

**Sistema de monitoreo basado en indicadores clave de rendimiento para mitigar el robo de cableado de fibra óptica de telecomunicaciones en las localidades de Kennedy, y Tunjuelito de Bogotá D.C.**

Laura Marcela Calderón García

Asesor Dra. Mónica Andrea Rico Martínez

Universidad Nacional Abierta y a Distancia UNAD

Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI Ingeniería de Telecomunicaciones

2025

## **Dedicatoria**

Este trabajo me lo dedico a mí.

A la mujer que ha enfrentado cada batalla con determinación, que ha caído y se ha levantado las veces que ha sido necesario. Me lo dedico por no rendirme nunca, aun cuando las circunstancias parecían ir en contra.

Me lo dedico por haber demostrado que, aun siendo madre soltera, es posible construir un camino lleno de logros, esfuerzo y resiliencia. Este proyecto es el reflejo de cada noche difícil, de cada sacrificio y de la fortaleza que descubrí en mí misma cuando más la necesitaba.

Hoy reconozco mi propio valor, mi capacidad de avanzar y de transformar cada reto en una oportunidad.

Este triunfo es el resultado de todo lo que he superado y de la mujer fuerte que me he convertido.

## Agradecimiento

A mi familia, con todo mi corazón, quiero dedicar este logro que hoy culmino. A mi mamá Roció, por ser mi ejemplo de fortaleza, amor incondicional y entrega absoluta. Su apoyo constante, sus palabras de aliento y su presencia en cada etapa de mi vida han sido mi mayor impulso para seguir adelante incluso cuando el camino se hizo difícil.

A mis dos hermanas Luisa y Sofía, quienes han sido compañeras, aliadas y refugio en los momentos más desafiantes. Gracias por su comprensión, por su compañía sincera y por recordarme siempre que no estoy sola, que juntas podemos superar cualquier adversidad.

A mi hijo Gabriel, el motor más grande de mis sueños. Gracias por tu paciencia, tu ternura y por darme una razón inmensa para ser mejor cada día. Todo este esfuerzo, cada desvelo y cada meta alcanzada, lleva tu nombre.

A todos ustedes, que han estado conmigo en las buenas y en las malas, que han sido mi sostén, mi fuerza y mi hogar, les agradezco profundamente. Este logro es tan mío como suyo, porque sin su apoyo incondicional no habría llegado hasta aquí.

Los amo con todo mi corazón. Ustedes son y siempre serán mi pilar.

## Resumen

El presente proyecto desarrolla un sistema de monitoreo basado en indicadores clave de rendimiento (KPI - Key Performance Indicators) para mitigar el robo de cableado de fibra óptica en las localidades de Kennedy y Tunjuelito de Bogotá D.C. La investigación se fundamenta en el diseño y simulación de un modelo analítico construido a partir de datos sintéticos que replican el comportamiento estructural de registros provenientes de sistemas OSS (Operation Support Systems) y NOC (Network Operations Center).

El sistema se implementa mediante el desarrollo de un dashboard interactivo que procesa información simulada bajo escenarios realistas de operación, aplicando técnicas de análisis estadístico, correlación de eventos y fundamentos de machine learning para identificar patrones de robo en tiempo casi real. La metodología incluye el diseño del sistema de trazabilidad, la definición de métricas específicas por zona geográfica y la validación funcional del modelo mediante pruebas controladas.

Los resultados obtenidos demuestran la viabilidad técnica del sistema propuesto, evidenciando su capacidad para identificar anomalías, generar alertas automáticas y representar gráficamente patrones temporales y geográficos asociados a incidentes de robo de cableado de fibra óptica. La propuesta constituye una base escalable para su futura implementación con datos reales en entornos operativos de telecomunicaciones.

**Palabras clave:** indicadores clave de desempeño (KPI), robo de cable de fibra óptica, telecomunicaciones, monitoreo en tiempo real, análisis de datos, aprendizaje automático.

