



**FACULTAD DE POSTGRADO
TRABAJO FINAL DE GRADUACIÓN**

**MEDICIÓN DE LA EFECTIVIDAD DE PROMOCIONES
COMERCIALES DE PAQUETES DE DATOS MEDIANTE
ANALÍTICA DE DATOS**

SUSTENTADO POR:

CRISTIAN ANTONIO ESPINOZA BANEGAS

PREVIA INVESTIDURA AL TÍTULO DE

**MÁSTER EN
ANALÍTICA DE NEGOCIOS**

TEGUCIGALPA, FRANCISCO MORAZAN, HONDURAS, C.A.

ENERO, 2026

**UNIVERSIDAD TECNOLÓGICA CENTROAMERICANA
UNITEC**

FACULTAD DE POSTGRADO

AUTORIDADES UNIVERSITARIAS

RECTORA

ROSALPINA RODRÍGUEZ

VICERRECTOR ACADÉMICO NACIONAL

JAVIER ABRAHAM SALGADO LEZAMA

SECRETARIO GENERAL

ROGER MARTÍNEZ MIRALDA

DECANA FACULTAD DE POSTGRADO

ANA DEL CARMEN RETTALLY VARGAS

**MEDICIÓN DE LA EFECTIVIDAD DE PROMOCIONES
COMERCIALES DE PAQUETES DE DATOS MEDIANTE
ANALÍTICA DE DATOS**

**TRABAJO PRESENTADO EN CUMPLIMIENTO DE LOS
REQUISITOS EXIGIDOS PARA OPTAR AL TÍTULO DE
MÁSTER EN**

ANALITICA DE NEGOCIOS

ASESOR

HENRY ANTONIO OSORIO

MIEMBROS DE LA TERNA:

**KEVIN EDUARDO FUNEZ
ANGELA PAOLA MARTINEZ
DAVID ANTONIO MEJIA**

DERECHOS DE AUTOR

© Copyright 2025
Cristian Antonio Espinoza Banegas

Todos los derechos son reservados.



FACULTAD DE POSTGRADO

MEDICIÓN DE LA EFECTIVIDAD DE PROMOCIONES COMERCIALES DE PAQUETES DE DATOS MEDIANTE ANALÍTICA DE DATOS

**Cristian Antonio Espinoza
Banegas**

Resumen

Esta investigación tuvo como objetivo desarrollar un modelo analítico capaz de identificar los factores que influyen en el éxito de las promociones de una empresa de telecomunicaciones en Honduras, así como dar seguimiento al comportamiento de las promociones durante su vigencia diaria y realizar un análisis histórico que permita estudiar los resultados y la evolución de las promociones y de las entidades involucradas. El estudio incluyó procesos rigurosos de análisis y procesamiento de datos, que abarcaron la limpieza, transformación y preparación de la información relevante de las promociones. Posteriormente, se aplicaron algoritmos de aprendizaje para evaluar los resultados a partir de diversos indicadores de desempeño y efectividad de las promociones. Finalmente, se implementaron herramientas de seguimiento que permiten a la empresa monitorear el comportamiento de sus campañas, optimizar estrategias comerciales, mejorar la asignación de recursos y maximizar la efectividad de las acciones de comunicación, contribuyendo así al crecimiento del producto, del negocio y de la empresa en general.

Palabras claves: (análisis, comportamientos, modelo, promociones, recursos)



GRADUATE SCHOOL

MEDICIÓN DE LA EFECTIVIDAD DE PROMOCIONES COMERCIALES DE PAQUETES DE DATOS MEDIANTE ANALÍTICA DE DATOS

**Cristian Antonio Espinoza
Banegas**

Abstract

This study aimed to develop an analytical model to identify the factors influencing the success of promotions in a telecommunications company in Honduras, as well as to monitor the daily behavior of promotions and conduct a historical analysis to examine the outcomes and evolution of the campaigns and the entities involved. The research involved comprehensive data analysis and processing, including cleaning, transformation, and preparation of relevant promotional information. Subsequently, learning algorithms were applied to evaluate results based on various performance and effectiveness indicators. Finally, tracking tools were implemented to enable the company to monitor promotional behavior, optimize commercial strategies, improve resource allocation, and maximize the effectiveness of communication campaigns, ultimately contributing to product growth, business development, and overall organizational performance.

Keywords: (model, promotions, analysis, behavior, resources, performance)

DEDICATORIA

Este proyecto de graduación es el resultado de esfuerzos, y lo dedico a: A mi padre Camilo A. Espinoza que, con su humildad, esfuerzo y perseverancia, me animó a través de su ejemplo de dedicación a los estudios sin importar el tiempo o situación que nos encontremos. Se enfrentó prematuramente a su muerte, pero dejando en mi un sueño que me mantuvo fuerte cuando quise rendirme en mi meta.

A mi madre Dinora Banegas que, con su amor, paciencia, sacrificios y muchos esfuerzos me han permitido ser la persona que soy hoy y que gracias a su inspiración y ejemplos me han permitido cumplir un sueño más y para ellos hacerlos sentir orgullosos como padres.

A mi esposa Jacquelin Colindres, mi hijo Andrés O. Espinoza, a mi hija Antonella E. Espinoza, quienes me han apoyado en este camino, he recibido amor y el apoyo incondicional. Su comprensión para aquellos momentos donde el tiempo dedicado a mi carrera eran para ellos y nuestra familia.

AGRADECIMIENTO

Agradezco primeramente a Dios, que ha sido por su gracia y misericordia que me ha permitido llegar hasta este día, dándome las fortalezas y bendiciones para seguir adelante a pesar de las adversidades que surgieron en este largo camino.

A la empresa para la cual laboro, la cual me ha dado la confianza y oportunidad de demostrar mis capacidades a diario y darme las facilidades para seguir mis estudios universitarios.

A mi amigo Jorge A. Fonseca, quien me ha brindado todo el apoyo que he requerido para culminar mi carrera universitaria, siendo en los momentos donde requerimos de apoyo y fortalezas recibí una frase de motivación y de ánimos a continuar con el objetivo establecido.

ÍNDICE DE CONTENIDO

DEDICATORIA	ix
AGRADECIMIENTO	x
ÍNDICE DE CONTENIDO	xi
INDICE DE ILUSTRACIONES	xvi
INDICE DE TABLA	1
CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN	1
1.1 INTRODUCCIÓN	1
1.2 ANTECEDENTES DEL PROBLEMA	2
1.3 DEFINICIÓN DEL PROBLEMA	3
1.4 OBJETIVOS DEL PROYECTO	4
1.4.1 OBJETIVO PRINCIPAL	4
1.4.2 OBJETIVOS ESPECIFICOS	4
1.5 JUSTIFICACIÓN.....	5
CAPÍTULO II. MARCO TEÓRICO	6
2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL	6
2.2 CONCEPTUALIZACIÓN.....	7
2.2.1 ANALISIS EDA	7
2.2.2 CLASIFICACIÓN DE CLIENTES	7
2.2.3 CLASIFICACIONES COMMUNES DE CLIENTES	8
2.2.4 CLUSTERING.....	9
2.2.5 K-MEANS	9
2.2.5.1 CÓMO SE APLICA A NIVEL EMPRESARIAL	9
2.2.6 ALGORITMOS DE CLASIFICACIÓN.....	10
2.2.6.1 TIPOS DE ALGORITMOS DE CLASIFICACIÓN	11
2.2.7 KNIME	12
2.2.8 EL CLIENTE	13
2.2.9 ALIADOS ESTRATÉGICOS	15
2.2.10 CICLO DE VIDA SIM PREPAGO	16
2.2.10.1 ANALISIS DE COMPORTAMIENTO DE CLIENTE EN SU CICLO DE VIDA	

2.3	TEORÍAS DE SUSTENTO.....	18
2.3.1	BASES TEÓRICAS.....	18
2.3.1.1	SEGMENTACIÓN DE CLIENTES MEDIANTE TEORIA DE AFINIDAD.....	19
2.3.1.2	TEORIA DEL CONSUMIDOR.....	19
2.3.1.3	TEORÍA DE LA RETENCIÓN DE CLIENTES.....	19
2.3.1.4	CUSTOMER RETENTION.....	20
2.3.1.5	¿CÓMO MEDIR EL DESEMPEÑO DE LAS PROMOCIONES?.....	20
2.3.2	MÉTRICAS CLAVE PARA EVALUAR EL DESEMPEÑO DE PROMOCIONES .	22
2.3.3	ELEMENTOS CLAVE DE UNA PROMOCIÓN DE VENTAS EXITOSA.....	23
2.3.4	MACHINE LEARNING.....	25
2.3.4.1	ALGORITMO DE MACHINE LEARNING.....	26
2.3.4.2	MODELOS DE APRENDIZAJE SUPERVISADO.....	26
2.3.4.3	MODELOS DE APRENDIZAJE NO SUPERVISADO:.....	28
2.3.5	FUNDAMENTACIÓN TEÓRICA.....	29
2.3.5.1	VARIABLES CONSIDERADAS.....	29
2.3.5.2	METODOLOGÍA PROPUESTA.....	30
2.3.5.3	APLICACIÓN PRÁCTICA HIPOTÉTICA.....	31
2.4	INSTRUMENTOS UTILIZADOS.....	33
2.5	MARCO LEGAL.....	34
2.5.1	LEY DE PROTECCIÓN AL CONSUMIDOR (DECRETO 24-2008).....	34
2.5.1.1	ARTÍCULO 22 DEBER DE PROPORCIONAR INFORMACIÓN CLARA, VERAZ Y SUFICIENTE.....	34
2.5.1.2	ARTÍCULO 27 PROHIBICIÓN DE PUBLICIDAD ENGAÑOSA EN PROMOCIONES.....	34
2.5.1.3	ARTÍCULO 28 REQUISITOS DE OFERTAS Y PROMOCIONES DIRIGIDAS A CONSUMIDORES.....	35
2.5.1.4	ARTÍCULO 30 PUBLICIDAD Y CONDICIONES PROMOCIONALES QUE OBLIGAN AL PROVEEDOR.....	35
2.5.2	LEY PARA LA DEFENSA Y PROMOCIÓN DE LA COMPETENCIA (DECRETO 357-2005).....	35
2.5.2.1	ARTICULO 3 DE CONFORMIDAD CON LA LEY, LA COMISIÓN TIENE LAS	

SIGUIENTES FUNCIONES Y ATRIBUCIONES	36
2.5.2.2 ARTÍCULO 4 CRITERIOS PARA LA VALORACIÓN DE PRÁCTICAS PROHIBIDAS POR SU NATURALEZA	36
2.5.2.3 ARTÍCULO 5 CRITERIOS PARA VALORAR PRÁCTICAS RESTRICTIVAS POR SU EFECTO.....	36
2.5.2.4 ARTÍCULO 6 DE CONFORMIDAD CON EL ARTÍCULO 9 DE LA LEY	36
2.5.3 REGLAMENTO DEL SECTOR TELECOMUNICACIONES / NORMATIVA DE SERVICIOS PÚBLICOS.....	36
2.5.3.1 ARTÍCULO 6, LITERAL F PRINCIPIO DE PREVALENCIA DEL USUARIO ..	37
2.5.3.2 ARTÍCULO 211, COMPETENCIA DE SERVICIOS.....	37
CAPÍTULO III. METODOLOGÍA	38
3.1 CONGRUENCIA METODOLÓGICA	38
3.1.1 MATRIZ METODOLÓGICA	39
3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO.....	41
3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES.....	43
3.2 ENFOQUE Y MÉTODOS.....	45
3.3 ENFOQUE.....	45
3.3.1 ALCANCE.....	46
3.3.2 DISEÑO.....	46
3.3.3 MÉTODOS	46
3.3.4 INSTRUMENTOS.....	47
3.4 DISEÑO DE LA INVESTIGACIÓN	47
3.4.1 POBLACIÓN.....	47
3.5 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS	48
3.5.1 TECNICAS	48
3.5.2 INSTRUMENTOS.....	49
3.5.3 PROCEDIMIENTOS.....	49
3.6 FUENTES DE INFORMACIÓN	50
3.6.1 FUENTES PRIMARIAS	50
3.6.2 FUENTES SECUNDARIAS	50
3.7 CRITERIOS DE EXCLUSION DE VARIABLES	50

CAPÍTULO IV. RESULTADOS Y ANÁLISIS	52
4.1 INFORME DE PROCESO DE RECOLECCIÓN DE DATOS	52
4.2 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS.....	52
4.2.1 DESCRIPCIÓN GENERAL DE LA MUESTRA	53
4.2.2 RESULTADOS CUANTITATIVOS	54
4.2.2.1 LÍNEA TEMPORAL	54
4.2.2.1.1 DISTRIBUCION ANUAL	54
4.2.2.1.2 DISTRIBUCION MENSUAL	55
4.2.2.2 DISTRIBUCIÓN POR DÍA DE LA SEMANA	56
4.2.2.3 DISTRIBUCIONES.....	57
4.2.2.4 CRUCES DE VARIABLES	63
4.2.3 ANÁLISIS CUALITATIVO	64
4.3 ANÁLISIS INFERENCIAL Y MODELOS APLICADOS	65
CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES.....	67
5.1 CONCLUSIONES	67
5.2 RECOMENDACIONES.....	68
CAPÍTULO VI. APLICABILIDAD.....	70
6.1 NOMBRE DE LA PROPUESTA.....	70
6.2 JUSTIFICACIÓN DE LA PROPUESTA.....	70
6.3 ALCANCE DE LA PROPUESTA	70
6.4 DESCRIPCIÓN Y DESARROLLO.....	71
6.4.1 DESCRIPCIÓN	71
6.4.2 DESARROLLO	71
6.4.2.1 RECURSO HUMANO REQUERIDO	72
6.4.2.2 FASES DE DESARROLLO.....	73
6.4.2.2.1 MODELO DE PREDICCIÓN KNIME	73
6.4.2.3 CONSTRUCCIÓN DEL MODELO.....	74
6.4.2.4 MODELO Y ALGORITMOS	74
6.4.2.5 RESULTADOS DE LOS ALGORITMOS DE PREDICCIÓN	75
6.4.2.6 TABLERO INTERACTIVO POWER BI	77
6.4.2.6.1 PASOS	77

6.4.2.6.2	DESARROLLO DE TABLERO INTERACTIVO	78
6.4.2.7	CAPACITACION.....	78
6.5	MEDIDAS DE CONTROL	79
6.5.1	INDICADORES Y MEDIACIÓN.....	79
6.5.2	MODELO PREDICTIVO.....	79
6.5.3	TABLERO INTERACTIVO	81
6.5.4	ANÁLISIS DE RENTABILIDAD DE LAS PROMOCIONES.....	82
6.6	CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO.....	83
6.6.1	CRONOGRAMA.....	84
6.6.2	PRESUPUESTO.....	86
6.6.2.1	RECURSOS DE HARDWARE	86
6.6.2.2	RECURSOS DE SOFTWARE.....	86
6.6.2.3	RECURSO HUMANO	86
6.6.2.4	RESUMEN	86
6.7	CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA	
	87	
	REFERENCIAS BIBLIOGRÁFICAS.....	90
	ANEXOS	95

INDICE DE ILUSTRACIONES

Ilustración 1 - Cuota de Mercado con base en ingresos y Umbral Melnik, Shy y Stenbacka	7
Ilustración 2 - Distancia euclidiana.....	9
Ilustración 3 - Ejemplo K-Means segmentación.....	10
Ilustración 4 - Estructura Comercial Masivo	14
Ilustración 6 - Ciclo de vida de numero Prepago.....	17
Ilustración 10 – Diagrama Enfoque y Métodos	45
Ilustración 11 – Machine Learning Ciclo de Vida.....	48
Ilustración 14 - Promociones año 2022 al 2025.....	54
Ilustración 15 - Comportamiento mensual de promociones	55
Ilustración 16 - Días de Promociones	56
Ilustración 17 – Promociones por Paquetes, año 2025	56
Ilustración 18 - Distribución de éxito de las promociones	57
Ilustración 19 – Formula del cálculo de incremento de ventas.....	58
Ilustración 20 - Promociones por canales de ventas, año 2025.	59
Ilustración 21 – Comparativo mensual de transacciones promedios con promociones y sin promociones en los últimos 61 días antes de las promociones.....	60
Ilustración 22 - Comparativo mensual de transacciones promedios con promociones y sin promociones en los últimos 61 días antes de las promociones, excluyendo promociones sin transacciones.....	61
Ilustración 23 - Comportamiento de las transacciones y líneas base.....	62
Ilustración 24 -Resultado mensuales de promociones	62
Ilustración 25 – Relación de las variables: cantidad de promociones, exitosas y día semana.....	63
Ilustración 26 - Modelo de Entrenamiento de algoritmos	75
Ilustración 27 - Matriz de Confusión Arboles de Decisión.....	75
Ilustración 28 - Matriz de Confusión Logistic Regression	76
Ilustración 29 - Matriz de Confusión Random Forest.....	76
Ilustración 30 - Matriz de Confusión Gradient Boosted	77
Ilustración 31 - Resumen General de resultados en entrenamiento de algoritmos	¡Error!
Marcador no definido.	
Ilustración 32 - Cronograma de actividades Semana 1 a 5.....	84

Ilustración 33 - Cronograma de actividades Semana 6 a 10..... 85

INDICE DE TABLA

Tabla 1 – Aliados Estratégicos	16
Tabla 2 - Canales de ventas recargas y paquetes	16
Tabla 3 - Matriz Metodológica	39
Tabla 4 - Esquema de variables de estudio	41
Tabla 5 - Matriz de operacionalización de variables	43
Tabla 6 - Variables de la tabla final de promociones.....	50
Tabla 7 - Estadísticas descriptivas de variables numéricas	53
Tabla 8 - Análisis de Rentabilidad Promociones 2025	82
Tabla 9 – Matriz de Concordancia.....	87
Tabla 10 - Matriz de Concordancia (continuación)	88
Tabla 11 - Matriz de Concordancia (continuación)	89

CAPÍTULO I. PLANTEAMIENTO DE LA INVESTIGACIÓN

1.1 INTRODUCCIÓN

En un mercado altamente competitivo como el de las telecomunicaciones en Honduras, donde únicamente dos empresas tienen la cobertura prácticamente del 100% de la telefonía móvil (Conatel, Informe anual 2022, s. f.), específicamente del mercado Prepago, esta compañía cuya casa matriz y corporativo está en México y de la cual estaremos conversando en el presente, la tasa de abandono de clientes y el efecto que tiene con las promociones asignadas para fidelización y retención se ha convertido en un objetivo clave para las empresas del sector. También conocida como “churn” es la relación entre el número de clientes que ya no usan un servicio y el número total de sus clientes (Dahiya & Bhatia, 2015). En los servicios de telefonía móvil prepago representa un problema crítico, dado que los usuarios pueden cambiar de operador con facilidad y sin restricciones contractuales, ya sea comprando una nueva SIM en el mercado, dejando de usar el servicio o realizando la portabilidad numérica de una compañía a otra. La pérdida de clientes no solo impacta los ingresos de la empresa, también en sus indicadores de participación de mercado, parque comercial, así como los indicadores financieros, sino que también implica costos adicionales asociados con la adquisición de nuevos usuarios y la implementación de estrategias de fidelización (Churn y cómo afecta a tu negocio., s. f.).

El propósito de la presente es analizar el impacto y la efectividad de las promociones de paquetes de datos, con el fin de establecer un modelo de referencia que permita determinar los días óptimos para lanzar campañas, estimar su impacto económico y evaluar el riesgo de fallar en su aplicación, tanto comercial, financiero y operativo. Para ello, se emplearán técnicas de analítica de negocios que integren información de ventas, comportamiento del cliente y variables temporales, con el objetivo de convertir los datos en conocimiento estratégico para la gestión comercial.

El reto principal para las empresas del sector radica en determinar cuáles promociones son realmente efectivas, en qué momentos es más conveniente aplicarlas y qué impacto económico generan en relación con la inversión realizada. Factores como la estacionalidad, factores sociales como climatológicos, los hábitos de recarga, las campañas de la competencia y la sensibilidad al precio influyen significativamente en la efectividad de las promociones. Una mala planificación puede conducir a una erosión del margen de ganancia del producto comercializado, canibalización de ingresos o una baja en el valor de vida del cliente.

Los modelos predictivos basados en inteligencia artificial, específicamente los modelos de probabilidad (admin, 2024) permiten predecir la probabilidad de que un cliente compre o no una promoción, este resultado nos podría permitir diseñar estrategias basadas en una probabilidad para mejorar programación de promociones, en canales de ventas, que clientes, el producto, para incrementar las ventas y a la vez disminuir la baja de clientes y mejorar la rentabilidad de la empresa. Asimismo, se analizará los costos asociados al tiempo y dinero invertido en cada promoción para establecer una relación costo / riesgo beneficio.

La investigación contribuirá a la toma de decisiones basada en datos y al desarrollo de acciones concretas para mejorar la sostenibilidad del negocio en el mercado de las telecomunicaciones y sobre todo aprovechar al máximo el Machine Learnig para tomar decisiones basadas en datos.

1.2 ANTECEDENTES DEL PROBLEMA

Esta empresa de telecomunicaciones, opera bajo el corporativo, y es propiedad del grupo mexicano. La empresa ofrece los servicios de telefonía móvil en la modalidad de Prepago y Pospago, también servicios de Internet, televisión y telefonía residencial como corporativa (empresas).

La participación de mercado en el segundo trimestre del 2023 era de un 33.88% en el mercado móvil (Luis Rodríguez, s. f.). Siendo su mercado más grande el segmento Prepago. Según datos oficiales de la comisión nacional de telecomunicaciones del año 2023, el 89.55% (7.1 Millones) de los móviles operan con la modalidad de Prepago (Conatel, Informe anual 2022, s. f.), representando económicamente la principal fuente de ingresos para las compañías y en esta no es la excepción.

La pérdida de estos clientes representa un impacto directo en los ingresos, gasto en recursos y esfuerzos humanos, sino también un aumento en costos operativos al intentar atraer nuevos usuarios (Churn y cómo afecta a tu negocio., s. f.). En el segmento de telefonía móvil prepago, este comportamiento es aún más complejo debido a la falta de un contrato que garantice un periodo de servicios y renta fija como lo son el mercado móvil pospago y de internet residencial o corporativo, lo que facilita la migración entre operadores en función de promociones, calidad del servicio, cobertura de red, conveniencia personal o simplemente es una venta que no generar ningún ingreso a la empresa.

En un análisis realizado en el último trimestre del año 2024 por el área comercial prepago en conjunto con el equipo de retenciones y fidelizaciones, se encontró que el 58% de las ventas que se realizan al mes se convierten en bajas en los próximos 180 días, 32% permanecen realizando consumo recurrente mes a mes generando valor a la empresa, y el restante 10% son clientes intermitentes en la generación de valor, es decir que su comportamiento de consumo es irregular mes a mes.

En este ámbito, es de suma importancia las razones detrás del abandono de clientes en telefonía prepago. Es muy importante para desarrollar estrategias de captación de clientes que generen valor a la empresa, incluyendo estrategias de fidelización efectivas y mejorar la retención de usuarios.

Este entorno ha obligado a las empresas del sector a desarrollar estrategias comerciales cada vez más innovadoras para atraer y retener a sus clientes. Una de las tácticas más utilizadas son las promociones de paquetes de datos y los multiplicadores de saldo, las cuales buscan incentivar las recargas, aumentar el consumo de datos móviles y fortalecer la lealtad de los usuarios (Wassouf, Alkhatib, Salloum, & Balloul, 2020).

Retener a un cliente es significativamente más rentable que adquirir uno nuevo, el costo es de 6 o 7 veces más que la retención (Retención y adquisición nuevos clientes., s. f.). En el ámbito nacional, las empresas de telecomunicaciones han replicado estas estrategias con relativo de éxito, pero aún no ha sido suficiente para bajar el churn de los clientes prepagos. La oferta de paquetes de datos con volumen de GB adicionales o con más duración y promociones que multiplican el saldo de recarga es una práctica recurrente que busca estimular el consumo y las recargas diarias o semanales (Ibe & Chibunma, 2023). Sin embargo, la mayoría de las decisiones respecto al diseño y calendario de estas promociones se basan en la experiencia de los equipos de marketing o en resultados históricos simples, sin un soporte robusto de analítica de negocios que permita identificar los patrones de comportamiento del consumidor y los días de mayor efectividad comercial (Aydın-Gökgöz et al., 2022).

1.3 DEFINICIÓN DEL PROBLEMA

El uso de promociones comerciales en el sector de las telecomunicaciones constituye una herramienta clave para incentivar el consumo y aumentar la participación de mercado. Sin embargo, su efectividad depende de una adecuada planificación basada en datos, ya que una

estrategia mal calendarizada o sin segmentación puede generar costos innecesarios o una rentabilidad decreciente (Aydın-Gökgöz, Ataman, & van Bruggen, 2022).

La empresa implementa de manera recurrente promociones de paquetes de datos y multiplicadores de saldo, con el objetivo de estimular el consumo de saldo y el uso del servicio móvil. No obstante, los resultados de estas campañas varían significativamente: algunas logran incrementos temporales en las ventas, mientras que muchas otras no alcanzan el retorno económico esperado (Wassouf, Alkhatib, Salloum, & Balloul, 2020). Esta variabilidad se debe, en gran medida, a la falta de un modelo analítico que permita determinar qué tipo de promoción funciona mejor, en qué momento realizarla y cuál es el impacto económico real de su ejecución, agregando un factor operativo importante en los controles que rigen este tipo de estrategias.

