

**Pontificia Universidad Católica del Ecuador
Facultad de Hábitat, Infraestructura y Creatividad
Maestría en Sistemas de Información mención Data Science**



Trabajo previo para la obtención del título de Magister en Sistemas de Información mención Data Science

Tema:

“Modelo predictivo para optimizar el tiempo de atención de ordenes de instalación y mantenimientos de servicios de redes fijas Gpon en Ecuador, basado en el indicador de calidad de customer experience”

Autor:

Mateo Nicolás Ospina Rivadeneira

Tutor:

Damián Aníbal Nicolalde Rodríguez Mg.

Quito – febrero de 2026

Introducción.....	3
Justificación.....	5
Planteamiento del Problema.....	7
Preguntas de la Investigación.....	9
Justificación del Enfoque.....	10
Objetivos.....	11
Marco Teórico.....	12
Metodología.....	16
Desarrollo.....	19
Conclusiones y Recomendaciones.....	47
Bibliografía.....	49
Anexos.....	52

INTRODUCCIÓN

En la actualidad, la infraestructura de redes de internet está bajo total dominio de las redes de fibra óptica “GPON” esta tecnología permite una conectividad de alta frecuencia con gran desempeño y con comparticiones distintas para distintos tipos de clientes, se encuentra en constante expansión por distintas empresas prestadoras de servicios de telecomunicaciones lo que hace que sea de fácil acceso con un costo accesible para todo tipo de mercado Bhais et al. (2025).

La instalación de un servicio de fibra óptica necesita ciertos procesos para completarse, primero la parte técnica y el aprovisionamiento de los sistemas integrados y permisos de servicio entre conexiones, al ser un flujo técnico muy repetitivo, pero con valores atípicos como cualquier actividad, logra relacionarse con Machine Learning y se genera una búsqueda de la eficiencia en la operatividad minimizando los errores que se producen día a día Arin et al. (2025).

La calidad es un factor clave para una empresa multinacional prestadora de servicios de telecomunicaciones, ya que la inversión por parte de la compañía va año a año desarrollando nuevas propuestas en un mercado altamente competitivo donde una recomendación hace la diferencia, los clientes valoran las experiencias que ofrezca la empresa muy aparte de la contratación del servicio de fibra óptica, les interesa que su opinión sea tomada en cuenta, que no les cueste trabajo generar un mantenimiento y mucho menos tener que esperar varios días entre otros, se convierte en un indicador que nos indica el índice de satisfacción del usuario hacia el servicio que contrató, aunque las empresas consolidadas que son grandes y poseen un músculo financiero fuerte para promover siempre el cambio atraviesan problemas como cualquier empresa pequeña, sesgar este tipo de inconvenientes se puede lograr mediante una planificación efectiva, las herramientas tecnológicas que se encuentran a disposición actualmente recrean escenarios para proyectarse a futuro y poder tener información en función al volumen neto generado en fechas anteriores, las métricas deben concluir con los factores que influyen en el diario de una operación nacional Anderson (2024).

Los canales comerciales que generan órdenes de instalación en distintos puntos del país tienden a ser variables debido a su personal variable, feriados, fines de semana, eventos especiales que generan al final del día incumplimiento por parte del área en sí y repercute directamente en el personal técnico que necesita de ese volumen para poder generar su planificación y netamente su trabajo, lo más importante es la relación con el cliente por n cantidad de tiempo, lo ideal es conseguir coordinar de manera efectiva e instalar la orden sin ninguna complicación, el nivel de servicio es una percepción de la cadena de valor que forma una instalación, mantener calidad se refleja en números que son medidos día a día, semana contra semana y mes contra mes, sin embargo, el más importante es poder atender órdenes en un rango de 0 a 24 horas ya que es la promesa directa con el cliente y en caso de existir escenarios distintos cumplir los objetivos del día a nivel individual y colectivo Farabi (2025).

JUSTIFICACIÓN

Las multinacionales ocupan una variedad de sistemas integrados que permiten digitalizar todos los procesos, sin embargo, la planificación futura a través de datos es una herramienta que permite tomar decisiones no solo a empresas grandes, incluso medianas o pequeñas, el objetivo es tener un panorama claro de los escenarios que atraviesa la empresa diariamente, un aspecto muy importante para la compañía es el chorn y lo que se monitorea netamente es que su valor no supere un porcentaje establecido, sin embargo, los motivos que reflejan ineficiencia deben ser revisados y corregidos, la fidelización de un cliente es un proceso que puede parecer complejo pero se define en momentos simples donde el cliente evalúa actitudes, tiempos de gestión, tiempos donde siente que su molestia está pasando desapercibida e incluso siente que la empresa no lo está considerando de la manera adecuada. Tomar decisiones en función a los datos nos da una visión clara de los problemas estructurales que está pasando el área técnica y que es responsabilidad de cada integrante levantar los números con peores resultados y copiar la estrategia de los mejores días, la disponibilidad de la red siempre está presente pero el servicio brindado es el que debe evaluarse al igual que sus relaciones aliadas como los contratistas Farabi (2025).

La resolución sencilla de problemas se transforma en eficiencia para el cliente, los puntos de mejora del área técnica influyen directamente en la experiencia de contratar un servicio, el modelo plantea adelantar las acciones a futuro como capacidades, cantidades, tiempos, etc., toda percepción puede atraer a mayor cantidad de clientes o incluso tener en un corto tiempo un cliente desertor, los servicios fijos y el rendimiento se engloban con la efectividad y para un usuario ser efectivo y realizar una pronta atención significa lealtad en el tiempo contratado Bhais et al. (2025).

Los modelos que abordan cantidades grandes de datos se realiza una revisión profunda en las tendencias, en crecimientos o decrecimientos en función a series temporales, el aspecto principal es el aprendizaje del modelo ya que los porcentajes de precisión nos indican que decisiones tomar.

Los modelos abordan las dudas que existen en una operación, estas predicciones son claves para lograr la eficiencia operativa y no tener escenarios donde por no haber controlado las variables influyan en la cadena de valor, estos algoritmos alcanzan valores muy acertados, cabe mencionar

que siempre existen los errores, por eso es importante ensayar entre herramientas cuál alcanza mejores resultados Ribeiro et al. (2024). Mejorar los indicadores del área técnica permite ordenar todos los parámetros además de tener el control y poder de decisión a través de cuadros de mando Anderson (2024).

En el país las empresas que gestionan y prestan sus servicios de telecomunicaciones tienen una infraestructura bastante compleja en cuanto a diseño de red, la inversión es fuerte y lo más importante es generar un rango de utilidad bastante alto, el mercado de contratación de servicios GPON sigue en crecimiento y las grandes empresas buscan crecer no en función al mercado sino al quedarse con la porción del mercado de otra empresa, la conectividad de alta velocidad supone solicitudes masivas, sin la organización necesaria podría colapsar la operación Arin et al. (2025).

La organización de los recursos técnicos es la parte esencial del flujo operativo ya que sostener picos de demanda, o caídas de la demanda, son escenarios que la empresa no puede tener el lujo de perder estas oportunidades, en ciudades como Quito y Guayaquil donde los clientes tienen trabajos más formales y exigen cumplimiento en el día y la franja horaria asignada, el modelo predictivo permitirá adelantarse a los hechos y tomar acciones en función a lo previsto, la promesa del canal de ventas con el cliente es prioridad, esto permite que los indicadores se orienten hacia la calidad de servicio.

PLANTEAMIENTO DEL PROBLEMA

Las diseño de las redes de fibra óptica brindan un mercado bastante amplio con distintas aristas del negocio, dividiendo redes masivas y corporativas según categorías, con la red a disposición de los canales de venta el insumo se genera de manera diaria ya tienen una meta por cumplir mensualmente y el área técnica debe tener todas las competencias para acompañar al negocio, la obligación de cumplir estándares de la empresa empuja hacia la mejora continua acompañada de medición de los objetivos, se pretende anticipar cuellos de botella evitando colapsos en zonas de alto flujo de órdenes Arin et al. (2025).

Según estudios muestra que los modelos aplicados a aprendizaje automático logran predecir patrones en series temporales en base a la información histórica, elevar las características técnicas del negocio a través de la optimización de procesos es favorable para cualquier entorno Faraji Googerdchi et al. (2024)

Los modelos con estructura lógica avanzada dimensionan de manera efectiva alcanzando valores muy favorables para la compañía, generalizar los escenarios del cliente es complicado ya que cada zona tiene su característica y se ponen a consideración en cuanto a la asignación de recursos técnicos Bhais et al. (2025) menciona que utilizar estas herramientas en tiempo real y fusionarlas con la operatividad de las instalaciones GPON del día a día es favorable debido a la predicción de comportamientos atípicos en el tiempo como la identificación de fallas previas por sector reduciendo tiempos de respuesta.

Anderson (2024) comenta que a través de los estudios enfocados al churn en distintas empresas de telecomunicaciones destaca que el uso de modelos predictivos basados en patrones de uso logra métricas de eficiencia muy altas entre el 70% y 90%, sin embargo, esto da un giro a la personalización y control operativo con el fin de mejorar.

Las herramientas puestas a disposición por el avance tecnológico deben ir de la mano de las compañías que buscan innovar y mejora de los procesos, estimar tiempos y eficiencias de servicios GPON enfrenta diversos factores ya que las condiciones del negocio no son estables debido a los múltiples cambios, el incumplimiento visto desde el cliente se debe a una mala coordinación, mala atención técnica o a una mala percepción del canal de ventas, la responsabilidad apunta

directamente al cumpliendo con todos los elementos que influyen en la instalación de un cliente masivo, pymes o corporativo, ya que lograr esto requiere de un control representado en gráficas.

PREGUNTAS DE INVESTIGACIÓN

- **Primaria:**

¿Un modelo predictivo que utiliza librerías de aprendizaje automático alimentado de una fuente de datos robusta de años pasados puede estimar capacidades e identificar patrones que permitan un mejor manejo del flujo operativo de instalaciones GPON alineados al cumplimiento de la promesa con el cliente?

- **Secundaria:**

1. ¿Qué factores influyen directamente con el incumplimiento de órdenes de instalación, planificación, coordinación, recursos mal georreferenciados, mala propuesta comercial, etc., cual de ellos afecta significativamente?
2. ¿Qué modelo es el más efectivo y con menor cantidad de error para emplear en una organización tan grande, Prophet, Random forest o XGBoost, cual me brinda mayor certeza al momento de tomar una decisión en base a datos?
3. ¿Cómo influyen los resultados del modelo en la cadena de valor, sin una vista que sea didáctica y de manejo simple para el entendimiento para toda el área, además de un monitoreo de tiempo real de las incidencias día a día?

JUSTIFICACIÓN DEL ENFOQUE

Las preguntas de la investigación se alinean a la búsqueda de resultados en corto tiempo con el fin de mejorar la experiencia del cliente, en la investigación de Faraji Googerdchi et al. (2024) permite apreciar que los modelos de evolucionan a través del aprendizaje y que pueden superar estándares y expectativas alcanzando verdaderos logros y valores eficientes en las métricas establecidas en el sector de telecomunicaciones, lo anterior sugiere que cuando exista un desbalance los datos pueden darte una guía sobre como operar a futuro. Ribeiro et al. (2024) menciona que la eficiencia de una empresa produce en el cliente lealtad y se mantiene por debajo los niveles de churn. Bhais et al. (2025) representan que el entorno de las telecomunicaciones de red GPON combinado con la analítica de patrones reduce tiempos muertos, retrasos en atenciones y resolución de fallas, mediante su uso el progreso es continuo.

El problema planteado es lógico ya que no se tiene control de las variables y no existe una delimitación de los procesos, lo que conlleva a generar errores operativos que luego se traducen en perdidas de oportunidades, a nivel masivo los datos son bastante claros ya que la organización no necesita un enfoque específico, al contrario, requiere de atención y control cual índice que afecte a la estadística de progreso en este caso serían las provincias pequeñas del Ecuador que aunque su margen es corto y podría llegar a ser descartable, sin embargo, la perdida de un cliente para una compañía representa una oportunidad para su competidor.

Para finalizar los resultados no pueden quedarse en simple análisis, el contexto debe contribuir a un mejor alcance de los objetivos de la empresa, generando valor totalmente empresarial Faraji Googerdchi et al. (2024).

Objetivo general

Desarrollar un modelo de aprendizaje basado en datos históricos de la compañía, que estime de forma precisa eventos futuros y permita planificar capacidades en función a la información, además de visualizar variables que influyen directamente en la cadena de valor de una instalación, además del monitoreo completo de la red GPON a nivel nacional buscando la eficiencia y la fidelización de los clientes a través de la calidad de servicio.