## Abstract

This project develops a monitoring system based on Key Performance Indicators (KPIs) to mitigate fiber optic cable theft in the localities of Kennedy and Tunjuelito in Bogotá D.C.

The research is based on the design and simulation of an analytical model built from synthetic data that replicate the structural behavior of records typically generated by OSS (Operation Support Systems) and NOC (Network Operations Centers).

The system is implemented through the development of an interactive dashboard that processes simulated information under realistic operational scenarios, applying statistical analysis techniques, event correlation, and machine learning fundamentals to identify theft patterns in near real time. The methodology includes the design of a traceability system, the definition of specific metrics by geographic area, and the functional validation of the model through controlled testing.

The results demonstrate the technical feasibility of the proposed system, highlighting its capability to detect anomalies, generate automated alerts, and graphically represent temporal and geographic patterns associated with fiber optic cable theft incidents. The proposal establishes a scalable foundation for future implementation using real operational data within telecommunications environments.

**Keywords:** key performance indicators, KPIs, fiber optic cable theft, telecommunications, real-time monitoring, data analysis, machine learning.

## Tabla de Contenidos

Dedicatoria.....	2
Agradecimiento.....	3
Resumen.....	4
Abstract.....	5
Lista de tablas .....	9
Lista de Figuras.....	10
1. Introducción .....	11
2. Generalidades.....	13
2.1 Planteamiento del Problema .....	14
2.2 Justificación .....	16
2.3 Objetivos.....	18
Objetivo General-----	18
Objetivos Específicos -----	18
2.4 Marco Teórico y Conceptual .....	19
Marco Conceptual: -----	19
Marco Teórico:-----	19
2.5 Metodología .....	20
2.6 Marco Teórico y Estado del arte.....	22
2.6.1. Problemática global y local del robo de cableado de fibra óptica en Kennedy y Tunjuelito -----	22
2.6.2. Tecnologías y sistemas para la prevención y monitoreo -----	23
2.6.3. Indicadores clave de rendimiento (KPIs) -----	23
2.6.4. Modelos predictivos y machine learning aplicados-----	23

2.6.5. Análisis espacial mediante GIS .....	24
3. Análisis Estadístico de Datos Históricos de Operadores de Telecomunicaciones en las Localidades de Kennedy y Tunjuelito .....	26
3.1 Sistemas OSS y NOC.....	26
3.1.1 Articulación de los KPIs con los patrones de robo, la geolocalización y el machine learning.....	28
3.1.2 Contexto de los operadores de telecomunicaciones.....	31
3.1.3 Impacto social y económico del robo de cableado, con patrones y evidencia de datos históricos.....	31
3.1.4 Distribución porcentual de incidentes por localidad.....	33
4. Identificación automática de patrones de robo y generación de alertas tempranas mediante analítica avanzada y machine learning.....	41
4.1 Diseño del modelo de machine learning.....	42
4.1.1. Variables consideradas .....	43
4.1.2. Bibliotecas empleadas .....	46
4.1.3. Procesos de machine learning involucrados .....	48
4.2 Algoritmo implementado para la simulación del KPI de cortes de fibra óptica. ...	50
4.3 Diseño general del software y análisis de requerimientos .....	52
5. Plataforma de visualización de los indicadores de desempeño para monitorear los incidentes de robo de cableado de fibra óptica. ....	54
5.1 Arquitectura general de la plataforma.....	54
5.1.2 Interfaz del dashboard y propuesta de desarrollo del frontend.....	57
5.1.3 Interpretación de resultados .....	64
5.1.4 Impacto operativo y beneficios esperados .....	69
5.1.5 Trabajo Futuro.....	70

6.	Conclusiones.....	72
7.	Referencias.....	74
	Anexos -----	76



### Lista de tablas

Tabla 1: <i>Variables empleadas para el modelo</i> .....	44
Tabla 2: Bibliotecas empleadas en el modelo Machine Learning .....	47
Tabla 3: <i>Procesos de machine learning involucrados para el modelo propuesto</i> .....	49