También la ausencia de modelos de predicción y modelos de medición del impacto y retorno de la inversión en las promociones finalizadas dificulta la evaluación verdadera del aporte que esta ha realizado en la fidelización de los clientes y crecimiento del negocio.

1.4 OBJETIVOS DEL PROYECTO

1.4.1 OBJETIVO PRINCIPAL

Desarrollar un enfoque analítico que permita optimizar la planificación y evaluación de las promociones comerciales, específicamente las promociones de paquetes y multiplicadores de saldo prepago. Usando herramientas y modelos analíticos predictivos, tomando los datos históricos y operativos para convertirlos en conocimiento estratégico, para que facilite la toma de decisiones a los equipos comerciales basado en los conocimiento y evidencia cuantitativa.

El logro de los objetivos después de aplicar estos modelos analíticos le permitirá a la empresa a fidelizar clientes, retener aquellas amenazas de Churn con las promociones estratégicamente programadas y mejorar la rentabilidad económica, sin mencionar la eficiencia comercial y operativa de las y los involucrados en todo el proceso de definición, creación, configuración y evaluación de las promociones.

1.4.2 OBJETIVOS ESPECIFICOS

- I. Analizar los resultados históricos de las promociones comerciales mediante indicadores clave relacionados con ventas de recargas y paquetes, con el fin de describir su comportamiento y desempeño general.

- II. Identificar patrones y tendencias en la ejecución de promociones que sirvan como insumo para proponer lineamientos orientados a una mejor planificación y programación de futuras campañas comerciales.
- III. Describir el impacto operativo y organizacional asociado al uso de herramientas y modelos analíticos en el proceso de diseño, configuración y control de promociones, identificando oportunidades de mejora y reducción de riesgos operativos.

1.5 JUSTIFICACIÓN

En el sector de las telecomunicaciones las promociones de saldos y en los últimos años las promociones de paquetes son usadas como una herramienta estratégica para incentivar el consumo (compras) de los clientes, fidelizarlos y mantener un parque sano. Sin embargo, la falta de una planificación analítica para su programación muchas veces se cuestiona la relación entre los esfuerzos operativos de los departamentos involucrados y los resultados económicos obtenidos.

Cada día se configuran en promedio 31 promociones al día con el objetivo de incentivar la compra de recargas y paquetes, sin embargo, no en todas se obtiene los resultados esperados en relación con todo lo que conlleva el proceso de selección de fechas, creación del ticket, ocho autorizaciones, configuración, revisiones para asegurar el correcto funcionamiento, por último, el cierre. Estos procesos pueden tomar entre 5 y 15 minutos cada etapa y puede durar hasta 30 días todo su flujo.

Si una de estas etapas no se realiza en el tiempo, con los procesos y la documentación correcta, pone en riesgo la eficiencia de uno de los controles establecidos por la corporación. Si el resultado de la promoción no se obtienen los resultados esperados, tanto económicos como comercial el riesgo es demasiado alto y es cuestionable su realización.

Ante este contexto, se justifica el desarrollo de un enfoque analítico integral que permita optimizar la planificación, ejecución y evaluación de las promociones comerciales. Esto busca transformar los datos históricos y operativos de las promociones en conocimiento estratégico, guiando las decisiones del equipo comercial a partir de evidencia cuantitativa en una programación de promociones eficientes con una proyección de resultados favorables bastante alta.

CAPÍTULO II. MARCO TEÓRICO

2.1 ANÁLISIS DE LA SITUACIÓN ACTUAL

CONATEL Es un organismo estatal desconcentrado que ejecuta, mediante la regulación y coordinación, la política de Telecomunicaciones en la República de Honduras.

CONATEL fue fundada el 5 de diciembre de 1995, mediante Decreto 185/95.

Somos el ente técnico especializado del Estado de Honduras que regula los servicios en el sector de telecomunicaciones, administra el Espectro Radioeléctrico e impulsa el desarrollo de las Tecnologías de la Información y la Comunicación (TIC), fomentando la competencia leal, la inversión, garantizando la calidad de los servicios, a fin de proteger los derechos de los usuarios e impulsar la conectividad de la población en general (Institución - Conatel, s. f.).

En el análisis realizado por (*Conatel, Informe anual 2022*, s. f.) ha mostrado incremento en los usuarios de telefonía móvil un 3.7% respecto al año anterior, alcanzando un valor de 82.7%, es decir que 82 de cada 100 hondureños posee una línea telefónica móvil.


Este mismo informe establece que los abonados de prepago representan un 89.55% del total de hondureños que poseen una línea móvil.

Para el año 2023 en según lo publicado por (Luis Rodriguez, 2024) los números se redujeron, siendo los nuevos indicadores de 81% los usuarios de telefonía móvil, es decir que 81 de cada 100 hondureños posee una línea telefónica móvil. Los abonados de prepago representan un 88.53% del total de hondureños que poseen una línea móvil.

En ese mismo estudio (Luis Rodriguez, 2024) afirma que para el 2024 los números fueron menores a los últimos dos informes que presentamos antes 2023 y 2024, esto es explicado por CONATEL que, para la modalidad prepago la disminución del 2023 al 2024 fue de 146,249 abonados, esto es compensado con el incremento en la modalidad pospago que represento 51,138 abonados.

Estos números son importantes, las compañías establecen metas a sus vendedores bastante retadoras para lograr la captación de nuevos abonados e incremento de las ventas. Las empresas miden mensualmente basados en sus registros de tráfico de interconexión la participación de mercado (Conatel, 2023) el cual es utilizado para medir la posición dominante en el país.

Ilustración 1 - Cuota de Mercado con base en ingresos y Umbral Melnik, Shy y Stenbacka



Fuente: (Conatel, 2023)

2.2 CONCEPTUALIZACIÓN

2.2.1 ANALISIS EDA

El Exploratory Data Analysis (EDA) o Análisis Exploratorio de Datos, es una herramienta que se usa en el mundo de la analítica para analizar e investigar un conjunto de datos y resumir sus características principales, muy utilizado con métodos de visualización de datos (IBM, 2023).

Se utiliza principalmente para analizar que pueden revelar los datos más allá del modelado formal o la prueba de hipótesis y proporcionar una mejor comprensión de las variables del conjunto de datos y sus relacionados.

2.2.2 CLASIFICACIÓN DE CLIENTES

Clasificar a los diferentes clientes actuales y potenciales clientes es una labor necesaria para toda organización si se busca mejorar la rentabilidad. Para poder realizar dicha clasificación es necesario conocer cuáles son los criterios que se van a utilizar para clasificarlos, así como de qué manera vamos a analizarlos y evaluar si esa clasificación es la adecuada.

La clasificación de clientes permitirá segmentar y seleccionar las estrategias a aplicar, las actividades a desarrollar, y en última instancia, los esfuerzos y recursos que se dedicarán a cada tipo de cliente acorde al tipo de relación que se desee tener con cada uno. El análisis por tipo de clientes permitirá identificar los clientes de mayor proyección para el crecimiento y sostenibilidad del negocio (Lastra, 2017).

2.2.3 CLASIFICACIONES COMUNES DE CLIENTES

- 1 **Cientes actuales.** Son aquellos que te compran periódicamente, bien sean empresas o particulares. En definitiva, son aquellos que sostienen tu negocio.
- 2 **Cientes activos.** Son aquellos que hacen compras con cierta frecuencia y que lo hicieron recientemente o en un periodo de tiempo establecido por la empresa. Este periodo de tiempo dependerá del tipo de empresa o el producto.
- 3 **Cientes inactivos.** Son clientes que han realizado compras, pero fuera del periodo establecido por la empresa. Son clientes a los cuales se puede recurrir en algún momento, de cara a que vuelvan a comprarnos, previo análisis del motivo de la baja, la frecuencia de compra, etc.
- 4 **Cientes potenciales.** Son aquellos que no han realizado compras a la empresa, pero que han mostrado interés a través de la solicitud de información, petición de presupuesto, y que cuentan con capacidad de compra pudiendo convertirse en cualquier momento en generadores de ingresos para la empresa.
- 5 **Cientes probables.** Son clientes que no han comprado nunca a la empresa, y que no han manifestado interés en nosotros. Sin embargo, por sus características consideramos que podrían convertirse en generadores de ingresos a futuro.

Otra manera de clasificar a nuestros clientes sería a través de la **frecuencia de compra**. Lo ideal es determinar una frecuencia de compra promedio, y a partir de ahí clasificar a nuestros clientes:

1. **Cientes frecuentes.** Es muy importante cuidar muy especialmente a los clientes de compra frecuente y darles un trato preferencial que les haga sentirse valorados y mantener de esta forma su nivel de compras.
2. **Cientes habituales.** A estos conviene mantenerlos con un excelente nivel de satisfacción generando actividades que propicien un aumento en la frecuencia.
3. **Cientes ocasionales.** Si bien es cierto que los clientes ocasionales merecen recibir un buen servicio como todo cliente, el nivel de inversión y atención a destinar, será menor que el suministrado a los clientes más rentables para la compañía (Lastra, 2017).

2.2.4 CLUSTERING

Es un método de análisis estadístico que agrupa datos en conjuntos, o *clústeres*, basándose en la similitud entre los puntos de datos. El objetivo es organizar los datos de tal manera que los elementos dentro de un mismo grupo sean similares entre sí, mientras que los elementos de diferentes grupos sean distintos.

Es una técnica de aprendizaje no supervisado, lo que significa que los datos no están etiquetados previamente, y el algoritmo determina las agrupaciones basándose únicamente en las características de los datos. (De Arregui, 2024)

2.2.5 K-MEANS

Para nuestro estudio el tipo k-means es el más conveniente. Divide los datos en un número definido de conjuntos predeterminados. La distancia euclidiana se define como la distancia en el espacio euclidiano. Para encontrarla se debe de medir la longitud del segmento que los une (*Euclidean Distance | Formula, Derivation & Solved Examples, 2025*).

En otras palabras, el algoritmo K-means es uno de los métodos de agrupamiento más populares y simples. Divide los datos en K clúster previamente especificados y trabaja minimizando la varianza interna de cada clúster. Este método es útil en aplicaciones empresariales como la segmentación de clientes.

Según (Han, Kamber y Pei, 2011) K-means es eficaz cuando se tiene una idea aproximada del número de *clusters* que se desea obtener y es fácil de implementar en situaciones con grandes conjuntos de datos.

Ilustración 2 - Distancia euclidiana

$$d = \sqrt{\sum_{i=1}^n (b_i - a_i)^2}$$

Fuente: (DataCamp, 2024)


2.2.5.1 CÓMO SE APLICA A NIVEL EMPRESARIAL

Se puede aplicar de diversas maneras en el entorno empresarial, brindando beneficios

significativos:

- **Segmentación de clientes:** Los algoritmos de agrupamiento de datos permiten agrupar clientes según su comportamiento o características demográficas, facilitando la creación de campañas de marketing personalizadas y estrategias de precios específicas para cada segmento.
- **Análisis de mercado:** Al identificar *clúster* en los datos del mercado, las empresas pueden detectar nichos de mercado o tendencias emergentes, permitiéndoles innovar y adaptar sus productos y servicios.
- **Detección de fraudes:** Al analizar transacciones y otros datos financieros, el agrupamiento de datos puede ayudar a identificar patrones sospechosos y a prevenir actividades fraudulentas.
- **Optimización de la cadena de suministro:** También puede ayudar a agrupar ubicaciones de entrega o proveedores similares, optimizando así las rutas de distribución y los procesos logísticos.
- **Investigación y desarrollo de productos:** Al agrupar datos de clientes, las empresas pueden identificar preferencias específicas y tendencias de consumo, guiando así la investigación y el desarrollo de productos hacia soluciones más alineadas con las necesidades del mercado.

Ilustración 3 - Ejemplo K-Means segmentación



Fuente: (Richaud, 2024)

2.2.6 ALGORITMOS DE CLASIFICACIÓN

Los algoritmos de clasificación son un conjunto de técnicas utilizadas en el aprendizaje

automático que se enfocan en clasificar objetos en diferentes categorías. Estos algoritmos son ampliamente utilizados en diversas áreas, como la industria, la investigación y la academia. En este artículo, exploraremos los diferentes tipos de algoritmos de clasificación y cómo se utilizan en el mundo real (Ceupe, 2023).

Estos algoritmos se pueden aplicar en diferentes campos, uno de esos campos que es de nuestro interés para su aplicación es detectar posibles fraudes. Asignando una categoría a un cliente basado en un comportamiento de sus eventos como del origen de la venta de su servicio.

2.2.6.1 TIPOS DE ALGORITMOS DE CLASIFICACIÓN

(Ceupe, 2023) nos detalla varios tipos de algoritmos de clasificación, cada uno con sus propias fortalezas y debilidades. A continuación, describimos algunos de los algoritmos de clasificación más comunes:

1. **Árboles de decisión:** los árboles de decisión son una técnica de aprendizaje automático supervisado que se utiliza para la clasificación y la predicción. En los árboles de decisión, se construye un modelo que divide los datos en diferentes ramas, cada una representando una categoría o un resultado. Estos modelos son especialmente útiles para problemas con múltiples variables y resultados posibles.
2. **Regresión logística:** la regresión logística es un algoritmo de clasificación binaria que se utiliza para predecir la probabilidad de un resultado. Se utiliza para problemas en los que la respuesta es "sí" o "no", "verdadero" o "falso", "1" o "0". La regresión logística se utiliza a menudo en la investigación médica y de la salud para predecir los resultados de diferentes tratamientos.
3. **Máquinas de vectores de soporte (SVM):** las SVM son una técnica de aprendizaje automático supervisado que se utiliza para la clasificación y la regresión. En las SVM, se construye un modelo que separa los datos en diferentes clases utilizando un hiperplano. Estos modelos son especialmente útiles para problemas con datos no lineales.
4. **K-Vecinos más cercanos (K-NN):** K-NN es un algoritmo de clasificación basado en la similitud. En K-NN, los datos se clasifican según la similitud entre los puntos de datos. El modelo utiliza los "k" puntos de datos más cercanos para clasificar un nuevo punto de datos.

5. **Redes neuronales:** las redes neuronales son un tipo de algoritmo de aprendizaje profundo que se utiliza para la clasificación, la regresión y la identificación de patrones. En las redes neuronales, se construyen modelos basados en la estructura y la función de las redes neuronales en el cerebro. Estos modelos son especialmente útiles para problemas con datos no lineales y patrones complejos.

Elegir el algoritmo de clasificación correcto para un problema en puede ser un desafío. Hay muchos factores a considerar, como la complejidad del problema, la naturaleza de los datos y los requisitos de precisión.

2.2.7 KNIME

KNIME es una plataforma integral para la ciencia de datos. Además de crear flujos de trabajo, los equipos comerciales utilizan KNIME para garantizar la seguridad de los datos confidenciales, la validación y monitorización de los análisis y modelos de IA, y la verificación y explicación de los resultados (KNIME, 2025).

KNIME (Konstanz Information Miner), es una plataforma de análisis de datos que le permite realizar estadísticas sofisticadas y Minería de Datos en sus datos para analizar las tendencias y predecir resultados potenciales. Su banco de trabajo visual combina acceso de datos, transformación de datos, la investigación inicial, potentes análisis predictivo y la visualización. Knime también proporciona la capacidad de desarrollar informes basados en su información o automatizar la aplicación de una nueva visión en los sistemas de producción. KNIME es de código abierto y disponible bajo licencia (GPL) [53] (*Chamba Jiménez, s. f.*).

Además, Knime ofrece opciones para crear informes personalizados basados en los datos analizados o para automatizar la integración de nuevos conocimientos en sistemas de producción existentes. KNIME es una herramienta de código abierto y se distribuye bajo una licencia específica.

KNIME, construido sobre la plataforma Eclipse y programado principalmente en Java, se caracteriza por ser una herramienta gráfica. Utiliza nodos, que encapsulan diversos algoritmos, y flechas, que simbolizan los flujos de datos, para crear y combinar procesos de manera visual e interactiva (KNIME, 2025).

Estos nodos permiten realizar varias operaciones en tablas de datos, incluyendo: Manipulación de filas y columnas, como selección de muestras, transformaciones y agrupaciones, visualización mediante gráficos como histogramas., desarrollo de modelos estadísticos y de minería de datos, incluyendo árboles de decisión, máquinas de vector soporte y regresiones.

La naturaleza abierta de KNIME permite su ampliación mediante la creación de nuevos nodos con algoritmos personalizados. También ofrece la posibilidad de integrar de forma directa y transparente herramientas como Weka, o incorporar código de R o Python/Jython (KNIME, 2025).

KNIME combina varios componentes para el aprendizaje automático y la minería de datos mediante un enfoque modular de canalización de datos (data pipelining). Su interfaz gráfica facilita la configuración rápida de nodos para el preprocesamiento de datos (ETL: extracción, transformación, carga), análisis de datos, modelado y visualización. Desde 2006, KNIME se ha utilizado en la investigación farmacéutica, pero también encuentra aplicación en otros campos como el análisis de datos de clientes en CRM, inteligencia empresarial y análisis de datos financieros (KNIME, 2025).

2.2.8 EL CLIENTE

Una empresa sin clientes no puede generar utilidades, pero ¿Quién es mi cliente? Podríamos que mencionar que un cliente es aquel que compra un servicio o producto, pero no siempre puede ser así. En todo tipo de negocios, existe un cliente que recibe los beneficios del producto y/o servicio, es decir, siempre habrá un consumidor final para todos los productos y/o servicios que se ofrecen en el mercado. Este concepto es cierto para cualquier empresa, sea ésta de servicios, de productos, comercial, etcétera. Existen empresas que venden directamente al consumidor final; en este caso, el consumidor final es el cliente del negocio. Por otro lado, existen empresas que no venden directamente al consumidor final, sino que forman parte de una cadena de distribución; en este caso, el cliente del negocio es, por ejemplo, el contratista, el distribuidor, etc. El hecho de encontrarse lejos del consumidor final ocasiona que, a veces, las empresas dediquen todo su esfuerzo para satisfacer a su cliente inmediato, sin estudiar a quienes serán los consumidores finales de sus productos (Fundamentos de Negocios, Nafin, 2004., s. f.).

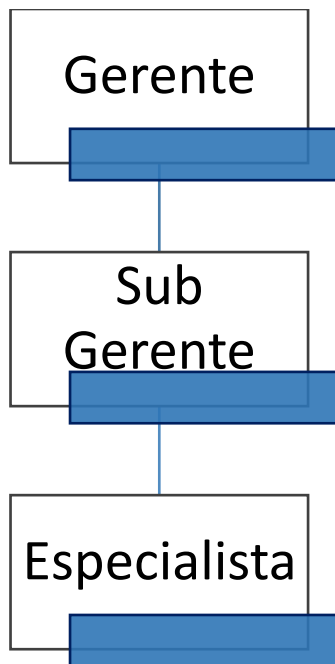
Esta empresa que hace una mezcla de ambas ventas mencionadas anteriormente, ¿Cómo? La distribución de las ventas de teléfonos, planes móviles y de internet, SIM, saldo la realiza en gran parte distribuidores (con una estructura muy grande de empleados y alcance geográfico) estratégicamente distribuidos en todo el país para lograr la mayor cobertura territorial asignada, así como otras pequeñas empresas regionales llamadas agentes autorizados que tienen la misma función que los distribuidores, pero más funciones muy específicas y con un alcance territorial limitado a su zona de geográfica donde se ubica.

La empresa tiene 35 tiendas propias (*Atención al Cliente Claro | Claro Honduras, s. f.*) que ofrece los mismos productos y servicios que los distribuidores y agentes autorizados, pero estas realizan una función adicional muy importante que es la atención al cliente, siendo el canal más importante por la relación física que existe entre la empresa y el cliente para reclamos y gestiones.

También podemos llamar al cliente como suscriptor, que según (Conatel, s. f.) se refiere a: Persona natural o jurídica que suscribe un Contrato de Prestación de Servicios, para formalizar la Relación de Consumo con un Operador y/o Proveedor y así poder recibir y gozar de uno o más Servicios Públicos de Telecomunicaciones que este ofrece y presta; por lo anterior, bajo el acuerdo o contrato suscrito, queda facultado a recibir los Servicios contratados de acuerdo a los términos y condiciones contenidas y al mismo tiempo, obligado legalmente a cumplir con los términos y pago de las facturas por los servicios consumidos y que efectivamente ha contratado y le han suministrado.

El equipo comercial forma parte fundamental, crear las estrategias, tácticas y la comunicación con los clientes, es el responsable de entender el cliente y diseñar las promociones, con el equilibrio entre el beneficio para la empresa y aliado comercial con la conveniencia para el cliente, el tiempo y la duración de la promoción. Los equipos comerciales trabajan en diferentes grupos, pero para nuestro análisis el equipo comercial prepago es el responsable de las promociones enfocadas al sector con la mayor cantidad de clientes.

Ilustración 4 - Estructura Comercial Masivo



Fuente: *Elaboración propia, 2025.*

2.2.9 ALIADOS ESTRATÉGICOS

El socio estratégico es la persona u organización que une sus fuerzas con otra para alcanzar unas metas concretas. Para ello, no solo se reparten las ganancias, sino que también comparten riesgos.

En lo relativo al trabajo, los socios estratégicos deberán trabajar de manera cooperativa. De este modo, es posible beneficiarse de la información que poseen, poner recursos en común y complementar las habilidades que poseen. Se trata, por tanto, de una relación enfocada a largo plazo (Cabia, 2022).

La empresa cuenta mensualmente con una estructura amplia de canales de ventas: tiendas, quioscos, tarimas, supermercados, agentes, personal móvil, pulperías, canales web y móvil donde es posible realizar la compra de los productos y servicios. Aliados que permiten a través de sus canales la compra de recargas y paquetes, y que mediante las promociones siempre busca generar un incentivo a los usuarios para la compra en sus canales y de la cual también la empresa se ve beneficiada.

“CONATEL” como ente regulador del sector de las telecomunicaciones, únicamente está dando cumplimiento a lo ordenado en el artículo 3 del Decreto Legislativo 71-2017, el cual

establece los requisitos mínimos de obligatorio cumplimiento para la adquisición de SIM.

Para la validación biométrica no se solicita la huella digital de las personas, solamente la validación del rostro aclara el organismo rector de las telecomunicaciones del país.

“CONATEL no interviene en el proceso de activación de SIM, ni en la validación biométrica, este proceso será realizado completamente por los operadores móviles que brindan el servicio”, asegura la institución (Redacción, 2025).

Los aliados están obligados a cumplir con ciertos requisitos establecidos por la empresa, así como requisitos obligados por la ley para la correcta identificación de los clientes a los cuales se les está realizando la venta del servicio, independientemente del canal usado por la venta.

Tabla 1 – Aliados Estratégicos

<i>Aliado</i>	<i>Cantidad</i>
<i>Distribuidor</i>	2,823
<i>Bancos</i>	13
<i>Cooperativas</i>	3
<i>Entidades Extranjeras</i>	4
<i>Supermercados y Farmacias</i>	12

Fuente: *Elaboración propia, 2025.*

Tabla 2 - Canales de ventas recargas y paquetes

<i>Canal</i>
<i>WEB</i>
<i>APP Móvil</i>
<i>USSD</i>
<i>ATM</i>
<i>Banca en Línea</i>
<i>Cajas Facturación</i>

Fuente: *Elaboración propia, 2025.*

2.2.10 CICLO DE VIDA SIM PREPAGO

El ciclo de vida de un producto es un proceso cronológico que transcurre desde su lanzamiento en el mercado hasta su desaparición. Durante este proceso se suceden diferentes etapas, que vienen principalmente condicionadas por dos variables: ventas y beneficios.

El producto es el elemento más importante para una empresa y condiciona en gran medida su existencia. Es por ello por lo que las empresas tratan de sistematizar el comportamiento de las ventas de sus productos a través de su permanencia en el mercado. No todos los productos permanecen durante el mismo período e incluso la gran mayoría no experimenta las mismas fluctuaciones en sus ventas, ni idéntica situación en cuanto a precios, publicidad y comercialización. La vida de cada producto evoluciona de forma diferente, pero siguiendo un ciclo que sí es idéntico, su ciclo de vida. (Godas, 2006).


Según la resolución NR003-16, en el artículo 9.-Vigencias y Reutilización de saldo en el inciso *a* establecer que la vigencia mínima de cada recarga será de 90 días calendarios a partir de su activación independientemente del valor de la denominación monetaria (Conatel, 2016).

Los números prepago tiene cinco estados, del uno al cinco permaneciendo en cada uno de los estados un periodo administrativamente establecido en días. Siendo el estado dos el que establece CONATEL con 90 días de vigencia asignados cuando se ingrese una recarga y/o un paquete.

Y es que lo anterior es la base para establecer el ciclo de vida un cliente prepago, el cual basado en su comportamiento ira avanzando o manteniéndose en su estado dos del ciclo de vida (cuando realice recargas o compras de paquetes) de acuerdo con el comportamiento de las recargas o compras de paquetes que realice.

Al llegar al día 181 (estado cuatro del ciclo de vida) es considera una baja o Churn.

Ilustración 5 - Ciclo de vida de numero Prepago



Fuente: *Elaboración propia, 2025.*

2.2.10.1 ANALISIS DE COMPORTAMIENTO DE CLIENTE EN SU CICLO DE VIDA

El estado 1 (introducción): es un estado que no es considerado como clientes, esto representan un inventario de SIM disponibles para la venta, es la introducción de la SIM al mercado.