Objetivos específicos

1. **Identificar variables relevantes.** Recopilar y depurar datos históricos de órdenes de instalación y mantenimiento, incluyendo volumen de órdenes, disponibilidad de técnicos, tipo de servicios, ubicación geográfica, etc., analizar su influencia en el tiempo y el peso operativo de controlar dichas variables.
2. **Construir y evaluar modelos predictivos.** Aplicar diferentes algoritmos de aprendizaje automático como Prophet, Random Forest y XGBoost, verificar resultados y validar el mejor modelo en base a su precisión, error y relación con la realidad operativa.
3. **Analizar el impacto en la experiencia del cliente en gráficas.** Implementar tableros de control que registren las variables que influyen en el incumplimiento con el cliente y que además promueven mejoras basadas en datos, la interfaz de los datos estará conectada a un servidor de IBM para consumir de manera diaria en tiempo real en Tableau Server, mejorando la respuesta del área ante sucesos no planificados.

MARCO TEÓRICO

1. Ciencia de datos, analítica y tecnologías asociadas

El análisis de los datos se forma desde un punto de vista crítico, ya que permite identificar diversos escenarios, comportamientos y procesos para procesar una gran cantidad de información, su utilidad es muy amplia ya que tiene varios enfoques, sin embargo, del punto de vista estadístico representa datos en conocimiento, en varios sectores se hace uso de grandes cantidades de información como en ciencias de la salud, ciencias exactas, telecomunicaciones, comercio, entre otros, se mantiene como fuente de innovación para las empresas que buscan solucionar problemas y tomar decisiones acertadas. Zabala-Vargas et al. (2023) sostiene que la combinación de herramientas tecnológicas para preparar información, procesarla y concluir con decisiones estratégicas, todo dentro del marco de la productividad garantizando procesos óptimos de calidad.

Procesar información de manera ágil y precisa se vuelve un reto sin el uso de herramientas de aprendizaje, estos procesos permiten validar datos de forma dinámica y a través de gráficos ver resultados Lin (2025) Sostiene que los algoritmos de aprendizaje en flujos continuos de información no solo nos ayudan a interpretar resultados futuros, sino que también se adaptan a cambios como días feriados, caídas en ventas masivas, daños en la red, etc., permiten implementar estrategias que aguanten cualquier cambio en la organización por más brusco que sea, lo que hace es consolidar un área en función al poder de la información adaptándose a las necesidades.

1.1. Big data y sus dimensiones críticas

La integración de sistemas genera contenido de alto valor empresarial ya que tiene alta escalabilidad y análisis en base a tomar decisiones fundamentadas, el paradigma big data agrupa grandes volúmenes de datos con eficiencia, además de complementarse con diversas herramientas de programación. Madanchian (2024) sostiene que, en ecosistemas digitales como la analítica de información representa de manera acertada tendencias y realizando inspecciones de muestras es donde se concluye un objetivo.

1.2. Aprendizaje automático y paradigmas en evolución

La lógica de un modelo es alimentarse de una fuente de datos históricos que lo lleven a sacar conclusiones en función de las tendencias y patrones relacionadas a la operación, este suceso se lleva a cabo sin la necesidad de explicar el caso, al contrario, los datos brindan las respuestas. Kufel et al. (2023) señalan que, el nivel que ha alcanzado los modelos de big data son bastante favorables pero la generalidad de los cálculos todavía se mantiene, esto se debe al planteamiento de directrices erróneas y no se llega a consolidar la información requerida, las órdenes deben tener un grado de detalle aceptable o superior.

Existen cinco aristas sobre los algoritmos de aprendizaje automático:

- **Aprendizaje Supervisado:** Utilizado para clasificar y planificar
- **No supervisado:** Identifica escenarios atípicos dimensionados
- **Semisupervisado:** Control sobre volúmenes de datos agrupados
- **Aprendizaje por refuerzo:** Sigue una cadena de procesos
- **Aprendizaje profundo:** Orientado a estructuras altamente no lineales.

El desarrollo de los puntos mencionados forma parte en los modelos de big data ya que existen distintos parámetros que debe cumplir la información para el análisis en función a lo que se requiera encontrar.

1.3. Redes neuronales y aprendizaje profundo

Las conexiones entre modelos o interpretaciones representan una parte del funcionamiento lo que son las redes neuronales, ya que procesar variables no solo evaluándolas, sino que realiza detecciones que podrían pasar por alto de un simple modelo estadístico. Se utilizan en grandes empresas para revisar volúmenes grandes de datos caracterizadas por su constante aprendizaje Kufel et al. (2023) muestran que las distintas áreas técnicas como ingenierías, diseñadores, arquitectos, financieros y medicinas transforman su desempeño con el uso de herramientas TI. Santos (2023) recalca que la mejora en procesos se debe a la estructura de datos y al gobierno de datos, los cuales garantizan un flujo ordenado de la información y permiten obtener valores consistentes, los componentes técnicos se alinean con los modelos de redes neuronales.

1.4. Modelos generativos y su aplicación en análisis del consumidor

El avance de la inteligencia artificial se ha fortalecido debido a la necesidad de comprender la estadística de una empresa, más allá de encontrar buenos o malos resultados o de planificar en función al futuro. Nos permite tener una visión que recrean escenarios en los cuales podamos identificar nuevos patrones como comportamientos emergentes según calidad socioeconómica, fechas no consideradas en base al aprendizaje y que salgan de lo habitual e incluso emergencias que afecten directamente a la organización.

Entre los modelos más relevantes se encuentran:

- **GANs:** Comparativas de alto nivel y robusto aprendizaje
- **VAEs:** Funcionalidad de escenarios latentes y continuo aprendizaje
- **Transformers:** Uso en medidas de frecuencia con altas variaciones

Madanchian (2024) Sostiene que los modelos mejoran la percepción del cliente no sólo en la operatividad sino también en la percepción de la publicidad, en el comportamiento de asistentes virtuales o de cualquier herramienta que considere aprendizaje a través de una interacción.

2. Teorías y modelos aplicados al comportamiento del consumidor

2.1. Teoría del Comportamiento Planificado (TPB)

Sun y Moon (2024) Explican la capacidad y la intención sobre las decisiones del comercio electrónico evidenciando en la integración entre modelos altamente operativo y sistemas integrados de una empresa con el fin de desarrollar algoritmos robustos y predictivos que evalúen los elementos cognitivos del cliente, como medir niveles de satisfacción por cantidad de llamadas de quejas o relación de costo con permanencia en el tiempo. Comprende la unión entre variables matemáticas y factores sociales e incluso psicológicos con comportamientos que pueden ser adaptados a una estimación estadística y mejor aún proporcionando tal orientación al modelo.

2.2. Integración entre TPB y aprendizaje automático

La interpretación de las variables en conjunto con distintos criterios ha avanzado de forma significativa. Azad et al. (2023) demostraron que los modelos de aprendizaje automático influyen en los resultados debido a una mayor perspectiva sobre los consumidores, la

interpretación se vuelve más robusta ya que cuenta con distintos puntos de vista, las vistas futuras de los modelos se ven reflejadas en las variables que tomemos en cuenta para el cálculo.

2.3. Modelos de ML aplicados al marketing y comportamiento de compra

Pronosticar valores relacionados al marketing entre la arquitectura empresarial y las decisiones de expansión y de ventas, expansión técnica, permite reconocer lugares con mayor aceptación, probabilidad de ventas por canal, probabilidad de carrusel por georreferencia, por zona, etc.,

Lin (2025) señala que los algoritmos de machine Learning como XGBoost, CatBoost u otros poseen una eficiencia inusual frente al comportamiento de los datos, se puede alcanzar valores de rendimiento bastante confiables y enfocado a la parte técnica se traduce a clientes nuevos.

Existen n cantidad de herramientas que permiten supervisar cálculos obteniendo una profundidad en la investigación incluso mayor a la que se tenía planteada, en cuanto a los cálculos no supervisados nos arrojan distintas perspectivas en este caso como perfiles de clientes, rutas de mejor manejo técnico, puntos donde influye directamente el vendedor de manera crítica, entre otros.

3. Antecedentes relevantes

Los antecedentes nos permiten representar las necesidades del cliente, en cuanto a los datos de la compañía nos muestran patrones, tendencias temporales y modelos de proyección para una efectividad alta enfocada a la calidad de servicio.

1. **Integración TPB + ML (2023):** Permite identificar patrones en clientes como clientes que pueden quedar en mora o estado de servicio suspendido.
2. **Modelos supervisados en marketing (2025):** Comparten un análisis donde se segmenta los clientes por su perfil para ofrecer paquetes comerciales con mayor valor.
3. **Definiciones contemporáneas de data science y big data (2023–2024):** Gobernanza de datos y arquitectura organizacional se alinean a los objetivos del aprendizaje automático conjuntamente con la toma de decisiones.

METODOLOGÍA

Métodos de Recolección de Datos

Para realizar el modelo predictivo se utilizará información proporcionada por el departamento de Datos de Claro - Ecuador, los registros son un consolidado por Data Warehouse, estos bloques grandes de datos son un histórico de órdenes de instalación y mantenimientos recopiladas en bases de CRM desde el año 2024 hasta la tendencia de 2026, para poder emplear estos datos el servidor centralizado de IBM Netezza Server es la conexión directa entre los sistemas comerciales y sus bases, permite un manejo total de los datos según los cortes y carga de los datos previo a consumir, además habilita inteligencia al negocio con la representación de resultados y tendencias mediante gráficas Alfie y Blake (2024).

La operatividad de la empresa en el manejo de las instalaciones y los mantenimientos divide al país en dos regiones, R1: Representa todas las provincias de la Sierra y la Amazonía, en cuanto a R2: Representa toda las provincias de la costa incluyendo la región insular. Las propuestas de mejora se deben a la presión de los canales comerciales y sobre todo de la dirección TIC que mide indicadores semanalmente para ver crecimiento o decrecimiento y validar el motivo, las métricas operativas presentadas en Dashboards serán de conocimiento de toda el área técnica y nos permite manejar la operación en tiempo real, rescatar indicadores que semana a semana los vemos perdidos e impulsar la efectividad con su arista el tiempo de atención de las órdenes, todo esto con el fin de mejorar la experiencia del cliente al contratar un servicio en la compañía Lin (2025).

Se pretende comparar los datos históricos para poder realizar un análisis de variación de órdenes, capacidades operativas entre otras, la intención de monitorear todas las variables que influyen en la perdida de la cadena de valor y promesa con el cliente es mejorar en tiempo y forma todo el flujo de las instalaciones y mantenimientos, la evaluación de los contratistas que prácticamente son los embajadores de marca ya que son el fin de la cadena de valor en la contratación de un servicio debe ser adecuado. Las series temporales permiten realizar una evaluación del área también ya que debemos evidenciar el mejor día de la semana, la mejor semana del mes en curso, el mejor mes y no solo eso sino ver la tendencia y los factores que influyeron para poder lograr valores que cumplen con las expectativas del cliente, estos cambios exógenos son registrados y

estudiados y posterior a una planificación, la cuota de instalación asignada a cada técnico debe ser la correcta ya que existen variables que implican demoras o incluso adelantos en cantidades menores de actividades, cada técnico será medido por su carga individual y su impacto en tiempos de respuesta Onyejekwe (et al., 2024).

Técnicas de Análisis

Para comprender la información y que sea de utilidad para poda el área se emplearán distintas librerías de Python como Prophet que a través de un aprendizaje supervisado en series temporales planteadas, el algoritmo lo que plantea es una planificación en función de los datos compuestos como patrones, valores atípicos, inferencias entre otros, la fórmula es mixta lineal por tramos con senos y cosenos, además de variables tomando en cuenta estacionalidad, feriados en valores atípicos e inferencia bayesiana para dudas, en comparativa contra otros modelos como es random forest y XGBoost en función a los cálculos, esto brinda mayor consolidación de la información y certeza al momento de tomar una decisión y ver que modelo tiene mejores resultados a emplear Weiser (2025).

Mediante el análisis del modelo se plantea realizar Dashboards interactivos vinculados a las piscinas de información del servidor de IBM Netezza Server, dicha conexión debe establecerse con un bridge administrador en tiempo real y poder consumir datos de producción, las gráficas, historias y dashboards son representados en Tableau Desktop, al contar con los desarrollos necesarios se puede publicar los dashboards en Tableau Server, que permite visualizar el contenido, manipular filtros de interés, definir parámetros en las distintas localidades con el fin de mejorar la operatividad del área TIC de Claro – Ecuador y repercutiendo en mejorar el servicio al cliente al momento de contratar un servicio. En consecuencia, la unión de ambas herramientas como Python y Tableau reflejan un flujo operativo de una multinacional líder en el país en Telecomunicaciones y la complejidad de los factores que influyen en el incumplimiento de expectativas y promesas con el cliente, el volumen analizado de los datos aborda adecuadamente las dudas que surgen en el manejo de personal y empresas aliadas que por lo general pasan desapercibidos sin gráficas a evaluar día a día Lin (2025).

Finalmente, los puntos evaluados de la operación tienen relación ya que la mejora estará

monitoreada en tiempo real, en función de las decisiones tomadas por el modelo, Tableau permitirá que el personal del área identifique los puntos de mejora y un seguimiento más profundo a las empresas aliadas de la operación, esta validación entre Claro y sus filiales pretende una mejora continua en cada provincia, región y principalmente nacional. Las evidencias de la información aseguran resultados planificados Onyejekwe (et al., 2024).

