gráfico que los conceptos de la izquierda se basan en la fidelidad que mantiene la tecnología en 'pensar' como humanos, por su parte los conceptos de la derecha miden la tecnología basándose en la racionalidad de 'pensar', entendiéndose como racional la capacidad de actuar correctamente basándose en los datos recibidos.

Asimismo (Theobald, 2017) nos menciona que la inteligencia artificial (IA) es la capacidad de las máquinas para realizar tareas cognitivas. Como sucedió en la Revolución Industrial, la IA está impulsando el desarrollo de las máquinas para simular capacidades cognitivas.

La IA está basada en la capacidad de diseñar y programar a las máquinas para simular la inteligencia humana. Aplicando algoritmos y técnicas de aprendizaje que permita el análisis de grandes cantidades de datos y así obtener información útil.

### 2.2.2. Machine learning.

El acto de aprender está fuertemente vinculado con la inteligencia humana, por lo que la capacidad de las máquinas para aprender en base a data es una rama de la inteligencia artificial. (Hurwitz, y otros, 2018) explican el concepto de machine learning como la capacidad que tienen las máquinas para aprender y tomar decisiones proporcionándoles los datos como entrada para su análisis.

Cabe aclarar que el machine learning no es un proceso netamente automático, ya que necesita de intervención humana para la obtención y alimentación de los datos de entrada para las maquinas.

Figura 2: Pasos en Aprendizaje de Máquina



Fuente: (Data Science Research)

El machine learning incorpora varios cientos de algoritmos basados en estadísticas y elegir el algoritmo o la combinación de estos para el trabajo resulta ser un desafío. Pero antes de examinar algoritmos específicos, es importante comprender las tres categorías generales del aprendizaje automático. Según

(Theobald, 2017) estas tres categorías son supervisadas, no supervisadas y de refuerzo.

### **2.2.3. Aprendizaje supervisado**

Tenemos al aprendizaje supervisado que se enfoca en la búsqueda de patrones, definiendo una relación entre las variables y resultados conocidos. El proceso consiste en brindar datos de entrada con ciertas características y el valor correcto de salida de los datos.

### **2.2.4. Aprendizaje no supervisado.**

Según (Stack, 2021) el tipo de aprendizaje no supervisado, no tiene una dependencia con las etiquetas de salida, el objetivo es poder lograr encontrar una estructura de forma “intrínseca” que sea parte del conjunto de información o datos. Así mismo, este tipo de aprendizaje tiende a ser usado para los tipos de agrupamientos, segmentación y en la reducción de dimensionalidad. Los algoritmos más comunes que son usados son: k-medias, análisis de componentes principales (PCA) y también en la factorización no negativa de matrices (NMF).

### **2.2.5. Algoritmos KNN**

En el libro “Introduction to Machine Learning with Python” del autor (Müller, y otros, 2016) nos dice que el algoritmo K-Nearest Neighbors (KNN) es un método de aprendizaje supervisado utilizado para la clasificación y regresión. En KNN, la predicción para un nuevo punto de datos se basa en la mayoría de sus k vecinos más cercanos en el espacio de características. Es un algoritmo intuitivo y fácil de entender.

Cómo Funciona:

- Distancia:  
Calcula la distancia entre el nuevo punto y todos los puntos en el conjunto de datos de entrenamiento. La distancia euclidiana es comúnmente utilizada, pero otras métricas de distancia también son posibles.

- **Vecinos más Cercanos:**  
Identifica los k puntos más cercanos al nuevo punto basándose en la distancia calculada.
- **Votación (para clasificación):**  
En el caso de clasificación, asigna al nuevo punto la etiqueta que es más común entre sus k vecinos más cercanos (votación).
- **Promedio (para regresión):**  
En el caso de regresión, predice el valor del nuevo punto tomando el promedio de los valores de sus k vecinos más cercanos.

#### **2.2.6. Banca.**

De acuerdo con (Gobat, 2012) un banco es una entidad financiera que pone en relación las personas que ahorran y las personas que prestan dinero y contribuye al adecuado funcionamiento de la economía.

En nuestra investigación se trabajará en un modelo predictivo para una entidad financiera del Perú que le permita predecir la cantidad de créditos a desembolsar en un periodo determinado en base a las características de los clientes potenciales.

#### **2.2.7. Ventas digitales.**

Las ventas digitales, según (Terán Espinoza, 2019) son el resultado de las estrategias ejecutadas en los diferentes canales y medios de internet. Según (Manrique Molina, y otros, 2022) así mismo al existir un incremento de los medios digitales las ventas por este medio han ido incrementando.

#### **2.2.8. Convenios corporativos**

Según (Albertí Rovira, 2022), los convenios son instrumentos que se ponen a disposición de las partes, que podrán hacer uso de los mismos según su voluntad, mediante el libre acuerdo entre las mismas

## **2.3.Marco conceptual.**

### **2.3.1. Crédito bancario.**

Al hablar de crédito bancario, estamos estudiando un tipo de financiamiento, según (Cerrinos Ponce, y otros, 2019) , lo define como un proceso que consiste en proveerse de capitales financieros de terceros, lo cual hace posible que el empresario consiga el capital que le es indispensable para poder solventar sus actividades empresariales y así optimizar la situación de su negocio.

Según (Velarde Flores, 2018) los créditos bancarios tuvieron sus inicios en la era de los fenicios con las operaciones financieras de los mercaderes del antiguo mundo, posteriormente se modernizaron en los puertos donde se realizaban las operaciones mercantiles entre diferentes mercados; cuando las operaciones comerciales incrementaron empezaron a operar los bancos financieros, siendo el primero en Venecia. Así mismo, la autora indica que existen diferentes tipos de créditos, los cuales los clasifica como: crédito empresarial, crédito pyme, crédito empresarial, crédito hipotecario de vivienda, crédito de consumo, crédito de vivienda social.

## **2.4.Definición de términos básicos.**

- **Leads digitales:** Los leads digitales son clientes potenciales que se han generado a través de canales digitales, como sitios web, redes sociales, correo electrónico, publicidad en línea y otras estrategias de marketing digital.
- **Crédito bancario:** Un crédito es un acuerdo en el que una entidad proporciona fondos a otro bajo ciertas condiciones, con la expectativa de que los fondos serán reembolsados en el futuro, generalmente con intereses o costos adicionales. Los créditos son una herramienta importante en las finanzas personales y comerciales y desempeñan un papel crucial en la economía.

Asimismo, (Lizarraga Cajamuni, 2022) nos dice que el crédito es la cantidad de efectivo que una entidad ya sea un individuo u organización presta a otra entidad bajo unos términos en un contrato entre ambas partes, detallando la modalidad de pago y cobro de la deuda incurrida.

- **Convenio:** Convenio es un acuerdo formal o contratado establecido entre dos o más partes con el propósito de regular ciertas acciones, obligaciones o compromisos mutuos. Además, los convenios son vinculantes y legalmente obligatorios, por lo que las partes que los firman deben cumplir con lo establecido en el documento.

Según (Huamaní Espinoza, 2021) es muy importante el incremento de convenios concretados, ya que se puede medir el crecimiento de las ventas, puesto que permite tener una mejor visión corporativa, este valor es importante para poder medir el crecimiento de los clientes a corto y largo plazo; además el tiempo de cierre de convenios, es un factor muy importante de un sistema de ventas ya que es el tiempo promedio que demora las ventas de los productos y con ello demostrar la efectividad del sistema en el negocio.

- **Canales digitales:** Una de las ventajas de los canales digitales es que nos permiten que los clientes tengan la impresión de una mejora en el servicio o producto que necesitan y que la organización tenga la alternativa de poder atraer a mayor clientela ahorrando costos (Espinoza Reyes, 2020).

Asimismo, (Beris Rodas, 2020) cuando los canales digitales hacen uso de tecnologías donde se desarrollaron sistemas el cual nos permite automatizar procesos en una empresa.

- **Desembolso:** Se refiere al acto de liberar o distribuir fondos financieros, ya sea en efectivo o a través de medios electrónicos, con el propósito de cumplir con una obligación financiera, realizar una inversión, efectuar un pago o cualquier otra transacción que implique la transferencia de recursos económicos.



- **Capital prestado:** Este término se refiere a la cantidad específica de dinero que el prestamista proporciona al prestatario en el momento del desembolso. Es la suma total que el prestatario tiene la obligación de devolver, además de los intereses u otros costos asociados, a lo largo del período acordado según los términos del préstamo.
- **Porcentaje de efectividad:** Es una medida que evalúa el éxito o la eficacia de un proceso, acción o sistema en relación con un objetivo específico. Este término se utiliza comúnmente en diversos contextos para expresar la proporción o el grado de éxito alcanzado en comparación con el total previsto o esperado.

Fórmula básica para calcular el porcentaje de efectividad es:

$$\text{Porcentaje de efectividad} = \left( \frac{\text{Resultado exitoso}}{\text{Total previsto}} \right) \times 100$$

- **Porcentaje de conversión:** Se refiere a la proporción de personas que realizan una acción deseada en relación con el número total de personas que tuvieron la oportunidad de realizar esa acción. Esta métrica es comúnmente utilizada en marketing y comercio electrónico para evaluar la eficacia de una campaña, sitio web o embudo de ventas.

Fórmula básica para calcular el porcentaje de conversión es:

$$\text{Porcentaje de conversión} = \left( \frac{\text{Num de Conversiones}}{\text{Num de visitantes o interacciones}} \right) \times 100$$

- **Modelo predictivo:** Un conjunto de algoritmos y técnicas estadísticas utilizados para predecir resultados futuros basados en datos históricos y patrones identificados.
- **Algoritmo:** Para este caso, nos referimos al algoritmo de machine learning que es un conjunto de reglas y procesos matemáticos diseñados para permitir que un sistema informático aprenda patrones a partir de datos y realice tareas específicas sin ser programado explícitamente para esas tareas. Estos algoritmos son esenciales para el funcionamiento de sistemas de machine learning, ya que son

responsables de identificar patrones, hacer predicciones o tomar decisiones basadas en datos.