El estado 2 (crecimiento): es el punto de partida de la vida comercial de un nuevo cliente en la empresa, inicia con la primera compra de un producto de la empresa (recarga o paquete).

El estado 3 (declive): es una alerta para el equipo comercial y de fidelizaciones y retenciones, es un cliente que tuvo 90 días sin la compra de un producto, las campañas de retenciones son más constantes y fuertes para convertirlo en una conversión o recuperación.

El estado 4 (desaparición): es la etapa final del ciclo de vida, ante la falta de compras de recargas y paquete, y sin reacción a las campañas su ciclo de vida continúa a esta etapa y la probabilidad de conversión es casi nula, aunque existen muy pocos casos que reactivan su ciclo en este estado.

El estado 5 (reciclaje): es el proceso lógico y físico de la baja de la SIM de los elementos de red y sistemas para reutilizar la numeración asignada para programar otro ciclo a un nuevo cliente.

2.3 TEORÍAS DE SUSTENTO

2.3.1 BASES TEÓRICAS

De acuerdo con nuestro objetivo de investigación, se ha investigado algunas literaturas

basadas en la segmentación y clasificación de clientes.

2.3.1.1 SEGMENTACIÓN DE CLIENTES MEDIANTE TEORIA DE AFINIDAD

El objetivo de aplicar al aplicar esta teoría es encontrar la existencia de conjuntos de consumidores homogéneos y facilitar el desarrollo de las actividades de marketing. Para la segmentación inciden más de un criterio y los clientes responden a un perfil que agrupa un conjunto de características, por lo que un segmento está definido por más de una característica. El reto consiste en encontrar un segmento optimo, resultante del cruce de varios criterios, que mejor describa el comportamiento de los consumidores (Lazzari, 2018).

La segmentación debe entenderse como una teoría y como una estrategia. Como teoría investiga el mercado con el objetivo de encontrar la existencia de conjuntos de consumidores homogéneos entre sí y distintos de los demás. Como estrategia representa la creación de diferentes planes de marketing, relativos a precio, producto, comunicación, distribución y promoción para llegar a los distintos segmentos que pudieran encontrarse (Lazzari, 2018).

2.3.1.2 TEORIA DEL CONSUMIDOR

La teoría del consumidor es de gran importancia para la gestión de empresas de todos los tamaños y en todos los ramos de actuación. En un análisis rápido, la teoría del consumidor te ayuda a comprender cómo las personas buscan y consumen los productos y/o servicios.

Además, la teoría del consumidor posibilita entender y analizar todos los factores presentes en la ponderación de tus clientes que los llevan a elegir determinada marca. Así, con la aplicación de la teoría del consumidor, expandes tu capacidad de estrechar esa relación con potenciales clientes, siempre con el objetivo de fortalecer la conversión (LATAM, 2023b).

En ese sentido, la teoría del consumidor, al estudiar el comportamiento del cliente, busca obtener una visión total sobre los factores, hábitos, influencias y estímulos que pueden interferir en la etapa de relación comercial y compra (LATAM, 2023b).

Tras aplicar la teoría del consumidor, gestores y equipos comerciales pueden implementar prácticas de venta centradas en su público objetivo, optimizando el proceso, mejorando sus indicadores y evitando desperdicios de tiempo y recursos con la captación de público no cualificado (LATAM, 2023b).

2.3.1.3 TEORÍA DE LA RETENCIÓN DE CLIENTES

2.3.1.4 CUSTOMER RETENTION

La retención de clientes se refiere a la tasa de permanencia de los clientes en una empresa durante un período determinado. Esto se conoce como tasa de abandono y es una métrica clave para prácticamente todas las empresas B2B y B2C. En general, cuanto menor sea la tasa de abandono, más fieles serán los clientes y más exitosa será la empresa, ya que esta retiene más clientes a lo largo del tiempo (LATAM, 2023a).

Para muchas empresas, la retención o pérdida de clientes es un KPI clave, porque la capacidad de una empresa para retener a los clientes existentes es fundamental para su éxito tanto a corto como a largo plazo.

Algunas de las razones clave incluyen las siguientes:

A menudo es mucho más económico retener a los clientes existentes que adquirir nuevos. Los costos de adquisición de ventas y marketing suelen superar con creces los costos relacionados con el servicio al cliente y su satisfacción continua.

Los clientes leales tienden a ser clientes recurrentes, lo que significa que son valiosos. Aumentar la retención de clientes aumenta la probabilidad de que un cliente se convierta en un cliente leal y recurrente, y puede aumentar significativamente las ganancias.

Es más eficaz para las empresas realizar ventas adicionales o cruzadas a sus clientes porque ya tienen una relación basada en la confianza y la satisfacción del producto.

Los clientes satisfechos a menudo pueden conducir a ganar nuevos clientes a través de referencias.

Es evidente que la retención de clientes no solo debe ser una métrica importante, sino un objetivo fundamental de casi todas las empresas. Por lo tanto, veamos primero cómo podemos medirla, antes de analizar diferentes maneras de mejorarla (LATAM, 2023a).

Las promociones son una estrategia para fidelizar y retener clientes, algunas promociones se diseñan para grupos de clientes específicos, incentivando la compra de recargas y paquetes para que su ciclo de vida sea establecido en la etapa segura, bajando las proyecciones de baja e incrementando los ingresos en la empresa.

2.3.1.5 ¿CÓMO MEDIR EL DESEMPEÑO DE LAS PROMOCIONES?

Según Price Lab, 2025 una sólida gestión de promociones incluye las siguientes acciones estratégicas para medir el desempeño:

Análisis de ventas antes y después de la promoción.

Una de las técnicas más comunes para medir el desempeño es analizar las ventas antes y después de una promoción.

Este método implica una comparación directa del volumen de ventas de un producto o servicio antes de que la promoción se active y durante el período en que está vigente.

Si bien este enfoque es útil para tener una idea general del impacto de una promoción, es crucial considerar otros factores externos que pueden influir en las ventas, como la estacionalidad, las tendencias del mercado o eventos externos.

II. Atribución de marketing para medir el impacto

Otra metodología clave en la gestión de promociones es la atribución de marketing, que permite identificar qué canales promocionales son los más efectivos. Utilizando modelos de atribución, como el último clic, el primer clic o la atribución multicanal, es posible determinar el valor real de cada canal de marketing en la conversión de clientes. Esta técnica proporciona una visión más clara del recorrido del cliente y permite ajustar las inversiones en los canales que generen mayores resultados.

III. Test A/B para la gestión de promociones

La prueba A/B es una técnica probada que permite comparar diferentes versiones de una promoción para identificar cuál genera mejores resultados. Al crear dos o más variantes de una promoción, se puede analizar cuál de ellas capta más la atención del cliente, genera más clics o incrementa más las ventas.

Esta técnica es especialmente útil para identificar elementos como el diseño, el texto o los incentivos que tienen mayor impacto en el comportamiento del consumidor.

IV. Uso de herramientas de análisis basadas en IA

En un mundo cada vez más digital, las herramientas de análisis basadas en inteligencia artificial están revolucionando la gestión de promociones.

Las soluciones de IA para retail permiten un análisis en tiempo real del rendimiento de las

campañas, identificando patrones y tendencias que pueden no ser evidentes a simple vista.

Además, integran técnicas de scraping de precios para evaluar el comportamiento de la competencia, ajustando las promociones de manera más efectiva y en tiempo real.

Estas herramientas no solo optimizan los resultados actuales, sino que también proporcionan una base sólida para futuras campañas.

2.3.2 MÉTRICAS CLAVE PARA EVALUAR EL DESEMPEÑO DE PROMOCIONES

La gestión de promociones es un proceso que puede trazarse y medirse de extremo a extremo, gracias a métricas como:

✓ Tasa de conversión como indicador de éxito

La tasa de conversión es una métrica fundamental para evaluar la efectividad de una promoción. Representa el porcentaje de visitantes o clientes potenciales que realizan una acción deseada, como comprar un producto después de interactuar con una promoción. Una alta tasa de conversión indica que la promoción está bien diseñada y es atractiva para los clientes, mientras que una baja tasa sugiere la necesidad de ajustes en el mensaje o el canal de distribución.

Que mide: Porcentaje de clientes que aceptaron o compraron la oferta.

Como se calcula: $(\text{Clientes que compraron} / \text{Clientes contactados}) \times 100$

✓ Incremento de ventas y su relevancia en la gestión de promociones

Otra métrica crítica es el incremento de ventas durante el período de la promoción en comparación con períodos anteriores similares. Este análisis ayuda a identificar si la promoción ha logrado impulsar las ventas de manera efectiva. También permite discernir si las ventas incrementales son sostenibles a largo plazo o si fueron simplemente un aumento temporal.

Que mide: Incremento en ventas durante la promoción.

Como se calcula: $(\text{Ventas durante promoción} - \text{Ventas promedio anteriores})$

✓ Tique promedio en las promociones

El tique promedio mide el gasto promedio por cliente durante una promoción. Un tique promedio más alto puede sugerir que los clientes están comprando más o productos de mayor valor, lo que es un indicador positivo de que la promoción está logrando maximizar el gasto por

cliente. Esta métrica es especialmente relevante en la gestión de promociones orientadas a aumentar el valor del cliente.

Que mide: Cambio en el ingreso promedio por cliente.

Como se calcula: Comparar ARPU antes y después de la campaña.

✓ **Cálculo del retorno sobre la inversión (ROI)**

El retorno sobre la inversión es quizás la métrica más completa y relevante para la gestión de promociones. Calcula la rentabilidad de una campaña promocional en función del costo de implementación.

Si el ROI es positivo, la promoción ha sido financieramente viable y exitosa. De lo contrario, indica la necesidad de revisar la estrategia y hacer los ajustes necesarios para futuras campañas.

Que mide: Rentabilidad de la promoción.

Como se calcula: $ROI = [(Ganancia\ generada - Costo\ de\ promoción) / Costo\ de\ promoción] \times 100$

✓ **Métricas de engagement y alcance**

Además de las métricas de ventas, es importante considerar las métricas de engagement, como las interacciones en redes sociales, los clics en correos electrónicos promocionales y las visitas al sitio web. Estas métricas son esenciales para medir el alcance de una promoción y la resonancia que tiene entre los clientes. Un alto nivel de engagement puede ser un indicativo de que la promoción está alineada con los intereses y preferencias de los clientes.

Que mide: Porcentaje de clientes que interactúan con la promoción.

Como se calcula: Abren SMS, clic en app, llamada al *Centro De Atención Telefónica*, etc.

2.3.3 ELEMENTOS CLAVE DE UNA PROMOCIÓN DE VENTAS EXITOSA

María Camila Gómez, 2025, nos explica que para hacer una buena promoción no es solo poner un descuento o factor y esperar a que se vendan más productos y/o servicios.

En 2025, con clientes más informados, exigentes y conectados, se necesitan estrategias

mucho más completas.

Los principales elementos de la promoción de ventas que hoy en día marcan la diferencia y cómo usarlos de forma inteligente con las mejores herramientas en promoción del mercado.

1. Definición de objetivos claros y medibles

Lo primero que debes preguntarte es: **¿qué quiero lograr con esta promoción?** Parece obvio, pero muchas marcas lanzan campañas sin una meta definida, y eso es un error.

Tal vez quieres aumentar ventas a corto plazo, promocionar un producto nuevo, recuperar clientes inactivos o atraer tráfico a tu sitio web.

Cada objetivo necesita un enfoque diferente y herramientas específicas. Por ejemplo, si tu meta es mover inventario antiguo, los descuentos por volumen o los combos son ideales. Pero si buscas captar leads, un sorteo digital con inscripción puede darte mejores resultados.

Lo más importante: mide. No hay promoción efectiva si no puedes rastrear su rendimiento.

2. Conocimiento profundo y segmentación del público

Este es uno de los instrumentos de la promoción que más impacto tiene. Ya no estamos en una época donde lanzar una promoción genérica servía para todos. Hoy, la personalización es la clave.

Gracias a los datos y a los CRMs inteligentes, puedes segmentar a clientes por ubicación, edad, historial de compras, intereses o comportamiento en redes sociales.

Esto te permite enviar la promoción correcta, al público adecuado, en el momento justo. Y eso, por supuesto, impulsa el crecimiento de tu negocio de manera mucho más rápida.

Por ejemplo, una marca de cosméticos puede enviar un código de descuento personalizado a quienes hayan comprado base líquida en los últimos 3 meses, con la sugerencia de complementar con un nuevo corrector de la misma línea.

3. Creación de ofertas con valor real

No todo se trata de ofrecer “20 % de descuento”. Las promociones deben responder a lo que tus clientes valoran. Las herramientas de promoción de ventas que mejor funcionan son

las que generan una percepción real de valor.

Puedes ofrecer acceso anticipado a un nuevo producto, una experiencia exclusiva, acumulación de puntos para canjear después, o incluso contenido premium (como guías, plantillas o máster clases) para quienes realicen una compra.

Un ejemplo concreto: una librería online ofrece un club de lectura gratuito solo para quienes compren un libro físico. No baja el precio, pero aporta valor y genera comunidad.

4. Implementación de estrategias omnicanal integradas

Estar presente en todos los canales no significa que estés usando una estrategia omnicanal. Esta se trata de ofrecer una experiencia conectada y coherente entre todos los puntos de contacto con tu cliente.

Por ejemplo, alguien que ve tu promoción en Instagram debería poder acceder al enlace que lo lleve al e-commerce, recibir un correo de seguimiento y, si entra a la tienda física, encontrar la misma promoción activa. Todo debe sentirse fluido, sin contradicciones, sin confusión. Eso es lo que esperan los usuarios de hoy.

5. Desarrollo de promociones digitales e interactivas

En 2025, las promociones dejaron de ser solo físicas o estáticas. Las marcas que están marcando la diferencia usan promociones interactivas y tecnológicas. ¿Qué significa esto? Que el cliente puede interactuar con la promoción desde su celular, computadora o incluso en una pantalla táctil en tienda.

Estas son tipos de promoción de ventas modernas, atractivas y diseñadas para captar la atención en segundos, algo clave en un entorno de sobrecarga publicitaria.

6. Análisis, monitoreo y optimización en tiempo real

Este paso, aunque suene técnico, es esencial. Puedes tener una promoción increíble, pero si no sabes cómo está funcionando mientras está activa, podrías estar perdiendo tiempo (y dinero).

Con las herramientas digitales de hoy, puedes ver cuántas personas hicieron clic, cuántas compraron, desde qué canal llegaron, cuánto gastaron, etc.

2.3.4 MACHINE LEARNING

Un modelo de machine learning es un programa que las computadoras utilizan para tomar decisiones o realizar predicciones. Aprende a partir de ejemplos y datos pasados para descubrir cosas por sí mismo.

Imagina que estás enseñando a una computadora a reconocer imágenes de gatos y perros. Le mostrarías muchas fotografías de gatos y perros y le dirías cuáles son gatos y cuáles son perros. La computadora aprende a partir de estos ejemplos y comienza a reconocer las diferencias entre gatos y perros.

Una vez que ha aprendido lo suficiente, puedes mostrarle una foto nueva y te dirá si es un gato o un perro. Logra esto empleando lo que ha aprendido de las imágenes de entrenamiento.

Los modelos de machine learning funcionan como el cerebro de una computadora. Es un marco matemático o algorítmico que ayuda a la computadora a adivinar, clasificar cosas o tomar decisiones cuando se le proporciona información. El modelo se vuelve más inteligente al analizar información antigua y luego puede utilizar ese conocimiento para hacer conjeturas sobre cosas nuevas que no ha visto antes (Ortega, 2023).

2.3.4.1 ALGORITMO DE MACHINE LEARNING

Un algoritmo de machine learning (ML) es un conjunto de reglas y procedimientos matemáticos y estadísticos que un modelo de aprendizaje automático utiliza para comprender patrones y hacer predicciones o juicios basados en datos. (Ortega, 2023) nos detalla ampliamente para que sirve, la clasificación y los modelos relacionados con Machine Learning.

Los algoritmos de machine learning ayudan a las computadoras a aprender cosas a partir de información, encontrar patrones y hacer conjeturas o elecciones. Estos algoritmos sirven como base para los modelos de machine learning. Estos modelos se utilizan en varios tipos de trabajos en diferentes industrias para descubrir información crucial y realizar tareas automáticamente en función de lo que han aprendido de los datos (Ortega, 2023).

2.3.4.2 MODELOS DE APRENDIZAJE SUPERVISADO

El modelo de aprendizaje supervisado es una categoría particular de diferentes modelos de machine learning que utilizan datos etiquetados para el entrenamiento. El algoritmo aprende a generar predicciones o juicios en el aprendizaje supervisado al mapear los datos de entrada a etiquetas objetivo-conocidas. Estos modelos se utilizan para tareas que requieren predecir un

resultado basado en características de entrada. A continuación, se presentan algunos modelos de machine learning supervisado populares:

- **Regresión lineal:** El modelo de regresión lineal predice una salida numérica continua en tareas de regresión. Cuando necesitas prever una salida numérica continua, puedes utilizar modelos de regresión lineal. Identifica la mejor conexión lineal entre tus variables de entrada y la variable objetivo.
- **Regresión logística:** La regresión logística se utiliza para tareas de clasificación binaria con una elección binaria (sí/no) como resultado. Basado en los atributos de entrada, calcula la probabilidad de un resultado binario.
- **Árboles de decisión:** Los árboles de decisión se utilizan para modelos de clasificación y regresión. Construyen una estructura similar a un árbol donde cada nodo refleja una decisión basada en una característica, y las hojas representan una etiqueta de clase final o un valor numérico.
- **Bosque aleatorio:** Un bosque aleatorio es una estrategia de aprendizaje por conjuntos que combina numerosos árboles de decisión para aumentar la precisión de las predicciones y reducir el sobreajuste.
- **Máquinas de soporte vectorial (SVM):** SVM es un algoritmo sofisticado de clasificación que encuentra el hiperplano óptimo para dividir las clases en el espacio de características. Puede clasificar datos binarios y multinivel.
- **K-Vecinos más cercanos (K-NN):** K-NN es un algoritmo básico pero efectivo de clasificación y regresión. Determina la clase o el valor de tus datos según la mayoría de las clases o el valor promedio de tus k-vecinos más cercanos en los datos de entrenamiento.
- **Naive Bayes:** Naive Bayes es un algoritmo de clasificación probabilística basado en el teorema de Bayes. Realiza tareas de categorización de texto, como la detección de spam y el análisis de sentimientos.
- **Redes neuronales:** Los modelos de aprendizaje profundo, como las redes neuronales convolucionales (CNNs) y las redes neuronales recurrentes (RNNs), son modelos supervisados altamente adaptables. Puedes utilizar estos modelos de machine learning para una variedad de tareas de aprendizaje supervisado, como la clasificación de imágenes y el

procesamiento de lenguaje natural.

2.3.4.3 MODELOS DE APRENDIZAJE NO SUPERVISADO:

El aprendizaje no supervisado es un tipo de aprendizaje automático en el que el algoritmo investiga patrones y estructuras en los datos sin producir una salida etiquetada. Estos métodos intentan encontrar patrones inherentes o correlaciones en los datos en lugar de predecir etiquetas específicas. Aquí tienes algunos modelos de aprendizaje automático no supervisado más comunes:

- **Agrupamiento K-Means:** K-means es un método de agrupación popular que divide los datos en grupos basados en similitudes. Busca reducir la varianza dentro de los grupos asignando puntos de datos al centro de clúster más cercano de forma iterativa.
- **Agrupamiento jerárquico:** El agrupamiento jerárquico crea un *dendrograma*, una estructura de clúster similar a un árbol. Puede representar las relaciones jerárquicas entre puntos de datos.
- **Modelos de mezcla Gaussiana (GMM):** Los modelos de mezcla gaussiana combinan diferentes distribuciones gaussianas para representar los datos. A menudo se utilizan en agrupación y estimación de densidad.
- **Modelos de Aprendizaje por Refuerzo:**

El aprendizaje por refuerzo es un subconjunto del aprendizaje automático en el que un agente aprende a tomar decisiones interactuando con su entorno. El agente aprende una política que optimiza las recompensas acumulativas con el tiempo al recibir información en forma de recompensas o penalizaciones. Aquí tienes algunos ejemplos de modelos y algoritmos populares de aprendizaje por refuerzo:

- **Q-Learning:** Q-Learning es un algoritmo de aprendizaje por refuerzo sin modelo que ayuda a los agentes a aprender la mejor política de selección de acciones. Mantiene una tabla Q que almacena las recompensas acumulativas esperadas para cada par estado-acción.
- **Redes neuronales profundas con Q (DQN):** DQN es una extensión de Q-Learning que utiliza redes neuronales profundas para aproximar los valores de Q. Ha demostrado ser efectivo en la resolución de tareas complejas.

- **SARSA ((State-Action-Reward-State-Action)):** SARSA, al igual que Q-Learning, es un algoritmo de aprendizaje por refuerzo sin modelo. Determina la mejor política al estimar los valores de Q para pares estado-acción y emplear modificaciones en la política.

2.3.5 FUNDAMENTACIÓN TEÓRICA

Cuando los registros disponibles no incluyen datos de los clientes como es en nuestro caso, no estaremos evaluando individualmente el parque de clientes y sus comportamiento de compras, llamadas, navegación, la evaluación de las promociones puede realizarse a partir de la información descriptiva y contextual de las promociones ya realizadas con información como: fecha, tipo, canal, paquete o recarga, clientes aplicables y clientes que recibieron la promoción. El algoritmo **Random Forest** permite detectar **patrones ocultos** en este tipo de datos, clasificando promociones exitosas y no exitosas según características como el canal de aplicable, el tipo de incentivo o la temporalidad (Breiman, 2001).

A diferencia de los métodos tradicionales de análisis de tendencias, el enfoque de aprendizaje automático no requiere relaciones lineales ni supuestos estadísticos estrictos, lo que lo hace especialmente útil para bases de datos de marketing con información categórica o heterogénea (Kuhn & Johnson, 2013).

Este modelo ha demostrado ser eficaz para identificar qué combinación de factores incrementa la probabilidad de éxito de una promoción, ayudando a las empresas de telecomunicaciones a optimizar la calendarización y el diseño de futuras campañas (Wierenga & van der Lans, 2017).

2.3.5.1 VARIABLES CONSIDERADAS

Dado que los datos disponibles incluyen información operativa, las variables se estructuran de la siguiente forma:

TIPO DE VARIABLE	DESCRIPCIÓN	EJEMPLO
Dependiente (objetivo)	Éxito o resultado de la promoción.	1 = exitosa
	Puede derivarse de indicadores históricos o de	0 = no exitosa

	eventos pasados.	
INDEPENDIENTES (PREDICTORAS)		
Fecha	Día, mes, semana del año.	31, 10, “viernes”
Tipo de promoción	Tipo de Promoción (doble GB, doble saldo, tiempo extra, volumen).	“Doble GB”
Canal	Medio de compra del paquete o saldo	Banco, Supermercado
Paquete	Paquete en promociones	12GB 7DIAS
Nombre del negocio o punto de venta	Ubicación o categoría del negocio donde se lanzó la promoción.	Banco Centro América.

El modelo busca descubrir **qué combinaciones de estos factores están asociadas con promociones más exitosas**, permitiendo generar reglas interpretables para futuras decisiones.

2.3.5.2 METODOLOGÍA PROPUESTA

1. Codificación de datos
 - Convertir las variables categóricas (tipo_promocion, canal) en variables numéricas mediante *one-hot encoding* o etiquetas binarias (Kuhn & Johnson, 2013).
 - Transformar la fecha en variables como mes, día de la semana o semana del año, para captar patrones estacionales.
2. Definición del objetivo
 - Se crea una variable de salida denominada “resultado” o “nivel de efectividad”, basada en registros históricos o indicadores previos (por ejemplo, si generó alta respuesta o incremento en las ventas).
3. Entrenamiento del modelo Random Forest

- Se entrena el modelo con las variables mencionadas, generando múltiples árboles de decisión.
 - Cada árbol predice si una promoción tendrá éxito o no, y el bosque final realiza una votación promedio (Breiman, 2001).
4. Evaluación del modelo
- Se dividen los datos en conjuntos de entrenamiento (70 %) y prueba (30 %).
 - Se miden indicadores como exactitud (accuracy), precisión, recall y matriz de confusión.
 - La importancia de variables muestra cuáles factores influyen más en el éxito (por ejemplo, canal o tipo de promoción).
5. Interpretación de resultados
- Si el modelo predice correctamente el éxito de las promociones, se concluye que existe una relación significativa entre las características operativas y la efectividad.
 - El análisis de importancia de variables permite jerarquizar factores, por ejemplo:
 - Canal = 40 % de importancia
 - Tipo de promoción = 35 %
 - Fecha/evento = 20 %
 - Punto de venta = 5 %

2.3.5.3 APLICACIÓN PRÁCTICA HIPOTÉTICA

Se entrenaron varios algoritmos con 1,213 registros de promociones configuradas en el año 2025. Los modelos probados con diferentes algoritmos alcanzaron precisiones en la clasificación de promociones exitosas.

Los algoritmos incorporados en el modelo fueron:

Decision Tree, divide el dataset en ramas basadas en decisiones de características, formando un árbol de condiciones que predice clases o valores. Es intuitivo y fácil de interpretar, pero puede sobre ajustarse si no se poda.

Logistic Regression modelo estadístico que predice probabilidades de una variable categórica usando una función logística. Ideal para clasificación binaria, interpretable, pero limitado frente a relaciones no lineales complejas.