Combinación de Herramientas TIC

Los datos brindados por Claro – Ecuador del departamento de Data Warehouse en vínculo con IBM Netezza Server, propone un flujo de información continuo lo que permite consumir gráficos en tiempo real interactivos para realizar comparativas de mejora. Emplear herramientas como los algoritmos de aprendizaje automático permite que el área técnica se consolide, además de nuevas ideas que pueden ir surgiendo a través de los flujos operativos, la gestión de instalaciones y mantenimientos pasará de tener un enfoque correctivo a uno proactivo, evitando escenarios que impactan a los números con los cuales son medidos, la mejora planteada desde los datos se vincula con la necesidad y comprende que el cliente debe ser la prioridad sobre todo brindar un servicio eficiente fortaleciendo la cadena de valor.

DESARROLLO

Análisis y Pronóstico de la Operación Claro – Ecuador

1. Instalamos los paquetes necesarios para el análisis de los datos proporcionados.

```
# Instalar Librerías
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from datetime import datetime

# Opcional para modelos de series temporales:
try:
    from prophet import Prophet
except ImportError:
    Prophet = None

from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import classification_report
```

2. Instalamos los paquetes necesarios para el análisis de los datos proporcionados.

```
from google.colab import files

# 1) Subir archivo desde tu PC (te abre el selector)
uploaded = files.upload()

# 2) Tomar el nombre del archivo subido (el primero)
csv_name = list(uploaded.keys())[0]
print("Archivo cargado:", csv_name)

# 3) Leer el CSV
df = pd.read_csv(csv_name)

# 4) Convertir columnas de fecha a datetime
date_cols = [
    'FECHA_REGISTRO_TICKET', 'FECHA_CREACION_ACTIVIDAD',
    'FECHA_AGENDAMIENTO_INICIAL', 'FECHA_AGENDAMIENTO',
    'FECHA_INICIO_ACTIVIDAD', 'FECHA_FIN_ACTIVIDAD'
]

for col in date_cols:
    df[col] = pd.to_datetime(df[col], errors='coerce')

# 5) Calcular duración en minutos
df['DURATION_MIN'] = (df['FECHA_FIN_ACTIVIDAD'] -
df['FECHA_INICIO_ACTIVIDAD']).dt.total_seconds() / 60

# 6) Derivar columnas útiles
df['YEAR'] = df['FECHA_REGISTRO_TICKET'].dt.year
df['MONTH'] = df['FECHA_REGISTRO_TICKET'].dt.month
df['WEEK'] = df['FECHA_REGISTRO_TICKET'].dt.isocalendar().week
df['DAY_OF_WEEK'] = df['FECHA_REGISTRO_TICKET'].dt.day_name()
```

```
df['IS_BROWNFIELD'] = (df['BROWNFIELD'] == 'SI').astype(int)

print("Datos cargados. Filas:", df.shape[0], "| Columnas:", df.shape[1])
df.head()
```

Propósito del código:

Se ejecuta una validación de los datos y campos vacíos además que la información de las órdenes de trabajo son reales, sin embargo, fueron randomizadas el código de la OT ya que esa identificación de orden se considera un dato sensible que se asocia a un cliente y a su cédula según el ente regulatorio de telecomunicaciones ARCOTEL, sin embargo, no influye para los otros campos.

3. Análisis de variables que intervienen de manera operativa diariamente en el flujo de instalaciones Gpon

```
# Asegura YEAR
df['YEAR'] = df['FECHA_REGISTRO_TICKET'].dt.year

def resumen_por_anio(anio):
    dfx = df[df['YEAR'] == anio].copy()

    # 1) Duración de finalizados
    completed = dfx[dfx['ESTADO_DEL_TICKET'] == 'finalizado']
    print(f"\n===== AÑO {anio} =====")
    print("1) Duración (min) SOLO tickets FINALIZADOS:")
    print(completed['DURATION_MIN'].describe())

    # 2) Conteo por día y tipo (solo muestra 5 días como ejemplo)
    daily_counts = dfx.groupby([dfx['FECHA_REGISTRO_TICKET'].dt.date,
                                'TIPO_ACTIVIDAD']) \
        .size().unstack(fill_value=0)
    print("\n2) Conteo de tickets por DÍA y TIPO (primeras 5 filas del año):")
    print(daily_counts.head())

    # 3) Proporción Brownfield en instalaciones
    instalaciones = dfx[dfx['TIPO_ACTIVIDAD'] == 'inst']
    if len(instalaciones) > 0:
        prop_bf = (instalaciones['BROWNFIELD'] == 'SI').mean()
    else:
        prop_bf = np.nan
    print(f"\n3) Proporción Brownfield SOLO en instalaciones: {prop_bf:.2%}")

    # 4) Vendedores necesarios (CORRECTO: por MES dentro del año)
    # 1 vendedor = 20 ventas/mes
    dfx['YEAR_MONTH'] =
dfx['FECHA_REGISTRO_TICKET'].dt.to_period('M').astype(str)
    ventas_canal_mes =
dfx.groupby(['YEAR_MONTH', 'CANAL_VENTA']).size().unstack(fill_value=0)
```

```

vendedores_canal_mes = np.ceil(ventas_canal_mes / 20)

print("\n5) Vendedores necesarios por CANAL por MES (top 3 meses con
más demanda total):")
top_meses =
ventas_canal_mes.sum(axis=1).sort_values(ascending=False).head(3).index
print(vendedores_canal_mes.loc[top_meses])

# Ejecutar por año
for anio in [2024, 2025, 2026]:
    resumen_por_anio(anio)

```

Propósito del código:

Tabla 1.

Órdenes finalizadas del año 2026, tiempo de gestión técnica.

Órdenes	Time Slot	Año
13.188 órdenes finalizadas	Promedio de 2 horas por instalación	2026

Nota: De la muestra de órdenes entre los diferentes estados se establece un promedio de 2 horas por instalación en el año en curso.

Operatividad

Tabla 2.

Cantidad ideal de instalaciones para evitar cuello de botella.

Conclusión	Time Slot
3–4 órdenes/día	2 horas máximo o menor – Tiempo ideal
5 órdenes por técnico/día.	2 horas exactas o mayor – Tiempo ajustado
2 – 3 órdenes/ día	3 horas órdenes – Tiempo Excesivo.

Nota: Escenarios de tiempo en órdenes

- Acometidas en Edificios
- Ductos
- Cable Drop mayor a 250 metros

Tabla 3.

Demanda Diaria

Instalaciones	Mantenimientos	Garantías
300/330	150/165	40/50 garantías
instalaciones/día	mantenimientos/día	generadas/día

Nota: En base al histórico se puede establecer un rango de confianza que promete valores en función a días pasados para poder tener una idea de los escenarios futuros.

Tabla 4.

Migraciones de clientes con tecnología HFC a GPON

BrownField	Capacidad
1 de cada 5 Instalaciones	2 – 3 órdenes/día

Nota: BrownField tiene mayor tiempo de gestión que Greenfield

- a. Más complejidad por ser doble trabajo, desinstalación y posterior instalación GPON
- b. Más probabilidad de extender duración debido al corte de la acometida anterior

Análisis

La cadena operativa de instalaciones tiene una estabilidad en función de la cantidad de órdenes que vayan generando los canales comerciales, el insumo debe generarse para poder tomar decisiones sobre el personal técnico ya que no se puede asignar capacidades técnicas en sectores donde no vayan a activar códigos de ventas, esto provoca que la cuadrilla se retire del sitio sin soporte y cuando exista la orden ya no se cuenta con el recurso en la ubicación, la relación es definitivamente funcional y permite que los intereses de la empresa se cumplan de ambas partes.

4. Pronóstico para una de las ciudades del Ecuador que genera mayor insumo de servicios fijos

```

from prophet import Prophet

# Tomamos un ejemplo: pronóstico para Guayas, franja "7AM - 10AM"
provincia = 'Guayas'
franja = '7AM - 10AM'

df_franja = df[(df['ID_PROVINCIA_DESCRIPCION'] == provincia) &
(df['FRANJA_HORARIO_INICIAL'] == franja)]
df_franja['DATE'] = df_franja['FECHA_REGISTRO_TICKET'].dt.date

# Serie diaria de tickets
daily_series = df_franja.groupby('DATE').size().reset_index(name='y')
daily_series.columns = ['ds', 'y']

# Entrenamos un modelo Prophet
model = Prophet()
model.fit(daily_series)

# Pronosticamos los próximos 30 días
future = model.make_future_dataframe(periods=30)
forecast = model.predict(future)

```

```

print(f"📅 Pronóstico de tickets diarios para {provincia} ({franja}) -  
próximos 30 días:")
print(forecast[['ds', 'yhat']].tail())

# Opcional: graficar
model.plot(forecast)
plt.title(f'Pronóstico para {provincia} - {franja}')
plt.show()

```

Análisis

Tabla 6.

Predicción de tickets diarios.

Año	Tickets
2024	25 – 30 tickets/día
2025	45 – 48 tickets/día
2026	48 – 50 tickets/día

Nota: Forecast de Demanda en base a los valores presentados se adjunta los siguientes análisis:

- Capacidad establecida para 48 órdenes en el año en curso no logra cumplir el flujo operativo en caso de aumento.


- b. Capacidad establecida para 55 órdenes se estabiliza y se podría decir que es un punto de equilibrio entre cumplimiento.
- c. Capacidad establecida para poder cumplir con los requerimientos del área comercial y realizar adelantos mejorando la percepción del cliente.

Conclusión

Un modelo que funciona con series temporales en base a evidencia histórica nos permite tener una visión sobre el nuevo régimen de alta demanda ya que el área comercial ha evolucionado en los años y va con tendencia creciente así que la planificación técnica se vuelve un factor clave para poder desempeñar eficientemente la operatividad de las órdenes, En el caso de Guayas no es una fase creciente común, al contrario, se encuentra a un nivel comercial mucho mayor al anterior, si planificamos con capacidades pasadas no vamos a lograr los cumplimientos del área técnica, del área comercial y sobre todo el incumplimiento con el cliente.

Figura 1.

Forecast de Demanda Guayas franja inicial 7am – 10am.



Nota: Evolución de tickets generados en Guayas a través de los canales de venta de Claro - Ecuador

5. Matriz de pronósticos para cada provincia con las variables consideradas anteriormente.

```
#Establecemos paarametros para la amtriz
# Capacidad de una cuadrilla: cambia a 4 si tus tiempos lo permiten
CAPACIDAD_CUADRILLA = 3

# Cargar DataFrame (ya debería estar en df) y derivar columna 'DATE' (fecha
sin hora)
df['DATE'] = df['FECHA_REGISTRO_TICKET'].dt.date

# Listado de provincias y franjas únicas en tu dataset
provincias = df['ID_PROVINCIA_DESCRIPCION'].unique()
franjas = df['FRANJA_HORARIO_INICIAL'].unique()
```

```
# Lista para acumular resultados
pronosticos = []

for provincia in provincias:
    for franja in franjas:
        # Filtra por provincia y franja
        subset = df[(df['ID_PROVINCIA_DESCRIPCION'] == provincia) &
                     (df['FRANJA_HORARIO_INICIAL'] == franja)].copy()

        # Crear serie diaria
        serie = subset.groupby('DATE').size().reset_index(name='y')
        # Renombrar columnas para Prophet
        serie.columns = ['ds', 'y']
```

```

# Omite combinaciones con menos de 10 días de datos
if len(serie) < 10:
    continue

# Entrenar modelo Prophet
model = Prophet()
model.fit(serie)

# Pronosticar próximos 30 días
future = model.make_future_dataframe(periods=30)
forecast = model.predict(future)

# Extraer fechas y valores pronosticados (yhat)
pron = forecast[['ds', 'yhat']].copy()
pron['PROVINCIA'] = provincia
pron['FRANJA'] = franja

pronosticos.append(pron)

# Unir todos los pronósticos en un solo DataFrame
pronosticos_df = pd.concat(pronosticos, ignore_index=True)
pronosticos_df.rename(columns={'ds': 'FECHA', 'yhat': 'TICKETS_ESPERADOS'},
inplace=True)

# Mostrar algunas filas
pronosticos_df.head()

```

Figura 2.

Proyección para cada franja y provincia de tickets generados.

index	PROVINCIA	FRANJA	TICKETS_PROMEDIO	CUADRILLAS_PROMEDIO
0	Azuay	10AM A 1PM	2.3	1.0
1	Azuay	1PM A 4PM	2.3	1.0
2	Azuay	1pm a 7pm	1.1	1.0
3	Azuay	4PM A 7PM	2.3	1.1
4	Azuay	7AM - 10AM	2.4	1.1
5	Azuay	7am a 1pm	1.2	1.0

Nota: Previo a establecer parámetros como tiempos de instalación necesarios para una cuadrilla se proyecta valores para cada provincia, franja y la cantidad de tickets esperados.

Propósito del código:

Las franjas de mayor demanda promedio se concentran en:

- 7AM – 10AM

- 1PM a 4PM
- 4PM a 7PM

Las franjas de menor demanda se observan en:

- 1PM a 7PM (DTH)
- 7AM a 1PM (DTH)

Los resultados de las cargas operativas permiten una visión del flujo de finalizaciones de órdenes en las franjas establecidas, en estos tiempos no se puede perder recursos por problemas externos ya que repercute directamente en las tareas individuales de cada cuadrilla.