- **Redes neuronales:** Modelos inspirados en la estructura del cerebro que se utilizan para una amplia variedad de tareas, desde reconocimiento de imágenes hasta procesamiento del lenguaje natural.
- **K-Means:** K-means es un algoritmo de clustering utilizado en el ámbito del aprendizaje no supervisado. Su objetivo principal es dividir un conjunto de datos en grupos homogéneos o clusters, donde los puntos de datos dentro de un mismo cluster son más similares entre sí que con los puntos de datos de otros clusters. Este algoritmo pertenece a la familia de métodos de partición, donde los datos se dividen en un número predefinido de clusters.
- **Overfitting (Sobreajuste):** Una situación en la que un modelo predictivo se ajusta demasiado a los datos de entrenamiento y tiene dificultades para generalizar correctamente a nuevos datos.
- **Validación cruzada:** Una técnica utilizada para evaluar el rendimiento de un modelo predictivo dividiendo los datos en conjuntos de entrenamiento y prueba de manera iterativa.

### **III. HIPÓTESIS Y VARIABLES.**

#### **3.1. Hipótesis.**

##### **3.1.1. Hipótesis general**

- a. La implementación de un modelo de Machine Learning incrementará las ventas digitales en el área de convenios de una entidad financiera del Perú.

##### **3.1.2. Hipótesis específicas**

- a. La implementación de un modelo de Machine Learning incrementará los clientes potenciales en el área de convenios de una entidad financiera del Perú.
- b. La implementación de un modelo de Machine Learning incrementará los montos desembolsados en el área de convenios de una entidad financiera del Perú.

#### **3.2. Operacionalización de variables.**

En el presente trabajo se han planteado como variable independiente (V.I) al modelo de machine learning y, como variable dependiente (V.D) las ventas digitales.

##### **3.2.1. Modelo de machine learning**

En el contexto de machine learning, un "modelo" se refiere a una representación matemática o computacional que se utiliza para aprender patrones a partir de datos y realizar predicciones o tomar decisiones sin ser programado explícitamente. Como nos dice (Theobald, 2017) estos se pueden agrupar en 3 categorías, supervisados, no supervisados y de refuerzo.

##### **3.2.2. Ventas digitales**

Las ventas digitales en el sector de banca se refieren a la comercialización de productos y servicios financieros a través de canales digitales. Según (Lizarraga Cajamuni, 2022) define el crédito como la cantidad de efectivo que una entidad ya sea un individuo u organización presta a otra entidad bajo unos términos en un contrato entre ambas partes, detallando la modalidad de pago y cobro de la deuda incurrida.

Tabla 1: Operacionalización de las variables

Fuente: Elaboración propia

Variables	Definición Conceptual	Definición Operacional	Dimensiones	Indicadores	Ítem	Método	Técnica e Instrumento
Modelo de Machine Learning (V.I.)	En el contexto de machine learning, un "modelo" se refiere a una representación matemática o computacional que se utiliza para aprender patrones a partir de datos y realizar predicciones o tomar decisiones sin ser programado explícitamente	Un modelo de machine learning es una herramienta que utiliza datos históricos para hacer predicciones o tomar decisiones en nuevos datos, con el objetivo de automatizar tareas y mejorar la toma de decisiones.	Confiabilidad del modelo	Nivel de confiabilidad del modelo	1, 2, 3, 4, 5	Cuantitativo - Deductivo	<b>Técnica:</b> Encuesta <b>Instrumento:</b> Cuestionario
			Validez del modelo	Nivel de validez del modelo	6, 7, 8, 9, 10	Cuantitativo - Deductivo	<b>Técnica:</b> Encuesta <b>Instrumento:</b> Cuestionario
Ventas Digitales (V.D.)	Las ventas digitales en el sector de banca se refieren a la comercialización de productos y servicios financieros a través de canales digitales.	Se refiere a los créditos otorgados mediante las plataformas digitales de la entidad financiera. Las ventas digitales se miden por cantidad de créditos otorgados a clientes potenciales.	Clientes potenciales	Aumento de clientes potenciales por canales digitales	11, 12, 13, 14, 15, 16, 17	Cuantitativo - Deductivo	<b>Técnica:</b> Encuesta <b>Instrumento:</b> Cuestionario
			Monto desembolsado	Aumento de montos desembolsados por crédito aceptado	18, 19, 20, 21, 22, 23, 24	Cuantitativo - Deductivo	<b>Técnica:</b> Encuesta <b>Instrumento:</b> Cuestionario

## **IV. METODOLOGÍA DEL PROYECTO.**

### **4.1. Diseño metodológico.**

A continuación, presentamos la clasificación del trabajo:

Según (Campbell, y otros, 1963) se produce una investigación preexperimental cuando “se mide el mismo sujeto o grupo de sujetos antes de la aplicación de la variable independiente y después de la aplicación de la misma”, bajo esa consideración, esta investigación se declarará preexperimental, ya que esta investigación estudia el impacto de la implementación de un modelo de machine learning para incrementar las ventas digitales del área de convenios de una entidad financiera del Perú.

En concordancia a los que nos mencionan (Hernandez Sampieri, y otros, 2014) por el objetivo de analizar cambios al paso del tiempo y la recolección de datos se da en el transcurso de un periodo de tiempo, el presente trabajo investigativo se considera de corte longitudinal.

Por su parte (Tamayo, 2011) nos indica “es el estudio y la aplicación de la investigación a problemas concretos, en circunstancias y características concretas. Esta forma de investigación se dirige a su aplicación inmediata y no al desarrollo de teorías”, por lo que podemos definir esta investigación del tipo aplicada.

Según la data que se recopila para dar respuesta a la problemática de investigación, la presente investigación es de enfoque cuantitativo.

### **4.2. Métodos de investigación.**

Este trabajo investigativo utiliza a su vez un método deductivo, ya que de acuerdo a (El método de la investigación Research Method, 2014) nos indica que el método deductivo facilita la identificación de los aspectos de una realidad específica mediante la deducción o el resultado de las propiedades o afirmaciones incluidas en proposiciones o leyes científicas más generales que fueron previamente establecidas.

### **4.3. Población y muestra.**

Como nos indica (Gómez, 2006) la población será definida como el conjunto de todos los objetos de estudio que compartan las mismas

características además deben situarse en el mismo entorno de lugar y en el tiempo, en ese sentido la población para esta investigación comprendería los clientes en el área de convenios de una entidad financiera del Perú con sede principal en La Victoria.

A su vez, para definir las pruebas probabilísticas (Hernandez Sampieri, y otros, 2014) nos indican que cada elemento de la población tiene una probabilidad igual de ser seleccionado para formar parte de la muestra. Por ende, la selección se realiza mediante un proceso aleatorio de las unidades de muestreo o análisis.

#### **4.3.1. Población**

Datos de los créditos que se ofrecieron a los clientes durante el tercer trimestre del año 2023 en el área de ventas por convenio de una entidad financiera del Perú con sede principal en La Victoria.

#### **4.3.2. Muestra**

Datos de los créditos que se ofrecieron a los clientes durante el mes de agosto del año 2023 en el área de ventas por convenio de una entidad financiera del Perú con sede principal en La Victoria.

#### **4.4. Lugar de estudio y periodo desarrollado.**

El presente trabajo se centra en el área de ventas por convenio de una entidad financiera del Perú con sede principal en el distrito de La Victoria, la información es alimentada por todas las agencias a nivel nacional a través de canales digitales, durante el periodo de un mes.

#### **4.5. Técnicas e instrumentos para la recolección de la información.**

Este trabajo de investigación ha trabajado con data real de una entidad financiera peruana. Esta data se ha obtenido cumpliendo requisitos mínimos de privacidad, la información no identifica al cliente. Para lograr cada uno de los objetivos de la investigación se utilizará las siguientes técnicas e instrumentos, detalladas a continuación:

En cuanto a las técnicas, se procederá a realizar un análisis del comportamiento de los usuarios con el uso del modelo de machine learning para optimizar las ventas digitales del área de ventas por

convenio de una entidad financiera, a través de encuestas hacia los asesores financieros como grupo objetivo, ya que ellos son la fuente de información e interacción con los clientes lo cual nos permitirá realizar un análisis de los datos arrojados en la encuesta a realizar, los que, a través de cuadros comparativos y análisis estadísticos, se sabrá el grado de significancia y valoración.

Por su parte los instrumentos, se realizará el llenado de encuestas para tener un conocimiento previo de la situación actual de la gestión comercial del área de ventas por convenio de una entidad financiera, los que se complementarán con fichas de gestión por asesor financiero en un lapso de tiempo.

La ficha de registro de acuerdo a (Valderrama, 2019) menciona que es un formato que nos permite la recolección de datos en forma coherente y con una adecuada estructura para poder registrar los hechos que se observaron.

Por consiguiente, este instrumento nos permitió la obtención de información de los clientes a los que se les ofreció un crédito en el área de ventas por convenio en el rango de un mes.

#### **4.6. Análisis y procesamiento de datos.**

##### **Validez y confiabilidad**

Para poder establecer la validez y confiabilidad de las fichas, como establecen (Hernandez Sampieri, y otros, 2014) ésta puede obtenerse a través de la validez de expertos, por ello las fichas se evaluaron por expertos, de los cuales se tomó en consideración sus recomendaciones para la creación de las fichas. Según la ficha de selección de muestra, se obtuvo una aprobación del 100% por parte de los expertos.

La V de Aiken: Este coeficiente posibilita la medición de la importancia de los ítems en relación con un dominio específico, utilizando las evaluaciones de N expertos. Tal como lo indica (Escrura M., 1988) este coeficiente combina la facilidad del cálculo y la evaluación de los resultados a nivel estadístico, el coeficiente resultante puede tener

valores entre 0 y 1. Cuanto más el valor se acerque a 1, entonces tendrá una mayor validez de contenido.

$$V = \frac{S}{(n(c - 1))}$$

Donde:

V = Coeficiente V de Aiken

S = Suma del si

n = número de jueces

c = número de valores de la escala de valoración

$$V = \frac{6}{(6(2 - 1))}$$

Para la validación del instrumento se ha utilizado el método de juicio de expertos, y el coeficiente V de Aiken para calcular el índice obteniéndose el valor V de Aiken igual 1, por lo tanto, concluimos la validez del instrumento es bueno.