Random Forest Conjunto de muchos *Decision Trees* entrenados con subconjuntos de datos y características. Promedia sus predicciones para mejorar precisión, reducir sobreajuste y

manejar relaciones no lineales complejas.

Gradient Boosted combina varios modelos, que construye árboles secuenciales donde cada nuevo árbol corrige errores del anterior. Altamente preciso para clasificación y regresión, pero más sensible a sobreajuste y requiere ajuste cuidadoso de hiper parámetros.

Los resultados obtenidos después de aplicar normalizaciones, balanceos y usando un particionamiento de 70% para el conjunto entrenamiento y 30% para el conjunto de pruebas fueron:

Estadística	Decision Tree	Logistic Regression	Random Forest	Gradient Boosted
Recall	97.24%	41.27%	76.88%	96.39%
Precision	98.19%	46.23%	92.94%	98.05%
Sensitivity	97.24%	41.27%	76.88%	96.39%
Specificity	97.24%	41.27%	76.88%	96.39%
F-measure	97.71%	39.07%	82.48%	97.20%
Overall Accuracy	99.03%	50.73%	93.88%	98.82%
Overall Error	0.97%	49.27%	6.12%	1.18%

Es muy importante hacer notar que del modelo realizado y usando los cuatro algoritmos los mejores resultados o precisiones fueron **Decision Tree** con 98.19% y **Gradient Boosted** con 98.05% de precisión.

Decision Tree clasifica bien la variable categoría objetivo, SI o NO. SI, si las ventas del día de la promoción son mayores vs. el promedio de ventas (línea base) que son 61 días, excluyendo los días donde si había promoción seleccionándolo como algoritmo base de nuestro modelo.

Si bien, el modelo es corto y el tratamiento de los datos es por decirlo sencillito, también los datos usados no son complejos, más que un tratamiento como siempre suelen ser en este tipo de análisis, las variables categóricas, por sí sola no proporcionan gran valor para el modelo, es por eso que se deben de tratar diferentes convertir a valores numéricos para darle un peso numérico. Respecto a la medición, la métrica usada para evaluar los resultados fue la **precisión**, cuantas promociones ingresadas al modelo clasifico correctamente.

Desde el punto de vista del negocio necesitábamos anticipar el éxito de una promoción.

Analíticamente, este modelo permitió identificar variables críticas, generando predicciones confiables que reducen el riesgo económico y operativo, que mejoran la toma de decisiones.

2.4 INSTRUMENTOS UTILIZADOS

La investigación adopta un enfoque cuantitativo sustentado en el uso de modelos predictivos de aprendizaje automático (machine learning). Como instrumentos se emplean algoritmos supervisados tales como regresión logística, árboles de decisión, Random Forest y Gradient Boosted, entre otros, seleccionados según su capacidad de manejar variables heterogéneas y que se adaptan a los datos históricos con los que se cuenta para realizar las predicciones.

El proceso de modelado se basa en datos históricos obtenidos de la base de datos de eventos transaccionales de las promociones, los cuales contienen registros detallados de promociones. Estos instrumentos permiten analizar el desempeño pasado de las promociones, identificar éxito o fracaso y generar predicciones que faciliten la toma calendarización de nuevas promociones basados en una predicción precisa.

La evaluación del éxito de una promoción requiere comprender cómo estas influyen en el comportamiento de compra y en los indicadores comerciales clave. Blattberg y Neslin (1990) establecen que las promociones pueden medirse mediante su impacto en el volumen de ventas, la participación de mercado, la rentabilidad y el comportamiento del consumidor antes, durante y después de su aplicación.

Los autores destacan que la efectividad promocional no debe analizarse únicamente desde el incremento inmediato de ventas, sino también considerando efectos de largo plazo como la lealtad del cliente, la elasticidad del precio y posibles “caídas post-promoción” en la demanda. Además, proponen el uso de datos transaccionales históricos para identificar patrones en la respuesta del consumidor, permitiendo evaluar si una promoción genera un “lift” real o si solo adelanta compras que habrían ocurrido de todos modos.

Esto respalda el enfoque utilizado en esta investigación, que se basa en analizar datos históricos de transacciones para determinar el éxito o no de las promociones. Al utilizar métricas cuantitativas y modelos estadísticos o de aprendizaje automático, es posible estimar si una promoción fue exitosa, identificar factores que influyen en su desempeño y predecir resultados futuros bajo diferentes escenarios.

Para la presente investigación, el éxito de una promoción se define a partir de su impacto directo en el volumen de ventas. Con el fin de contar con un punto de comparación objetivo para

evaluar la promoción, se establece una línea base, calculada como el promedio de ventas correspondiente a los 61 días previos al inicio de la promoción. Dicho cálculo se realiza con los mismos criterios de configuración de la promoción, como el tipo de promoción y paquete.

Una vez finalizada la promoción, se procede a comparar las ventas registrado durante la promoción con el valor de la línea base previamente obtenido. En aquellos casos en que las ventas durante la promoción superan el valor de la línea base, la promoción se considera como exitosa. Por el contrario, cuando el volumen de ventas no alcanza o supera dicho valor de la línea base, la promoción se considera no exitosa.

2.5 MARCO LEGAL

Dentro de las regulaciones en Honduras aplicadas a promociones, protecciones al usuario, y libre competencia se encuentran:

2.5.1 LEY DE PROTECCIÓN AL CONSUMIDOR (DECRETO 24-2008)

2.5.1.1 ARTÍCULO 22 DEBER DE PROPORCIONAR INFORMACIÓN CLARA, VERAZ Y SUFICIENTE

Este artículo en la Ley obliga a que los proveedores suministren al consumidor, en idioma español, información oportuna, clara, veraz, adecuada y suficiente sobre las características esenciales de los bienes o servicios y las condiciones de comercialización.

Esta disposición es relevante para las promociones de paquetes al exigir que se informe con precisión el contenido, el precio, la vigencia y otras condiciones de la promoción ofrecida.

2.5.1.2 ARTÍCULO 27 PROHIBICIÓN DE PUBLICIDAD ENGAÑOSA EN PROMOCIONES

Este artículo prohíbe toda publicidad que pueda resultar total o parcialmente engañosa, falsa o capaz de inducir a error respecto a las características, calidad, precio o condiciones de comercialización de bienes y servicios.

Esta regla es fundamental en la revisión de promociones de paquetes para garantizar que la información publicada y comunicada a los clientes sea aplicada en las compras que realice y sobre todo si aplican a una promoción en la compra de su paquete esta sea otorgada en tiempo y

forma como fue diseñada y publicada.

2.5.1.3 ARTÍCULO 28 REQUISITOS DE OFERTAS Y PROMOCIONES DIRIGIDAS A CONSUMIDORES

De acuerdo con el Artículo 28, la oferta dirigida a los consumidores obliga a quien la emite durante el período en que se realiza y debe contener fechas de inicio y finalización, así como sus modalidades, condiciones y restricciones. De forma complementaria, el Artículo 29 exige que en promociones, rebajas u ofertas especiales se consigne el precio o condición anterior y las nuevas condiciones o precio rebajado.

Estas disposiciones son aplicables a las promociones de paquetes y forman la base legal para comparar condiciones antes y durante la promoción, o si existen exclusiones por la no aplicación de la promoción deberá de ser informada al cliente de forma oportuna.

2.5.1.4 ARTÍCULO 30 PUBLICIDAD Y CONDICIONES PROMOCIONALES QUE OBLIGAN AL PROVEEDOR

Las precisiones formuladas en la publicidad incluidos anuncios y demás medios de difusión obligan al proveedor y se consideran incluidas en el contrato con el consumidor.

En el caso de las promociones de paquetes, cualquier condición anunciada en la oferta forma parte de la relación contractual con el consumidor y debe cumplirse tal como se difundió, es por eso que parte del proceso de las promociones se hacen monitoreos de cada una para asegurar la aplicación correcta de los publicado.

2.5.2 LEY PARA LA DEFENSA Y PROMOCIÓN DE LA COMPETENCIA (DECRETO 357-2005)

El Reglamento desarrolla y operacionaliza las normas de la Ley para la Defensa y Promoción de la Competencia (Decreto 357-2005) y establece procedimientos, funciones, criterios y definiciones concretas para aplicar la ley en casos prácticos.

La ley no establece un apartado directo sobre las promociones, pero muchos de sus criterios y requisitos afectan directamente cómo deben diseñarse y evaluarse promociones en mercados competitivos.

2.5.2.1 ARTICULO 3 DE CONFORMIDAD CON LA LEY, LA COMISIÓN TIENE LAS SIGUIENTES FUNCIONES Y ATRIBUCIONES

Estas funciones y atribuciones permiten analizar datos del mercado de las telecomunicaciones evaluar prácticas comerciales que afecten la competencia.

2.5.2.2 ARTÍCULO 4 CRITERIOS PARA LA VALORACIÓN DE PRÁCTICAS PROHIBIDAS POR SU NATURALEZA

Que exista una correlación positiva, importante y continuada en los precios de dos o más competidores, durante un periodo de tiempo significativo; que no pueda ser atribuido a variaciones en los precios de los factores de producción.

2.5.2.3 ARTÍCULO 5 CRITERIOS PARA VALORAR PRÁCTICAS RESTRICTIVAS POR SU EFECTO

El otorgamiento de descuento por parte de productores o proveedores a los compradores con el requisito de exclusividad en la distribución o comercialización de los productos o servicios, cuando no se justifiquen en términos de eficiencia económica.

Este punto la regulación de competencia con prácticas comunes en el mercado de las telecomunicaciones, se permite realizar promociones de paquetes o excluir clientes y canales, que pueden ser utilizados por las operadoras telefónicas para segmentar o controlar canales de distribución.

2.5.2.4 ARTÍCULO 6 DE CONFORMIDAD CON EL ARTÍCULO 9 DE LA LEY

El Reglamento indica que la Comisión debe valorar si hay ganancias de eficiencia económica que justifiquen una práctica.

Esto permite que promociones de datos no sean automáticamente consideradas negativas, siempre que puedas demostrar con datos que aportan beneficios reales.

2.5.3 REGLAMENTO DEL SECTOR TELECOMUNICACIONES / NORMATIVA DE SERVICIOS PÚBLICOS.

2.5.3.1 ARTÍCULO 6, LITERAL F PRINCIPIO DE PREVALENCIA DEL USUARIO

En todas las actividades que realicen, tanto el Estado como regulador, así como las empresas prestadoras de servicios públicos, el interés del usuario será un factor relevante. Esto en razón a que el usuario es el destinatario final de todas las actividades de creación, fabricación, comercialización de equipos y tecnologías, así como la prestación de toda clase servicios de telecomunicaciones, en consecuencia, también todas las acciones de regulación deben tener en cuenta este principio.

Este principio establece a al usuario final objetivo final. Las promociones deben diseñarse con criterios que beneficien siempre al usuario (precios, vigencias, valores y volúmenes mayores), no solo con estrategias comerciales que favorezcan a los objetivos de la empresa, sino que generen mayor satisfacción a los usuarios.

2.5.3.2 ARTÍCULO 211, COMPETENCIA DE SERVICIOS

Las telecomunicaciones en Honduras se brindan en un régimen de libre, leal y sana competencia. Están prohibidas las prácticas que limiten o distorsionen la libre competencia en la prestación de servicios de telecomunicaciones, así como el acceso de nuevos operadores al mercado. CONATEL cuenta con atribuciones y las potestades necesarias para velar por la libre competencia, así como para corregir las distorsiones que se produzcan, sancionando a los responsables.

Este artículo aplicado a las promociones de paquetes, indica que deben de ser diseñadas de manera que no restrinjan ni distorsionen la competencia. Creando promociones que incentiven el consumo, preferencia y/o beneficio del usuario y por ende de la empresa, pero no una promoción excesivamente agresiva que busque expulsar competidores del mercado o afectar su imagen.

CAPÍTULO III. METODOLOGÍA

3.1 CONGRUENCIA METODOLÓGICA

Para llevar a cabo la investigación se implementarán modelos de clasificación y predictivos mediante algoritmos de aprendizaje en la empresa con el objetivo identificar las promociones con mejores posibilidades de efectividad según las variables independientes.

En la matriz metodología se presenta un resumen del objetivo de la investigación, así como las interrogantes que ayudaran a finalizar la misma.

3.1.1 MATRIZ METODOLÓGICA

Tabla 3 - Matriz Metodológica

Título de la investigación	Objetivos de la investigación		Variables	
	General	Específicos	Dependientes	Independiente
Análisis de la efectividad de las promociones de saldo y paquetes mediante técnicas de analítica de datos.	Evaluar la efectividad de las promociones de saldo y paquetes implementadas utilizando técnicas de analítica de datos para identificar los factores que inciden en el éxito y determinar qué tipos de promociones podrían resultar más efectivas en futuras fechas basada una estrategia comercial.	Analizar la información histórica de promociones (fecha, tipo, canal, compras y promociones aplicadas) para identificar patrones y relaciones de las variables con los resultados obtenidos.	Nivel de efectividad de la promoción (éxito/no éxito).	Fecha Tipo de Promoción Canal Nombre negocio
		Determinar los factores que más influyen en la efectividad de las promociones (por ejemplo, tipo de incentivo, canal o fechas).		

		<p>Aplicar el algoritmo Random Forest para clasificar las promociones según su nivel de éxito (medición realizada previamente) y estimar la importancia de las variables predictoras ya definidas anteriormente.</p>		
--	--	--	--	--

Fuente: *Elaboración propia, 2025.*

3.1.2 ESQUEMA DE VARIABLES DE ESTUDIO

Tabla 4 - Esquema de variables de estudio

<i>Variable</i>	<i>Tipo</i>	<i>Definición conceptual</i>	<i>Definición operacional / Indicadores</i>
<i>Efectividad de la promoción</i>	Dependiente	Grado en que una promoción logró incrementar las recargas y/ compras de paquetes, recargas.	Indicador 1: Incremento de recargas y/o paquetes respecto al promedio antes de la promoción.
<i>Tipo de promoción</i>	Independiente	Categoría del incentivo ofrecido por la promoción (ej.: doble GB, doble saldo, tiempo extra)	Variable categórica: 1=doble GB, 2=Triple, 4=Cuádruple, X=Tiempo extra.
<i>Canal</i>	Independiente	Medio a través del cual se realiza la compra del paquete y/o recarga que aplica a la promoción.	Variable categórica: PP, WEB, BANCO, FARMACIA, etc.
<i>Fecha / Semana del Año</i>	Independiente	Momento de la promoción, que puede influir en su efectividad (mes, día de la semana)	Variables: Mes de la promoción (1-12), Día de la semana (lunes-domingo), Semana del año.
<i>Nombre o punto de venta / Negocio</i>	Independiente	Ubicación o categoría del negocio donde se lanzó la promoción, que puede afectar su impacto (Tipo de	Variable categórica: 1= “Banco Centro America”, 2= “Supermercado La

		negocio, ubicación, etc.)	Colonia”, etc.
--	--	---------------------------	----------------

Fuente: *Elaboración propia, 2025.*

3.1.3 OPERACIONALIZACIÓN DE LAS VARIABLES

Tabla 5 - Matriz de operacionalización de variables

<i>Variable</i>	<i>Dimensión</i>	<i>Definición Conceptual</i>	<i>Definición Operacional</i>	<i>Unidad de Medida</i>	<i>Indicador</i>
<i>Efectividad de la promoción</i>	Respuesta	Grado en que una promoción incrementa las compras de recargas y paquetes.	Si el resultado de la efectividad es mayor al promedio anterior es Exitosa. Si no se clasifica como NO Exitosa.	%	1=Exitosa 0=NO exitosa
<i>Tipo de promoción</i>	Incentivo ofrecido	Categoría de la promoción según el beneficio que recibe el cliente.	Clasificación de la promoción: doble GB, doble saldo, volumen adicional, tiempo extra.	Categórica	1=doble GB; 2=doble saldo; 3=volumen adicional; 4=tiempo extra
<i>Canal de Venta</i>	Medio de Venta	Canal de venta de recarga o paquete que aplica a la promoción.	Canales ventas donde se compran las recargas y/o paquetes que aplican a la promoción.	Categórica	1=WEB 2=BANCOS y CADENAS

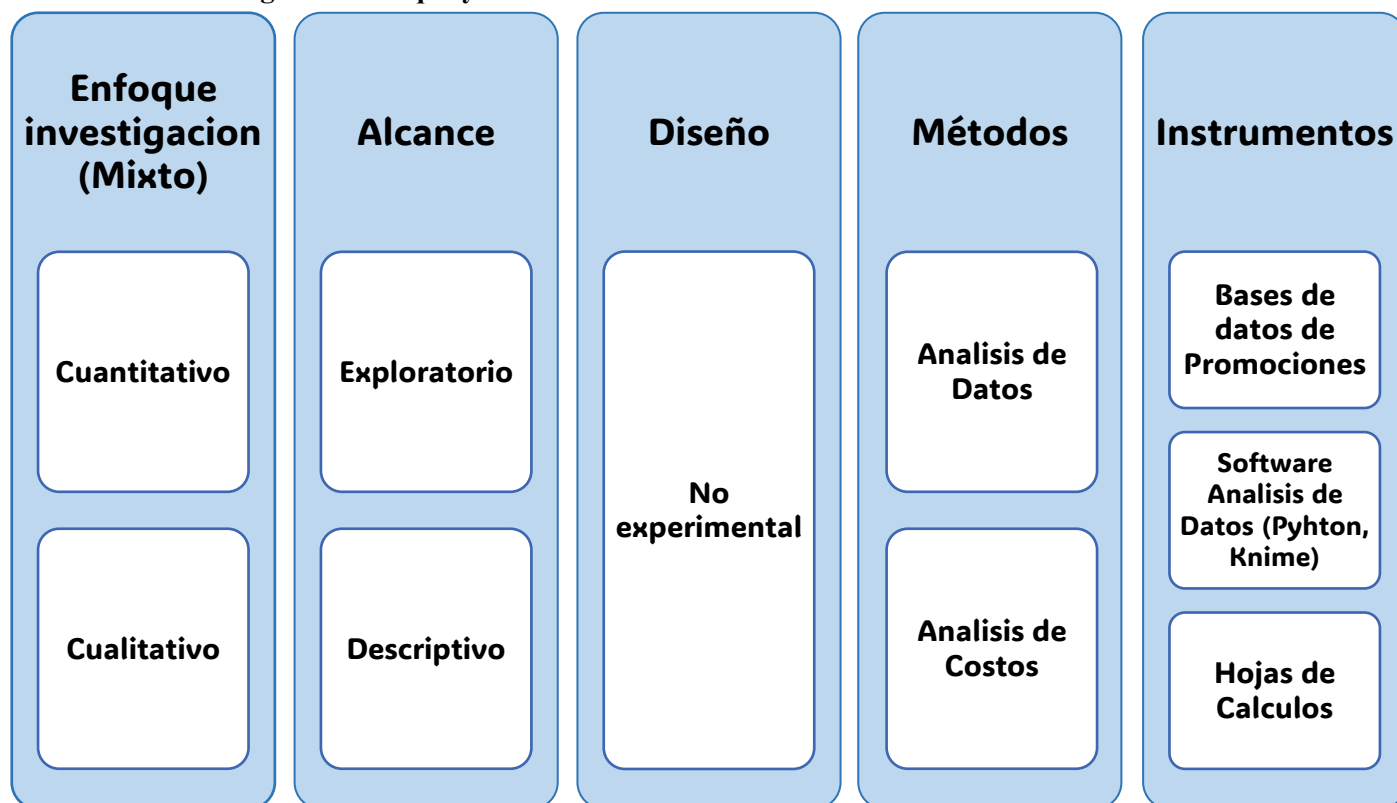
					3=WEB VENTAS 4=MiWebPaquetes
<i>Fecha / Estacionalidad</i>	Momento temporal	Fecha de realización de la promoción, que puede influir en su efectividad.	Se transforma en variables: mes, día de la semana, semana del año.	Mes / Día / Binaria	Mes de lanzamiento; día de la semana.
<i>Nombre o punto de venta / negocio</i>	Ubicación o tipo de canal	Identificación del punto de venta o categoría del negocio donde se lanzó la promoción.	Se registra el nombre o código del negocio/punto de venta y se clasifica por tipo de canal (Banco, Farmacia, Supermercado, etc.).	Catagórica	Nombre o código del negocio.

Fuente: *Elaboración propia, 2025.*

3.2 ENFOQUE Y MÉTODOS

Según Hernández Sampieri et al., (2006) (Hernández- Sampieri, 2023) el enfoque de investigación se define como la perspectiva general que orienta al diseño del estudio, determinando la naturaleza y el alcance de la investigación. Por otra parte, los métodos de investigación comprenden las técnicas especificadas empleadas para la recopilación y el análisis de datos en el contexto de la investigación.

Ilustración 6 – Diagrama Enfoque y Métodos



Fuente: *Elaboración propia, 2025.*

3.3 ENFOQUE

El enfoque de esta investigación se sustenta en un enfoque mixto. Ya que usaremos el enfoque cuantitativo centrado en el análisis de datos numéricos, de grandes cantidades de información como historial de promociones, paquetes, fechas y otros relacionadas con las acciones de promociones. Este enfoque es precisamente el más adecuado con nuestros objetivos de investigación, como el análisis de comportamiento de las promociones para determinar si una promoción puede tener efectividad o no

después de analizar todos los datos.

El enfoque cualitativo porque exploraremos otras circunstancias y motivos que puede influir en la decisión del cliente en el abandono que no pueden ser obtenidas o descubiertas a través un análisis de datos ya que estas no se tienen registradas en una base de datos y será necesario obtenerlos a través de otros métodos.

3.3.1 ALCANCE

El alcance de la presente investigación es de tipo exploratorio y descriptivo.

Es **exploratorio** porque busca identificar y analizar patrones, tendencias y características asociadas a las promociones de paquetes y a la gestión del abandono de clientes, a partir del análisis de datos históricos y operativos, en un contexto donde no existen estudios previos que aborden de manera sistemática estas dinámicas dentro de la organización.

Asimismo, es **descriptivo**, ya que permite caracterizar el comportamiento de las promociones de paquetes a partir del análisis de información histórica, describiendo aspectos como su frecuencia de programación, periodos de vigencia, distribución temporal por días de la semana, semanas y meses, así como los promedios de ventas y resultados observados durante el día de su ejecución.

3.3.2 DISEÑO

La investigación tendrá un diseño o tipo no experimental, debido a que no existe manipulación de las variables, estas serán únicamente observadas, tal como ocurrieron y en su contexto. En este caso, se analizaron las variables que son obtenidas directamente desde una base de datos tal cual fueron guardadas cuando el cliente las genero con su comportamiento.

3.3.3 MÉTODOS

Nuestros métodos serán análisis de datos y análisis de costos. El análisis de datos es el proceso que implica la inspección, limpieza, transformación e interpretación de los datos con el objetivo de descubrir información útil, generar conclusiones y respaldar la toma de decisiones. Para nuestra investigación se realizará análisis de datos desde diferentes bases de datos y durante un periodo de 7 meses (del septiembre 2024 a marzo 2025) registros de eventos del usuario generados durante ese periodo. también los análisis de costos nos permitirán calcular los costos que la empresa género en los clientes que, durante su ciclo de vida en la empresa, estos serán obtenidos desde formularios alimentados por la información que será proporcionada por los equipos comerciales y de

finanzas.

3.3.4 INSTRUMENTOS

Según Hernández Sampieri et al., (2006), un instrumento de medición es aquel que registra datos observables que representan verdaderamente los conceptos o las variables que el investigador tiene en mente. Esto implica que el instrumento debe ser válido y confiable.

Análisis de datos existentes, se usarán bases de datos que tienen registros de eventos de los clientes involucrados en la investigación. Existen diferentes bases de datos ya que la información se encuentra segregada, por lo que será necesario realizar “cruces” de información para crear una fuente de información que contenga todas las características necesarias para los análisis planteados y que resolverán las preguntas planteadas al inicio de la investigación.

Los softwares de análisis de datos son herramientas diseñadas para extraer información relevante de un conjunto de datos, para facilitar la toma de decisiones. Estos tienen diferentes tareas programadas, que van desde la visualización de datos, hasta análisis estadísticos complejos y modelados predictivos. Para nuestra investigación usaremos KNIME para análisis de datos y líneas de comandos escritas en lenguaje Python para los análisis.

3.4 DISEÑO DE LA INVESTIGACIÓN

Según Hernández Sampieri et al., (2006), se refiere al plan o estrategia general para obtener la información que se desea con el fin de responder al planteamiento del problema. En decir, es el esquema o marco de trabajo que guía al investigador en el proceso de recopilación y análisis de datos. Esta investigación usará el diseño no experimental, ya que no será necesario realizar manipulaciones o intervenciones controladas en las variables de estudio. Por lo que se recopilarán los datos desde bases de datos y se analizarán en su contexto para identificar correlaciones y patrones entre las variables de interés.

3.4.1 POBLACIÓN

Según (Bernal Torres, 2022) establece que población es el conjunto de todos los elementos a los cuales se refiere la investigación. También lo define como el conjunto de todas las unidades de muestreo.

Según Hernández Sampieri et al., (2006) la población se refiere al conjunto de individuos, objetos, eventos o fenómenos que comparte una o varias características comunes y que son objeto de

estudio en una investigación.

Para esta investigación la población será de 9,638 registros de promociones, correspondientes al periodo entre 01/01/2025 al 31/10/2025.