Comparativas de Modelos

1. Instalación de librerías necesarias

```
import pandas as pd
import numpy as np

from prophet import Prophet

from sklearn.ensemble import RandomForestRegressor
from xgboost import XGBRegressor

from sklearn.metrics import mean_absolute_error, mean_squared_error
import matplotlib.pyplot as plt
```

2. Cargamos el dataset compartido por DWH

```
from google.colab import files
uploaded = files.upload()
csv_name = list(uploaded.keys())[0]
df = pd.read_csv(csv_name)

date_cols = [
    'FECHA_REGISTRO_TICKET', 'FECHA_CREACION_ACTIVIDAD',
    'FECHA_AGENDAMIENTO_INICIAL', 'FECHA_AGENDAMIENTO',
    'FECHA_INICIO_ACTIVIDAD', 'FECHA_FIN_ACTIVIDAD'
]
for c in date_cols:
    df[c] = pd.to_datetime(df[c], errors='coerce')

df['DATE'] = df['FECHA_REGISTRO_TICKET'].dt.floor('D')

H = 60
train = ts.iloc[:-H].copy()
test = ts.iloc[-H:].copy()

train.shape, test.shape
```

3. Prophet

```
prophet_train = train.rename(columns={'DATE':'ds'})
prophet_test  = test.rename(columns={'DATE':'ds'})

m = Prophet()
m.fit(prophet_train[['ds','y']])

future = prophet_test[['ds']].copy()
fc = m.predict(future)

test_pred_prophet = fc['yhat'].values
```

4. Future Engineering

```
def make_features(df_):
    d = df_.copy()
    d['dow'] = d['DATE'].dt.dayofweek
    d['month'] = d['DATE'].dt.month
    d['day'] = d['DATE'].dt.day
    d['weekofyear'] = d['DATE'].dt.isocalendar().week.astype(int)

    # Lags
    d['lag1'] = d['y'].shift(1)
    d['lag7'] = d['y'].shift(7)
    d['lag14'] = d['y'].shift(14)

    # Rolling
    d['roll7_mean'] = d['y'].shift(1).rolling(7).mean()
    d['roll14_mean'] = d['y'].shift(1).rolling(14).mean()

    return d

feat = make_features(ts)
feat = feat.dropna().reset_index(drop=True)

# volver a separar train/test usando fechas, no filas
cutoff = test['DATE'].min()
train_feat = feat[feat['DATE'] < cutoff].copy()
test_feat = feat[feat['DATE'] >= cutoff].copy()

X_train = train_feat.drop(columns=['y'])
y_train = train_feat['y'].values
X_test = test_feat.drop(columns=['y'])
y_test = test_feat['y'].values

# quitar DATE para modelos
X_train_m = X_train.drop(columns=['DATE'])
X_test_m = X_test.drop(columns=['DATE'])
```

5. Random Forest Regressor

```
rf = RandomForestRegressor(  
    n_estimators=400,  
    random_state=42,  
    max_depth=None,  
    min_samples_leaf=2,  
    n_jobs=-1  
)  
rf.fit(X_train_m, y_train)  
pred_rf = rf.predict(X_test_m)
```

6. XGBoost

```
xgb = XGBRegressor(  
    n_estimators=1200,  
    learning_rate=0.03,  
    max_depth=6,  
    subsample=0.9,  
    colsample_bytree=0.9,  
    reg_lambda=1.0,  
    objective='reg:squarederror',  
    random_state=42  
)  
xgb.fit(X_train_m, y_train)  
pred_xgb = xgb.predict(X_test_m)
```

7. Comparativa de modelos Prophet vs RF vs XGB

```

def rmse(y, yhat):
    return np.sqrt(mean_squared_error(y, yhat))

def smape(y, yhat):
    y, yhat = np.array(y), np.array(yhat)
    denom = (np.abs(y) + np.abs(yhat)) + 1e-9
    return np.mean(2*np.abs(yhat - y)/denom)*100

results = pd.DataFrame({
    'Modelo': ['Prophet', 'RandomForest', 'XGBoost'],
    'MAE': [
        mean_absolute_error(y_test, test_pred_prophet),
        mean_absolute_error(y_test, pred_rf),
        mean_absolute_error(y_test, pred_xgb),
    ],
    'RMSE': [
        rmse(y_test, test_pred_prophet),
        rmse(y_test, pred_rf),
        rmse(y_test, pred_xgb),
    ],
    'sMAPE_%': [
        smape(y_test, test_pred_prophet),
        smape(y_test, pred_rf),
        smape(y_test, pred_xgb),
    ]
}).sort_values('MAE')

results

```

Análisis

Tabla 7.

Errores en los Modelos Evaluados

Modelo	MAE	RMSE	sMAPE
Prophet	6,1117	7,4259	13,9944
Random Forest	6,4979	7,8892	14,7779
XGBoost	7,0638	8,4722	15,9479

Nota: Comparativa de resultados en función de errores presentados del modelo.

En función a los resultados de la comparativa para ver que modelo tiene mejor desempeño se midieron tres parámetros importantes como MAE, RMSE y sMAPE, el valor de 6,11 para Prophet nos muestra que su error promedio en unidades operativas es el más bajo lo que para instalaciones

y mantenimientos debería ser las órdenes de trabajo individuales por día representando un error prácticamente de 6 tickets diarios, de igual manera RMSE posee el valor más acertado para Prophet lo que implica penalización de errores extremos, como este es netamente un Forecast de demanda se vuelve un indicador bastante fuerte, por último tenemos sMAPE que mide el error en porcentajes y de manera relativa, Prophet es el modelo que más se ajusta a la necesidad. Taylor y Letham (2018) sostienen que Prophet tiene una característica por encima de Random Forest y XGBoost ya que el aprendizaje se basa netamente en series temporales y Prophet permite descomponer estos elementos y los analiza con mayor detalle.

8. Comportamiento de los modelos


```
plot_df = test_feat[['DATE']].copy()
plot_df['y_real'] = y_test
plot_df['prophet'] = test_pred_prophet[:len(plot_df)]
plot_df['rf'] = pred_rf
plot_df['xgb'] = pred_xgb

plt.figure(figsize=(14,5))
plt.plot(plot_df['DATE'], plot_df['y_real'], label='Real')
plt.plot(plot_df['DATE'], plot_df['prophet'], label='Prophet')
plt.plot(plot_df['DATE'], plot_df['rf'], label='RF')
plt.plot(plot_df['DATE'], plot_df['xgb'], label='XGB')
plt.legend()
plt.title(f'{provincia} - {franja} | Test últimos {H} días')
plt.show()
```

Análisis

Tabla 8.

Comportamiento de Modelos vs Demanda Real



Nota: Relación de modelos con picos y valles de desviación y comportamiento en base a datos.

A través de la gráfica vemos que Prophet fue el modelo con mejor comportamiento y con un desempeño global esperado, Prophet mantiene la estabilidad, si bien es cierto Random Forest se acerca más a los picos y valles al igual que XGB esto genera una reacción de alta variabilidad cuando la demanda decrece y tienden a sobreestimar valores eso explica porque el MAE es menor con Prophet. Baloch et al. (2025) en su investigación compara de igual manera los tres modelos y Prophet al igual que en este estudio y obtiene resultados favorables ya que es el modelo con menor error MAE y RMSE en series temporales, la captura de estacionalidades da robustes al análisis y se considera como primera opción de desarrollo.

9. Interpretación estratégica de variables

```
importances = pd.Series(xgb.feature_importances_,
index=X_train_m.columns).sort_values(ascending=False)
importances.head(10)
```

Análisis

Tabla 9.

Interpretación de variables

Variable	Tipo de Variable	Descripción	Resultado
Roll7_mean	Temporal	Promedio móvil últimos 7 días	0.6369
Roll14_mean	Temporal	Promedio móvil últimos 14 días	0.104805
Weekofyear	Calendario	Semana del año	0.061616
lag14	Rezago	Demanda hace 14 días	0.040223
lag1	Rezago	Demanda del día anterior	0.038121
lag7	Rezago	Demanda hace 7 días	0.037827

Nota: Frecuencia de los datos y comportamiento del modelo en el tiempo.

En la tabla 8 observamos que roll7_mean obtiene 63.69% este valor indica que la estructura de la información sigue un comportamiento fuerte de frecuencia semanal. No es una operación fuera de control con grandes alteraciones, el patrol semanal es el comportamiento que siguen las

instalaciones y mantenimientos. Los valores adicionales influyen poco y podrían ser descartables ya que no desajustan el flujo operativo de la empresa.

Ayele et al. (2025) comenta que Prophet compete en alto nivel contra los modelos de aprendizaje automático con mayores características ya que presenta resultados eficientes en cuanto a proyección y error, de igual manera predominaban las series temporales en el análisis manteniéndose estable y sobre todo confiable.

Dashboards de Monitoreo

1. Tiempo de “0 a 24Horas exactas” – frecuencia diaria: Monitoreo de la atención más pronta de las órdenes.

KPI INSTALACIONES TIC I&M

Backlog

24 horas: Nacional

24 horas: Region y Mes

% 24 Diario

24HRS CONTRATISTA

24 horas: Region Tecnología

HORAS X CONTRATISTA

Detalle de Efectividad

Brownfield

Efectividad Contratista

		INSTALADO																					
		febrero de 2026																					
REGION_DA	CREACION_24	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	Total	Total				
R1	0 A 24	%	45,2%	48,4%	50,9%	67,0%	62,0%	68,9%	63,0%	63,5%	57,9%	50,0%	71,2%	73,3%	83,0%	76,5%	74,4%	63,5%	63,5%				
	Total	%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%				
R2	0 A 24	%	34,1%	23,9%	26,9%	48,8%	47,2%	42,0%	37,3%	31,4%	25,2%	34,2%	41,5%	45,6%	66,7%	67,4%	60,9%	44,7%	44,7%				
	Total	%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%	100,0%				

Todo se Conecta

5G Claro

Mes, Año de FECHA_AGEN...

febrero de 2026

REGION_DA

☒ (Todo)

☒ R1

☒ R2

☐ FECHA_AGEN...

- a. Tiempo “0 a 24 Horas”

```

IF round([FECHA_FIN_ACTIVIDAD]-[FECHA_CREACION_ACTIVIDAD],5) <=1
THEN '0 A 24'
ELSEIF round([FECHA_FIN_ACTIVIDAD]-[FECHA_CREACION_ACTIVIDAD],5) <=2
THEN '24 A 48'
ELSEIF round([FECHA_FIN_ACTIVIDAD]-[FECHA_CREACION_ACTIVIDAD],5) <=3
THEN '48 A 72'
ELSE '> = 72'
END

```

2. Cálculo para tiempo “mismo día o día siguiente”: evaluado por México dueños de la compañía

Instalaciones Region									
Tiempo AMX									
Mes, Año d...	Semana de ...	% de total **Ticket junto con **AMX							
		R1				R2			
		mismo día o día s...	en 2 o 3 días	en 4 a 5 días	seis o mas días	mismo día o día s...	en 2 o 3 días	en 4 a 5 días	seis o mas días
diciembre de 2025	Semana 49	71,46%	9,18%	1,38%		65,59%	18,15%	1,21%	0,05%
	Semana 50	62,98%	12,15%	2,91%	0,88%	56,69%	18,26%	4,09%	1,57%
	Semana 51	57,33%	13,96%	3,36%	1,61%	56,08%	18,57%	3,94%	1,55%
	Semana 52	61,26%	8,32%	3,36%	1,40%	57,60%	14,93%	4,74%	1,73%
	Semana 53	63,62%	7,87%	1,83%	1,54%	66,36%	12,20%	1,48%	1,14%
	Total	63,01%	10,89%	2,69%	1,05%	59,42%	17,11%	3,35%	1,25%
enero de 2026	Semana 1	48,30%	16,72%	5,57%	1,24%	42,86%	20,95%	9,21%	2,86%
	Semana 2	66,81%	9,89%	1,35%	0,68%	60,89%	17,48%	2,27%	1,79%
	Semana 3	56,09%	18,35%	2,78%	0,63%	36,20%	35,35%	6,14%	2,22%
	Semana 4	59,13%	13,52%	3,52%	2,10%	35,70%	31,66%	7,94%	4,70%
	Semana 5	65,19%	10,59%	2,77%	1,38%	43,72%	28,06%	5,53%	2,85%
	Total	61,19%	13,27%	2,75%	1,22%	43,37%	28,29%	5,75%	2,98%
febrero de 2026	Semana 5	56,77%	11,98%	4,69%	1,04%	41,48%	30,11%	3,98%	1,70%
	Semana 6	62,85%	13,94%	2,04%	0,44%	53,08%	20,00%	5,20%	1,92%
	Semana 7	62,25%	11,98%	2,27%	0,86%	46,40%	26,42%	5,60%	2,44%
	Semana 8	64,57%	7,44%	2,77%	1,56%	56,44%	12,52%	5,69%	3,77%
	Total	62,86%	11,53%	2,39%	0,89%	51,01%	20,91%	5,45%	2,57%

REGIONES

☐ (Todo)

☐ NULL

☒ R1

☒ R2

**Días vs DÍ...

☒ (Todo)

☒ Lunes

☒ Martes

☒ Miércoles

☒ Jueves

☒ Viernes

☒ Sábado

☒ Domingo

Mes, Año d...