*Tabla 2: Cálculo de calificación de expertos*

CALIFICACIONES DE JUECES								
ITEM	Juez 1	Juez 2	Juez 3	Juez 4	Juez 5	Juez 6	SUMA	V
1	1	1	1	1	1	1	6	1
2	1	1	1	1	1	1	6	1
3	1	1	1	1	1	1	6	1
4	1	1	1	1	1	1	6	1
5	1	1	1	1	1	1	6	1
6	1	1	1	1	1	1	6	1
7	1	1	1	1	1	1	6	1
8	1	1	1	1	1	1	6	1
9	1	1	1	1	1	1	6	1
10	1	1	1	1	1	1	6	1
11	1	1	1	1	1	1	6	1
12	1	1	1	1	1	1	6	1
13	1	1	1	1	1	1	6	1
14	1	1	1	1	1	1	6	1
<b>V de Aiken general</b>							Promedio	1

Fuente: Elaboración propia



#### **4.7. Aspectos éticos en investigación.**

Como investigadores, nosotros respetamos y nos adherimos a la normatividad institucional de la Universidad Nacional del Callao, tanto a nivel nacional como internacional. El presente estudio consideró los principios fundamentales, como la beneficencia, confidencialidad, justicia y no maleficencia, que son de vital importancia para llevar a cabo una investigación de manera transparente y óptima. Además, se adoptaron las pautas del ISO 690 para citar a los autores y sus investigaciones de manera responsable.

## V. RESULTADOS.

Se realizó el entrenamiento del modelo de machine learning de KNN, utilizando como data de entrenamiento un 80% de la muestra. Asimismo, se realizaron procesos estadísticos para determinar el grado de influencia, así como la validación de la Hipótesis General e Hipótesis Específicas.

### 5.1. Modelo K-NN

La elección de este modelo se debe a la facilidad de su implementación dada la simplicidad y precisión del algoritmo, además de su gran adaptabilidad por lo que a medida que se agregan nuevas muestras de entrenamiento, el algoritmo se ajusta para tener en cuenta cualquier nuevo dato, ya que los datos de entrenamiento se almacenan en la memoria.

*Figura 3: Importación de librerías*

```
#Importando Librerías
%matplotlib inline
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from matplotlib import style
import seaborn as sns
from scipy.stats import pearsonr
from sklearn.linear_model import LinearRegression
from sklearn.model_selection import train_test_split
from sklearn.metrics import r2_score
from sklearn.metrics import mean_squared_error
import statsmodels.api as sm
import statsmodels.formula.api as smf
import warnings
# Configuración matplotlib
# =====
plt.rcParams['image.cmap'] = "bwr"
plt.rcParams['figure.dpi'] = "100"
plt.rcParams['savefig.bbox'] = "tight"
style.use('ggplot') or plt.style.use('ggplot')
warnings.filterwarnings('ignore')
```

Fuente: Elaboración propia

Figura 4: Carga de datos

```
from google.colab import drive
drive.mount('/content/drive')
```

Mounted at /content/drive

```
df_credito = pd.read_csv('/content/drive/MyDrive/Colab Notebooks/BD_KNN.csv',
                          sep=';')
df_credito.head()
df_credito_1 = pd.read_csv('/content/drive/MyDrive/Colab Notebooks/BD_KNN.csv',
                             sep=';')
```

Fuente: Elaboración propia

Figura 5: Visualización previa de los datos

```
df_credito.head()
```

	fecha	convenio	fuelle	campania	region	plaza	derivacion	familia	credito	capital
0	03/8/2021	1	3	2	4	33	2	2	0	0.00
1	05/8/2021	1	3	2	2	19	2	2	0	0.00
2	05/8/2021	1	3	2	3	31	2	2	0	0.00
3	05/8/2021	1	3	2	2	17	2	2	0	0.00
4	06/8/2021	1	3	2	3	31	2	2	0	0.00

Fuente: Elaboración propia

Figura 6: Limpieza de datos

```
#Eliminando variables Linea Final, fecha
array_delete = ['capital', 'fecha']
df_credito = df_credito.drop(array_delete, axis = 1)
df_credito.head()
```

	convenio	fuelle	campania	region	plaza	derivacion	familia	credito
0	1	3	2	4	33	2	2	0
1	1	3	2	2	19	2	2	0
2	1	3	2	3	31	2	2	0
3	1	3	2	2	17	2	2	0
4	1	3	2	3	31	2	2	0

Fuente: Elaboración propia

Figura 7: Tipos de datos

```
print(df_credito.dtypes, "\n")
print(df_credito_credito.describe(), "\n")
print(df_credito_fuente.describe(), "\n")
print(df_credito_region.describe(), "\n")
```

convenio	int64
fuentes	int64
campania	int64
region	int64
plaza	int64
derivacion	int64
familia	int64
credito	int64
dtype:	object

Fuente: Elaboración propia

Figura 8: Tamaño de la data

```
df_credito.shape
```

(2461, 8)

Fuente: Elaboración propia

Figura 9: División de datos

```
#Definiendo las variables X y Y
X = df_credito.drop(columns="credito")
y = df_credito["credito"]
```

```
#Determinando el tamaño de entrenamiento y pruebas
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y, train_size = 0.8, random_state=1234)
print(f"Tamaño de entrenamiento: {X_train.shape}")
print(f"Tamaño de Pruebas: {X_test.shape}")
```

Tamaño de entrenamiento: (1968, 7)  
Tamaño de Pruebas: (493, 7)

Fuente: Elaboración propia

Figura 10: Clasificando con el modelo KNN

```
from sklearn.neighbors import KNeighborsClassifier
knn_cls = KNeighborsClassifier(n_neighbors=2)
knn_cls.fit(X_train, y_train)

KNeighborsClassifier
KNeighborsClassifier(n_neighbors=2)

y_pred = knn_cls.predict(X_test)
```

Fuente: Elaboración propia

Figura 11: Métricas del modelo

```
cm = confusion_matrix(y_test,y_pred)
print(cm)

[[127 16]
 [ 7 343]]

print(classification_report(y_test,y_pred))
```

	precision	recall	f1-score	support
0	0.95	0.89	0.92	143
1	0.96	0.98	0.97	350
accuracy			0.95	493
macro avg	0.95	0.93	0.94	493
weighted avg	0.95	0.95	0.95	493

Fuente: Elaboración propia

Figura 12: Precisión del modelo

```
print(accuracy_score(y_test,y_pred))

0.9614604462474645
```

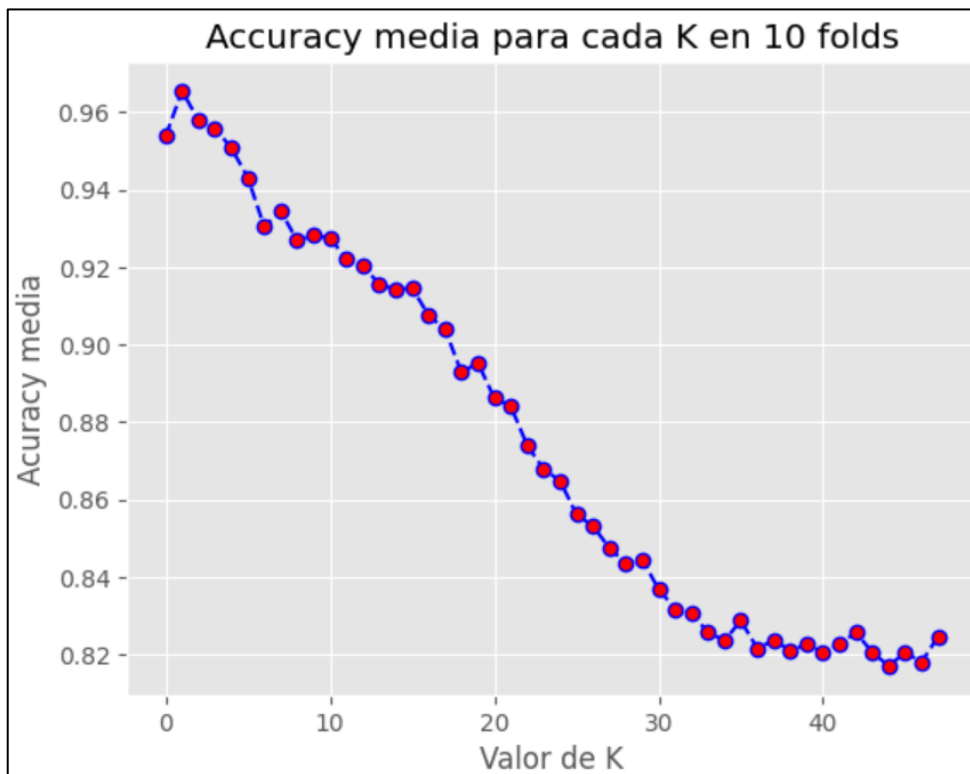
Fuente: Elaboración propia

Figura 13: Validando el mejor hiperparámetro

```
scores = grid_scv.cv_results_["mean_test_score"]
plt.plot(scores, color="blue", linestyle = "dashed", marker="o", markerfacecolor="red")
plt.title("Accuracy media para cada K en 10 folds")
plt.xlabel("Valor de K")
plt.ylabel("Acuracy media")
plt.show()
```

Fuente: Elaboración propia

Figura 14: Gráfica del hiperparámetro



Fuente: Elaboración propia

Figura 14: Valores con el hiperparametro 3

```
grid_scv.best_params_

{'n_neighbors': 3}

grid_scv.best_score_

0.9654537449497564
```

Fuente: Elaboración propia


Figura 15: Métricas con el hiperparámetro igual a 3

```
knn_cls = KNeighborsClassifier(n_neighbors=3)
knn_cls.fit(X_train, y_train)
y_pred = knn_cls.predict(X_test)
print(accuracy_score(y_test,y_pred))
print(classification_report(y_test,y_pred))
```

	precision	recall	f1-score	support
0	0.95	0.89	0.92	143
1	0.96	0.98	0.97	350
accuracy			0.95	493
macro avg	0.95	0.93	0.94	493
weighted avg	0.95	0.95	0.95	493

Fuente: Elaboración propia

Figura 16: Correlación entre las variables del modelo



Fuente: Elaboración propia

Viendo los resultados de las métricas obtenidas, se usó del hiperparámetro igual a 2, al obtener una mayor precisión de 96.14%.

## 5.2. Resultados descriptivos.

En primer lugar, presentaremos los datos del mes de prueba que se tomó para el entrenamiento del modelo de machine learning. Se ha trabajado con un total de 2461 registros, donde se tiene los datos de los clientes a los que se les ofreció un crédito en el periodo de agosto, teniendo 1,844 clientes que aceptaron el crédito y 617 clientes que no aceptaron el crédito. En el siguiente cuadro se detalla los porcentajes de clientes que aceptaron el crédito con respecto al total de la muestra y lo mismo para los clientes no aceptaron el crédito.

*Tabla 3: Clientes que aceptaron o no aceptaron un crédito*

	Cantidad	Porcentaje
Aceptaron	1844	74.93%
Rechazaron	617	25.07%
<b>Total</b>	<b>2461</b>	<b>100%</b>

Fuente: Elaboración propia

En la tabla N°3 se muestran los resultados para las categorías de clientes que aceptaron o no aceptaron el crédito en el mes de agosto, de donde obtenemos que, de un total de 2461 clientes, el 74.93% aceptó el crédito y el 25.07% no aceptó.