3.5 TÉCNICAS, INSTRUMENTOS Y PROCEDIMIENTOS APLICADOS

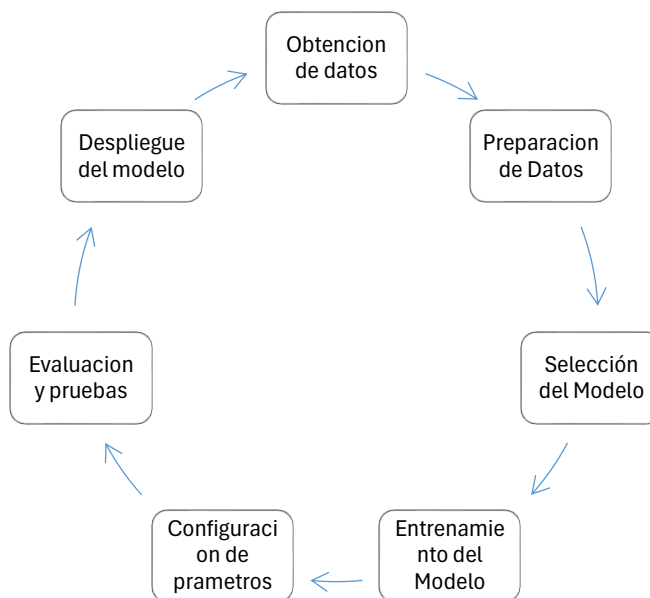
3.5.1 TÉCNICAS

Las técnicas que utilizaremos en esta investigación serán técnicas y herramientas de aprendizaje automático modelos predictivos como Regresión Logística, Máquinas de Vectores de Soporte (SVM), Árboles de Decisión, Bosques Aleatorios (Random Forest) y Gradient Boosted, que permitirán clasificar y predecir la probabilidad de éxito de distintas promociones, así como estimar el impacto potencial en ventas y retención. Se emplearán para la recolección y análisis de datos.

Como herramienta de validación, se utilizarán registros históricos de campañas promocionales reales, incluyendo métricas como tasa de conversión, incremento ventas y respuestas a los clientes focalizados. Estos datos servirán para entrenar y evaluar los modelos, garantizando la mayor precisión posible en las predicciones y la identificación de factores determinantes del éxito o fracaso de una promoción.

Asimismo, se hará uso de plataformas y librerías de análisis y modelado como Python (pandas, scikit-learn, XGBoost, TensorFlow, Prophet), junto con herramientas de visualización como Power BI, para facilitar la interpretación de resultados y la toma de decisiones estratégicas.

Ilustración 7 – Machine Learning Ciclo de Vida



Fuente: *Elaboración propia, 2025.*

3.5.2 INSTRUMENTOS

En el contexto de esta investigación se empleará una base de datos Oracle para la extracción, almacenamiento y gestión de la información extraída de las promociones implementadas y obtenidas en la muestra y sus resultados históricos que para nuestro proyecto es del año 2025. Esta base de datos permitirá almacenar y estructurar de manera eficiente los registros de campañas, métricas de desempeño y respuestas de los usuarios, facilitando la extracción y posterior aplicación de técnicas analíticas y modelos predictivos.

Asimismo, se utilizará Python como herramienta principal de análisis de datos y alternamente el software KNIME, dado que permite integrar procesos de limpieza, transformación, minería de datos y modelado predictivo en flujos de trabajo visuales. Se realizarán los ejercicios de segmentación, clasificación y predicción del rendimiento de las promociones, empleando algoritmos de aprendizaje automático previamente seleccionados.

Por último, se hará uso de hojas de cálculo en Microsoft Excel para la ejecución de cálculos complementarios y el análisis de resultados preliminares y financieros que requieren operaciones más directas o personalizadas. Aunque Excel no será la herramienta principal de modelado, se aprovechará su capacidad para realizar procesamientos rápidos y verificación de datos, así como para la presentación de resultados numéricos y estadísticos derivados de los modelos desarrollados

3.5.3 PROCEDIMIENTOS

Para esta investigación será requerido una serie de pasos para realizar las actividades requeridas para poder completar cada uno de los objetivos planteados y que nos darán una respuesta al problema principal planteado.

1. Extracción de los datos de la población establecida en forma csv.
2. Carga de los datos extraídos anteriormente en nuestra base de datos que usaremos para el procesamiento y análisis en la investigación.
3. Limpieza de los datos.
4. Exportar información de la población ya depurada en un archivo csv.
5. Realizar análisis exploratorio de datos.
6. Carga del archivo exportado anteriormente en la carpeta de repositorio de trabajo.
7. Aplicación de técnicas de aprendizaje automática para el o los algoritmos seleccionados para el

objetivo a ser cumplido en KNIME.

8. Prueba con distintos escenarios para determinar el mejor rendimiento de acuerdo con las técnicas aplicadas para el o los algoritmos.
9. Interpretación de los resultados proporcionados por el o los algoritmos entrenados.
10. Revisión de resultados.
11. Documentación del proceso y conclusiones de los resultados.

3.6 FUENTES DE INFORMACIÓN

3.6.1 FUENTES PRIMARIAS

Para esta investigación se tendrán varias fuentes de información primarias.

1. La base de datos de promociones, donde se obtendrán los datos de la muestra (año 2025).
2. Base de datos de transacciones de ventas de paquetes, la cual proporcionara detalle de las compras realizadas por la muestra seleccionada.

3.6.2 FUENTES SECUNDARIAS

Para obtener detalles de los cálculos de costos se usarán valores promedios sobre salarios, tiempos, herramienta Jira para obtener detalles de las promociones, procesos y tiempos. Estos nos servirán para realizar los cálculos de los costos, tiempo y riesgo asociado a cada configuración de promoción para posterior comparar con el beneficio / pérdida obtenida por la promoción.

3.7 CRITERIOS DE EXCLUSION DE VARIABLES

De las 19 variables iniciales, se realizaron exclusiones estratégicas de 7 de ellas, dado que contenían información redundante. Estos elementos se consideraron poco relevantes para el enriquecimiento del entrenamiento del modelo predictivo. Esta exclusión se determinó considerando que estas variables estarían implícitamente consideradas en otras variables como la fecha.

Tras esta exclusión, se logró establecer un conjunto de variables finales que se consideraban más relevantes y específicas para el objetivo de entrenar el modelo de predicción éxito o no de las promociones.

Este proceso de selección y exclusión de variables crea expectativas de mejorar la precisión y la capacidad predictiva del modelo al centrarse en los factores más precisos con nuestro objetivo, predicción de probabilidad de éxito o no de una promoción futura.

Tabla 6 - Variables de la tabla final de promociones

No.	Variable (Campo)	Tipo de Datos	Descripción
1	FECHA	DATE	Fecha de la promoción.
2	DIA	INTEGER	Día de la semana de la promoción.
3	SEMANA	INTEGER	Semana del año de la promoción.
4	ID_PRODUCTO	INTEGER	Identificar único del paquete en promoción.
5	PAQUETE	STRING	Nombre del paquete en promoción.
6	TIPO_PROMOCION	STRING	Tipo, Volumen o Vigencia del paquete.
7	VALOR_PROMOCION	STRING	Factor, DOBLE o TRIPLE volumen de paquete.
8	CANAL	STRING	Canal seleccionado para ventas del paquete.
9	ID_ENTIDAD	STRING	Identificar único de la entidad en promoción.
10	ENTIDAD	STRING	Nombre de la entidad en promoción.
11	VENTAS	INTEGER	Ventas del paquete durante la promoción.
12	ÉXITO_PROMOCION	INTEGER	0=Fallido, 1=Éxito de la promoción.
13	PROMEDIO_VENTAS_61D_SP	DOUBLE	Promedio de ventas últimos 61 días del paquete sin promoción incluido
14	PROMEDIO_VENTAS_61D_CP	DOUBLE	Promedio de ventas últimos 61 días del paquete incluyendo promociones.
15	PROMEDIO_VENTAS_31D_SP	DOUBLE	Promedio de ventas últimos 31 días del paquete sin promoción incluido
16	PROMEDIO_VENTAS_31D_CP	DOUBLE	Promedio de ventas últimos 31 días del paquete incluyendo promociones.

Fuente: *Elaboración propia, 2025.*

Para establecer el éxito de la promoción se analizar el promedio de ventas de los últimos 61 días sin considerar las ventas de los días donde se había realizado una promoción para el mismo paquete.

CAPÍTULO IV. RESULTADOS Y ANÁLISIS

4.1 INFORME DE PROCESO DE RECOLECCIÓN DE DATOS

El proceso de recolección de datos se llevó a cabo mediante la compilación de diversas bases de datos históricas, abarcando el periodo desde el 1 de enero de 2022 hasta el 31 de octubre de 2025. Esta compilación incorpora múltiples tablas de estructuran el sistema de promociones de paquetes, que proporcionan todas las configuraciones que necesarias para su funcionamiento, incluyendo las transacciones históricas de compras y asignaciones. A partir de estas tablas, se generó una tabla más completa, detallando las características de cada promoción y el resultado promedio a 31 y 61 días, así como las ventas del día de la promoción, comparando ambos registros estableciendo el éxito o no de la promoción según el indicador.

Una vez presentada la información disponible, se procedió a explorar y verificar los datos, permitiendo así realizar un primer análisis para determinar la consistencia y la completitud de la información recopilada. En su forma inicial, la data consiste en 13 variables y 7,800 registros.

4.2 RESULTADOS Y ANÁLISIS DE LAS TÉCNICAS APLICADAS

Luego del proceso realizado para la recolección de datos, se continuo con el análisis de los datos obtenidos, esto con el objetivo de realizar un análisis exploratorio de los datos para comprender como se encuentra la empresa y con qué variables se cuenta y sus comportamientos que puedan ser de interés para la investigación actual.

Se realizó un análisis EDA por sus siglas en ingles Exploratory Data Analysis, o Análisis Exploratorio de Datos la cual es una herramienta que se utiliza para examinar y analizar conjuntos de datos asegurando que los resultados obtenidos sean válidos y relevantes (IBM Corp., 2023).

El análisis exploratorio de datos permitió obtener una visión inicial del comportamiento habitual de las variables antes de aplicar cualquier técnica de evaluación. Este proceso tuvo como finalidad identificar la estructura y variabilidad de los datos, así como reconocer tendencias temporales, posibles anomalías y factores que pudieran afectar la medición del desempeño de las promociones.

Para ello se examinaron el promedio de transacciones de los 61 días previos a la fecha de cada promoción, las transacciones registradas durante la promoción y la variable que define su éxito. Este análisis permitió describir cómo se comportan las transacciones en periodos sin intervención de promociones del mismo tipo (mismo paquete, canal, entidad, etc.), distinguir patrones mensuales y

semanales, y verificar si las promociones generan aumentos respecto a su nivel de referencia.

Los resultados de este diagnóstico sirvieron como línea base para la definición de los criterios analíticos posteriores, respaldaron la elección del promedio de 61 días como línea de comparación y facilitaron la comprensión de los comportamientos previstos y atípicos dentro de la muestra.

4.2.1 DESCRIPCIÓN GENERAL DE LA MUESTRA

La base de datos utilizada para el análisis estuvo conformada por un total de **9,559** registros correspondientes a promociones ejecutadas durante el año 2025 (desde enero a octubre). Cada registro incluye información relativa a la fecha de la promoción (fecha inicio), el paquete en promoción, el tipo de promoción, el canal de venta, el valor de la promoción, las transacciones durante la promoción y los promedios históricos de transacciones en periodos de 31 y 61 días previos a la promoción, para el mismo paquete y canal asociado.

Esta sección presenta los resultados cuantitativos obtenidos a partir del análisis de las variables principales, con el objetivo de describir el comportamiento general de las promociones y establecer un punto de referencia para posteriores evaluaciones de éxito.

El Análisis Exploratorio de Datos nos permite comprender la estructura, comportamiento y calidad de los datos utilizados en la investigación. Buscando patrones tendencias y relaciones entre las variables, incluyendo valores atípicos y posibles inconsistencias. Esto para considerar los resultados y las formas de analizarlos.

Se calcularon estadísticos básicos para las variables cuantitativas más relevantes, incluyendo la media, mediana, valor mínimo, valor máximo y desviación estándar. Las variables analizadas fueron:

- **Transacciones durante la promoción** (ventas)
- **Líneas base de 61 días sin y con promoción** (AVG_61D_CP)
- **Líneas base de 61 días sin y sin promoción** (AVG_61D_SP)

Tabla 7 - Estadísticas descriptivas de variables numéricas

	<i>MEDIA</i>	<i>MEDIANA</i>	<i>MIN</i>	<i>MAX</i>	<i>DESVIACION ESTANDAR</i>
AVG_61D_SP	84.39	5.07	1	2311.67	244.79
AVG_61D_CP	113.49	5.95	1	2528.95	313.57
Ventas	96.38	8	1	2141	242.55

Fuente: *Elaboración propia, 2025.*

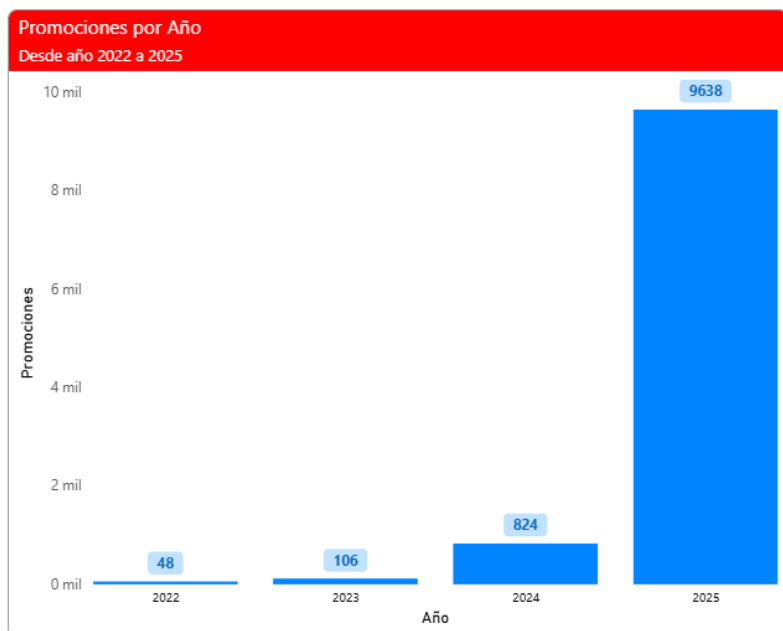
4.2.2 RESULTADOS CUANTITATIVOS

1. El 14.41% de las promociones no están alineadas con los resultados históricos de 61 días analizados, a pesar de que no tener resultados, se configuraron en meses posteriores.
2. Los paquetes de 13GB y 16GB son los que generan mayores ventas en promociones, mientras que los de 7GB presentan menor impacto, lo que sugiere preferencia por paquetes de mayor volumen y vigencia.
3. El éxito evaluando el promedio de ventas a 31 y a 61 días está altamente correlacionado, lo que indica que las promociones mantienen su efectividad en el tiempo.
4. Un porcentaje considerable de promociones (62.28%) muestra ventas igual a cero, lo que sugiere la necesidad de revisar la planificación y estrategia comercial.
5. El 22.58% de las promociones configuradas tuvieron ventas por debajo de su promedio diario de ventas en los últimos 61 días, lo que sugiere la necesidad de revisar la planificación y estrategia comercial.

4.2.2.1 LÍNEA TEMPORAL

4.2.2.1.1 DISTRIBUCION ANUAL

Ilustración 8 - Promociones año 2022 al 2025



Fuente: *Elaboración propia, 2025.*

Se ha identificado un aumento del 1,169.66% de la cantidad de promociones configuradas del año 2025 respecto al 2024.

Esta cantidad tan elevada de promociones de un año a otro fue producto de tratamiento realizado a solicitud del equipo de control interno, donde las promociones se configuran de una manera diferente a la anterior, es decir se configuran por día y anteriormente se realizaba por rango de fecha. Aunque es posible que también un crecimiento también sea por una estrategia comercial enfocada más agresivamente para los aliados comerciales.

Con esta afirmación, no podemos establecer una métrica de crecimiento confiable para medir el desempeño comercial respecto al número de promociones de un año respecto al anterior.

4.2.2.1.2 DISTRIBUCION MENSUAL

Ilustración 9 - Comportamiento mensual de promociones



Fuente: *Elaboración propia, 2025.*

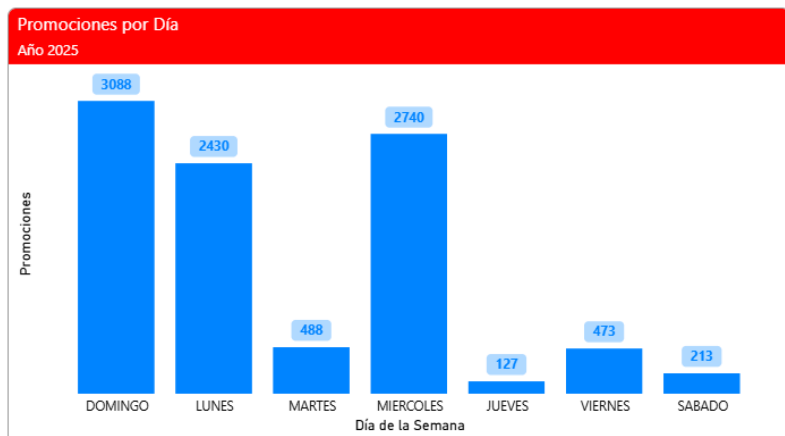
El análisis por mes muestra variaciones en el comportamiento de promociones. Los meses con mayor número de promociones es agosto con 1,720 y el mes con menor promociones fue mayo con 31, en promedio se configuraron 955.9 mensualmente.

Los datos muestran un patrón irregular, con meses de alta actividad de promociones (febrero, marzo, junio, julio, agosto, septiembre) y otros con caídas marcadas de promociones (enero, mayo, octubre). Estas variaciones podrían explicarse por varios factores, podrían ser factores externos de mercado y sociales e internas; las internas suelen ser por incumplimiento de objetivos en los resultados de las

promociones recientes, comercialmente las propuestas presentadas no han cumplidos con las expectativas presentadas y no son aprobadas.

4.2.2.2 DISTRIBUCIÓN POR DÍA DE LA SEMANA

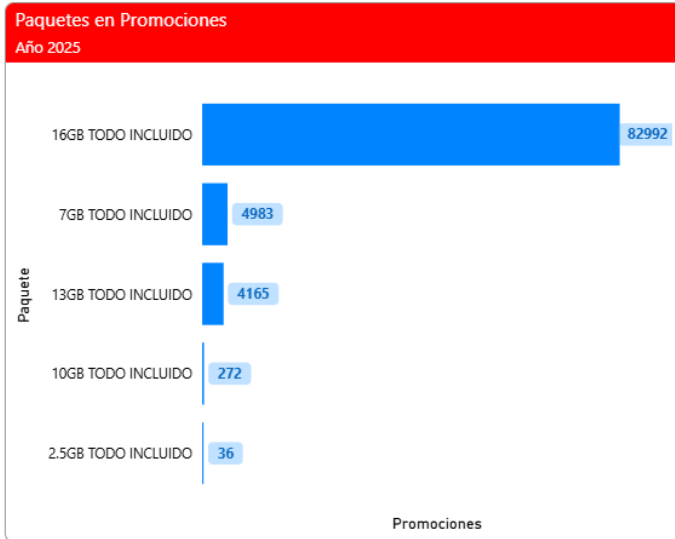
Ilustración 10 - Días de Promociones



Fuente: *Elaboración propia, 2025.*

El análisis de promociones por día de la semana muestra irregularidad bien marcadas para los días domingo, lunes y miércoles exponencialmente respecto a los demás días de la semana. La selección de los días para las promociones corresponde a dos factores: en primer lugar, se consideran los días que no concuerden con las promociones de saldo, que comúnmente son los martes, viernes y sábado. Y en segundo lugar el analista comercial selecciona el día más conveniente para el comercio considerando los días de bajo volumen de venta para el comercial y para la empresa. Uno de los objetivos de la promoción precisamente es ajustar lo más posible los ingresos regular para los días domingo, lunes y miércoles a los demás días.

Ilustración 11 – Promociones por Paquetes, año 2025




Fuente: *Elaboración propia, 2025.*

En la investigación se encontró que las promociones se enfocan en un 52.13% en dos paquetes, 16GB TODO INCLUIDO (L 125.00, 7 días) con un 41.34% y 7GB TODO INCLUIDO (L 64.00, 3 días) con 40.23%. La razón de esta gran predominancia es que comercial ambos paquetes forman parte de los paquetes más vendidos, por su accesibilidad económica (precio), vigencia y se adapta al consumo de datos (GB) promedio de los usuarios.

4.2.2.3 DISTRIBUCIONES

Ilustración 12 - Distribución de éxito de las promociones



Fuente: *Elaboración propia, 2025.*

Los resultados obtenidos evidencian que las promociones analizadas presentan un 89.48 % de éxito y un 10.52 % de no éxito. Este nivel de efectividad se determinó a partir de tres variables principales:

1. Promedio de transacciones realizadas en los 61 días previos a la fecha de inicio de la promoción, excluyendo aquellos días en los que se llevó a cabo otra promoción del mismo tipo.
2. Número de transacciones efectuadas durante el periodo de la promoción.
3. Criterio de evaluación del éxito: se considera que una promoción es exitosa cuando el número de transacciones registradas durante su vigencia supera el promedio de transacciones de los 61 días previos. En caso contrario, la promoción se clasifica como no exitosa.

Según (Hensel & Sikora, 2020) propone un enfoque basado en modelos predictivos para estimar la eficiencia de promociones, considerando múltiples indicadores de desempeño. Puede sustentar que la definición cuantitativa de “éxito” (ventas durante promoción vs promedio previo) es una forma válida, aunque también puede complementarse con modelos más avanzados.

En su artículo “*Sales lift from promotion*” (Sakhana, 2025) propone el cálculo de ascensor de ventas que usamos en nuestra investigación.

Debido a la falta de variables las cuales no son capturadas por los procesos de promociones, impide la aplicación de modelos más avanzados y nos quedamos con la evaluación del punto 3.

Ilustración 13 – Formula del cálculo de incremento de ventas

To calculate sales lift, use this formula:


$$\text{Sales lift (\%)} = \frac{(\text{Sales during promotion} - \text{Baseline sales})}{\text{Baseline sales}} \times 100$$

Fuente: Hensel & Sikora, 2020.

Para el punto 1, se consideran 61 días para considerar factores artificiales que puedan alterar el promedio, distribuyendo las variabilidades aleatorias en un periodo más amplio. Estos factores artificiales pueden ser factores sociales, climatológicos, políticos o comerciales que suelen existir, sobre todos aquellas que están establecidos con anticipación, como fiestas patrias, feriados fin de año,

semana mayor, entre otros. Estos factores pueden provocar extremos (mayores ventas o bajar en las ventas) afectando el promedio a corto plazo.

Ilustración 14 - Promociones por canales de ventas, año 2025.




Fuente: *Elaboración propia, 2025.*

En la continuación del análisis, se identificó que uno de los canales con mayor cantidad de promociones configuradas corresponde a un canal asociado a un servicio ESB. Este canal concentra aproximadamente el 99 % de las entidades o aliados comerciales dedicados a la venta de recargas y paquetes. Además, su estructura permite identificar de manera precisa a cada entidad que realiza transacciones, lo que facilita la aplicación individualizada de las promociones. Debido a estas características, resulta razonable que en este canal se haya asociado el 97.63 % de las promociones registradas durante el año analizado (2025).

Un bus de servicio empresarial (ESB) es un patrón arquitectónico en el que un componente de software centralizado realiza integraciones entre aplicaciones. Un ESB realiza transformaciones de modelos de datos, gestiona la conectividad, efectúa el enrutamiento de mensajes, convierte los protocolos de comunicación y gestiona potencialmente la composición de múltiples peticiones. El ESB puede hacer que estas integraciones y transformaciones estén disponibles como interfaz de servicio para su reutilización por aplicaciones nuevas. (ESB | IBM, 2021).

Ilustración 15 – Comparativo mensual de transacciones promedios con promociones y sin promociones en los últimos 61 días antes de las promociones



Fuente: *Elaboración propia, 2025.*


El análisis mensual de las promociones se complementó con una comparación histórica basada en los 61 días previos a la fecha de cada promoción. Para cada promoción configurada se calculó el promedio de transacciones correspondientes a los 61 días calendario anteriores, con el propósito de establecer una línea base que permitiera evaluar adecuadamente el comportamiento normal de las transacciones antes del día de la promoción.

Con el fin de obtener una referencia más precisa, se generaron dos medidas de línea base. La primera corresponde al promedio de transacciones considerando todos los días del periodo de 61 días, incluyendo aquellos en los que existieron promociones del mismo tipo (AVG con promoción). La segunda medida corresponde al promedio del mismo periodo, excluyendo los días con promociones activas (AVG sin promoción). Esta diferenciación permite identificar el efecto que las promociones previas pueden tener sobre el comportamiento natural de las transacciones y evitar posibles distorsiones en el cálculo del promedio base.

La gráfica elaborada presenta el promedio mensual de ambas líneas base, junto con una línea que representa el promedio general de la serie completa. Esta visualización facilita la identificación de

tendencias, variaciones estacionales (pero distribuidas en un periodo de 60 días) y posibles anomalías en el comportamiento de las transacciones antes de cada promoción, proporcionando así un insumo fundamental para la interpretación del desempeño de la promoción.