☐ (To...

☐ ag...

☐ oct...

☐ dici...

☐ en...

☐ feb...

☐ ma...

☐ abr...

☐ ma...

a. Tiempo AMX

```

IF round(ROUND([FECHA_FIN_ACTIVIDAD]) - DATE([FECHA_CREACION_ACTIVIDAD]), 5) <= 1
THEN 'mismo día o día siguiente'
ELSEIF round(ROUND([FECHA_FIN_ACTIVIDAD]) - DATE([FECHA_CREACION_ACTIVIDAD]), 5)
<= 3
THEN 'en 2 o 3 días'
ELSEIF round(ROUND([FECHA_FIN_ACTIVIDAD]) - DATE([FECHA_CREACION_ACTIVIDAD]), 5)
<= 5
THEN 'en 4 a 5 días'
ELSEIF round(ROUND([FECHA_FIN_ACTIVIDAD]) - DATE([FECHA_CREACION_ACTIVIDAD]), 5)
> 5
THEN 'seis o mas días'
END

```

3. Tiempo según lo planteado por el presidente de la compañía para pago de comisiones a terceros y áreas TIC.

PN 14.1 Y 14.2		
	FECHA_AGENDAMIENTO	
	**CantTicket	% de total Total Cant Ticket junto con Tabla (abajo)
**TiempoPlanNegocios	diciembre de 2025	diciembre de 2025
0 A 24	11.445	82,50%
24 A 48	1.179	8,50%
48 A 72	513	3,70%
>= 72	736	5,31%
Total general	13.873	100,00%

a. Tiempo 0 a 24Horas tomando agenda y franja iniciales

```

IF round([FECHA_FIN_ACTIVIDAD]-[**Agenda Inicial PN],5) <=1

```

```

THEN '0 A 24'
ELSEIF round([FECHA_FIN_ACTIVIDAD]-[**Agenda Inicial PN],5) <=2
THEN '24 A 48'
ELSEIF round([FECHA_FIN_ACTIVIDAD]-[**Agenda Inicial PN],5) <=3
THEN '48 A 72'
ELSE '> = 72' END

```

b. Tiempo de agenda inicial.

```

DATETIME(
  IF RIGHT([FRANJA_HORARIO_INICIAL],2) = '10' THEN
  STR([FECHA_AGENDAMIENTO_INICIAL]) + ' 10:00:00'
  ELSEIF RIGHT([FRANJA_HORARIO_INICIAL],2) = '13' THEN
  STR([FECHA_AGENDAMIENTO_INICIAL]) + ' 13:00:00'
  ELSEIF RIGHT([FRANJA_HORARIO_INICIAL],2) = '16' THEN
  STR([FECHA_AGENDAMIENTO_INICIAL]) + ' 16:00:00'
  ELSEIF RIGHT([FRANJA_HORARIO_INICIAL],2) = '19' THEN
  STR([FECHA_AGENDAMIENTO_INICIAL]) + ' 19:00:00'
  ELSE STR([FECHA_AGENDAMIENTO_INICIAL]) + ' 19:00:00'
END)

```

4. Comparativa “DoD” día versus día para evaluar los mejores días y los peores y en función a los datos tomar decisiones: Vista de los domingos pasados de febrero.

		FINALIZADO					
		febrero de 2026				Total	Total general
REGIONES	**Tiempo 2..	1	8	15	Total		
R1	0 A 24	58,74%	47,80%	57,26%	53,90%	53,90%	53,90%
	24 A 48	25,87%	37,36%	27,42%	30,96%	30,96%	30,96%
	48 A 72	6,29%	8,79%	4,84%	6,90%	6,90%	6,90%
	>= 72	9,09%	6,04%	10,48%	8,24%	8,24%	8,24%
	Total	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
R2	0 A 24	25,00%	24,67%	29,29%	26,29%	26,29%	26,29%
	24 A 48	50,00%	42,00%	41,43%	44,37%	44,37%	44,37%
	48 A 72	13,97%	17,33%	18,57%	16,67%	16,67%	16,67%
	>= 72	11,03%	16,00%	10,71%	12,68%	12,68%	12,68%
	Total	100,00%	100,00%	100,00%	100,00%	100,00%	100,00%
Total general		100,00%	100,00%	100,00%	100,00%	100,00%	100,00%

a. Día vs Día

```

CASE DATEPART('weekday', [FECHA_CREACION_ACTIVIDAD])
WHEN 1 THEN "Domingo"
WHEN 2 THEN "Lunes"
WHEN 3 THEN "Martes"
WHEN 4 THEN "Miércoles"
WHEN 5 THEN "Jueves"
WHEN 6 THEN "Viernes"
WHEN 7 THEN "Sábado"
END

```

5. Comparativa para mantenimientos y garantías tomando parámetro de finalización para no perder datos: Monitoreo de los lunes.

REGIONES	**Tiempo 2..	FECHA_FIN_ACTIVIDAD febrero de 2026			
		2	9	16	Total
R1	0 A 24	60,6%	48,6%	67,8%	57,4%
	24 A 48	14,7%	21,8%	10,3%	16,6%
	48 A 72	17,4%	12,7%	14,9%	14,8%
	>= 72	7,3%	16,9%	6,9%	11,2%
	Total	100,0%	100,0%	100,0%	100,0%
R2	0 A 24	35,6%	38,3%	50,0%	40,0%
	24 A 48	28,7%	21,5%	30,0%	26,5%
	48 A 72	20,1%	24,2%	8,0%	18,7%
	>= 72	15,5%	16,1%	12,0%	14,9%
	Total	100,0%	100,0%	100,0%	100,0%

a. Día vs Día Mantenimientos

```

CASE DATEPART('weekday', [FECHA_FIN_ACTIVIDAD])
WHEN 1 THEN "Domingo"
WHEN 2 THEN "Lunes"
WHEN 3 THEN "Martes"
WHEN 4 THEN "Miércoles"
WHEN 5 THEN "Jueves"
WHEN 6 THEN "Viernes"
WHEN 7 THEN "Sábado"
END

```

6. Comparativa para vistas de corte: Corte vs Corte y no Corte vs Meses cerrados:

Ejemplo: Enero – Mes Cerrado (1 al 31) vs Febrero – Mes en Curso (1 al 22)

Con Corte: 1 al 22 de Enero vs 1 al 22 de febrero.

```


IF DAY([FECHA_REGISTRO_TICKET]) < DAY(TODAY())
then "Corte"
else "No Corte"
END

```

7. Efectividad

Se mide Lo finalizado / Cancelado – Anulado

- Por zona
- Por contratista
- Por inspector asignado
- Por analista asignado




Agrupaciones de Estados en Función de las demás categorías:

- Finalizado / Cancelado y Anulado

Para lo pendiente: Backlog se debe gestionar la provincia con mayor backlog de órdenes y cada analista debe dar el seguimiento pertinente.

El cálculo para validar la cantidad de tickets: COUNTD(N_TICKET)



- Verificación de la efectividad de las zonas divididas a los contratistas con mayor afluencia de tickets en la sierra:

```
IF CONTAINS(UPPER(TRIM([ZONAS GPON ])), "RUMINAHUI")
THEN "EBICSA"
```

```
ELSEIF CONTAINS(UPPER(TRIM([ZONAS GPON ])), "NORTE 4")
THEN "HAGGERSTON"
```

```
ELSEIF CONTAINS(UPPER(TRIM([ZONAS GPON ])), "CENTRO SUR OCCIDENTAL")
THEN "AGROVOLVER"
```

```
ELSEIF [ZONAS GPON ] IN (
  "GPON R1 - QUITO NORTE 3",
  "GPON R1 - QUITO CENTRO",
  "GPON R1 - QUITO CENTRO - 1",
  "GPON R1 - QUITO CENTRO -1",
  "GPON R1 - QUITO CENTRO - SUR ORIENTAL - 1",
  "GPON R1 - QUITO CENTRO - SUR ORIENTAL -1",
  "GPON R1 - QUITO NORTE - 1",
  "GPON R1 - QUITO NORTE -1",
  "GPON R1 - QUITO SUR - 1",
  "GPON R1 - QUITO SUR -1",
  "GPON R1 - QUITO SUR OCCIDENTAL - 1",
  "GPON R1 - QUITO SUR OCCIDENTAL -1",
  "GPON R1 - QUITO CENTRO SUR OCCIDENTAL -1",
  "GPON R1 - QUITO CENTRO SUR OCCIDENTAL - 1"
) THEN "AGROVOLVER"
```

```
ELSEIF [ZONAS GPON ] IN (
  "GPON R1 - QUITO NORTE 1",
  "GPON R1 - QUITO NORTE 4"
) THEN "HAGGERSTON"
```


```
ELSEIF [ZONAS GPON ] IN (
  "GPON R1 - RUMIÑAHUI VALLE 1",
  "GPON R1 - RUMINAHUI VALLE 1",
  "GPON R1 - QUITO NORTE",
  "GPON R1 - QUITO CENTRO - SUR ORIENTAL - 1",
  "GPON R1 - QUITO CENTRO - SUR ORIENTAL -1",
  "GPON R1 - QUITO SUR OCCIDENTAL - 1",
  "GPON R1 - QUITO SUR OCCIDENTAL -1",
  "GPON R1 - QUITO VALLE - 2",
  "GPON R1 - QUITO VALLE -2",
  "GPON R1 - QUITO VALLE - 1",
  "GPON R1 - QUITO VALLE -1"
) THEN "EBICSA"
```

```
ELSEIF [ZONAS GPON ] IN (
  "GPON R1 - QUITO SUR 3",
  "GPON R1 - QUITO CENTRO - 1",
  "GPON R1 - QUITO CENTRO -1",
  "GPON R1 - QUITO SUR ORIENTAL - 2",
  "GPON R1 - QUITO SUR ORIENTAL -2",
  "GPON R1 - QUITO NORTE 5"
) THEN "PROCISA"
```

```
ELSEIF [ZONAS GPON ] IN (
  "GPON R1 - QUITO CENTRO",
  "GPON R1 - QUITO NORTE 5"
) THEN "PANATEL"
```

ELSE
 "PANATEL."
 END

8. Actividades que cumplen con su agenda inicial y adelantamientos de agenda vs actividades que incumplen con la agenda o promesa con el cliente.



- a. Cumplimiento de promesa con el cliente


```

IF (DATE([FECHA_FIN_ACTIVIDAD])<DATE([FECHA_AGENDAMIENTO_INICIAL]))

THEN 'Actividad Adelantada'
  ELSEIF (DATE([FECHA_FIN_ACTIVIDAD])=DATE([FECHA_AGENDAMIENTO_INICIAL]))
    THEN 'Actividad Cumple agenda inicial'
  ELSEIF
    (DATE([FECHA_FIN_ACTIVIDAD])>DATE([FECHA_AGENDAMIENTO_INICIAL]))
    THEN 'Actividad Incumple agenda inicial'

ELSE NULL

END
  
```



b. Cumplimiento de promesa y franja asignada

```

IF [**Cumplimiento/Incumplimiento Franja] = 'Actividad Incumple franja' THEN
  'Actividad Incumple franja'
ELSEIF [**Cumplimiento/Incumplimiento Franja] = 'Actividad Cumple franja'
  OR [**Cumplimiento/Incumplimiento Franja] = 'Actividad Adelantada a franja' THEN
  'Actividad Cumple franja'
END

```

c. Validación de cumplimiento

```

IF ISNULL([FECHA_FIN_ACTIVIDAD]) OR ISNULL([**DT Inicio Franja]) OR ISNULL([**DT Fin
Franja]) THEN
  NULL

ELSEIF [FECHA_FIN_ACTIVIDAD] >= [**DT Inicio Franja]
  AND [FECHA_FIN_ACTIVIDAD] <= [**DT Fin Franja] THEN
  'Actividad Cumple franja'

ELSEIF [FECHA_FIN_ACTIVIDAD] < [**DT Inicio Franja] THEN
  'Actividad Adelantada a franja'

ELSE
  'Actividad Incumple franja'
END

```

d. Datetime

Inicio de Franja:

DATEADD('hour', [**Hora Inicio Franja], DATETIME([FECHA_AGENDAMIENTO_INICIAL]))

Fin de Franja:

DATEADD('hour', [**Hora Fin Franja], DATETIME([FECHA_AGENDAMIENTO_INICIAL]))


Hora de Inicio:

INT(SPLIT([FRANJA_HORARIO_INICIAL], '-', 1))

Hora Fin:

INT(SPLIT([FRANJA_HORARIO_INICIAL], '-', 2))

9. Monitoreo de órdenes reagendadas para evaluar el motivo y dar seguimiento para mejorar SLA





a. Estados del ticket

Seleccionamos los pendientes en estado: Reagendado diario para seguimiento de órdenes rezagadas.