En la siguiente tabla se detalla la distribución de los distintos canales digitales utilizados para captar a los clientes.

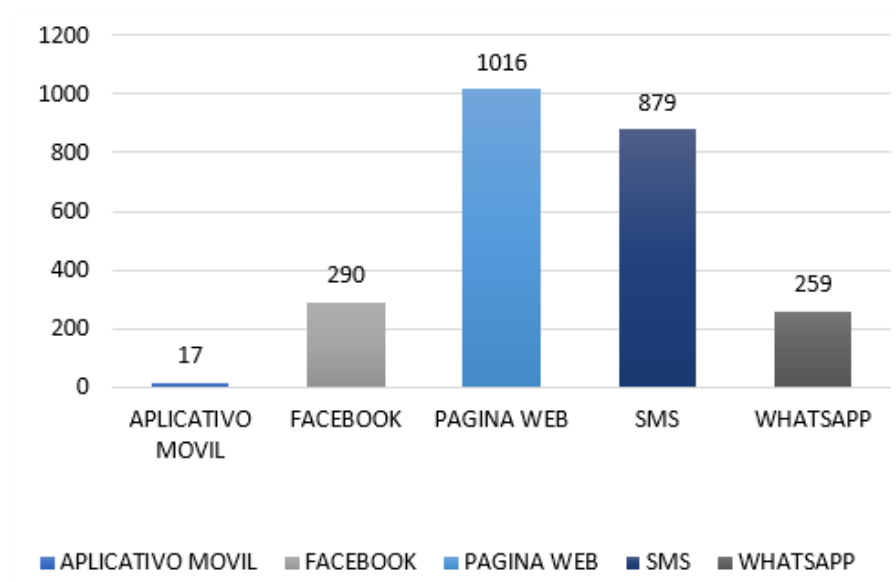
*Tabla 4: Fuentes por las que fueron captados los clientes potenciales*

FUENTE	Conteo de FUENTE
APLICATIVO MOVIL	17
FACEBOOK	290
PAGINA WEB	1016
SMS	879
WHATSAPP	259
<b>Total</b>	<b>2461</b>

Fuente: Elaboración propia



Figura 17 Fuentes por las que fueron captados los clientes potenciales



Fuente: Elaboración propia

### Interpretación:

De la figura N°17 y la tabla N°4 se pueden observar que los medios más utilizados son la página web y el SMS, del total de clientes de 2461, aproximadamente el 41% fue captado por la página web y 36% por SMS, después tenemos los siguientes canales con un 12% por redes sociales (FB), 10% por Whatsapp y por último 0.7% por aplicativo móvil.


En la siguiente tabla se detalla la distribución de los clientes potenciales que tenían una campaña vigente en el momento de ofrecer el crédito bancario.

Tabla 5: Clientes potenciales con campaña vigente

CON CAMPAÑA	Conteo CON CAMPAÑA
NO	617
SI	1844
<b>Total general</b>	<b>2461</b>

Fuente: Elaboración propia

Figura 18: Clientes potenciales con campaña vigente



Fuente: Elaboración propia

**Interpretación:**

En la figura N°18 y la tabla N°5 podemos ver que de este total de clientes se tiene que el 75% se encontraba dentro de una campaña vigente y el 25% no se encontraba en la campaña vigente.

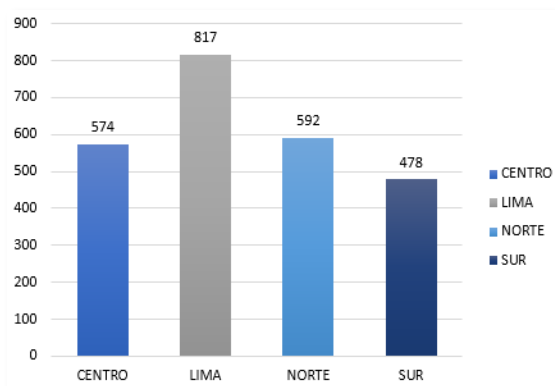
En la siguiente tabla se detalla la segmentación de los clientes potenciales captados por región durante el periodo de agosto.

*Tabla 6: Segmentación de clientes potenciales por región*

REGION	Conteo de REGION
<b>CENTRO</b>	574
LIMA	817
NORTE	592
SUR	478
<b>Total general</b>	<b>2461</b>

Fuente: Elaboración propia

Figura 19: Segmentación de clientes potenciales por región



Fuente: Elaboración propia

### Interpretación:

De la figura N°19 y la tabla N°6 se puede observar que entre las regiones más importantes tenemos a Lima, con una participación de 37% aproximadamente, luego sigue el Sur con un 24%, Centro con un 22% y el 17% viene por parte de la región Norte.


En la siguiente tabla se detalla las familias por convenio a la que pertenecen los clientes potenciales captados por región durante el periodo de agosto.

Tabla 7: Segmentación de clientes potenciales por familia por convenio

FAMILIA	Conteo de FAMILIA
CAJA PENSIONES MP	313
CORPORATIVO	19
EDUCACION	575
EJERCITO	147
ESSALUD	197
FAP	1
GOBIERNO	28
MARINA	124
MINISTERIO PUBLICO	27
MUNICIPALIDAD	50
ONP	30
OTROS	41
PNP	786
PODER JUDICIAL	70
UNIVERSIDADES	53
<b>Total general</b>	<b>2461</b>

Fuente: Elaboración propia

Figura 20: Segmentación de clientes potenciales por familia por convenio



Fuente: Elaboración propia

### Interpretación:

De la figura N°20 y la tabla N°7 se puede ver la lista de familias por convenio a los que se puede llegar y de donde podemos obtener que, de un total de 2461 clientes, se tiene que entre las familias por convenio se tiene que las más importantes son la PNP con una participación de 32%, Educación con una participación de 23%, CPMP con 13%, Ejército con 5%, MGP y Salud con 3% cada una y el resto suma un total de participación de 21%, con un total de menos de 4% de participación cada una.

### 5.3. Resultados inferenciales.

Aquí analizaremos la implementación de un modelo de Machine Learning en el área de convenios de una entidad financiera del Perú. Para contrastar esta hipótesis general, analizaremos el comportamiento de los datos obtenidos, primero analizaremos la bondad de ajuste (la normalidad) de los datos usando el SPSS v29.

### 5.3.1. Prueba de normalidad

Según (Metodología de la investigación: Pruebas de bondad de ajuste a una distribución normal, 2016) cuando la muestra es mayor de 50 se emplea la prueba de Kolmogórov-Smirnov, mientras que si la muestra es menor o igual a 50 se emplea la prueba de Shapiro-Wilk. Por lo tanto, se ha utilizado el estadístico de Shapiro-Wilk pues el tamaño de la muestra está conformado por 20 encuestados.

#### **Nivel de significancia:**

Confianza: 95%

Significancia (ALFA): 5%

#### **Decisión:**

1. Si p-valor es MENOR o IGUAL que el ALFA, se rechaza la  $H_0$  y se acepta  $H_1$  (Los datos no tienen distribución normal, por lo que se emplearán pruebas NO PARAMÉTRICAS)
2. Si p-valor es MAYOR que el ALFA, se acepta la  $H_0$  y se rechaza  $H_1$  (Los datos tienen distribución normal, por lo que se emplearán pruebas PARAMÉTRICAS)

#### **Prueba de normalidad 1:**

**Variable dependiente:** Ventas digitales en el área de convenios

#### **Hipótesis:**

$H_0$ : Los datos de las ventas digitales en el área de convenios de una entidad financiera del Perú tienen una distribución normal.

$H_1$ : Los datos de las ventas digitales en el área de convenios de una entidad financiera del Perú no tienen una distribución normal.

Tabla 8: Prueba de normalidad de ventas digitales

	Pruebas de normalidad					
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Ventas digitales en el área de convenios	0.141	20	0.200*	0.941	20	0.250

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Fuente: Elaboración propia

### Conclusión:

Para las ventas digitales en el área de convenios de una entidad financiera del Perú el p-valor es  $0.250 > 0.05$  por lo que se acepta la hipótesis nula: “Los datos de las ventas digitales en el área de convenios de una entidad financiera del Perú tienen una distribución normal.”

### Prueba de normalidad 2:

**Variable dependiente:** Clientes potenciales en el área de convenios

#### Hipótesis:

**H<sub>0</sub>:** Los datos de los clientes potenciales en el área de convenios de una entidad financiera del Perú tienen una distribución normal.

**H<sub>1</sub>:** Los datos de los clientes potenciales en el área de convenios de una entidad financiera del Perú no tienen una distribución normal.

### Prueba de normalidad 3:

**Variable dependiente:** Montos desembolsados en el área de convenios

#### Hipótesis:

**H<sub>0</sub>:** Los datos de los montos desembolsados en el área de convenios de una entidad financiera del Perú tienen una distribución normal.

**H<sub>1</sub>:** Los datos de los montos desembolsados en el área de convenios de una entidad financiera del Perú no tienen una distribución normal.

*Tabla 9: Prueba de normalidad de clientes potenciales y montos desembolsados*

<b>Pruebas de normalidad</b>						
	Kolmogorov-Smirnov <sup>a</sup>			Shapiro-Wilk		
	Estadístico	gl	Sig.	Estadístico	gl	Sig.
Cientes potenciales	0.121	20	.200 <sup>*</sup>	0.972	20	0.801
Montos desembolsados	0.139	20	.200 <sup>*</sup>	0.957	20	0.486

\*. Esto es un límite inferior de la significación verdadera.

a. Corrección de significación de Lilliefors

Fuente: Elaboración propia

### **Conclusiones:**

Para los clientes potenciales en el área de convenios de una entidad financiera del Perú el p-valor es  $0.801 > 0.05$  por lo que se acepta la hipótesis nula: “Los datos de los clientes potenciales en el área de convenios de una entidad financiera del Perú tienen una distribución normal.”

Para los montos desembolsados en el área de convenios de una entidad financiera del Perú el p-valor es  $0.486 > 0.05$  por lo que se acepta la hipótesis nula: “Los datos de los montos desembolsados en el área de convenios de una entidad financiera del Perú tienen una distribución normal.”

### 5.3.2. Prueba de hipótesis

Con la prueba de hipótesis para determinar si los datos siguen una distribución Normal, se ha encontrado que los datos siguen una distribución Normal, por lo tanto, para probar la hipótesis planteada se utilizará el Estadístico paramétrico T-student.