Ilustración 16 - Comparativo mensual de transacciones promedios con promociones y sin promociones en los últimos 61 días antes de las promociones, excluyendo promociones sin transacciones



Fuente: *Elaboración propia, 2025.*

Al excluir las promociones sin ventas o transacciones, se obtiene una visión más precisa del efecto real de las promociones activas. El incremento notable en los promedios de 40.87 a 126.31 para transacciones con promoción y de 26.89 a 93.39 para transacciones sin promoción indica que las observaciones válidas (es decir, aquellas con actividad real) muestran un comportamiento mucho más consistente y elevado que el reflejado cuando se incluyen promociones que no dan resultado y peor aún, no tiene ninguna venta.

Esto sugiere que la presencia de promociones efectivas tiene un impacto importante, pero también que existe un segmento de promociones que, al no generar movimiento, distorsionaba la media hacia abajo por sus bajas transacciones. La diferencia relativa entre ambos grupos se mantiene, reforzando la conclusión de que las promociones tienen un efecto positivo, pero solo cuando realmente se activan y generan ventas.

Ilustración 17 - Comportamiento de las transacciones y líneas base

Análisis de Promedios de Transacciones				
Año 2025, de marzo a octubre				
Mes	Promociones	AVG sin Promoción	AVG con Promoción	Delta
MARZO	1312	19.16	27.92	↑ 8.76
ABRIL	909	31.87	41.34	↑ 9.47
MAYO	31	3.98	4.51	↑ 0.53
JUNIO	1260	40.07	45.24	↑ 5.18
JULIO	1300	56.48	69.91	↑ 13.43
AGOSTO	1720	47.84	74.02	↑ 26.18
SEPTIEMBRE	1213	18.18	30.26	↑ 12.08
OCTUBRE	409	21.91	33.76	↑ 11.84
Total	8154	35.74	49.06	13.32

Fuente: *Elaboración propia, 2025.*


El análisis comparativo entre las transacciones registradas durante las promociones y la línea base de 61 días revela que las promociones generaron, en promedio, un incremento de 5.34 ventas respecto a los días sin promoción. Sin embargo, este efecto positivo se encuentra subestimado debido a un número considerable de promociones configuradas que no registraron transacciones, como ocurrió en julio con 743 promociones sin éxito y peor, que no tienen cero ventas.

La presencia de estas promociones sin ventas ejerce métricas a la baja sobre los promedios, reduciendo la visibilidad del impacto real que pueden tener las promociones exitosas. Cuando solo se consideran promociones con ventas, los incrementos en promedio se vuelven mucho más significativos, lo que evidencia una brecha clara entre promociones diseñadas y promociones realmente ejecutadas o relevantes para el negocio y de beneficio a los clientes.

Además, el comportamiento observado durante marzo y abril muestra que un mayor número de promociones no garantiza automáticamente un mayor volumen de ventas. A pesar de tener más promociones configuradas en marzo, el promedio de ventas fue inferior al de abril.

En conjunto, estos hallazgos indican que la estrategia promocional actual presenta problemas de eficiencia y focalización, y que una parte relevante de las promociones no está generando valor ni contribuyendo al crecimiento esperado de los aliados y de la empresa.

Ilustración 18 -Resultado mensuales de promociones




Fuente: *Elaboración propia, 2025.*

En los análisis previos se definió el criterio utilizado para determinar el éxito de una promoción, el cual consiste en verificar si las ventas generadas durante su ejecución superan el promedio correspondiente a los últimos 61 días de línea base. A partir de este criterio, la gráfica presentada evidencia que el éxito de una promoción no está garantizado. Una propuesta no adecuada a los resultados previos o un análisis insuficiente puede repercutir negativamente en las métricas, incrementar los riesgos y demandar recursos adicionales sin asegurar resultados favorables para la empresa. Este factor es relevante para el sustento de la investigación, ya que, aunque la media de promociones clasificadas como no exitosas alcanza un valor de 97 (muy bajo respecto a las exitosas), dicho resultado es considerable frente al esfuerzo operativo, tecnológico y comercial que implica la configuración y ejecución de una promoción.

4.2.2.4 CRUCES DE VARIABLES

Ilustración 19 – Relación de las variables: cantidad de promociones, exitosas y día semana



Fuente: *Elaboración propia, 2025.*

Como resultado del análisis anterior, el domingo es el día con mayor cantidad de promociones, las que tienen mayor éxito, es un buen día para lanzar promociones. Siguiendo de lunes y miércoles, aunque en análisis anterior se explica bien, los tres días mencionados con los que más promociones tienen y como resultado el éxito también es mayor.

4.2.3 ANÁLISIS CUALITATIVO

Posterior de revisar los resultados del Análisis Exploratorio de Datos se encontraron algunos comportamientos y características de las promociones.

1. El canal ESB concentra la mayor cantidad de promociones 96.62%, este canal agrupa el 97% de aliados o negocios para la venta de paquetes, bancos, farmacias, supermercados, gasolineras, portales web, etc.
2. Los paquetes 7GB TODO INCLUIDO y 16GB TODO INCLUIDO con el 92.26% concentran las promociones, esto porque las propiedades de estos paquetes (precio, duración y volumen datos) se adapta al consumo promedio de los clientes en el mercado.
3. Existe una estrecha relación para garantizar el éxito de una promoción y es el promedio de eventos en los últimos 61 días, esto es un indicador importante para predecir si la promoción tendrá éxito o no.
4. Los días que más promociones se programan son domingos, martes, jueves y sábado.

El equipo comercial en sus análisis indica que esos días muestran una baja en el consumo general del mercado prepago y por eso se trata de incrementar el consumo a través del incentivo de promociones. Resaltando que los martes, viernes y sábados son días de promociones de saldo, lo que entra en conflicto con las promociones de paquetes y reducen considerablemente las promociones de esos tres días.

5. Al analizar el resultado de las promociones de forma general, el promedio de ventas se ve afectado (hacia abajo) por promociones no exitosas donde no registran ventas, esto es importante para hacer un análisis de profundidad para descartar este tipo de casos para analizar de forma general el resultado.
6. A partir del análisis comparativo entre el promedio de ventas de los últimos 61 días previos a la promoción y las ventas registradas durante el día de la promoción, se observa que una proporción significativa de promociones cumple con el criterio establecido para ser consideradas exitosas. Este criterio clasifica una promoción como exitosa únicamente cuando las ventas del día de la promoción superan dicho promedio. No obstante, es importante mencionar que la presencia de promociones sin transacciones impide afirmar que el éxito esté garantizado; más bien, los resultados indican una tendencia favorable, aunque sujeta a variabilidad según el comportamiento específico de cada promoción.
7. Existe una notable baja de promociones para mayo, esto corresponde a acuerdos comerciales con aliados comerciales (Bancos, Farmacias, Gasolineras, Supermercados, etc.) para aprobar una estrategia.
8. El año 2025 tiene una marcada diferencias de promociones respecto a los años 2022, 2023 y 2024, esto fue debido a cambios en la forma de configurar las promociones, antes eran configuradas por rango de fecha y ahora de forma diaria, asimismo el crecimiento de alianzas comerciales ha permitido mayores promociones.

4.3 ANÁLISIS INFERENCIAL Y MODELOS APLICADOS

Texto. Como lo indica anteriormente, la siguiente investigación busca un modelo que pueda predecir si una promoción tendrá éxito o no en una posible planificación comercial. Basado en esto, se consideran los siguientes algoritmos:

1. Árboles de Decisión.
2. Regresión Logística.
3. Random Forest
4. Gradient Boosted

Para la creación de los modelos usando los algoritmos anteriormente planteados se usó la herramienta KNIME, se cargó la base de información obtenida de las promociones, está ya venía limpia, pero fue necesario hacer algunas conversiones de datos y eliminaciones de columnas con los nodos que la herramienta poner a disposición en los flujos.

Para el modelo se usó 70% de los registros para el entrenamiento y 30% para las pruebas, estos valores debido al notable desbalance entre ambas clasificaciones. Precisamente para crear ejemplos sintéticos de la clase minoritaria ($\text{exito_promocion} = 0$) ya que el desbalanceo lo ameritaba (88.68 / 11.32).

Para realizar la investigación se realizaron los cuatro algoritmos de predicción listados anteriormente, estos se entrenaron de dos formas distintas.

El resultado de las matrices de cada algoritmo en el modelo se detalla a continuación.

Ilustración 20 - Resumen General de resultados en entrenamiento de algoritmos

Estadística	Decision Tree	Logistic Regression	Random Forest	Gradient Boosted
Recall	97.24%	41.27%	76.88%	96.39%
Precision	98.19%	46.23%	92.94%	98.05%
Sensitivity	97.24%	41.27%	76.88%	96.39%
Specificity	97.24%	41.27%	76.88%	96.39%
F-measure	97.71%	39.07%	82.48%	97.20%
Overall Accuracy	99.03%	50.73%	93.88%	98.82%
Overall Error	0.97%	49.27%	6.12%	1.18%

Fuente: *Elaboración propia, 2025.*

CAPÍTULO V. CONCLUSIONES Y RECOMENDACIONES

5.1 CONCLUSIONES

1. Los factores que determinan el éxito o el fracaso de las promociones de paquetes en la empresa fueron identificados a partir de un análisis exploratorio exhaustivo y del desarrollo de un modelo predictivo en KNIME. Este proceso permitió reconocer las variables que más influyen en el desempeño de las promociones y posteriormente generar información cuantitativa confiable para el equipo comercial, especialmente en lo relacionado con el análisis y la programación de fechas adecuadas para su calendarización. Esta investigación brinda una base analítica que facilita anticipar la probabilidad de éxito de nuevas promociones y orienta la planificación en conjunto con los aliados comerciales y financieros de la empresa tomando en consideración estas variables o factores. Esto contribuye a una gestión más eficiente, al permitir que las decisiones se fundamenten en datos históricos, patrones de comportamiento y resultados de las promociones ya conocidas.
2. El análisis temporal de las promociones evidenció que la fecha (entre otras variables) de la promoción incide directamente en los resultados de esta. Considerando que la oferta de paquetes es reducida a 6 paquetes, predominando dos que son frecuentes, pero este no determina un peso sobre el desempeño de la promoción como si lo es la fecha. Se identificaron patrones y comportamientos específicos asociados a días de la semana, feriados y periodos de mayores porcentajes de éxito en las promociones que influyen directamente en la respuesta de los clientes. Esta comprensión del comportamiento le permite a la empresa programar promociones en momentos estratégicos de días, meses o periodos, maximizando el resultado (ventas) y evitando periodos donde históricamente se observó baja efectividad de las promociones. Por lo tanto, la correcta selección de fechas se reafirma como una variable clave para el éxito de las promociones y debe ser considerada como unas de las principales a tomar en cuenta para la planificación.
3. En el capítulo de aplicabilidad se plantea la propuesta de implementar un tablero interactivo en Power BI, junto con un modelo predictivo orientado a evaluar el desempeño esperado de futuras promociones. El tablero representa un aporte importante y valioso para el seguimiento, así como la gestión comercial, ya que consolida la información histórica de las promociones y

sus métricas de resultado una vez finalizadas estas. Además, permite visualizar promedios históricos, analizar el comportamiento de cada promoción y comparar su rendimiento con otras promociones que comparten las mismas configuraciones. Esta herramienta se convierte en algo esencial para la toma de decisiones basadas en datos. Por su parte, el modelo predictivo ofrece la posibilidad de anticipar la probabilidad de éxito de una promoción antes de ser realizada, considerando patrones identificados en los datos históricos y variables clave que influyen en el éxito o no de una promoción. De esta manera, el equipo comercial puede evaluar diferentes escenarios, ajustar sus estrategias y mejorar la selección de promociones con mayor potencial de impacto comercial e ingresos, reduciendo riesgos y fortaleciendo la efectividad de sus programaciones.

5.2 RECOMENDACIONES

1. Las promociones que tiene baja cantidad de eventos o transacciones (propuestas inferiores a las 25) se analizan por separado del universo de promociones, este grupo de promociones afecta negativamente los promedios y efectividad de las promociones realmente relevante para el negocio. Con las herramientas propuestas; tablero interactivo de Power BI y el modelo predictivo realizado en KNIME este grupo de promociones pone en evidencia y deben de ser analizadas si es necesario seguirlas realizando por su baja eficiencia y alto costo operativo.

2. Usar herramientas de análisis de datos como se plantea en la sección de aplicabilidad; como un tablero dinámico de Power BI para el monitoreo, análisis y evaluación de las promociones una vez finalizadas. Esto le permitirá mantener datos actualizados de las promociones durante el periodo establecido en sus planes y establecer un indicador clave basados en resultados históricos para establecer objetivos a corto y mediano plazo y a la vez ir creando una cultura de programación de promociones basados en datos que muestran los resultados reales.

3. Se recomienda al equipo comercial incorpore en su planificación mensual o semanal de promociones el análisis histórico de promociones que demuestran los resultados y mayores probabilidades de éxito. Así como incluir evidencias analíticas como el tablero de Power BI proporciona al finalizar las promociones, esto con el objetivo de sustentar las programaciones y mejorar los resultados, reducir la cantidad de promociones que no tienen éxito y que generan

carga operativa, que bajan la efectividad en general de las promociones.

4. Se recomienda mantener en constante evaluación y actualización de variables del modelo predictivo desarrollado en KNIME, incorporando nuevas variables, entrenamiento con datos de no más de seis meses y validaciones periódicas de desempeño. Se debe de considerar el modelo como una herramienta activa, que requiere entrenamiento constante con datos recientes para que sus resultados sea lo más apegado a la realidad comercial del negocio, especialmente cuando surgen cambios en patrones de ventas, comportamiento del mercado, nuevos productos o tipos de promociones que se integran y que antes no existían. De igual manera, se sugiere utilizar los resultados del modelo como evidencia requerida dentro del proceso de autorizaciones de promociones, permitiendo evaluar escenarios antes de su lanzamiento y reduciendo el riesgo financiero o comercial asociado a promociones con poca probabilidad de éxito.

CAPÍTULO VI. APLICABILIDAD

6.1 NOMBRE DE LA PROPUESTA

Medición de la Efectividad de Promociones Comerciales de paquetes mediante Analítica de Datos.

6.2 JUSTIFICACIÓN DE LA PROPUESTA

La propuesta nace de la necesidad del equipo comercial de contar con información que sirva de apoyo al momento de decidir qué promociones programar para los aliados comerciales. Actualmente, el equipo comercial no dispone de datos, ni indicadores que permitan evaluar el desempeño de las promociones realizadas en el pasado, como su nivel de éxito, la cantidad de transacciones generadas, los promedios históricos o el impacto por aliado o segmento. Esta falta de información dificulta entender cómo se comporta realmente el negocio y limita la posibilidad de planificar estrategias más efectivas.

Como resultado, las promociones se siguen programando sin un análisis previo y, en muchos casos, con bajos o nulos resultados, lo que aumenta la carga operativa y reduce la eficiencia general de las promociones. Frente a esta situación, la incorporación de un modelo predictivo y de un tablero interactivo de análisis se vuelve una necesidad, ya que permitirá anticipar el desempeño probable de cada promoción y dar seguimiento eficiente a los resultados.

La propuesta se justifica porque ofrece una herramienta basada en datos que ayudará a mejorar la planificación, aumentar la efectividad de las campañas y reducir la incertidumbre al programarlas. Al mismo tiempo, facilita una mejor coordinación con los aliados comerciales y permite aprovechar mejor los recursos disponibles. Ambas herramientas, vendrán a fortalecer la gestión comercial y contribuye a decisiones inteligentes y orientadas a resultados.

6.3 ALCANCE DE LA PROPUESTA

La propuesta contempla la implementación de un modelo predictivo y un tablero interactivo en Power BI orientados a fortalecer el análisis y la gestión de las promociones comerciales. El tablero integra las métricas más relevantes, los resultados históricos y las comparaciones entre promociones, lo que brinda al equipo comercial una visión más clara del comportamiento de cada promoción o segmento. En conjunto, ambas herramientas permiten evaluar de forma anticipada la probabilidad de

éxito de una promoción y dar seguimiento continuo a su desempeño una vez ejecutada. El alcance de la propuesta se centra en mejorar la capacidad analítica y de planificación del equipo comercial, proporcionando información que respalde decisiones más precisas sin sustituir los criterios estratégicos propios de la operación.

6.4 DESCRIPCIÓN Y DESARROLLO

6.4.1 DESCRIPCIÓN

Desarrollo e implementación de un Modelo predictivo mediante algoritmos de aprendizaje capaz de predecir el éxito o no de una promoción, la cual se determina si las ventas de ese día sean superiores al promedio diario de los últimos 61 días. De manera que el modelo predictivo servirá de apoyo para realizar programaciones más eficientes y aumentar las ventas de paquetes.

Para la creación del modelo e implementación es necesario realizar un análisis de datos, extracción, limpieza, transformaciones y procesamiento previos al entrenamiento de un algoritmo de aprendizaje. Posteriormente se realiza el entrenamiento del algoritmo y evaluar los resultados de la clasificación con las variables ingresadas. Una vez realizado el ajuste necesario de acuerdo con la evaluación de los resultados deseados, se realiza el proceso de implementación.

El tablero interactivo realizado es alimentado con la base de datos de las promociones actuales e históricas, se crean visualizaciones (graficas) de acuerdo con la métrica a medir, tomando la información de la promoción y vista desde diferentes perspectivas y cruzada con otras variables para encontrar correlaciones que puedan dar información importante para el analista. Una vez diseñado e implementado se publica el informe para que sea accesible por los usuarios que realizaran los análisis.

6.4.2 DESARROLLO

Desarrollo e implementación de un Modelo predictivo fundamentado en los descubrimientos de la investigación realizada, desarrollado y entrenado en KNIME (plataforma de análisis de datos) con un tablero interactivo desarrollado en Power BI para la visualización de datos de las promociones al finalizar su calendarización.

6.4.2.1 RECURSO HUMANO REQUERIDO

- **CIENTÍFICO DE DATOS**

- Profesional en Sistemas, Ingeniería o carreras afines.
- Experiencia de 2 a 4 años en analítica de negocios, ciencia de datos o estrategia empresarial, preferiblemente en el sector telecomunicaciones.
- Experiencia creando modelos predictivos y analítica.
- Dominio de herramientas de Python, KNIME, R y visualización de datos como Power BI, Looker Studio o Tableau.
- Liderazgo estratégico, pensamiento analítico e innovación orientada a resultados.

- **ANALISTA COMERCIAL**

- Profesional Administración de empresas, Negocios o carreras afines.
- Experiencia de 3 a 5 años en comercialización de productos y/o servicios masivos.
- Experiencia Análisis de ventas, planificación de objetivos y establecimiento y seguimiento de indicadores comerciales.
- Manejo de herramientas Office 365, CRM, Power BI.
- Organización, priorización y atención a detalles en datos.
- Pensamiento crítico y orientado a resultados.

- **ANALISTA DE DATOS**

- Licenciatura o técnico universitario en Sistemas, Ingeniería Industrial, Ingeniería en Sistemas, Informática, o afines.
- Diseño y mantenimiento de dashboards e informes analíticos.
- Análisis de datos operativos y comerciales.
- Dominio avanzado de herramientas de visualizaciones de datos como Power BI, Looker Studio o Tableau.
- Conocimiento SQL básico, Modelado de datos, DAX, Excel Avanzado y base de datos relacionales.
- Análisis de tendencias, variaciones y desempeño comercial.
- Pensamiento analítico y crítico
- Comunicación clara de insights

6.4.2.2 FASES DE DESARROLLO

6.4.2.2.1 MODELO DE PREDICCIÓN KNIME

1. Recolección y preparación de los datos

- Generación de información de la base de datos de promociones y exportarla.
- Importar los datos históricos de promociones (CSV Reader).
- Verificar que las variables relevantes estén disponibles.

2. Limpieza y preprocesamiento

- Eliminar registros duplicados o inconsistentes.
- Tratar valores faltantes (asignación de valores por defecto).
- Convertir variables categóricas a formato adecuado (One Hot Encoding).
- Normalización de variables numéricas (Z-Score).

3. Definición de la variable objetivo

- Establecer la columna objetivo (valor que se desconoce) que guardara si la promoción tiene **éxito** o **no éxito** (1 = éxito, 0 = no éxito).

4. División del conjunto de datos

- **Partitioning**, entrenamiento (70%) y prueba (30%)

5. Selección y configuración del modelo

- **Modelos de clasificación probados:**
 - Decision Tree Learner
 - Random Forest Learner
 - Logistic Regression Learner
 - Gradient Boosted Trees Learner
- Configurar el nodo seleccionando:
 - Variables predictoras.
 - Variable objetivo (éxito/no éxito).
 - Parámetros según sea el algoritmo para entrenar (profundidad del árbol, número de árboles, tasa de aprendizaje, etc.).

6. Entrenamiento del modelo

- Se conecta el conjunto de entrenamiento al nodo del o de los algoritmos seleccionados.

- Ejecución del nodo para generar el modelo entrenado.
- Visualizar estadísticas básicas del modelo.

7. Evaluación del modelo

- Conectar el conjunto de prueba al **Predictor correspondiente**.
- Evaluar los resultados:
 - **Scorer** (precisión, recall, F1-score, matriz de confusión)
 - **ROC Curve** (curva ROC y AUC)
- Validar si el algoritmo clasifica correctamente el éxito o no éxito de la promoción.

8. Ajustes y optimización

- Probar otros algoritmos y comparar resultados.
- Seleccionar el algoritmo con mejor rendimiento general.

9. Guardado del modelo entrenado

- Usar nodos como **Model Writer** para almacenar el modelo entrenado.

6.4.2.3 CONSTRUCCIÓN DEL MODELO

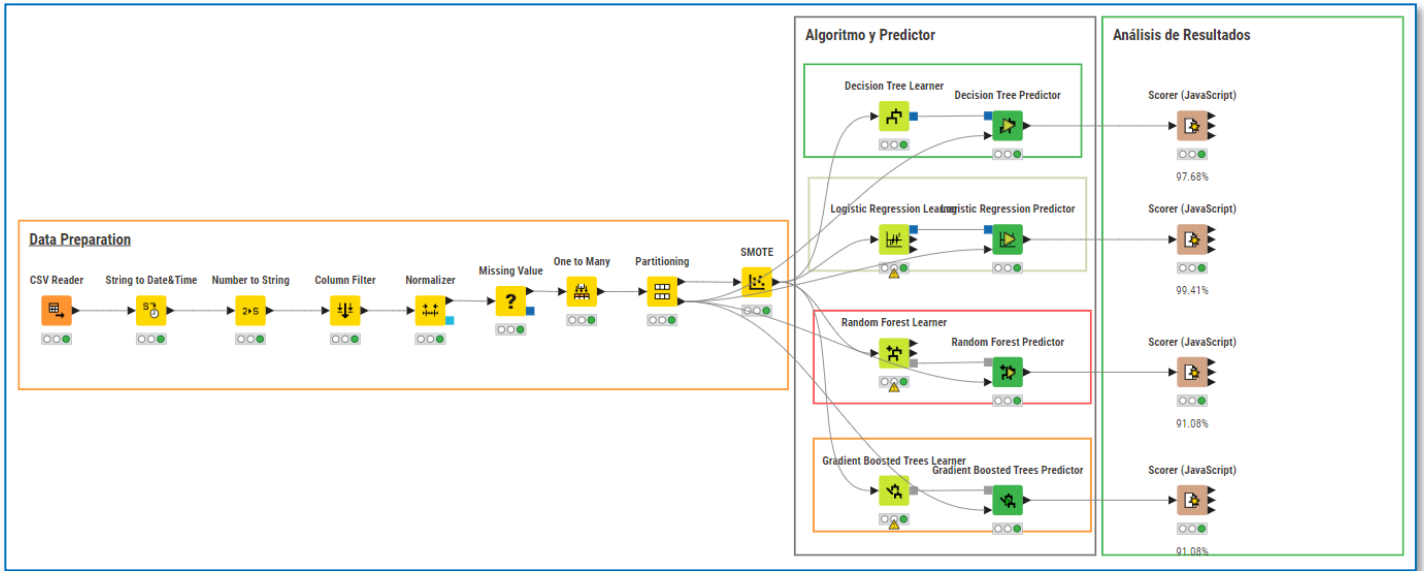
Para desarrollar el modelo con variables categóricas, se emplearon nodos de CVS Reader para importar el archivo con los datos proporcionados de promociones. Después, se realizaron conversiones de datos en las variables, String to Date, Number to String para optimizar lo mejor posible la capacidad del modelo en entrenamiento, asimismo filtrado de columnas para aquellas que no representaban influencia en el modelo. Se llevaron a cabo normalizaciones para las variables con mucho desbalanceo. Una vez completado la preparación de los datos, se realizó a la partición del conjunto de datos para entrenar el modelo.

El proceso de entrenamiento y predicción de los modelos se llevó a cabo mediante nodos especializados para cada uno de ellos. El proceso finalizado con la generación de la matriz de confusión que muestra los datos de manera clara los resultados obtenidos por el modelo.

Es importante mencionar que fue necesario el uso de un nodo, SMOTE para ajustar el desbalanceo de la clase `exit_promocion`, esto nos ayudara a tener mejores datos y balanceado para el algoritmo.