10. Monitoreo anual de torres de control encargadas de la coordinación de las contratistas:

Frecuencia mensual.



- a. Campo calculado para filtrar que partes funcionan con torre y que partes de la contratista la maneja su coordinación propia.

```

IF [TORRES DE CONTROL] = 'CANTEC' THEN
  // Dentro de CANTEC, separa por contratista
  IF [NOMBRE_CONTRATISTA (grupo)] = 'HAGGERSTONE' THEN
    'CANTEC - HAGGERSTONE'

  ELSEIF [NOMBRE_CONTRATISTA (grupo)] = 'EBICSA' THEN
    // Limpia provincia y detecta Pichincha/Quito (incluye variantes)
    IF ISNULL([ID_PROVINCIA_DESCRIPCION]) THEN
      'CANTEC - EBICSA - PROVINCIAS' // decide si los nulos van a Provincias
    ELSE
      IF CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'pichincha')
        OR CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'quito')
        OR CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'dmq')
        OR CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'distrito metropolitano')
      THEN

```

```

        'EBICSA - PICHINCHA'
    ELSE
        'EBICSA - PROVINCIAS'
    END
END

```

```

ELSE
    'HAGGERSTONE' // opcional
END

```

```

ELSE
    // Otras torres quedan igual
    [TORRES DE CONTROL]
END

```

- b. Filtrar actividades realizadas por provincia de cada contratista:

Ejemplo: Ebicssa

```

// EBICSA - Provincias
IF [NOMBRE_CONTRATISTA (grupo)] = 'EBICSA'
AND NOT ISNULL([ID_PROVINCIA_DESCRIPCION])
AND NOT (
    CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'pichincha')
    OR CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'quito')
)
THEN
    'EBICSA - PROVINCIAS'
ELSE
    NULL
END

// EBICSA - Pichincha
IF [NOMBRE_CONTRATISTA (grupo)] = 'EBICSA' THEN
    IF ISNULL([ID_PROVINCIA_DESCRIPCION]) THEN
        NULL
    ELSE
        IF CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'pichincha')
        OR CONTAINS(LOWER(TRIM([ID_PROVINCIA_DESCRIPCION])), 'quito') THEN
            'EBICSA - PICHINCHA'
        ELSE
            NULL
        END
    END
ELSE
    NULL
END

```

11. Efectividad bruta de los canales de ventas con los motivos de cancelación extraídos piscina de información

KPI I&M																		
Motivo Cancelación SM+OFSC 2	Cumplimiento de Agenda Semana Diario		Cumplimiento de Franjas Semana Diario		Reagendamientos		Motivos Cancelación Inst		Motivos Cancelación Inst Zonas		Capacidad de Agenda Provincia		Capacidad de Agenda Ciudad		Capacidad de Agenda Parroquia		Total general	
	Fecha Registro Ticket / Región / Canal Venta (grupo)																	
	2026																	
	enero				R2				R1				febrero					
	FVD R2	CAC	CC	DIS	FVD R1	FVD R2	CAC	CC	DIS	FVD R1	FVD R2	CAC	CC	DIS	FVD R1	FVD R2		
Instalado Correctamente	75.0%	77.2%	68.3%	80.9%	70.8%	81.8%	75.3%	64.9%	80.1%	80.9%	63.8%	79.3%	71.1%	82.6%	65.2%	81.4%	79.2%	
Fuera de Cobertura	3.1%	3.2%	3.3%	2.1%	7.7%	1.6%	3.4%	3.8%	2.0%	2.2%	4.3%	2.2%	2.6%	2.1%	4.3%	1.5%	2.3%	
Servicios Operativos en el Predio	1.6%	1.0%	0.8%	1.6%	1.2%	1.2%	1.8%	2.3%	1.2%	1.5%	2.1%	1.0%	2.0%	1.5%	1.8%	1.3%	1.3%	
Desiste de activación	1.6%	0.6%	2.3%	1.6%	1.5%	1.6%	0.5%	2.3%	0.8%	1.1%	2.1%	0.8%	1.8%	1.2%	2.2%	1.5%	1.4%	
Infraestructura		2.4%	2.2%	1.2%	3.1%	0.7%	2.0%	3.4%	1.4%	1.3%	4.3%	1.6%	2.4%	1.4%	2.2%	0.6%	1.4%	
Illocalizable con visita en domicilio		2.3%	2.9%	1.3%		2.2%	0.6%	0.8%	0.4%	0.8%		1.7%	2.4%	1.1%	2.2%	1.4%	1.2%	
Rechazado Cliente No Acepta la Visita		1.2%	3.6%	1.1%	3.1%	1.6%	0.6%	2.3%	0.6%	0.6%	2.1%	2.2%	3.0%	0.9%	4.3%	2.0%	1.2%	
Rechazado Cliente No solicitó el Servi.		0.6%	1.7%	0.6%	1.5%	0.7%	0.8%	2.3%	0.8%	1.2%	2.1%	0.5%	1.2%	0.4%		1.1%	0.3%	
Postergado por cliente - Fuera de tie..	1.6%	0.5%	1.5%	0.8%		0.8%	0.8%	1.5%	0.8%	1.1%		0.6%	0.6%	0.4%	2.2%	0.7%	0.3%	
Cambio de oferta - cambio de plan		0.7%	1.2%	1.0%	1.5%	1.0%	0.6%	1.3%	0.7%	0.5%		0.7%	1.4%	1.2%	4.3%	0.9%	0.3%	
Rechazado por Cliente No da Motivo		0.4%	0.9%	0.5%		0.9%	0.5%	2.3%	1.4%	1.1%	2.1%	0.1%	0.6%	0.3%		0.7%	0.3%	
Rechazado Sin Red GPON en el Sector		0.3%	1.7%	1.3%	3.1%	1.0%		0.4%	0.5%	0.2%		1.0%	1.4%	0.9%	4.3%	0.8%	0.7%	
Permisos Administrativos	3.1%	0.6%	0.6%	0.4%		0.2%	1.6%	1.5%	0.9%	0.5%		0.6%		0.3%	4.3%	0.1%	0.3%	
Rechazado Cliente Mantiene Servicio ..		0.3%	0.6%	0.4%		0.6%		1.3%	0.6%	0.9%		0.1%	1.2%	0.6%		0.4%	0.3%	
Rechazado por Postergado por el clie..	1.6%	0.6%	0.4%	0.2%		0.5%	0.9%	0.4%	0.7%	0.5%		0.5%	0.8%	0.3%		0.6%	0.3%	
Rechazado por Datos incorrectos nu..	1.6%	0.6%	0.3%	0.6%	3.1%	0.5%	1.1%	0.6%	0.6%	0.5%		0.3%	1.0%	0.4%		0.4%	0.3%	
Rechazado Cliente esta de viaje		0.2%	0.3%	0.3%		0.3%	0.1%	1.1%	0.1%	0.7%	2.1%	0.2%	0.6%	0.3%		0.6%	0.4%	
Rechazado Oferta Ingresada x el Can..		0.1%	0.5%	0.2%		0.1%	0.7%	0.6%	0.6%	0.3%		0.2%	0.6%	0.2%		0.0%	0.3%	
Rechazado NAP saturada		0.1%	0.1%	0.2%		0.4%	0.2%	0.8%	0.8%	0.6%	2.1%			0.2%		0.4%	0.3%	
Cancel-Reason-GPON	1.6%	0.4%	1.5%	0.2%		0.1%	0.6%	0.4%	0.1%	0.2%		0.7%	1.4%	0.1%		0.2%	0.3%	
Cambio de Información - teléfonos de..		0.8%	0.8%	0.4%		0.2%	0.2%	0.8%	0.6%	0.1%		0.6%	0.6%	0.2%		0.3%	0.3%	
Rechazado Cliente ya tiene el servicio.		0.2%	0.8%	0.3%		0.2%	0.1%	0.1%	0.2%	0.4%		0.1%	0.2%	0.3%		0.4%	0.3%	
Rechazado Nap Mayor a 500 Metros		0.4%	0.1%	0.2%	1.5%	0.1%	0.1%	0.4%	0.8%	0.2%		0.7%		0.3%		0.2%	0.2%	
Rechazado Ciudad Ingresada Incorre..	4.7%	0.2%		0.1%	1.5%	0.1%	0.4%	0.2%	0.1%	0.2%	4.3%	0.6%	0.6%	0.2%		0.4%	0.2%	
Rechazado X Falta de Información d..		0.1%	0.4%	0.0%		0.0%	0.6%	0.4%	0.4%	0.2%			0.4%	0.1%		0.2%	0.2%	
Cancelado por Carrusel		0.2%	0.1%	0.5%		0.2%	0.1%	0.2%	0.2%	0.1%	2.1%			0.1%		0.0%	0.2%	
Doble Ambiente		0.4%	0.4%	0.1%		0.1%	0.7%	0.6%	0.3%	0.1%		0.2%		0.1%		0.0%	0.2%	
Rechazado Sucursal Incorrecta		0.1%	0.8%	0.2%		0.2%	0.2%		0.1%	0.1%		0.7%	0.4%	0.3%	4.3%		0.2%	
Edificio No Tiene Acometida Interna	1.6%	0.1%				0.0%	0.7%	0.6%	0.1%							0.0%	0.1%	

a. Query para extraer datos completos de ambas fuentes:

SELECT

a.N_TICKET,
a.FECHA_AGENDAMIENTO_INICIAL,
a.FECHA_CANCELACION_ACTIVIDAD,
a.MOTIVO_CANCELACION,
a.BROWNFIELD,
a.TIPO_ACTIVIDAD,
a.ID_PROVINCIA_DESCRIPCION,
a.CANAL_VENTA,
a.NOMBRE_CONTRATISTA,
a.FECHA_CREACION_ACTIVIDAD,
a.CATEGORIA,
a.FECHA_PROCESO,
a.TECNOLOGIA,
a.ESTADO_SUBSCRIPCION,
a.FECHA_FIN_ACTIVIDAD,
a.ESTADO_DEL_TICKET,
a.FRANJA_HORARIO_INICIAL,
a.SERVICIO_PRINCIPAL,
a.FECHA_AGENDAMIENTO,
b.ID_ORDEN,
b.ESTADO_ACTIVIDAD,
b.MOTIVO_NO_REALIZADA

FROM OID_DB.OID_INSTALACIONES_SERVICE_MANAGER a
JOIN OID_DB.OID_INSTALACIONES_DETALLE_ACTIVIDADES b
ON a.N_TICKET = b.ID_ORDEN

WHERE EXTRACT(YEAR FROM a.FECHA_AGENDAMIENTO_INICIAL) = 2025
OR EXTRACT(YEAR FROM a.FECHA_CANCELACION_ACTIVIDAD) = 2025

b. Campo calculado para separar efectividad bruta entre lo instalable y no instalable

Indicadores Área

Indicadores Área

Efectividad Total	Efectividad Plan de Negocios - Funnel	Edwin Castillo	Edwin Castillo PN	Edwin Castillo SLA	Marzo Guzman	Me
-------------------	---------------------------------------	----------------	-------------------	--------------------	--------------	----