#### Nivel de significancia:

Confianza: 95%

Significancia (ALFA): 5%

#### Prueba estadística:

T-Student

#### Decisión:

1. Si p-valor es MENOR o IGUAL que el ALFA, se rechaza la  $H_0$  y se acepta  $H_1$ .
2. Si p-valor es MAYOR que el ALFA, se acepta la  $H_0$  y se rechaza  $H_1$ .

#### Formulación de hipótesis:

$H_1$ : La implementación de un modelo de Machine Learning incrementa las ventas digitales en el área de convenios de una entidad financiera del Perú.

$H_0$ : La implementación de un modelo de Machine Learning no incrementa las ventas digitales en el área de convenios de una entidad financiera del Perú.

#### Cálculo de la prueba:

*Tabla 10: Estadística de la muestra*

Estadísticas para una muestra				
	N	Media	Desv. estándar	Media de error estándar
Ventas digitales	20	48.600	3.60409	0.80590

Fuente:Elaboración propia



Tabla 11: Prueba T-student para ventas digitales

**Prueba para una muestra**

Valor de prueba = 42

	t	gl	Significación		Diferencia de medias	95% de intervalo de confianza de la diferencia	
			P de un factor	P de dos factores		Inferior	Superior
Ventas digitales	8.190	19	<.001	<.001	6.60000	4.9132	8.2868

Fuente: Elaboración propia

**Conclusión:**

Para las ventas digitales en el área de convenios de una entidad financiera del Perú el p-valor es  $0.001 < 0.05$  por lo que se rechaza la hipótesis nula y se acepta la hipótesis alterna “La implementación de un modelo de Machine Learning incrementa las ventas digitales en el área de convenios de una entidad financiera del Perú.”

**Formulación de hipótesis específicas:**

H<sub>1</sub>: La implementación de un modelo de Machine Learning incrementa los clientes potenciales en el área de convenios de una entidad financiera del Perú.

H<sub>0</sub>: La implementación de un modelo de Machine Learning no incrementa los clientes potenciales en el área de convenios de una entidad financiera del Perú.

Tabla 12: Prueba T-student para clientes potenciales

**Prueba para una muestra**

Valor de prueba = 21

	t	gl	Significación		Diferencia de medias	95% de intervalo de confianza de la diferencia	
			P de un factor	P de dos factores		Inferior	Superior
Clientes potenciales	5.749	19	<.001	<.001	3.050	1.94	4.16

Fuente: Elaboración propia

**Conclusión:**

Para los clientes potenciales en el área de convenios de una entidad financiera del Perú el p-valor es  $0.001 < 0.05$  por lo que se rechaza la hipótesis nula y se acepta la hipótesis alterna “La implementación de un modelo de Machine Learning incrementa los clientes potenciales en el área de convenios de una entidad financiera del Perú.”

$H_1$ : La implementación de un modelo de Machine Learning incrementa los montos desembolsados en el área de convenios de una entidad financiera del Perú.

$H_0$ : La implementación de un modelo de Machine Learning no incrementa los montos desembolsados en el área de convenios de una entidad financiera del Perú.

*Tabla 13: Prueba T-student para montos desembolsados*

Prueba para una muestra							
Valor de prueba = 21							
t	gl	Significación		Diferencia de medias	95% de intervalo de confianza de la diferencia		
		P de un factor	P de dos factores		Inferior	Superior	
Montos desembolsados	5.061	19	<.001	<.001	3.550	2.08	5.02

Fuente:Elaboración propia

**Conclusión:**

Para los montos desembolsados en el área de convenios de una entidad financiera del Perú el p-valor es  $0.001 < 0.05$  por lo que se rechaza la hipótesis nula y se acepta la hipótesis alterna “La implementación de un modelo de Machine Learning incrementa los montos desembolsados en el área de convenios de una entidad financiera del Perú.”

## **VI. DISCUSIÓN DE RESULTADOS.**

### **6.1. Contrastación y demostración de la hipótesis con los resultados.**

#### **Indicador clientes potenciales.**

La implementación de un modelo de machine learning en el área de convenios en un banco del Perú incrementó el total de clientes potenciales de un 2461 a 3341, lo que equivale a un incremento de 35.75% aproximadamente.

Los resultados obtenidos para la presente investigación comprueban que la implementación de un modelo de machine learning permite procesar, mostrar información de forma dinámica, de fácil acceso y de manera oportuna para el área de convenios, confirmando que la implementación de un modelo de machine learning influye significativamente en la cantidad total de clientes potenciales de un banco del Perú e incrementa la cantidad de clientes potenciales en 35.75 en el área de convenios de una entidad financiera del Perú.

#### **Indicador ventas digitales.**

La implementación de un modelo de machine learning en el área de convenios en un banco del Perú incrementó el promedio de montos aprobados de un 15570790.60 a 19842663.93, lo que equivale a un incremento promedio del 27.44% aproximadamente.

Los resultados obtenidos para la presente investigación comprueban que la implementación de un modelo de machine learning permite procesar, mostrar información de forma dinámica, de fácil acceso y de manera oportuna para el área de convenios, confirmando que la implementación de un modelo de machine learning influye significativamente en el incremento de los montos de los créditos aprobados de un banco del Perú e incrementa la cantidad de montos de ventas digitales en 27.44% en el área de convenios de una entidad financiera del Perú.

### **6.2. Contrastación de los resultados con otros estudios similares.**

De acuerdo con los resultados de (Rodríguez Villanueva, y otros, 2023) donde la construcción del modelo se utilizaron técnicas de machine

learning de clasificación k-NN y SVM, los datos utilizados son de clientes a los que se les ofreció un crédito entre enero y febrero del año 2023, en la primera simulación tuvieron una precisión de 61.68% y 68.41% respectivamente; dada la dispersión de los datos se realizó la normalización para la segunda simulación la cual resultó con una precisión de 91.12% para k-NN y 93.85% para SVM, concluyendo de esta forma que esta última técnica es la mejor para conocer el número de ventas de crédito con la finalidad de agilizar la toma de decisiones frente a nuevas estrategias o mejoras en las ventas. En nuestro estudio utilizando la prueba estadística paramétrico T-student pudimos concluir que al 95% de confianza la implementación de un modelo de Machine Learning incrementa las ventas digitales en el área de convenios de una entidad financiera del Perú.

De igual forma (Barrueta Meza, y otros, 2018) en su investigación, determinó que el algoritmo más preciso era el R-K-Means logrando una precisión del 93.20% en la prueba de validación, el árbol R-CNR y la red neuronal R-NNet tenían precisiones de validación de 92.5% y 87.3% respectivamente, concluyendo de esta manera de que un Modelo de Análisis Predictivo demuestra ser capaz de lograr una precisa predicción de clientes desertores. Nuestro estudio pudo determinar que la implementación de un modelo de Machine Learning incrementa los clientes potenciales en el área de convenios de una entidad financiera del Perú.

### **6.3. Responsabilidad ética de acuerdo a los reglamentos vigentes.**

La presente investigación fue elaborada bajo los lineamientos y el código de ética de investigación de la Universidad Nacional del Callao, aprobada por resolución del Consejo Universitario N°210–2017-CU. tomando en cuenta los principios como son los indicados: el profesionalismo, la transparencia, la objetividad, la igualdad, el compromiso, la honestidad y la confidencialidad, con el fin de elaborar un buen trabajo de investigación.

La información recopilada del área de convenios de una entidad financiera con sede principal en el distrito de La Victoria en el Perú, fueron manejados de manera confidencial, con la exclusiva finalidad de utilizarlos para propósitos de investigación.

## **VII. CONCLUSIONES.**

1. El modelo de machine learning incrementó en 17% el promedio de las ventas digitales, por lo tanto, se afirma que la implementación de un modelo de machine learning influye significativamente en el incremento de ventas digitales en el área de convenios de una entidad financiera del Perú.
2. El modelo de machine learning incrementó en 35.84% los clientes potenciales, por lo tanto, se afirma que la implementación de un modelo de machine learning influye significativamente en el incremento de clientes potenciales en el área de convenios de una entidad financiera del Perú.
3. El modelo de machine learning incrementó en 27.44% los montos desembolsados, por lo tanto, se afirma que la implementación de un modelo de machine learning influye significativamente en el incremento de montos desembolsados en el área de convenios de una entidad financiera del Perú.

## **VIII. RECOMENDACIONES.**

1. Poder plantear posteriores investigaciones y/o ampliar la ya existente, con el propósito de poder mejorar el proceso de ventas digitales y su otros relacionados, de esta manera se podrá optimizar aún más este y sus otros procesos que se relaciones o involucrados con el proceso de ventas digitales en el área de convenios.
2. Evaluar y desarrollar lo que se ha obtenido en la investigación con el fin de que se logre fortalecer y estrechar más aún los lazos comerciales con los clientes a fin de alcanzar un posicionamiento sólido en el mercado nacional e internacional.
3. Realizar procesos de investigación para poder realizar más cambios a fin de adaptar mucho mejor el modelo de machine learning y poder agregar mejoras, a fin de optimizar los montos ofrecidos a los clientes.

## IX. REFERENCIAS BIBLIOGRÁFICAS.

**Albertí Rovira, Enoch. 2022.** *Los convenios de colaboración.* Barcelona : s.n., 2022.

**Araujo Mesias, Brunella Berenice y Su Valenzuela, Allison Guisela. 2022.** *Factores que influyen en la intención de uso de la banca.* Lima : s.n., 2022.

**Azabache La Torre, Pablo Julio. 2019.** *Optimización del Margen Comercial de Préstamos de Consumo: Algoritmo de Optimización con Machine Learning, Tesis presentada en satisfacción parcial de los requerimientos para obtener el grado de Maestro en Marketing en la ESAN.* Lima : s.n., 2019.

**Barrueta Meza, Renzo André y Castillo Villarreal, Edgar Jean Paul. 2018.** *Modelo de análisis predictivo para determinar clientes Modelo de análisis predictivo para determinar clientes.* Lima : s.n., 2018.

**Beris Rodas, Pastor Wilfredo. 2020.** *Transformación digital y canales digitales del BCP en la Agencia Centro Aéreo, Lima - Perú, 2020, Tesis para obtener el título profesional de Licenciado en Administración.* Lima : s.n., 2020.

**Caillaux, Charles. 2020.** ¿Cuánto ha transformado la tecnología nuestras vidas durante la pandemia? *Conexión esan.* [En línea] Esan, 13 de Octubre de 2020.