## Lista de Figuras

Figura 1: <i>Operaciones Clave Del Sistema OSS En Telecomunicaciones</i> .....	27
Figura 2: <i>Centro De Operaciones De Red</i> .....	27
Figura 3: <i>Indicadores clave de desempeño (KPI)</i> .....	29
Figura 4: <i>Métodos de marcación en tapas de telecomunicaciones antirrobo en Bogotá</i> .....	32
Figura 5: <i>Distribución porcentual de incidentes por localidad</i> .....	34
Figura 6: <i>Distribución de incidentes por localidad</i> .....	36
Figura 7: <i>Identificación de robos en días y horas</i> .....	37
Figura 8: <i>Acrobacias y maniobras de ladrones para hurtar cableado</i> .....	39
Figura 9: <i>Algoritmo implementado</i> .....	51
Figura 10: <i>Arquitectura general de la plataforma de visualización propuesta</i> .....	57
Figura 11: <i>Panel principal Dashboard</i> .....	59
Figura 12: <i>Dashboard de monitoreo de cortes de fibra óptica para las localidades de Kennedy y Tunjuelito (enero–junio 2025)</i> .....	60
Figura 13: <i>Comparación de cortes de fibra</i> .....	61
Figura 14: <i>Niveles de riesgo por mes en Kennedy</i> .....	62
Figura 15: <i>Niveles de riesgo por mes en Tunjuelito</i> .....	63
Figura 16: <i>Visualización geoespacial de eventos de corte de fibra óptica con categorización de anomalías según el KPI</i> .....	64
Figura 17: <i>Resultado del algoritmo: gráfica de KPI de cortes de fibra óptica en Kennedy y Tunjuelito</i> .....	65
Figura 18: <i>Distribución de frecuencia de cortes de fibra óptica en la localidad de Kennedy</i> .....	65
Figura 19: <i>Promedio móvil de cortes de fibra óptica en la localidad de Kennedy</i> .....	66
Figura 20: <i>Promedio móvil de cortes en Kennedy</i> .....	68
Figura 21: <i>Promedio móvil de cortes en Tunjuelito</i> .....	68

## 1. Introducción

En la ciudad de Bogotá, el robo de cableado de fibra óptica se ha convertido en una problemática crítica que afecta directamente la infraestructura de las telecomunicaciones. Este delito no solo genera importantes pérdidas económicas para las empresas operadoras, sino que también impacta negativamente en la calidad del servicio, afectando a miles de usuarios residenciales, instituciones educativas, empresas y entidades de salud que dependen del acceso continuo a internet, telefonía y televisión.

Los operadores de telecomunicaciones han señalado que estos incidentes comprometen la operación de las redes, deterioran la confianza de los usuarios y aumentan la carga operativa y financiera de las compañías. A pesar de los esfuerzos realizados por empresas como ETB, Movistar, Claro y Tigo, mediante patrullajes, cámaras de seguridad y vigilancia en puntos críticos, estas medidas han resultado insuficientes para disminuir de manera sostenida la incidencia de robos en zonas especialmente vulnerables como Kennedy y Tunjuelito.

Esta situación revela una brecha importante en el uso de tecnologías predictivas y de monitoreo que permitan anticiparse a los incidentes, analizar patrones y apoyar la toma de decisiones estratégicas. Frente a este panorama, surge la necesidad de implementar soluciones más sistemáticas y basadas en datos. Por ello, este proyecto propone el desarrollo de un sistema de trazabilidad soportado en indicadores clave de rendimiento (Key Performance Indicators), diseñado para monitorear, clasificar y visualizar incidentes asociados al robo de cableado en las localidades objeto de estudio.

El sistema se fundamenta en el diseño y simulación de un modelo analítico construido a partir de datos sintéticos que replican el comportamiento estructural de registros generados

por sistemas OSS (Operation Support Systems) y NOC (Network Operations Center). A través de esta simulación controlada, se busca identificar patrones geográficos y temporales de posibles robos, generar mapas interactivos y producir reportes automatizados que sirvan como herramienta de apoyo para la toma de decisiones. Con esta propuesta, se pretende demostrar la viabilidad técnica de una solución basada en KPIs, orientada a mitigar el impacto operativo y económico del robo de infraestructura de telecomunicaciones.