Motivo Cancelación ...	Motivo Cancelación SM+OFSC 2 (gr...	Fecha Registro Ticket							Mes de Fecha Registro Ti...	
		agosto	septie...	octubre	noviem...	diciemb...	2026		Total	
							enero	febrero	general	
Instalado Correctam...	Instalado Correctamente	80,8%	80,3%	81,2%	80,3%	78,7%	79,0%	79,5%	79,9%	☒ (Todo)
Instalable	Datos incorrectos	1,9%	1,8%	1,6%	1,7%	1,9%	1,9%	1,9%	2,0%	☒ enero
	Postergado por cliente	1,2%	1,1%	1,2%	1,3%	1,9%	1,6%	1,4%	1,4%	☒ febrero
	Cliente ilocalizable	0,7%	1,1%	1,1%	1,0%	1,4%	1,3%	1,1%	1,0%	☒ marzo
	Cancel-Reason-GPON	0,2%	0,1%	0,2%	0,3%	0,3%	0,3%	0,3%	0,2%	☒ abril
	Rechazado Cliente esta de viaje	0,3%	0,2%	0,2%	0,3%	0,4%	0,3%	0,4%	0,3%	☒ mayo
	Motivo de cancelación proceso aut...	0,1%	0,1%	0,1%	0,1%	0,1%	0,1%	0,1%	0,1%	☒ junio
	CRUCE DE VENTAS	0,0%	0,1%	0,0%	0,0%	0,1%	0,1%	0,1%	0,1%	☒ julio
	Cancel-Reason-	0,2%	0,1%	0,1%	0,1%	0,1%	0,1%	0,0%	0,1%	☒ agosto
	Cambio de titular	0,0%	0,0%	0,1%	0,1%	0,0%	0,1%	0,1%	0,1%	☒ septiembre
	Servicio Residencial en Comercial	0,1%	0,1%	0,0%	0,0%	0,1%	0,0%	0,0%	0,1%	☒ octubre
	Zona Peligrosa/Sector conflictivo	0,0%	0,0%	0,0%	0,1%	0,1%	0,0%	0,0%	0,1%	☒ noviembre
	Otros motivos agrupados	0,2%	0,1%	0,1%	0,1%	0,1%	0,0%	0,1%	0,2%	☐ diciembre
	Pendiente por Stock Eq./material	0,0%	0,0%	0,0%	0,0%	0,1%	0,0%	0,0%	0,1%	Año de Fecha Registro Ti...
	Pendiente Problema de Sistemas						0,0%		0,0%	☐ (Todo)
	Rechazados por Serv. Residencial e...	0,0%		0,0%	0,0%	0,0%	0,0%		0,0%	☐ 2022
Rechazado por incumplimiento de F...	0,0%	0,0%	0,0%	0,1%	0,0%	0,0%	0,0%	0,0%	☐ 2023	
Rechazado Refleja Servicios de Inst...	0,0%					0,0%		0,0%	☐ 2024	
Pendiente por afectación planta ex...	0,0%				0,0%	0,0%		0,0%	☒ 2025	
No Instalable	Fuera de Cobertura	3,7%	4,0%	3,8%	3,8%	3,8%	3,7%	3,4%	3,8%	☒ 2026
	No desea	2,4%	2,3%	2,3%	2,3%	2,2%	2,2%	2,4%	2,2%	Región
	Posible Carrusel	1,5%	1,4%	1,3%	1,7%	1,7%	1,9%	2,0%	1,5%	☒ (Todo)
	No Solicitó Servicio	1,8%	2,2%	1,8%	1,8%	1,7%	1,8%	1,8%	1,9%	☒ R1
	Infraestructura	1,5%	1,7%	1,5%	1,6%	1,7%	1,6%	1,7%	1,7%	☒ R2
	Desiste de activación	0,7%	0,7%	0,9%	1,1%	1,4%	1,6%	1,2%	0,8%	Id Provincia Descripcion
	Permisos Administrativos	0,8%	0,9%	0,7%	0,7%	0,8%	0,7%	0,7%	0,8%	☒ (Todo)
	Rechazado Cliente Mantiene Servic...	0,8%	0,7%	0,6%	0,6%	0,5%	0,6%	0,6%	0,6%	☒ AZUAY
	NAP/TAP Saturado	0,3%	0,3%	0,3%	0,3%	0,3%	0,3%	0,4%	0,3%	☒ BOLIVAR
	Doble Ambiente	0,2%	0,3%	0,3%	0,2%	0,3%	0,2%	0,2%	0,2%	☒ CAÑAR
	Cluster No Liberado	0,5%	0,2%	0,1%	0,1%	0,1%	0,1%	0,1%	0,2%	☒ CARCHI
	Rechazado por Permiso Municipal	0,0%	0,1%	0,0%	0,0%	0,0%	0,1%	0,1%	0,1%	☒ CHIMBORAZO

```

IF [**MotivosCancelacionAgrupados] = '' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CAMINO INACCESIBLE' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'DATOS INCORRECTOS' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'AGENDADO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'ASIGNACION CUADRILLA' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CAMINO INACCESIBLE' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CIUDAD INGRESADA INCORRECTA' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CLIENTE ILOCALIZABLE' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CLIENTE LOCALIZADO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CORREO ELECTRONICO DE FACTURACION
INCORRECTO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'CORREO ELECTRONICO DE IPTV INCORRECTO'
THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'DATOS INCORRECTOS NUMEROS DE CONTACTO
ERRONEOS' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'DISPONIBILIDAD DEL CLIENTE' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'FUERA DE TIEMPOS DE GESTION' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'MOTIVO DE CANCELACIÓN PROCESO
AUTOMÁTICO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'OFERTA INGRESADA X EL CANAL INCORRECTA'
THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'PENDIENTE CLIENTE NO CONTESTA' THEN
'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'PENDIENTE POR RECUPERACIÓN' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'PENDIENTE POR TIENDA CLARO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'PENDIENTE POSTERGADO POR CLIENTE' THEN
'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'PENDIENTE X POSTERGADO POR EL CLIENTE
INTENTO DE ADELANTO' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'POSTERGADO POR CLIENTE' THEN 'Instalable'

```

```

ELSEIF [**MotivosCancelacionAgrupados] = 'POSTERGADO POR EL CLIENTE EXCEDE DIAS DE
GESTION' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'REGULARIZACION' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'REGULARIZACIÓN' THEN 'Instalable'
ELSEIF [**MotivosCancelacionAgrupados] = 'ZONA PELIGROSA/SECTOR CONFLICTIVO' THEN
'Instalable'
ELSE 'No Instalable'
END

```

		Fecha Registro Ticket / Región										Total general
		octubre		noviembre		diciembre		2026 enero		febrero		
Motivo ..	Motivo Cancelación SM..	R1	R2	R1	R2	R1	R2	R1	R2	R1	R2	
Instala..	Instalado Correctamente	95,0%	95,0%	93,7%	94,1%	91,1%	93,4%	92,8%	93,1%	93,1%	93,7%	93,3%
Instala..	Datos incorrectos	1,6%	1,6%	2,3%	1,7%	2,7%	1,9%	2,6%	1,9%	2,7%	2,0%	2,4%
	Postergado por cliente	0,9%	0,9%	1,9%	1,2%	3,6%	1,2%	2,4%	1,5%	2,1%	1,3%	1,6%
	Cliente ilocalizable	1,4%	1,4%	0,6%	1,7%	0,8%	2,2%	0,7%	2,2%	0,7%	1,7%	1,1%
	Cancel-Reason-GPON	0,2%	0,2%	0,4%	0,3%	0,4%	0,3%	0,5%	0,3%	0,3%	0,4%	0,2%
	Rechazado Cliente esta..	0,2%	0,2%	0,4%	0,3%	0,6%	0,3%	0,4%	0,3%	0,6%	0,5%	0,3%
	Motivo de cancelación p..	0,2%	0,2%	0,1%	0,1%	0,1%	0,1%	0,1%	0,1%	0,2%	0,0%	0,1%
	CRUCE DE VENTAS	0,0%	0,0%	0,1%	0,0%	0,0%	0,1%	0,0%	0,1%	0,1%	0,1%	0,1%
	Cancel-Reason-	0,1%	0,1%	0,0%	0,1%	0,0%	0,1%	0,0%	0,1%	0,0%	0,0%	0,1%
	Cambio de titular	0,1%	0,1%	0,0%	0,1%	0,0%	0,1%	0,1%	0,1%	0,0%	0,1%	0,1%
	Servicio Residencial en ..	0,0%	0,0%	0,1%		0,1%	0,0%	0,1%	0,0%	0,0%	0,0%	0,1%
	Zona Peligrosa/Sector c..	0,1%	0,1%	0,0%	0,1%	0,0%	0,1%	0,1%	0,0%	0,1%		0,1%
	Otros motivos agrupad..	0,1%	0,1%	0,1%	0,1%	0,2%	0,1%	0,1%	0,0%	0,1%	0,1%	0,3%
	Pendiente por Stock Eq..	0,0%	0,0%	0,1%	0,0%	0,1%	0,1%	0,0%	0,0%	0,0%	0,1%	0,1%
	Pendiente Problema de ..							0,1%				0,0%
	Rechazados por Serv. R..		0,0%	0,0%		0,0%		0,0%	0,0%			0,0%
	Rechazado por incumpli..	0,0%		0,1%	0,1%		0,0%	0,0%	0,0%	0,0%	0,0%	0,0%
	Pendiente por afectació..			0,0%	0,0%	0,0%		0,0%				0,0%
	Rechazado Refleja Servi..							0,0%				0,0%

12. Medidas de Control Ticket finalizado vs Ticket pendiente para evitar fraudes: Query para

Aginity

- Números Repetidos
- Carruseles de servicios

```

WITH base AS (
  SELECT DISTINCT
    N_TICKET,
    NOMBRE_CLIENTE,
    DOCUMENTO_CLIENTE,
    DIRECCION,
    FECHA_REGISTRO_TICKET AS FECHA_REGISTRO_TICKET_1,
    NOMBRE_RECURSO,
    CANAL_VENTA,
    SUBSTR(NUMERO, LENGTH(NUMERO) - 8, 9) AS NUMERO_NORMALIZADO,
    ID_CIUADAD_DESCRIPCION
  FROM (
    SELECT
      N_TICKET,
      NOMBRE_CLIENTE,
      CAST(NUMERO_1_CLIENTE AS VARCHAR(20)) AS NUMERO,
      DOCUMENTO_CLIENTE,
      DIRECCION,

```

```

    FECHA_REGISTRO_TICKET,
    NOMBRE_RECURSO,
    CANAL_VENTA,
    ESTADO_DEL_TICKET,
    TIPO_ACTIVIDAD,
    TECNOLOGIA,
    NOMBRE_EJECUTIVO,
    ID_CIUADAD_DESCRIPCION
  FROM OID_DB.OID_INSTALACIONES_SERVICE_MANAGER

```

```

  UNION ALL

```

```

  SELECT
    N_TICKET,
    NOMBRE_CLIENTE,
    CAST(NUMERO_CONTACTO AS VARCHAR(20)) AS NUMERO,
    DOCUMENTO_CLIENTE,
    DIRECCION,
    FECHA_REGISTRO_TICKET,
    NOMBRE_RECURSO,
    CANAL_VENTA,
    ESTADO_DEL_TICKET,
    TIPO_ACTIVIDAD,
    TECNOLOGIA,
    NOMBRE_EJECUTIVO,
    ID_CIUADAD_DESCRIPCION
  FROM OID_DB.OID_INSTALACIONES_SERVICE_MANAGER

```

```

  UNION ALL

```

```

  SELECT
    N_TICKET,
    NOMBRE_CLIENTE,
    CAST(NUMERO_CLIENTE AS VARCHAR(20)) AS NUMERO,
    DOCUMENTO_CLIENTE,
    DIRECCION,
    FECHA_REGISTRO_TICKET,
    NOMBRE_RECURSO,
    CANAL_VENTA,
    ESTADO_DEL_TICKET,
    TIPO_ACTIVIDAD,
    TECNOLOGIA,
    NOMBRE_EJECUTIVO,
    ID_CIUADAD_DESCRIPCION
  FROM OID_DB.OID_INSTALACIONES_SERVICE_MANAGER

```

```

) SB

```

```

WHERE ESTADO_DEL_TICKET = 'Finalizado'
AND TIPO_ACTIVIDAD = 'INST'
--AND CANAL_VENTA = 'DIS PROCATEL S.A. GYE'
AND TECNOLOGIA = 'GPON'
AND NUMERO IS NOT NULL
AND LENGTH(NUMERO) >= 9
AND FECHA_REGISTRO_TICKET > '2025-07-01'
--and ID_CIUADAD_DESCRIPCION = 'QUEVEDO'

```

```

),

```

```

sm_norm AS (
  SELECT DISTINCT
    N_TICKET,
    DOCUMENTO_CLIENTE,
    FECHA_REGISTRO_TICKET,

```

SUBSTR(NUMERO, LENGTH(NUMERO) - 8, 9) AS NUMERO_NORMALIZADO,

DIRECCION,NOMBRE_CLIENTE,NOMBRE_EJECUTIVO,ID_CIUADAD_DESCRIPCION,ID_PROVINCIA_DESCRIPCION

FROM (

SELECT

N_TICKET,

DOCUMENTO_CLIENTE,

FECHA_REGISTRO_TICKET,

CAST(NUMERO_1_CLIENTE AS VARCHAR(20)) AS NUMERO,

DIRECCION,NOMBRE_CLIENTE,NOMBRE_EJECUTIVO,ID_CIUADAD_DESCRIPCION,ID_PROVINCIA_DESCRIPCION

FROM OID_DB.OID_INSTALACIONES_SERVICE_MANAGER

WHERE NUMERO IS NOT NULL

AND LENGTH(NUMERO) >= 9

--AND FECHA_REGISTRO_TICKET > '2025-11-01'

--AND CANAL_VENTA = 'DIS PROCATEL S.A. GYE'

--AND NOMBRE_EJECUTIVO = 'VERONICA DEL PILAR GALARZA PEÑA'

AND ESTADO_DEL_TICKET in ('Agendado','Re-Agendado')

AND TECNOLOGIA = 'GPON'

AND TIPO_ACTIVIDAD = 'INST'

--AND ID_CIUADAD_DESCRIPCION = 'QUEVEDO'

)SB

)

SELECT DISTINCT

B.N_TICKET AS TICKET_ANTERIOR,

S.N_TICKET AS TICKET_POSTERIOR,

B.NUMERO_NORMALIZADO,

B.NOMBRE_CLIENTE AS CLIENTE_1,

S.NOMBRE_CLIENTE AS CLIENTE_2,

B.DIRECCION AS DIRECCION_1,

S.DIRECCION AS DIRECCION_2,

B.DOCUMENTO_CLIENTE AS DOCUMENTO_1,

S.DOCUMENTO_CLIENTE AS DOCUMENTO_2,

B.FECHA_REGISTRO_TICKET_1,

S.FECHA_REGISTRO_TICKET

FROM sm_norm S

JOIN base B

ON S.NUMERO_NORMALIZADO = B.NUMERO_NORMALIZADO

WHERE S.FECHA_REGISTRO_TICKET > B.FECHA_REGISTRO_TICKET_1

AND (DATE(S.FECHA_REGISTRO_TICKET) - DATE(B.FECHA_REGISTRO_TICKET_1)) > 15

AND S.DOCUMENTO_CLIENTE <> B.DOCUMENTO_CLIENTE

AND B.NUMERO_NORMALIZADO NOT IN

('22222222','999999999','222222223','422222222','000000000')

and S.ID_PROVINCIA_DESCRIPCION not IN ('GUAYAS','LOS RIOS','MANABI','AZUAY',
'EL ORO','SANTA ELENA','LOJA','CAÑAR','ZAMORA CHINCHIPE')

AND S.ID_CIUADAD_DESCRIPCION = B.ID_CIUADAD_DESCRIPCION

ORDER BY S.FECHA_REGISTRO_TICKET DESC;

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

Mediante el análisis del modelo desarrollado en Google Colab con las asistencias de Python se pudo tener una visión general de lo que representa el flujo operativo en las instalaciones de servicios fijos a nivel nacional, tiene potencial de escalabilidad, esto permite formar una estructura sólida en la toma de decisiones técnicas para el cumplimiento de objetivos empresariales y para un número (n) de evaluaciones día a día como parte de la mejora continua.