**Campbell, D.T. y Stanley, J.C. 1963.** *Diseños experimentales y cuasi-experimentales.* Buenos Aires : Amorrortu, 1963.

**Cerrinos Ponce, Jaime Cesar y Pinedo Vega, Sheyla Estefanie. 2019.** *Incidencia de préstamos bancarios en la situación financiera de Avamar Sac – Chimbote 2019, Tesis para obtener el título profesional de Contador Público.* 2019. Chimbote.

**Chavez Muñoz, Javier Raul, y otros. 2019.** *Factores que influyen en la intención de uso de tecnología de medios de pago móvil en negocios minoristas en Lima Metropolitana, Tesis presentada en satisfacción parcial de los requerimientos para obtener el grado de Maestro en Marketing.* Lima : s.n., 2019.



**Cristianini, Nello y Shawe-Taylor, John. 2000.** *Support Vector Machines and Other Kernel-based Learning Methods*. Reino Unido : Cambridge University Press, 2000.

*El método de la investigación Research Method*. **Abreu, José Luis. 2014.** 3, México : International journal of good conscience, 2014, Vol. 9. p.195-204.

**Escurra M., Luis Miguel. 1988.** *Cuantificación de la validez de contenido por criterio de jueces*. Lima : PSICO, 1988.

**Espinoza Reyes, Robinson Lener. 2020.** *Los canales digitales y su relación en las ventas*. Piura : s.n., 2020.

**Farro Toranzo, Kamira Mirella, y otros. 2023.** *Plan de negocio de una plataforma digital de intermediación de ventas*. Lima : s.n., 2023.

**Francés Monedero, Teresa. 2020.** *Impacto del Machine learning en el sistema financiero*. Madrid : s.n., 2020.

**Gobat, Jeanne. 2012.** *¿Qué es un banco?* *Finanzas & Desarrollo*. 2012.

**Gomez Fabian, Brunnella Alejandra y Blas Corrales, Walter Leonardo. 2021.** *Aplicación de herramientas de analítica y optimización matemática para mejorar la cobertura de los canales digitales en una entidad bancaria*. Lima : s.n., 2021.

**Gómez, Marcelo. 2006.** *Introducción a la metodología de la investigación científica*. Córdoba : Brujas, 2006.

**Hernandez Sampieri, Roberto, Fernandez Collado, Carlos y Baptista Lucio, Pilar. 2014.** *Metodología de la investigación 6ta edición*. México : McGRAW-HILL / INTERAMERICANA EDITORES, 2014.

**Huamaní Espinoza, Alex Alberto. 2021.** *Sistema de Gestión de Convenios Institucionales de un banco, Tesis para obtener el título profesional de Ingeniería de sistemas*. Lima : s.n., 2021.

**Hurwitz, Judith y Kirsch, Daniel. 2018.** *Machine Learning for dummies IBM edition*. Nueva Jersey : John Wiley & Sons, Inc, 2018.

**Lizarraga Cajamuni, Martin Ronald. 2022.** *La implementación de la era digital y sus efectos en la colocación de créditos personales digitales de las instituciones bancarias de Perú y México, Tesis para obtener el grado académico de doctor en ciencias Contables y Financieras.* Lima : s.n., 2022.

**Manrique Molina, Valentina y Castañeda Villamarin, Carolina. 2022.** *Evolución del marketing a la era digital, Universidad Autónoma de Bucaramanga.* Bucaramanga, Colombia : s.n., 2022.

**Martínez Guzmán, Julián Camilo. 2022.** *Propuesta de implementación de un canal de ventas digitales para una compañía de banca basado en Bogotá, Colombia.* Buenos Aires : s.n., 2022.

*Metodología de la investigación: Pruebas de bondad de ajuste a una distribución normal.* **Romero-Saldaña, Manuel. 2016.** 3, s.l. : Revista Enfermería del Trabajo, 2016, Vol. 6.

*Modelos de Machine Learning para el análisis y pronóstico de la situación financiera de bancos – Caso boliviano.* **Cáceres Santos, Jonnathan R. 2020.** 2020, Revista de Análisis, págs. 69-91.

**Müller, Andreas C. y Guido, Sarah. 2016.** *Introduction to Machine Learning with Python.* California : O'Reilly Media, 2016.

**Núñez Gonzáles, María Alejandra y Sifuentes Barrientos, Diana Rosario. 2019.** *Las fintech como herramienta para la promoción de la inclusión financiera en el Perú, Tesis presentada en satisfacción de los requerimientos para obtener el grado de Maestro en Finanzas y Derecho.* Lima : s.n., 2019.

**Quintero Acuña, Lady Katherine. 2023.** *Aplicación de machine learning a un modelo tradicional de prevención y detección de fraude en entidad financiera proyectado periodos trimestrales.* Bogotá : s.n., 2023.

**Rodriguez Condezo, Juan Pablo. 2022.** *Machine learning y su incidencia en la gestión comercial en una entidad financiera, Lima 2022.* Lima : s.n., 2022.

**Rodriguez Villanueva, Alvaro André, Sánchez Adauto, Egor Leonardo y Valverde Rojo, Lisset Milena. 2023.** *Aplicación de técnicas de Machine*

*Learning para predecir el número de ventas de créditos en el sector bancario, Trabajo de Suficiencia Profesional presentado para obtener el título profesional de Ingeniero Industrial y Comercial en la ESAN.* Lima : s.n., 2023.

**Russell, Stuart J. y Norvig, Peter. 2008.** *Inteligencia Artificial un enfoque moderno (2da ed.).* Madrid : PEARSON EDUCACIÓN, S.A, 2008.

**Suarez Ramirez, Camilo Steven. 2022.** *Investigación sobre el estado actual de las ventas digitales y la percepción de los colaboradores del banco BBVA.* Bogotá : s.n., 2022.

**Tamayo, Mario. 2011.** *El proceso de la investigación científica.* México : Limusa noriega editores, 2011.

**Terán Espinoza, Brenda Bony. 2019.** *Marketing digital y el incremento de las ventas en la empresa Contasiscorp SAC, San Isidro, 2019, Tesis para obtener el título profesional de licenciada den administración.* Lima : s.n., 2019.

*The Impact of COVID-19 on Consumers: Preparing for Digital Sales.* **KIM, RAE YULE. 2020.** 3, Montclair : IEEE ENGINEERING MANAGEMENT REVIEW, 2020, Vol. 48. THIRD QUARTER.

**Theobald, Oliver. 2017.** *Machine Learning for absolute beginners 2nd edition.* London : Scatterplot Press, 2017.

**Troncoso Ponce, Pablo Andrés. 2022.** *Transformación digital a nivel corporativo mediante la realización de proyectos basados en analytics y machine learning.* Santiago de Chile : s.n., 2022.

**Urrego Álvarez, Mauricio y Yepes Sánchez, Edison. 2021.** *Transformación Digital de la Banca: Modelo basado en Machine Learning para la clasificación de transacciones bancarias realizadas a través de PSE.* Medellín : s.n., 2021.

**Valderrama, Santiago. 2019.** *Pasos para Elaborar Proyectos de Investigación Científica Cualitativa, Cuantitativa y Mixta 11va edición.* Lima : San Marcos, 2019.

**Velarde Flores, Shirley Rosario. 2018.** *Las tasas de interés y tipos de crédito en sistema financiero de Bolivia, Tesis para la obtención del Grado Académico de Licenciatura.* La Paz : s.n., 2018.

## ANEXOS:

### Anexo 1: Matriz de consistencia

Problema	Objetivo	Hipótesis	Variables	Metodología por utilizar
<p>Problema General</p> <p>¿De qué manera la implementación de un modelo de Machine Learning incrementará las ventas digitales en el área de convenios de una entidad financiera del Perú?</p>	<p>Objetivo General</p> <p>Determinar el incremento de las ventas digitales en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning</p>	<p>Hipótesis General</p> <p>La implementación de un modelo de Machine Learning incrementará las ventas digitales en el área de convenios de una entidad financiera del Perú.</p>	<p>Variable Independiente: Machine Learning</p> <p>Variable Dependiente: Ventas digitales</p>	<p>METODO</p> <p>Cuantitativo-deductiva</p> <p>TIPO Y DISEÑO DE LA INVESTIGACIÓN</p> <p>Preexperimental - aplicada</p> <p>DETERMINACIÓN DEL UNIVERSO:</p> <p>Población y muestra: Datos de clientes que solicitaron un crédito en el periodo de agosto del 2023.</p> <p>LUGAR DE ESTUDIO</p> <p>Entidad financiera del Perú</p> <p>TECNICA</p> <p>Encuesta</p> <p>INSTRUMENTO</p> <p>Cuestionario</p>
<p>Problema Específico</p> <p>¿De qué manera la implementación de un modelo de Machine Learning incrementará los clientes potenciales en el área de convenios de una entidad financiera del Perú?</p>	<p>Objetivo Específico</p> <p>Determinar el incremento de clientes potenciales en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning</p>	<p>Hipótesis Específico</p> <p>La implementación de un modelo de Machine Learning incrementará los clientes potenciales en el área de convenios de una entidad financiera del Perú.</p>	<p>Dimensiones</p> <ul style="list-style-type: none"> <li>• Clientes potenciales</li> </ul>	
<p>¿De qué manera la implementación de un modelo de Machine Learning incrementará los montos desembolsados en el área de convenios de una entidad financiera del Perú?</p>	<p>Determinar el incremento de montos desembolsados en el área de convenios de una entidad financiera del Perú con la implementación de un modelo de Machine Learning</p>	<p>La implementación de un modelo de Machine Learning incrementará los montos desembolsados en el área de convenios de una entidad financiera del Perú.</p>	<ul style="list-style-type: none"> <li>• Montos desembolsados</li> </ul>	
<p><b>TÍTULO: APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023</b></p>				

Anexo 2: Instrumentos validados



**UNIVERSIDAD NACIONAL DEL CALLAO**  
**FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS**

**INSTRUMENTO PARA MEDIR LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ**

**TÍTULO DE LA INVESTIGACIÓN**

**APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023**

**INSTRUCCIONES.**

Estimado, tenga usted un buen día, a continuación, leerá un cuestionario que tiene como objetivo conocer su opinión sobre modelo de machine learning en las ventas digitales en el área de convenios de una entidad financiera. Dicha información es completamente anónima, por lo que le solicito responda todas las preguntas con sinceridad.