6.4.2.4 MODELO Y ALGORITMOS

Ilustración 21 - Modelo de Entrenamiento de algoritmos



Fuente: *Elaboración propia, 2025.*

6.4.2.5 RESULTADOS DE LOS ALGORITMOS DE PREDICCIÓN

En esta sección se mostrarán los resultados obtenidos por los modelos para seleccionar el mejor modelo que se ajuste para proponer una respuesta de que promoción podría ser exitosa después de que el modelo evalué cada una de las variables propuestas según su entrenamiento.

Ilustración 22 - Matriz de Confusión | Árboles de Decisión

Scorer View

Confusion Matrix

Rows Number : 1928	0 (Predicted)	1 (Predicted)	
0 (Actual)	205	6	97.16%
1 (Actual)	3	1714	99.83%
	98.56%	99.65%	

Class Statistics

Class	True Positives	False Positives	True Negatives	False Negatives	Recall	Precision	Sensitivity	Specificity	F-measure
0	205	3	1714	6	97.16%	98.56%	97.16%	99.83%	97.85%
1	1714	6	205	3	99.83%	99.65%	99.83%	97.16%	99.74%

Overall Statistics

Overall Accuracy	Overall Error	Cohen's Kappa (κ)	Correctly Classified	Incorrectly Classified
99.53%	0.47%	0.976	1919	9

Fuente: *Elaboración propia, 2025.*

Ilustración 23 - Matriz de Confusión | Logistic Regression

Scorer View

Confusion Matrix

Rows Number : 1928	0 (Predicted)	1 (Predicted)	
0 (Actual)	5	206	2.37%
1 (Actual)	6	1711	99.65%
	45.45%	89.25%	

Class Statistics

Class	True Positives	False Positives	True Negatives	False Negatives	Recall	Precision	Sensitivity	Specificity	F-measure
0	5	6	1711	206	2.37%	45.45%	2.37%	99.65%	4.50%
1	1711	206	5	6	99.65%	89.25%	99.65%	2.37%	94.17%

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
89.00%	11.00%	0.035	1716	212

Fuente: *Elaboración propia, 2025.*

Ilustración 24 - Matriz de Confusión | Random Forest

Scorer View

Confusion Matrix

Rows Number : 1928	0 (Predicted)	1 (Predicted)	
0 (Actual)	136	75	64.45%
1 (Actual)	4	1713	99.77%
	97.14%	95.81%	

Class Statistics

Class	True Positives	False Positives	True Negatives	False Negatives	Recall	Precision	Sensitivity	Specificity	F-measure
0	136	4	1713	75	64.45%	97.14%	64.45%	99.77%	77.49%
1	1713	75	136	4	99.77%	95.81%	99.77%	64.45%	97.75%

Overall Statistics

Overall Accuracy	Overall Error	Cohen's kappa (κ)	Correctly Classified	Incorrectly Classified
95.90%	4.10%	0.753	1849	79

Fuente: *Elaboración propia, 2025.*

Ilustración 25 - Matriz de Confusión | Gradient Boosted

Scorer View

Confusion Matrix

Rows Number : 1928	0 (Predicted)	1 (Predicted)	
0 (Actual)	200	11	94.79%
1 (Actual)	5	1712	99.71%
	97.56%	99.36%	

Class Statistics

Class	True Positives	False Positives	True Negatives	False Negatives	Recall	Precision	Sensitivity	Specificity	F-measure
0	200	5	1712	11	94.79%	97.56%	94.79%	99.71%	96.15%
1	1712	11	200	5	99.71%	99.36%	99.71%	94.79%	99.53%

Overall Statistics

Overall Accuracy	Overall Error	Cohen's Kappa (κ)	Correctly Classified	Incorrectly Classified
99.17%	0.83%	0.957	1912	16

Fuente: *Elaboración propia, 2025.*

Es muy importante hacer notar que del modelo realizado y usando los cuatro algoritmos los mejores resultados o precisiones fueron Decision Tree y Gradient Boosted, seguido de Random Forest con buenas estadísticas y por últimos Decision Logistic Regression con muy bajas precisiones, y es necesario recalcar que todos los algoritmos usan el mismo modelo (datos, transformaciones, normalizaciones, particionamiento de datos) y aun así los datos varían entre sí. Esto no indica que algunos algoritmos son sensibles a algún tipo de dato o no los trabajan muy bien y por eso el resultado de las matrices mostradas.

En base a los resultados, se puede concluir que Decision Tree y Gradient Boosted proporcionan herramientas precisas para identificar promociones que pueden tener éxito en un futuro según la planificación comercial, estableciendo con más certeza que el proceso que lleva la realización de una promoción valga la pena y que financieramente represente un beneficio económico y comercial a la empresa.

6.4.2.6 TABLERO INTERACTIVO POWER BI

6.4.2.6.1 PASOS

1. Carga de datos

- Conectar Power Query con la base de datos de promociones y ejecutar consulta de datos de promociones.
- Realizar las depuraciones, normalizaciones, filtros y asignar el tipo de datos para cada

columna.

2. Estructurar el informe

- Determinar la cantidad de páginas del informe.
- Clasificar las páginas de acuerdo con la métrica a ser analizada.
- Creación de estructuras de cada página (títulos, segmentaciones, etc.)

3. Creación de visualizaciones

- Creación de visualizaciones y/o gráficas para cada rol o página clasificada.
- Aplicación de filtros y segmentadores necesarios para la interactividad que tendrá el informe.
- Creación de marcadores para simplificar las consultas.

4. Aplicación de estilos corporativos

- Aplicación de diseños o plantillas para las páginas.
- Ordenar los objetos visuales aplicando diseño cognitivo.
- Configurar análisis de profundidad y otras funciones para mejorar la interacción y exploración de los datos por el usuario.

5. Publicación del informe

- Publicación del informe en portal local.
- Asignación de permisos para los usuarios que trabajaran con el informe.

6.4.2.6.2 DESARROLLO DE TABLERO INTERACTIVO

Carga de datos en Power Query

6.4.2.7 CAPACITACION

Para garantizar el uso adecuado del modelo predictivo entrenado, es necesario que el personal reciba una capacitación específica sobre su funcionamiento y los procedimientos asociados. Este proceso formativo incluye tres áreas principales:

1. Uso del modelo para generar predicciones

- a. Selección correcta de los campos requeridos.
- b. Ingreso y validación de los datos que alimentarán el modelo.
- c. Interpretación de los resultados generados.
- d. Extracción de las predicciones para su análisis posterior.

2. Entrenamiento y actualización del modelo

- a. Obtención de la información histórica de promociones utilizada como base de entrenamiento.
- b. Carga y preparación de los datos dentro del flujo del modelo.
- c. Reentrenamiento del modelo cuando se modifiquen variables o se incorporen nuevos datos relevantes de promociones.
- d. Análisis de resultados del entrenamiento, ajustes necesarios y evaluación del desempeño.
- e. Guardar e implementación del modelo actualizado para su uso operativo.

3. Uso del tablero dinámico en Power BI

- a. Interpretación adecuada de las métricas, visualizaciones y comparaciones entre promociones.
- b. Identificación de tendencias y análisis del comportamiento histórico para apoyar decisiones comerciales.
- c. Actualización de información para el tablero.

6.5 MEDIDAS DE CONTROL

6.5.1 INDICADORES Y MEDIACIÓN

Con el fin de garantizar que el modelo predictivo y el tablero interactivo funcionen de manera adecuada, se listan una serie de medidas de control orientadas a mantener la calidad de los datos y la integridad de los resultados. Estas medidas incluyen la revisión periódica de la información histórica utilizada para alimentar el modelo, así como la evaluación constante de los resultados del modelo mediante indicadores que permitan asegurar su consistencia. Cuando se detecten cambios importantes en el comportamiento comercial o se incorporen variantes, será necesario entrenar el modelo nuevamente para asegurar su vigencia y resultados más cercanos a la situación actual.

De igual manera, se establecen controles relacionados con el uso del tablero en Power BI, de modo que las visualizaciones reflejen la información más reciente y se interpreten a la realidad mostrada en los datos.

6.5.2 MODELO PREDICTIVO

- Para el entramiento del modelo predictivo se usó un dataSet con esta estructura:

No.	Variable (Campo)	Tipo de Datos	Tipo de Datos	Descripción
1	FECHA	DATE		Fecha de la promoción.
2	DIA	INTEGER		Dia de la semana de la promoción.

3	SEMANA	INTEGER	Semana del año de la promoción.
4	ID_PRODUCTO	INTEGER	Identificar único del paquete en promoción.
5	PAQUETE	STRING	Nombre del paquete en promoción.
6	TIPO_PROMOCION	STRING	Tipo, Volumen o Vigencia del paquete.
7	VALOR_PROMOCION	STRING	Factor, DOBLE o TRIPLE volumen de paquete.
8	CANAL	STRING	Canal seleccionado para ventas del paquete.
9	ID_ENTIDAD	STRING	Identificar único de la entidad en promoción.
10	ENTIDAD	STRING	Nombre de la entidad en promoción.
11	VENTAS	INTEGER	Ventas del paquete durante la promoción.
12	ÉXITO_PROMOCION	INTEGER	0=Fallido, 1=Éxito de la promoción.
13	PROMEDIO_VENTAS_61D_SP	DOUBLE	Promedio de ventas últimos 61 días del paquete sin promoción incluido
14	PROMEDIO_VENTAS_61D_CP	DOUBLE	Promedio de ventas últimos 61 días del paquete incluyendo promociones.
15	PROMEDIO_VENTAS_31D_SP	DOUBLE	Promedio de ventas últimos 31 días del paquete sin promoción incluido
16	PROMEDIO_VENTAS_31D_CP	DOUBLE	Promedio de ventas últimos 31 días del paquete incluyendo promociones.

- Particionamiento, 70% de los datos para entrenamiento y 30% pruebas, Draw randomly
- Para el algoritmo Decision Tree, parámetros usados fueron:
 - Quality measure: Gain ratio
 - Pruning method: No pruning
 - Min number records per node: 2
 - Number records to store for view: 10,000
 - Number threads: 8
- Valores de precisión del modelo predictivo para referencias y futuros entrenamientos:

Estadística	Decision Tree
Recall	97.24%
Precision	98.19%
Sensitivity	97.24%
Specificity	97.24%
F-measure	97.71%
Overall Accuracy	99.03%
Overall Error	0.97%

6.5.3 TABLERO INTERACTIVO

Insight Data es un tablero de control desarrollado en Power BI, diseñado para resumir y visualizar los resultados de las promociones programadas mediante el análisis de su comportamiento histórico. Este tablero presenta la información de forma gráfica e interactiva, facilitando la comprensión y el análisis de los datos por parte de los usuarios.

Las visualizaciones se construyen a partir de métricas obtenidas para cada promoción, tales como el promedio de ventas correspondiente a los 61 días previos a su ejecución, las ventas registradas en el día de la promoción, el tipo de paquete y la fecha de ejecución. Estas métricas permiten describir el desempeño observado de las promociones y analizar su comportamiento en distintos periodos de tiempo, sin establecer relaciones causales ni predictivas.

En la sección de Anexos se muestran los detalles y una descripción de lo mostrado.

Medida	Valor optimo
Hora actualización	6:00 a. m.
Promedio Mensual Promociones	955
Promedio Mensual Exitosas	906.28
Promedio Mensual NO Exitosas	112.88
Promedio transacciones por promoción	98.62

6.5.4 ANÁLISIS DE RENTABILIDAD DE LAS PROMOCIONES

La tabla siguiente muestra el análisis mensual (año 2025) del desempeño de las promociones de paquetes, donde se compara el promedio de ventas de los 61 días previos al día de la promoción, con las ventas durante el mes de las promociones (columna “Delta”). Además, se presenta un cálculo aproximado de impacto económico, comprendida como el ingreso adicional estimado de cada promoción, considerando la diferencia en ventas y el precio de venta de cada paquete. Los costos variables relacionados a la ejecución (en este caso, los costos de configuración no se consideraron por no contar con un valor real de ellos).

Tabla 8 - Análisis de Rentabilidad Promociones 2025

Mes	AVG Ventas 61d	Ventas	Delta	Impacto Económico
Marzo	25,137.60	23,924	↓ -1,213.60	✗ -L132,535.05
Abril	28,967.00	18,200	↓ -10,767.00	✗ -L1,216,407.93
Mayo	123.34	164	↑ 40.66	✓ L3,476.08
Junio	50,483.90	40,280	↓ -10,203.90	✗ -L909,907.35
Julio	73,425.04	58,149	↓ -15,276.04	✗ -L1,199,399.62
Agosto	82,282.74	75,595	↓ -6,687.74	✗ -L446,127.01
Septiembre	22,049.92	22,602	↑ 552.08	✓ L126,895.79
Octubre	8,961.92	8,983	↑ 21.08	✓ L18,223.46
Noviembre	53,856.18	54,089	↑ 232.82	✓ L137,663.78
Diciembre	54,081.12	57,633	↑ 3,551.88	✓ L381,132.68
Total	399,368.76	359,619	-39,749.76	-L3,236,985.17

Fuente: *Elaboración propia, 2025.*

La evaluación del desempeño de las promociones no se limita únicamente al volumen de transacciones generadas, sino que debe considerar el valor económico que dichas estrategias aportan a la empresa a través del incremento en los ingresos y la rentabilidad comercial como lo muestra el cuadro anterior. Sin embargo, existen beneficios asociados a estas promociones que no pueden cuantificarse de forma directa en términos monetarios.

Entre estos beneficios destaca que cada compra de paquete contribuye a reactivar el ciclo de vida del cliente dentro del servicio prepago, extendiendo su permanencia activa durante un período aproximado de 90 días. Este efecto permite mantener actualizado el parque de clientes, favoreciendo la continuidad del consumo y reduciendo la necesidad de ejecutar campañas intensivas de retención.

Por ende, se genera una disminución temporal en los niveles de abandono churn, fortaleciendo la estabilidad de la base de usuarios y optimizando la gestión comercial de la empresa.

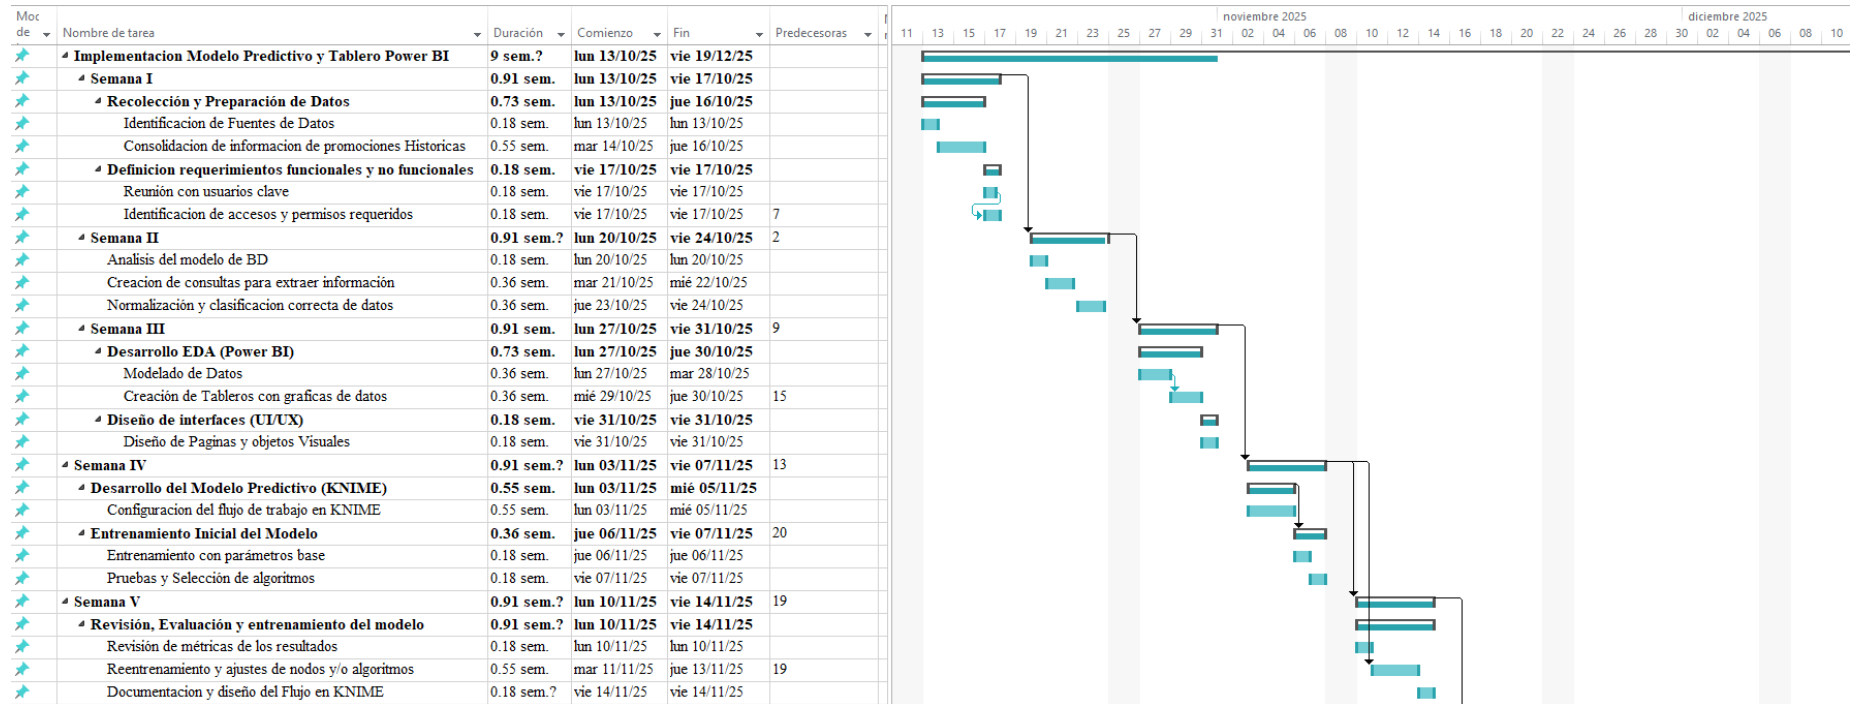
Este último efecto se presenta como una consecuencia indirecta del proceso de compra de paquetes. El tablero interactivo desarrollado y detallado en los ANEXOS y mencionado en la sección de aplicabilidad incorpora una pantalla de análisis denominada “**Focalizados**”, orientada a la identificación y promociones proactivas de clientes que comparten patrones de comportamiento o presentan alertas tempranas asociadas al riesgo de abandono (churn).

A través de este módulo analítico, se facilita la implementación de estrategias comerciales dirigidas, mediante promociones exclusivas diseñadas para incentivar la compra de paquetes y reactivar el consumo. Estas acciones buscan reducir la probabilidad de abandono, promoviendo la migración de los clientes desde estados de riesgo hacia segmentos de mayor estabilidad y permanencia dentro de la base activa de usuarios.

6.6 CRONOGRAMA DE IMPLEMENTACIÓN Y PRESUPUESTO


6.6.1 CRONOGRAMA

Ilustración 26 - Cronograma de actividades Semana 1 a 5



Fuente: *Elaboración propia, 2025.*

Ilustración 27 - Cronograma de actividades Semana 6 a 10



Fuente: *Elaboración propia, 2025.*

6.6.2 PRESUPUESTO

6.6.2.1 RECURSOS DE HARDWARE

No.	Elemento	Cantidad	Precio	Total
1	Dell Latitude 3410 Portátil 14”, Core i7 10Gen, Win11, 1.7Ghz, 16 GB, 256 SSD.	3	\$. 748.00	\$. 2,244.00
Total				\$. 2,244.00

Fuente: *Elaboración propia, 2025*

6.6.2.2 RECURSOS DE SOFTWARE

No.	Elemento	Cantidad	Precio	Total
1	Licencia PRO Power BI (12 meses)	1	\$. 24.00	\$. 288.00
2	Licencia KNIME PRO (12 meses)	1	\$. 19.00	\$. 228.00
3	Licencia Microsoft Excel (12 meses)	1	\$. 87.99	\$. 87.99
Total				\$. 603.99

Fuente: *Elaboración propia, 2025*

6.6.2.3 RECURSO HUMANO

No.	Elemento	Cantidad	Precio	Total
1	Científico de datos (12 meses)	1	\$. 807.00	\$. 9,684.00
2	Analista Comercial (12 meses)	1	\$. 692.00	\$. 8,304.00
3	Analista de datos Power BI (12 meses)	1	\$. 900.00	\$. 10,800.00
Total				\$. 28,788.00

Fuente: *Elaboración propia, 2025*

6.6.2.4 RESUMEN

No.	Elemento	Cantidad	Total
1	Recursos de hardware	1	\$. 2,244.00
2	Recursos de software	1	\$. 603.99
3	Recurso humano	1	\$. 28,788.00
Total			\$. 31,635.99

Fuente: *Elaboración propia, 2025*

6.7 CONCORDANCIA DE LOS SEGMENTOS DE LA TESIS CON LA PROPUESTA

Tabla 9 – Matriz de Concordancia

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías de Sustento	Variables	Poblaciones	Técnicas	Conclusiones	Nombre de la Propuesta	Objetivos Propuesta
Medición de la Efectividad de Promociones Comerciales de Paquetes de Datos Mediante Analítica de Datos	Desarrollar un modelo predictivo fundamentados en los resultados de la investigación, que permita al analista comercial programar promociones con más probabilidades de éxito, así como el análisis de resultados de las promociones finalizadas.	Diseñar un sistema que ayude a planificar y programar las futuras promociones de manera más eficiente basados en los resultados de los análisis y modelos aplicados.	<ul style="list-style-type: none"> • Teoría del Consumidor. • Segmentación de Clientes Mediante Teoría de Afinidad. • Teoría de la retención de clientes. 	<ul style="list-style-type: none"> • Fecha • Tipo de promoción • Canal • Negocio • Paquete 	La población se compone por 9,638 promociones del año 2025.	<ul style="list-style-type: none"> • Decision tree • Logistic Regression • Random Forest • Gradient boosted 	Se identificaron variables que influyen en el éxito de las promociones mediante un EDA y un modelo predictivo realizado en KNIME. Esto permitirá anticipar resultados y optimizar la calendarización.	Modelo predictivo para fomentar los ejercicios de promociones para una calendarización efectiva.	Se recomienda uso del modelo predictivo en KNIME para identificar y evaluar las promociones con más probabilidades de éxito y mejorar la eficiencia en la programación de promociones.

Fuente: *Elaboración propia, 2025*

Tabla 10 - Matriz de Concordancia (continuación)

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías de Sustento	Variables	Poblaciones	Técnicas	Conclusiones	Nombre de la Propuesta	Objetivos Propuesta
		Diseñar un sistema o método que ayude a planificar y programar las futuras promociones de manera más eficiente basados en los resultados de los análisis y modelos aplicados.	Teoría de la Medición del Desempeño de Promociones Comerciales	<ul style="list-style-type: none"> • Ventas promedios últimos 61 días. • Ventas promedios últimos 61 días sin promoción. • Ventas durante la promoción 	La población se compone por 9,638 promociones del año 2025.	Análisis comparativo pre y post promoción.	Evaluar la efectividad de las promociones mediante la comparación del desempeño histórico de 61 días previos frente al día de la promoción, facilita la identificación de promociones exitosas, la validación de resultados y la toma de decisiones comerciales basadas en evidencia cuantitativa.	Tablero Interactivo de Power BI.	Incentivar el uso de un tablero interactivo en Power BI para monitorear y evaluar el desempeño de las promociones mediante el análisis comparativo del histórico previo y los resultados obtenidos para sustentar la programación de promociones basada en datos.

Fuente: *Elaboración propia, 2025*

Tabla 11 - Matriz de Concordancia (continuación)

Capítulo I			Capítulo II	Capítulo III			Capítulo V	Capítulo VI	
Título Investigación	Objetivo General	Objetivos Específicos	Teorías de Sustento	Variables	Poblaciones	Técnicas	Conclusiones	Nombre de la Propuesta	Objetivos Propuesta
		Evaluar el impacto operativo y organización al del uso de modelos analíticos en el proceso de diseño, configuración y control de promociones, identificando oportunidades de mejoras y reducción de riesgos operativos y de control.		Éxito de promoción (NO / SI)	La población se compone por 9,638 promociones del año 2025.		Se identificaron variables que influyen en el éxito de las promociones mediante un EDA y un modelo predictivo realizado en KNIME. Esto permitirá anticipar resultados y optimizar la calendarización.	Modelo predictivo y tablero interactivo en Power BI.	Se recomienda realizar ejercicios de predicción de promociones en el modelo predictivo, también mostrar el resultado de promociones pasadas del mismo tipo y cliente para sustentar la decisión de aprobación o no de la calendarización de las promociones.

Fuente: *Elaboración propia, 2025*

REFERENCIAS BIBLIOGRÁFICAS

Atención al Cliente Claro | Claro Honduras. (s. f.). Recuperado 13 de marzo de 2025, de

<https://www.claro.com.hn/personas/atencion-al-cliente/>

Bernal Torres, C. (2022). *Metodología de la investigación* (Primera edición, 2022). Pearson.

Cabia, D. L. (2022, julio 5). *Socio estratégico*. Economipedia.