A través del modelo se planteó un monitoreo completo de los datos utilizando Tableau Desktop, los datos son presentados en Dashboards en tiempo real conectados directamente con las piscinas de información con conexión a IBM Netezza Server, la conexión que permite el flujo continuo de datos de producción es la conexión bridge de Tableau.

Con la ayuda de ambas herramientas como Python y Tableau se puede generar un análisis de la operatividad de una empresa multinacional como es Claro – Ecuador. Además de planificar la logística y soportar altos y valles de la operación con recursos como cuadrillas, analistas, operadores, supervisores, jefes y gerentes de empresas filiales que buscan un mismo objetivo.

Por medio del código de control desarrollado permite inspeccionar parámetros como la validación de carruseles, esto interfiere al perfil financiero de la empresa ya que el Payback no logra cubrirse hasta (n) cantidad de tiempo y si esta práctica se realiza por parte de los canales de ventas afecta directamente a la efectividad de las instalaciones con los ingresos de la compañía.

Recomendaciones

Para futuras investigaciones se recomienda ajustar la cuota de agendamiento para poder tener control absoluto de la agenda y manejar el flujo de parte del área técnica ya que esto lo lleva el área comercial y genera inconsistencias como ventas tempranas que terminan con reagendamientos o ventas ficticias que el cliente jamás solicitó el servicio contratado.

Se propone extrapolar el Forecast de demanda con la cantidad de inventario en bodegas para poder ajustar y presupuestar kits empleados durante el año en curso y poder tener abastecimiento de hasta 4 meses en adelante, ya que un rango mayor representaría un riesgo financiero para material sensible ya que podría perder soporte operativo.

Se sugiere evaluar por parte del área comercial el flujo inferior de la tecnología DTH en sectores comerciales y provincias de alto flujo de órdenes como Pichincha y Guayas, y planificar atacar sectores rurales con algún diferenciador para sacar provecho de dicho producto.

Bibliografía

1. Bhais, O. A. A., Mohd Yusoh, Z. I., Othman, M. F. I. y cols. (2025). *Machine Learning-Based Proactive Fault Monitoring and Prediction in GPON Networks*. **Modern Applied Science**, 19(2), 13. Recuperado de: [Machine Learning-Based Proactive Fault Monitoring and Prediction in GPON Networks | Bhais | Modern Applied Science | CCSE](#)
2. Arin, I. A., Murad, D. F., Warnars, H. L. S. y Meyliana (2025). *An Integrated Digital Twin Architecture for Proposing Field Service Management Model in Fiber Optic Network Infrastructure: A Design Science Approach*. **Intelligent Systems in Industry**, 30(5), 1229–1250. Recuperado de: [An Integrated Digital Twin Architecture for Proposing Field Service Management Model in Fiber Optic Network Infrastructure: A Design Science Approach | IIETA](#)
3. Anderson, D. A. (2024). *Predictive Modeling of Customer Churn in Telecommunication Companies in USA*. **Journal of Statistics and Actuarial Research**, 8(2), 32–41. Recuperado de: [View of Predictive Modeling of Customer Churn in Telecommunication Companies in USA](#)
4. Farabi, S. S. A. (2025). *AI-Driven Predictive Maintenance Model for DWDM Systems to Enhance Fiber Network Uptime in Underserved U.S. Regions*. **Preprints**, 2025-06-13. Recuperado de: [AI-Driven Predictive Maintenance Model for DWDM Systems to Enhance Fiber Network Uptime in Underserved U.S. Regions\[v1\] | Preprints.org](#)
5. Ribeiro, H., Barbosa, B., Carrizo Moreira, A. y Rodrigues, R. (2024). *Customer Experience, Loyalty, and Churn in Bundled Telecommunications Services*. **SAGE Open**, 14(2), 1–16. Recuperado de: [Customer Experience, Loyalty, and Churn in Bundled Telecommunications Services - Hugo Ribeiro, Belem Barbosa, Antonio C. Moreira, Ricardo Rodrigues, 2024](#)
6. Faraji Googerdchi, K., Asadi, S., y Jafari, S. M. (2024). *Customer churn modeling in telecommunication using a novel multi-objective evolutionary clustering-based ensemble learning*. **PLoS ONE**, 19(6), e0303881. Recuperado de: [Customer churn modeling in telecommunication using a novel multi-](#)

7. Azad, M. S., Khan, S. S., Hossain, R., Rahman, R., y Momen, S. (2023). Predictive modeling of consumer purchase behavior on social media: Integrating theory of planned behavior and machine learning for actionable insights. *PLOS ONE*, 18(12), e0296336. Recuperado de: [Predictive modeling of consumer purchase behavior on social media: Integrating theory of planned behavior and machine learning for actionable insights | PLOS One](#)
8. Kufel, J., Bargieł-Lączek, K., Kocot, S., Koźlik, M., Bartnikowska, W., Janik, M., ... Gruszczyńska, K. (2023). What is machine learning, artificial neural networks and deep learning? Examples of practical applications in medicine. *Diagnostics (Basel)*, 13(15), 2582. Recuperado de: [What Is Machine Learning, Artificial Neural Networks and Deep Learning?—Examples of Practical Applications in Medicine](#)
9. Lin, J. (2025). Application of machine learning in predicting consumer behavior and precision marketing. *PLOS ONE*, 20(5), e0321854. Recuperado de: [Application of machine learning in predicting consumer behavior and precision marketing | PLOS One](#)
10. Madanchian, M. (2024). Generative AI for consumer behavior prediction: Techniques and applications. *Sustainability*, 16(22), 9963. Recuperado de: [Generative AI for Consumer Behavior Prediction: Techniques and Applications](#)
11. Santos, N. P. (2023). The expansion of data science: Dataset standardization. *Standards*, 3(4), 400–410. Recuperado de: [The Expansion of Data Science: Dataset Standardization](#)
12. Sun, K.-A., y Moon, J. (2024). The theory of planned behavior and antecedents of attitude toward bee propolis products using a structural equation model. *Foods*, 13(18), 3002. Recuperado de: [The Theory of Planned Behavior and Antecedents of Attitude toward Bee Propolis Products Using a Structural Equation Model](#)
13. Zabala-Vargas, S., Jaimes-Quintanilla, M., y Jimenez-Barrera, M. H. (2023). Big data, data science, and artificial intelligence for project management in the architecture, engineering, and construction industry: A systematic review. *Buildings*, 13(12), 2944.


Recuperado de: [Big Data, Data Science, and Artificial Intelligence for Project Management in the Architecture, Engineering, and Construction Industry: A Systematic Review](#)

14. Alfie, S., y Blake, H. (2024). *A performance and scalability review of data warehousing solutions for large enterprises*. ResearchGate. Recuperado de: [Search Publications | ResearchGate](#)
15. Onyejekwe, E. R., Sherifi, D., y Ching, H. (2024). Perspectives on big data and big data analytics in healthcare. *Perspectives in Health Information Management*, 21(1), 1f. Recuperado de: [Advances in Health Information Science and Practice](#)
16. Weiser, E. B. (2025). Leveraging artificial intelligence in public health: A comparative evaluation of machine-learning algorithms in predicting COVID-19 mortality. *Journal of Scientific Innovation in Medicine*, 8(1), 1–12 Recuperado de: [Leveraging Artificial Intelligence in Public Health: A Comparative Evaluation of Machine-Learning Algorithms in Predicting COVID-19 Mortality | Journal of Scientific Innovation in Medicine](#)
17. Taylor, S. J., & Letham, B. (2018). *Forecasting at scale*. **The American Statistician**, 72(1), 37–45. Recuperado de: [Forecasting at Scale: The American Statistician: Vol 72, No 1 - Get Access](#)
18. Baloch, M., Honnurvali, M. S., Kabbani, A., Ahmed, T., Chauhdary, S. T., & Saeed, M. S. (2025). *Solar energy forecasting framework using Prophet based machine learning model: An opportunity to explore solar energy potential in Muscat Oman*. **Energies**, 18(1), 205. Recuperado de: [Solar Energy Forecasting Framework Using Prophet Based Machine Learning Model: An Opportunity to Explore Solar Energy Potential in Muscat Oman](#)
19. Ayele, S. T., Ageze, M. B., Zeleke, M. A., & Miliket, T. A. (2023). *Adama II wind farm long-term power generation forecasting based on machine learning models*. **Scientific African**, 21, e01831. Recuperado de: [Adama II wind farm long-term power generation forecasting based on machine learning models - ScienceDirect](#)

ANEXOS


Dashboard 1.

Control de Tiempos de Atención.



Dashboard 2.

Control del Backlog de órdenes rezagadas.




Dashboard 3.

Control de Tiempos de atención a los contratistas.



Dashboard 4.

Control de Órdenes de Instalación tipo BrownField



Dashboard 5.

Control de la efectividad dividida por cada canal de venta

<



Dashboard 7.

Órdenes de Instalación finalizadas por cada provincia

TIC I&M

Acción	Instalados por Franja	Instalados por Franja Canales	Instalados Franja Relacion Agenda	Instalaciones Provincia	Total de Instalaciones portecnología semana	Instalaciones por semana proveedores	Instalaciones por proveedor y canal	Ins
						</		

Dashboard 9.

Tiempo de gestión en órdenes de instalación.

TIC I&M															
S Zona	Instalados CACS	Browfield Diario	Browfield Diario Cuadrillas	Time Slot Instalaciones	Time Slot Mantenimientos	Indicador 0 a 24 Horas Traslados	Effectividad de Traslados								
RE..	ID_PROVIN..	NOMB..	NOMBRE_REC..	N_TICKET	1	2	3	4	5	6	7	8	9	10	1
		EBICSA	0604376327EB..	OT3573124		95 1h 35m									
				OT3575979			108 1h 48m								
				OT3576321			189 3h 09m								
				OT3576330			78 1h 18m								
				OT3576495			108 1h 48m								
				OT3580759			164 2h 44m								
				OT3585118				177 2h 57m							
				OT3585225				99 1h 39m							
				OT3585661				138 2h 18m							
				OT3586570				145 2h 25m							
				OT3587314				175 2h 55m							
				OT3588045				100 1h 40m							
				OT3588228				94 1h 34m							
				OT3588523				110 1h 50m							
				OT3593636							227 3h 47m				
				OT3593654							128 2h 08m				
				OT3593658							36 0h 36m				
				OT3596903								107 1h 47m			
				OT3600091								0 0h 00m			
				OT3605663									7 1h 13m		
				OT3606198									9 1h 36m		

Mes, Año de FECHA_REG..

☐ (Todo)☐ agosto de 2021☐ octubre de 2021☐ diciembre de 20...☐ enero de 2022☐ febrero de 2022☐ marzo de 2022☐ abril de 2022☐ mayo de 2022☐ junio de 2022☐ julio de 2022☐ agosto de 2022

ID_PROVINCIA_DESCRIP..

☒ (Todo)☒ NULL☒ AZUAY☒ BOLIVAR☒ CAÑAR☒ CARCHI☒ CHIMBORAZO☒ COTOPAXI☒ ELORO☒ ESMERALDAS☒ GUAYAS☒ IMBABURA

REGIONES


☐ (Todo)☐ NULL☒ R1☒ R2

TIPO_ACTIVIDAD

☐ (Todo)☐ CEQU☐ COAC☐ CWIFI☒ INST☐ INST_GAR☐ MANT☐ MANT_GAR


Dashboard 10.

Cumplimiento de Agenda Inicial Semanal.



Dashboard 10.

Cumplimiento de Agenda Inicial Semanal y franja horaria.



Dashboard 11.

Control de órdenes reagendadas.



Dashboard 12.

Control de efectividad bruta de los canales de venta con motivos agrupados.