En sus respuestas, sírvase marcar con una (X) la respuesta que considere correcta:

<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>
<b>Muy Poco</b>	<b>Poco</b>	<b>Medio</b>	<b>Alto</b>	<b>Muy Alto</b>

Variable	Dimensiones	Ítems	Preguntas	Valoración				
				5	4	3	2	1
Modelo de Machine learning (V.I.)	Confiabilidad	1	¿Qué tan consistente es tu modelo predictivo en proporcionar resultados similares ante situaciones similares?					
		2	¿En qué medida tu modelo mantiene su precisión y rendimiento a lo largo del tiempo?					
		3	¿Qué tan robusto es tu modelo ante variaciones en los datos de entrada, manteniendo su confiabilidad?					
		4	¿Cuán consistente es la confiabilidad de tu modelo al aplicarlo a conjuntos de datos diferentes pero relevantes?					
		5	¿En qué medida tu modelo es fiable al identificar patrones subyacentes en los datos de créditos bancarios?					

	Validez	6	¿Qué tan preciso es tu modelo para prever las cifras reales de ventas digitales?							
		7	¿Qué tan válido es tu modelo en generalizar sus predicciones a nuevos casos y clientes no presentes en el conjunto de entrenamiento?							
		8	¿Cuán válido es tu modelo al generalizar sus predicciones en diferentes regiones geográficas?							
		9	¿Qué tan relevante es la información proporcionada por tu modelo para la toma de decisiones estratégicas en otorgamiento de créditos?							
		10	¿Cuánto contribuyen las variables incluidas en tu modelo a la validez de las predicciones sobre créditos bancarios?							
	Ventas digitales (V.D)	Clientes Potenciales	11	¿Qué tan preciso es tu modelo en identificar clientes potenciales con la probabilidad de realizar un desembolso bancario?						
			12	¿Cómo evalúas la capacidad del modelo para adaptarse a cambios en el comportamiento financiero de los clientes en distintas regiones geográficas?						
			13	¿En qué medida tu modelo contribuye a una eficiente identificación y focalización de clientes potenciales para incrementar las ventas digitales en banca?						
			14	¿Cuán preciso es tu modelo al identificar clientes potenciales elegibles para créditos bancarios por convenio?						
			15	¿En qué medida las predicciones de tu modelo son consistentes al identificar oportunidades de ventas digitales entre los clientes potenciales en el ámbito bancario?						
16			¿Cuánto confías en la capacidad de tu modelo para adaptarse a cambios en las preferencias y comportamientos de los clientes potenciales en banca digital?							
17			¿Qué impacto ha tenido el modelo en la expansión y diversificación de la cartera de clientes de la entidad financiera?							
Monto Desembolsado		18	¿Qué tan bien el modelo generaliza su capacidad de evaluación de clientes y montos de crédito a través de diferentes conjuntos de datos?							
		19	¿Qué tan significativamente ha aumentado el monto total de créditos concedidos desde la implementación del modelo predictivo?							
		20	¿En qué medida tu modelo considera variables clave al evaluar y prever los montos desembolsados en transacciones digitales en el sector bancario?							
		21	¿Qué tan bien tu modelo se ajusta a las dinámicas cambiantes del mercado digital en relación con los montos desembolsados en ventas bancarias?							
		22	¿Cuán cercanas fueron las predicciones del modelo con respecto al rango de monto desembolsado por regiones geográficas?							
		23	¿Considera que el modelo predictivo fue eficaz para anticipar variaciones significativas en el monto desembolsado en sus ventas digitales?							
		24	¿Considera que el modelo predictivo proporcionó insights que no eran evidentes a través de métodos tradicionales al analizar el monto desembolsado en ventas digitales?							

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): M<sup>s</sup>. Angelino Abad Ramos Chozhuanca

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable  No aplicable  Aplicable después de corregir

No aplicable [ ]

SUGERENCIAS:

Apellidos y nombres del juez validador. Dni Mg: Angelino Abad Ramos

DNI: 10101015, Especialidad del validador: metodólogo [ ] temático [ ]

estadístico [ ]

27 de 11 del 2023



Firma y sello del Experto Informante.



FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): Dr. César Vilchez Inga

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable  Aplicable después de corregir

No aplicable

SUGERENCIAS:

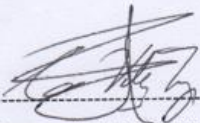
.....  
 .....

Apellidos y nombres del juez validador: Dr. Vilchez Inga César

DNI: 02672875, Especialidad del validador: metodólogo  temático

estadístico

27 de 11 del 2023



Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): Dra. Sally Karina Torres Alvarado

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable       Aplicable después de corregir

No aplicable

SUGERENCIAS:

.....  
 .....

Apellidos y nombres del juez validador. Dr/ Mg: Dra Sally Torres Alvarado

DNI: 15724611....., Especialidad del validador: metodólogo  temático

estadístico

27.de.11del 20.23

  
 -----  
 Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): Mg JOSÉ FANTAN GARCIA

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable       Aplicable después de corregir

No aplicable

SUGERENCIAS:

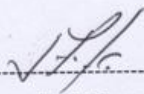
.....  
 .....

Apellidos y nombres del juez validador, Dr/ Mg: JOSÉ FANTAN GARCIA

DNI: 07365739....., Especialidad del validador: metodólogo  temático

estadístico

27 de 11 del 2023

  
 .....  
 Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): Dr. GUILLERMO ANTONIO MAS AZAHUANCHE

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable  Aplicable después de corregir [ ]

No aplicable [ ]

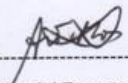
SUGERENCIAS:

.....  
 .....

Apellidos y nombres del juez validador. Dr/ Mg: Dr. GUILLERMO ANTONIO MAS AZAHUANCHE  
 DNI: 08386156, Especialidad del validador: metodólogo [ ] temático [ ]

estadístico

27 de 11 del 2023

  
 -----  
 Firma y sello del Experto Informante.

FICHA DE VALIDEZ POR JUECES EXPERTOS (II)

ESCALA DE CALIFICACIÓN

Estimado (a): DR. Herman Mario VILCAPUMA MALPICA

Teniendo como base los criterios que a continuación se presenta, se le solicita dar su opinión sobre el instrumento de recolección de datos que se adjunta:

Marque con una (X) en SI o NO, en cada criterio según su opinión.

CRITERIOS	SI	NO	OBSERVACIÓN
1. El instrumento recoge información que permite dar respuesta al problema de investigación.	X		
2. El instrumento propuesto responde a los objetivos del estudio.	X		
3. La estructura del instrumento es adecuada.	X		
4. Los ítems del instrumento responden a la operacionalización de las variables.	X		
5. La secuencia presentada facilita el desarrollo del instrumento.	X		
6. Los ítems son claros y entendibles.	X		
7. El número de ítems es adecuado para su aplicación.	X		

Opinión de aplicabilidad: Aplicable  Aplicable después de corregir [ ]

No aplicable [ ]

SUGERENCIAS:

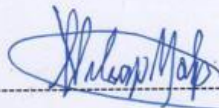
.....  
 .....

Apellidos y nombres del juez validador. Dr/ Mg: Herman Mario VILCAPUMA MALPICA

DNI: 25575248, Especialidad del validador: metodólogo [ ] temático [ ]

estadístico [ ]

27 de 11 del 2021



Firma y sello del Experto Informante.

Anexo 3: Base de Datos

Tabla 14: Encuesta de variable dependiente

ESCALA DE LIKERT																		
PREGUNTAS																		
Dimensiones	Clientes potenciales							SUMA	Montos desembolsados							SUMA	SUMA TOTAL	
Encuestados	I11	I12	I13	I14	I15	I16	I17		I18	I19	I20	I21	I22	I23	I24			
1	5	3	4	4	5	3	2	26	5	4	4	2	3	2	3	23	49	
2	3	3	5	4	4	5	5	29	2	2	4	2	3	2	3	18	47	
3	3	4	3	2	5	2	3	22	2	3	5	2	4	2	5	23	45	
4	5	5	2	2	2	5	4	25	5	5	5	4	4	2	3	28	53	
5	4	5	2	2	5	5	2	25	4	3	3	4	2	2	4	22	47	
6	4	2	3	5	2	2	3	21	4	4	3	4	4	3	5	27	48	
7	3	3	5	4	2	2	3	22	5	5	3	4	4	2	5	28	50	
8	3	5	4	5	3	4	2	26	4	5	2	5	4	5	3	28	54	
9	5	4	4	2	3	3	2	23	5	5	3	3	2	4	3	25	48	
10	2	4	3	5	3	5	5	27	2	4	4	3	5	3	5	26	53	
11	4	5	2	2	2	2	3	20	2	5	2	2	5	5	3	24	44	
12	4	5	3	2	2	2	3	21	5	3	4	4	4	2	2	24	45	
13	5	5	2	4	2	2	2	22	2	5	4	5	3	2	2	23	45	
14	4	2	2	5	4	4	3	24	5	5	3	5	2	3	4	27	51	
15	4	5	3	3	5	2	5	27	3	3	2	2	3	5	5	23	50	
16	4	2	3	5	2	4	5	25	5	3	2	4	2	2	5	23	48	
17	2	3	2	5	5	4	5	26	5	4	4	4	5	5	3	30	56	
18	3	4	3	3	4	4	2	23	3	3	2	3	2	5	3	21	44	
19	3	5	2	3	3	5	2	23	5	5	4	4	3	2	5	28	51	
20	2	4	4	2	5	3	4	24	2	2	3	2	4	5	2	20	44	