<https://economipedia.com/definiciones/empresas/socio-estrategico.html>

Ceupe. (2023, octubre 24). *¿Cuáles son los algoritmos de clasificación?*

<https://www.ceupe.mx/blog/cuales-son-los-algoritmos-de-clasificacion.html>

Chamba Jiménez. (s. f.). Recuperado 21 de marzo de 2025, de

<https://dspace.unl.edu.ec/jspui/bitstream/123456789/10462/1/Chamba%20Jim%C3%A9nez%20C%20Sairy%20Fernanda.pdf>

Conatel. (s. f.). *Sesión No. Xxx Página 1 de 33 Resolución NR0XX/22.*

<https://www.google.com/url?sa=t&source=web&rct=j&opi=89978449&url=https://www.conatel.gob.hn/wp-content/uploads/2022/10/Anteproyecto-de-Resolucion-NRXXX-2022-Modificacion-del-Reglamentos-de-Tarifas-y-Costos-de-Servicios-de-Telecomunicaciones-CA.pdf>

Conatel. (2016, enero 13). *NR003-16.*

www.conatel.gob.hn/doc/Regulacion/resoluciones/2016/NR003-16.pdf&ved=2ahUKEwjpcLu5IqMAXX7RjABHUigmNEQFnoECBwQAQ&usg=AOvVaw2gzhzjOoWGHeIvTmoxObFm

Conatel, 2022. (2023, agosto 9). *Estudio de Telefonía*. [https://www.conatel.gob.hn/wp-](https://www.conatel.gob.hn/wp-content/uploads/2023/09/Informe-FINAL_Estudio-de-Telefonia_version-publica_compressed.pdf)

[content/uploads/2023/09/Informe-FINAL_Estudio-de-Telefonia_version-publica_compressed.pdf](https://www.conatel.gob.hn/wp-content/uploads/2023/09/Informe-FINAL_Estudio-de-Telefonia_version-publica_compressed.pdf)

- Conatel, *Informe anual 2022*. (s. f.). Recuperado 12 de marzo de 2025, de <https://www.conatel.gob.hn/wp-content/uploads/2024/01/INFORME-ANUAL-DEL-SECTOR-DE-TELECOMUNICACIONES-2022.pdf>
- DataCamp. (2024, octubre 1). *Comprender la distancia euclidiana: De la teoría a la práctica*. <https://www.datacamp.com/tutorial/euclidean-distance>
- De Arregui, M. (2024, abril 29). *Clustering: Definición, tipos y aplicaciones empresariales*. OBS Business School. <https://www.obsbusiness.school/blog/clustering-definicion-tipos-y-aplicaciones-empresariales>
- Euclidean Distance | Formula, Derivation & Solved Examples*. (2025, marzo 1). GeeksforGeeks. <https://www.geeksforgeeks.org/euclidean-distance/>
- Fundamentos de Negocios, Nafin, 2004*. (s. f.). Recuperado 13 de marzo de 2025, de https://www.nafin.com/portalfn/files/secciones/capacitacion_asistencia/pdf/Fundamentos%20de%20negocio/Administracin/administracion2_1.pdf
- Godas, L. (2006, septiembre 8). *El ciclo de vida del producto*. https://gc.scalahed.com/recursos/files/r161r/w24792w/TV/GODAS_ciclo.pdf
- Han, Kamber y Pei. (2011). *Data Mining: Concepts and Techniques*. <https://shop.elsevier.com/books/data-mining-concepts-and-techniques/han/978-0-12-381479-1>
- Hernández- Sampieri, R. (2023). *METODOLOGÍA DE LA INVESTIGACIÓN. Las rutas cuantitativa, cualitativa y mixta* (Segunda edición).
- Hernández Sampieri, R., Baptista Lucio, P., & Fernández-Collado, C. (2006). *Metodología de la investigación* (4a. ed). McGraw-Hill.
- IBM. (2023, enero 15). *What is Exploratory Data Analysis? | IBM*. <https://www-ibm-com.translate.google/think/topics/exploratory-data->

analysis?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=tc

KNIME. (2025, febrero 1). *Open for Innovation* | KNIME. [https://www-knime-](https://www-knime-com.translate.google/?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=rq)

[com.translate.google/?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=rq](https://www-knime-com.translate.google/?_x_tr_sl=en&_x_tr_tl=es&_x_tr_hl=es&_x_tr_pto=rq)

Lastra, E. F. (2017, mayo 18). Cómo clasificar y segmentar a tus clientes. *artyco* | *the data driven*

company. <https://artyco.com/como-clasificar-segmentar-clientes/>

LATAM, S. (2023a, mayo 10). *What is customer retention?* Salesforce.

<https://www.salesforce.com/eu/learning-centre/customer-service/customer-retention/>

LATAM, S. (2023b, mayo 31). *Teoría del Consumidor: ¿qué motiva la conversión?* Salesforce.

<https://www.salesforce.com/mx/blog/teoria-del-consumidor/>

Lazzari, L. L. (2018). La segmentación de mercados mediante la aplicación de teoría de afinidad.

Cuadernos del CIMBAGE, 2, 27-44.

Luis Rodriguez. (2024, noviembre 19). *Telefonía celular en Honduras en 2024*. www.elheraldo.hn.

[https://www.elheraldo.hn/economia/cuantas-personas-cuentan-telefonía-celular-honduras-](https://www.elheraldo.hn/economia/cuantas-personas-cuentan-telefonía-celular-honduras-2024-BC22753714)

[2024-BC22753714](https://www.elheraldo.hn/economia/cuantas-personas-cuentan-telefonía-celular-honduras-2024-BC22753714)

Ortega, C. (2023, noviembre 7). Modelos de machine learning: Qué son, tipos y aplicaciones.

QuestionPro. <https://www.questionpro.com/blog/es/modelos-de-machine-learning/>

Redacción, E. C. (2025, febrero 28). *Decreto Legislativo 71-2017*. CONATEL aclara que validación

biométrica de SIM no implica nueva base de datos. [https://confidencialhn.com/conatel-aclara-](https://confidencialhn.com/conatel-aclara-que-validacion-biometrica-de-sim-no-implica-nueva-base-de-datos/)

[que-validacion-biometrica-de-sim-no-implica-nueva-base-de-datos/](https://confidencialhn.com/conatel-aclara-que-validacion-biometrica-de-sim-no-implica-nueva-base-de-datos/)

Richaud, A. (2024, febrero 7). *¿Qué es K-Means y para qué sirve?* [https://antonio-](https://antonio-richaud.com/blog/archivo/publicaciones/12-k-means.html)

[richaud.com/blog/archivo/publicaciones/12-k-means.html](https://antonio-richaud.com/blog/archivo/publicaciones/12-k-means.html)

Blattberg, R. C., & Neslin, S. A. (1990). *Sales Promotion: Concepts, Methods, and Strategies*.

Prentice Hall.

Aydın-Gökgöz, Z., Ataman, M. B., & van Bruggen, G. (2022). *The Rise of Mobile Marketing: A Decade of Research in Review. Foundations and Trends® in Marketing*, 17(3), 140-226.

<https://doi.org/10.1561/17000000077>

GSMA Intelligence. (2024). *Mobile network usage in Latin America*. [Report]. Recuperado de https://www.gsma.com/about-us/regions/latin-america/gsma_resources/mobile-network-usage-latin-america/

Ibe, M. I., & Chibunma, C. C. (2023). *Advertising strategies and customers' retention of telecommunication messages among users in Port Harcourt. BW Academic Journal*, 12. Recuperado de <https://bwjournal.org/index.php/bsjournal/article/view/1133>

Rurianto, J., Sumarwan, U., Suharjo, B., & Hasanah, N. (2021). *Mobile Advertising Modelling for Telecommunications Industry: Focusing on the Boosting of Value Co-creation. Journal of Telecommunications and the Digital Economy*, 9(4), 101-115.

Wassouf, W. N., Alkhatib, R., Salloum, K., & Balloul, S. (2020). *Predictive analytics using big data for increased customer loyalty: Syriatel Telecom Company case study. Journal of Big Data*, 7(29), 1-15. <https://doi.org/10.1186/s40537-020-00290-0>

Aydın-Gökgöz, Z., Ataman, M. B., & van Bruggen, G. (2022). *The Rise of Mobile Marketing: A Decade of Research in Review. Foundations and Trends® in Marketing*, 17(3), 140-226.

<https://doi.org/10.1561/17000000077>

GSMA Intelligence. (2024). *Mobile network usage in Latin America*. [Report]. Recuperado de https://www.gsma.com/about-us/regions/latin-america/gsma_resources/mobile-network-usage-latin-america/

Ibe, M. I., & Chibunma, C. C. (2023). *Advertising strategies and customers' retention of*

telecommunication messages among users in Port Harcourt. BW Academic Journal, 12. Recuperado de <https://bwjournal.org/index.php/bsjournal/article/view/1133>

Rurianto, J., Sumarwan, U., Suharjo, B., & Hasanah, N. (2021). *Mobile Advertising Modelling for Telecommunications Industry: Focusing on the Boosting of Value Co-creation. Journal of Telecommunications and the Digital Economy*, 9(4), 101-115.

Wassouf, W. N., Alkhatib, R., Salloum, K., & Balloul, S. (2020). *Predictive analytics using big data for increased customer loyalty: Syriatel Telecom Company case study. Journal of Big Data*, 7(29), 1-15. <https://doi.org/10.1186/s40537-020-00290-0>

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
<https://doi.org/10.1023/A:1010933404324>

Kuhn, M., & Johnson, K. (2013). *Applied predictive modeling*. Springer.

Wierenga, B., & van der Lans, R. (2017). *Marketing analytics: A practical guide to real marketing science*. Springer.

Kotler, P., & Keller, K. L. (2016). *Dirección de marketing* (15.ª ed.). Pearson Educación.

Hernández Sampieri, R., Fernández Collado, C., & Baptista Lucio, P. (2014). *Metodología de la investigación* (6.ª ed.). McGraw-Hill.

ANEXOS

Anexo 1: Tablero interactivo Power BI

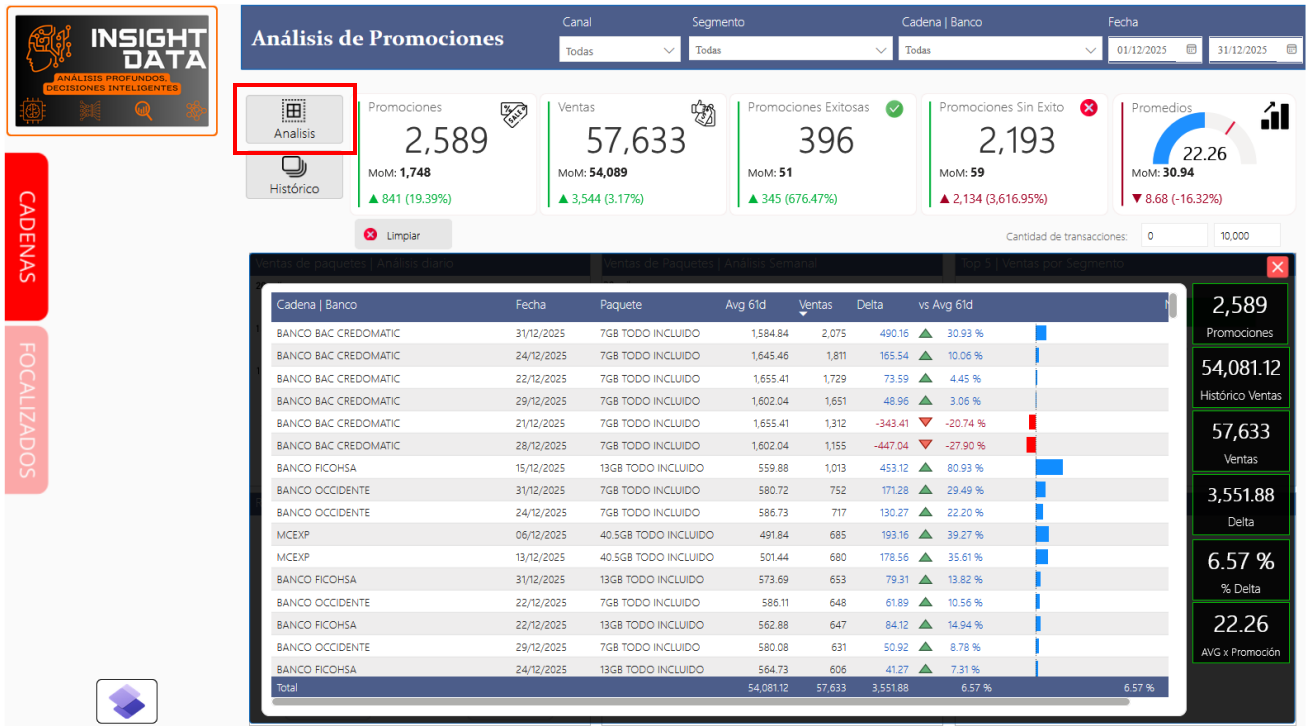


Descripción: pantalla inicial del informe, enfocado en la sección CADENAS las cuales corresponde a promociones para negocios como Bancos, Supermercados, Gasolineras, Billeteras electrónicas.

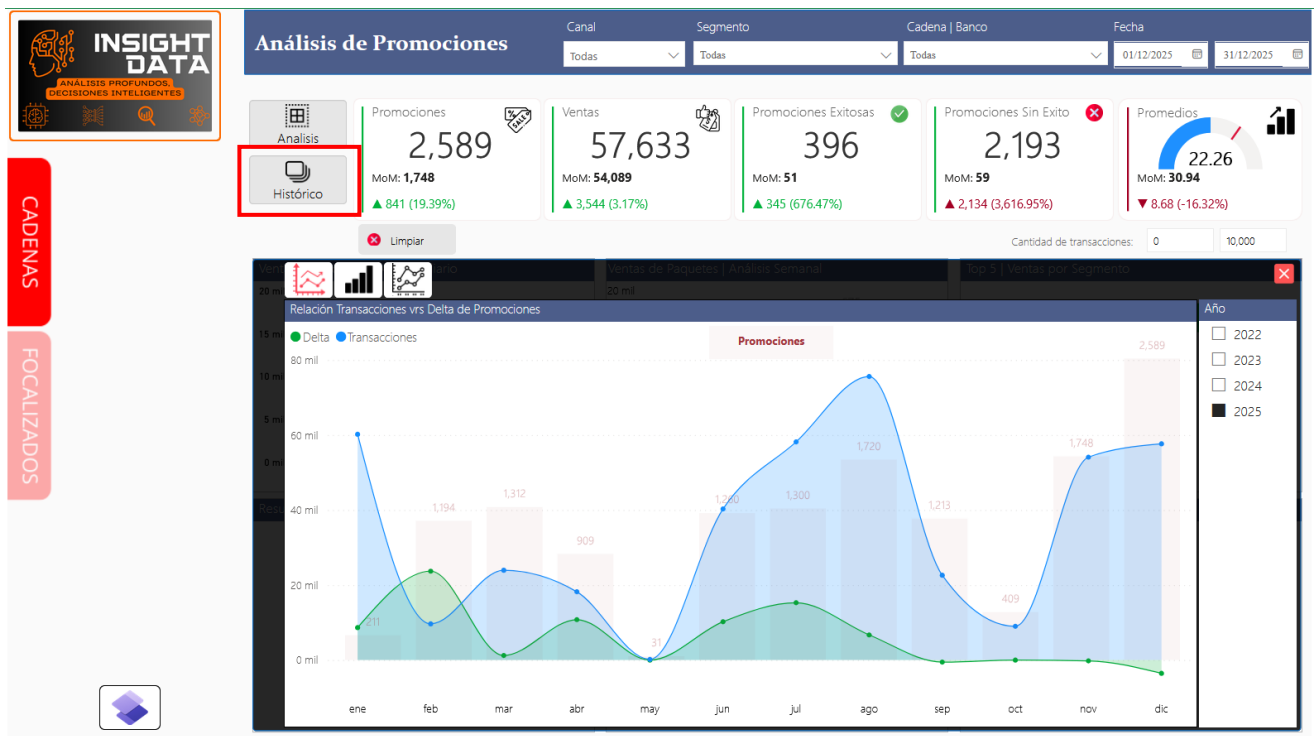
La sección 1 muestra el **Nivel Estratégico**; visión general y de alto nivel para tomar decisiones, muestra los valores del mes, el comparativo unitario del mes anterior y más abajo la variación unitaria y porcentual del mes en análisis versus el mes anterior.

La sección 2 muestra el **Nivel Táctico o Analítico**, orientado al análisis y seguimientos de los objetivos a mediano plazo, análisis comparativo de periodos y detectar tendencias y/o causas.

La sección 3 muestra el **Nivel Operativo**, muestra mas detalles de los resultados, sirve de monitoreo individual de cada promoción.



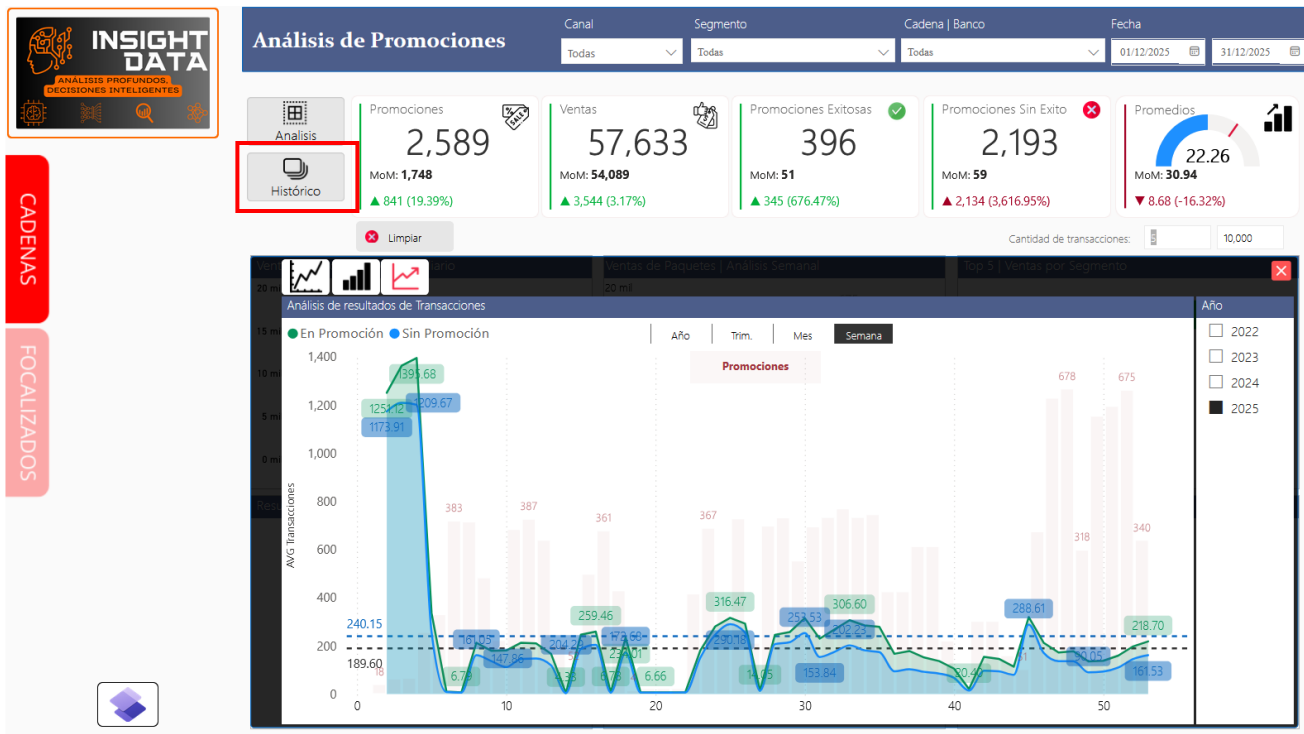
Descripción: Nivel Operativo: Se muestra al presionar el botón “Análisis”, muestra análisis detallado de cada promoción del periodo (fecha inicio y fin de los segmentadores)



Descripción: Se muestra al presionar el botón “*Histórico*”, la primera gráfica corresponde a la relación, cantidad promociones mensuales y el resultado de estas. El área verde corresponde a las ventas superiores al promedio de esa misma promoción 61 días antes de la fecha de ejecución. El área azul es la cantidad de ventas realizadas por esa promoción. Aquí se hace una relación de ventas, ventas adicional y cantidad de promociones por mes.



Descripción: Se muestra al presionar el botón “*Histórico*”, la segunda gráfica corresponde a la relación, cantidad promociones mensuales con el éxito o no de ellas. El segmento azul representa aquellas promociones que vendieron más que su promedio histórico de 61 días. El segmento gris, las que no vendieron más que su promedio, es decir vendieron el día de la promoción menos.



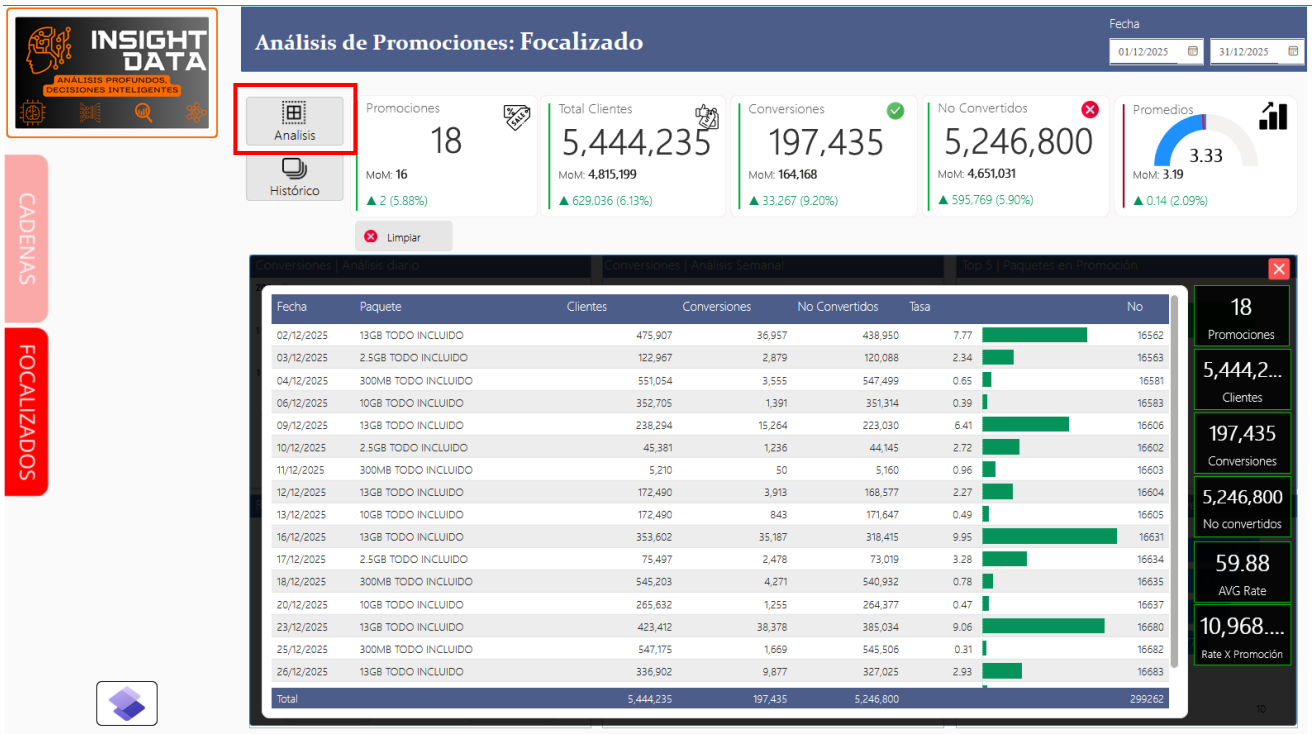
Descripción: Se muestra al presionar el botón “Histórico”, la tercera gráfica corresponde a la relación, cantidad promociones en el periodo de análisis que puede ser por Año, Trimestre, Mensual y Semanal. Las barras rojas al fondo representan la cantidad de promociones que se realizaron en ese periodo. El área verde representa el promedio de ventas en días de promoción. El área azul representa el promedio de ventas en días de NO promoción. Esto muestra una brecha, indicando que influencia tienen las promociones en los comercios para incrementar sus ventas. Sin el factor artificial de Promociones las ventas no incrementan orgánicamente.



Descripción: segunda pantalla del informe, enfocado en la sección FOCALIZADOS las cuales corresponde a promociones diseñadas para un grupo de clientes en particular. Las promociones configuradas solo tendrán validez para el grupo de clientes que sean asociados a través de su número de teléfono relacionados con la promoción.

Los indicadores de la sección estratégica se enfocan exclusivamente para estas promociones, realizando los mismos análisis que en la pantalla inicial. Relación de periodo actual versos el mes anterior.

Aquí se agrega un indicador nuevo, llamado *factor de conversión*, que son la cantidad de clientes que compran la promoción, dividido entre el total de clientes que aplicaban a la promoción.



Descripción: Se muestra al presionar el botón “Análisis”, análisis individual de cada promoción, mostrando los detalles de la promoción como fecha, paquete, clientes que aplicaban a la promoción, las conversiones (los clientes que compraron la promoción) y la tasa de conversión, con una barra mostrando gráficamente la tasa.



Descripción: Se muestra al presionar el botón “*Histórico*”, primera gráfica, muestra la relación de la cantidad de promociones creadas en el mes durante el año (barras color rojo) y la tasa promedio de conversión de las promociones en el mes (línea azul). Esto podría mostrarnos que tan efectivas fueron las promociones que realizamos durante el mes.



Descripción: Se muestra al presionar el botón “*Histórico*”, segunda gráfica, muestra la relación de la cantidad de promociones creadas en el mes durante el año (barras color rojo) y las conversiones realizadas en todas las promociones del mes (área verde).

Anexo 2: Modelo predictivo para uso del analista comercial