Fuente: Elaboración Propia

Tabla 15:Ficha de Registro – Antes de la implementación

FICHA DE REGISTRO										
Investigadores : Leslie Perez / Ana Orihuela / Ximena Vicuña										
Proceso : Ventas digitales en el área de convenios										
Periodo : Agosto 2023										
Indicador : Crédito aceptado										
ITEM	Fecha	Convenio	Fuente	Tiene Campaña	Canal de derivación	Región	Plaza	Familia Convenio	Aceptó crédito	Monto de línea
1	01/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	SUR	ICA	CAJA PENSIONES MP	SI	2,123.00
2	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	CHIMBOTE	EDUCACION	SI	26,223.00
3	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	JUNIN	EDUCACION	SI	2,973.00
4	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	CAJAMARCA	EDUCACION	SI	1,222.00
5	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	TRUJILLO	EDUCACION	SI	1,105.00
6	01/08/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	EDUCACION	SI	7,890.00
7	01/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	NORTE	PIURA	EDUCACION	SI	6,900.00
8	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	AYACUCHO	EDUCACION	NO	0.00
9	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	CAJAMARCA	EDUCACION	NO	0.00
10	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	CHINCHA	EDUCACION	NO	0.00
11	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	PISCO	EDUCACION	NO	0.00
12	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	CENTRO	JUNIN	EJERCITO	NO	0.00
13	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	CHICLAYO	EJERCITO	NO	0.00
14	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	MARINA	SI	6,550.00
15	01/08/2023	Vigente	APLICATIVO MOVIL	SI	FFVV_LIMA	LIMA	LIMA	MARINA	SI	13,700.00
16	01/08/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	MARINA	SI	8,333.00
17	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
18	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
19	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
20	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	AREQUIPA	MINISTERIO PUBLICO	NO	0.00
21	01/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	CHICLAYO	PODER JUDICIAL	NO	0.00
22	01/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	HUANUCO	PNP	SI	58,900.00
23	01/08/2023	Vigente	SMS	SI	FFVV_PROV	NORTE	CHICLAYO	PNP	SI	8,905.00
24	01/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	NORTE	CAJAMARCA	PNP	SI	8,438.00

25	01/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	NORTE	JAEN	PNP	SI	7,104.00
...	...	...	...	...	...	...	...	...	...	...
2437	25/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	CENTRO	CHIMBOTE	ESSALUD	NO	0.00
2438	26/08/2023	Vigente	FACEBOOK	SI	FFVV_LIMA	LIMA	LIMA	EDUCACION	SI	2,351.00
2439	26/08/2023	Vigente	FACEBOOK	SI	FFVV_PROV	SUR	TACNA	EDUCACION	SI	1,722.00
2440	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	ICA	EDUCACION	NO	0.00
2441	26/08/2023	Bloqueada	PAGINA WEB	NO	FFVV_PROV	NORTE	TRUJILLO	EDUCACION	NO	0.00
2442	26/08/2023	Bloqueada	FACEBOOK	NO	FFVV_PROV	NORTE	CHICLAYO	EDUCACION	NO	0.00
2443	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
2444	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
2445	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	MARINA	NO	0.00
2446	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	ONP	NO	0.00
2447	26/08/2023	Vigente	SMS	SI	FFVV_LIMA	LIMA	LIMA	PNP	SI	2,741.00
2448	26/08/2023	Vigente	SMS	SI	FFVV_PROV	NORTE	PIURA	PNP	SI	2,679.00
2449	26/08/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	JUNIN	PNP	SI	2,668.00
2450	26/08/2023	Vigente	SMS	SI	FFVV_LIMA	LIMA	LIMA	PNP	SI	1,175.00
2451	26/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	CENTRO	CHIMBOTE	PNP	SI	1,042.00
2452	26/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	CENTRO	JUNIN	PNP	SI	9,260.00
2453	26/08/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	PNP	SI	6,730.00
2454	26/08/2023	Vigente	WHATSAPP	SI	FFVV_PROV	NORTE	PIURA	PNP	SI	9,900.00
2455	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	TRUJILLO	PNP	NO	0.00
2456	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	CENTRO	TARAPOTO	PNP	NO	0.00
2457	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	AREQUIPA	PNP	NO	0.00
2458	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	ABANCAY	PNP	NO	0.00
2459	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	CENTRO	PUCALLPA	ESSALUD	NO	0.00
2460	26/08/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	CUSCO	UNIVERSIDADES	NO	0.00
2461	27/08/2023	Vigente	SMS	SI	FFVV_PROV	NORTE	TRUJILLO	EDUCACION	SI	2,735.00

Fuente: Elaboración Propia



Tabla 16:Ficha de Registro – Después de la implementación

FICHA DE REGISTRO										
Investigadores : Leslie Perez / Ana Orihuela / Ximena Vicuña										
Proceso : Ventas digitales en el área de convenios										
Periodo : Setiembre 2023										
Indicador :										
ITEM	Fecha	Convenio	Fuente	Tiene Campaña	Canal de derivación	Región	Plaza	Familia Convenio	Aceptó crédito	Monto de línea
1	01/09/2023	Vigente	APLICATIVO MOVIL	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	1,400
2	01/09/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	1,000
3	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	CHIMBOTE	CAJA PENSIONES MP	SI	1,000
4	01/09/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,321
5	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	5,000
6	01/09/2023	Vigente	APLICATIVO MOVIL	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,800
7	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	4,094
8	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	1,850
9	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	3,200
10	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,000
11	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,450
12	01/09/2023	Vigente	SMS	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	3,450
13	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	3,500
14	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	PIURA	CAJA PENSIONES MP	SI	1,000
15	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	1,000
16	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	CAJAMARCA	CAJA PENSIONES MP	SI	1,000
17	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	SUR	ABANCAY	CAJA PENSIONES MP	SI	1,000
18	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,450
19	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	1,000
20	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	PIURA	CAJA PENSIONES MP	SI	1,000
21	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	CAJA PENSIONES MP	SI	2,000
22	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	PIURA	CAJA PENSIONES MP	SI	1,000
23	01/09/2023	Vigente	WHATSAPP	SI	FFVV_LIMA	LIMA	LIMA	EJERCITO	SI	6,350
24	01/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	SUR	TACNA	EJERCITO	SI	2,100

25	01/09/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	EJERCITO	NO	0
...	...	...	...	...	...	...	...	...	...	...
3319	25/09/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	CENTRO	LA MERCED	OTROS	NO	0.00
3320	25/09/2023	Vigente	FACEBOOK	SI	FFVV_PROV	SUR	PUERTO MALDONADO	EDUCACIÓN	SI	16,099
3321	25/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	NORTE	PIURA	EDUCACIÓN	SI	45,937
3322	25/09/2023	Vigente	FACEBOOK	SI	FFVV_LIMA	LIMA	LIMA	ONP	SI	6,700
3323	25/09/2023	Vigente	FACEBOOK	SI	FFVV_LIMA	LIMA	LIMA	UNIVERSIDAD	SI	1,000
3324	25/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	EDUCACIÓN	SI	4,600
3325	25/09/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	ABANCAY	OTROS	NO	0.00
3326	26/09/2023	Vigente	FACEBOOK	SI	FFVV_PROV	CENTRO	JUNIN	PNP	SI	2,768
3327	26/09/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	OTROS	NO	0.00
3328	26/09/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	SUR	AREQUIPA	OTROS	NO	0.00
3329	26/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	ESSALUD	SI	9,640
3330	26/09/2023	Vigente	FACEBOOK	SI	FFVV_LIMA	LIMA	LIMA	ONP	SI	2,700
3331	26/09/2023	Bloqueada	PAGINA WEB	NO	FFVV_PROV	NORTE	TALARA	OTROS	NO	0.00
3332	26/09/2023	Bloqueada	PAGINA WEB	NO	FFVV_PROV	SUR	PISCO	OTROS	NO	0.00
3333	26/09/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	JAEN	OTROS	NO	0.00
3334	26/09/2023	Vigente	WHATSAPP	SI	FFVV_PROV	NORTE	JAEN	EDUCACIÓN	SI	5,650
3335	26/09/2023	No vigente	PAGINA WEB	NO	FFVV_PROV	SUR	JULIACA	OTROS	NO	0.00
3336	26/09/2023	Bloqueada	PAGINA WEB	NO	FFVV_PROV	CENTRO	HUANUCO	OTROS	NO	0.00
3337	26/09/2023	Vigente	PAGINA WEB	SI	FFVV_PROV	CENTRO	CHIMBOTE	PNP	SI	2,580
3338	26/09/2023	Vigente	PAGINA WEB	NO	FFVV_PROV	NORTE	PIURA	OTROS	NO	0.00
3339	26/09/2023	Vigente	FACEBOOK	SI	FFVV_PROV	SUR	JULIACA	ONP	SI	6,740
3340	26/09/2023	Vigente	PAGINA WEB	SI	FFVV_LIMA	LIMA	LIMA	EDUCACIÓN	SI	2,270
3341	26/09/2023	Vigente	PAGINA WEB	NO	FFVV_LIMA	LIMA	LIMA	OTROS	NO	0.00
3342	27/09/2023	Vigente	SMS	SI	FFVV_PROV	NORTE	CAJAMARCA	ESSALUD	SI	4,145
3343	27/09/2023	Vigente	SMS	SI	FFVV_PROV	CENTRO	IQUITOS	ESSALUD	SI	5,867

Fuente: Elaboración Propia

## Anexo 4: Declaración Jurada de autenticidad de datos



**UNIVERSIDAD NACIONAL DEL CALLAO**  
FACULTAD DE INGENIERÍA INDUSTRIAL Y DE SISTEMAS



### DECLARACIÓN JURADA DE AUTENTICIDAD DE LA BASE DE DATOS

Yo, **ANA MARLENE ORIHUELA RAMIREZ**, egresada de la Escuela Profesional de **INGENIERÍA DE SISTEMAS**, identificada con DNI N° **70001369**.

Yo, **LESLIE FRIDA PEREZ RAMOS**, egresada de la Escuela Profesional de **INGENIERÍA DE SISTEMAS** identificada con DNI N° **74541358**.

Yo, **XIMENA PIERINA OMAIRA VICUÑA PEÑA**, egresada de la Escuela Profesional de **INGENIERÍA DE SISTEMAS**, identificada con DNI N° **74240141**.

Declaramos bajo el juramento lo siguiente:

Declaramos que la base de datos utilizada en el presente proyecto de tesis titulado **“APLICACIÓN DE UN MODELO DE MACHINE LEARNING EN LAS VENTAS DIGITALES EN EL ÁREA DE CONVENIOS DE UNA ENTIDAD FINANCIERA DEL PERÚ, 2023”** son verídicos y han sido obtenidos de fuentes confiables y pertinentes al tema de investigación.

Confirmamos que no hemos alterado de manera fraudulenta los datos incluidos en la base de datos con el propósito de manipular los resultados de la investigación.

Asumimos la responsabilidad total de la integridad de la base de datos y estamos dispuestas a proporcionar cualquier información adicional o aclaración que pueda ser requerida por los evaluadores de la tesis.

Comprendemos las implicancias académicas y legales de presentar información falsa o fraudulentamente modificada en este proyecto de tesis y aceptamos las consecuencias correspondientes en caso de incumplimiento.

Bellavista, 13 de diciembre de 2023

  
\_\_\_\_\_  
Ana Marlene Orihuela Ramirez

  
\_\_\_\_\_  
Leslie Frida Perez Ramos

  
\_\_\_\_\_  
Ximena Pierina O. Vicuña Peña