## 2. Generalidades

En la ciudad de Bogotá, el robo de cableado de fibra óptica se ha convertido en una problemática crítica que afecta directamente la infraestructura de las telecomunicaciones. Este delito no solo genera importantes pérdidas económicas para las empresas operadoras que existen en Bogotá, sino que también impacta negativamente en la calidad del servicio, afectando a miles de usuarios residenciales, instituciones educativas, empresas y entidades de salud que dependen del acceso continuo a internet, telefonía y televisión en su diario.

Los operadores de telecomunicaciones denuncian que diariamente de manera directa estos incidentes comprometen la operación diaria de las redes, deterioran la confianza de los usuarios y aumentan la carga operativa y financiera de los operadores diariamente. A pesar de los esfuerzos realizados por empresas como ETB, Movistar, Claro y Tigo, mediante patrullajes, cámaras de seguridad o vigilancia en puntos críticos estas medidas han resultado insuficientes para disminuir de manera sostenida la incidencia de robos en zonas especialmente vulnerables como Kennedy y Tunjuelito principalmente.

Esta situación revela una brecha importante en el uso de tecnologías predictivas y de monitoreo que permitan anticiparse a los incidentes que pueden pasar, analizar patrones y tomar decisiones estratégicas. Frente a este panorama, surge la necesidad de implementar soluciones más sistemáticas y basadas en datos. Por ello, este proyecto propone el desarrollo de un sistema de trazabilidad soportado en indicadores clave de rendimiento (Key Performance Indicators), diseñado para monitorear, clasificar y visualizar en tiempo real los incidentes de robo de cableado en las distintas localidades de Bogotá.

El sistema se fundamenta en el análisis de datos históricos y en tiempo real, que permitan identificar patrones geográficos y temporales de robos, generando mapas interactivos y reportes automatizados que sirvan como herramienta de apoyo para la toma de

decisiones. Con esta propuesta, se busca no solo reducir la frecuencia de estos delitos, sino también mitigar su impacto operativo y económico, y fortalecer la capacidad de respuesta de los actores involucrados en la protección de la infraestructura crítica de telecomunicaciones diariamente.

En este capítulo se presentan los fundamentos iniciales del proyecto, proporcionando al lector el contexto necesario para comprender la problemática abordada de robo de cableado de telecomunicaciones. Se expone la introducción y el planteamiento del problema, así como los objetivos generales y específicos que guiaron el desarrollo de la investigación. Igualmente, se justifica la relevancia técnica, social, económica y educativa de la propuesta. Posteriormente a esto, se describen los elementos conceptuales y teóricos que sustentan el trabajo, la metodología aplicada y a su fin el estado del arte relacionado con la temática de estudio.

## **2.1 Planteamiento del Problema**

El robo de cableado de fibra óptica constituye una problemática crítica y persistente que afecta considerablemente la infraestructura de telecomunicaciones en Bogotá D.C. Este delito no solo representa un riesgo para la integridad de las redes, sino que también interrumpe el acceso a servicios esenciales como lo son internet, televisión y telefonía, afectando a miles de usuarios entre residenciales, empresas, instituciones educativas y entidades de salud pública a diario.

Según los datos de la Comisión de Regulación de Comunicaciones (CRC, 2023), los incidentes relacionados con el robo de cableado de fibra óptica han incrementado en un 35% durante los últimos dos años, siendo las localidades de Kennedy y Tunjuelito las más afectadas, con un promedio mensual de 45 y 32 incidentes, respectivamente. Este aumento

revela una tendencia sostenida y preocupante, que evidencia la vulnerabilidad actual de la red de fibra óptica en zonas estratégicas de la ciudad de Bogotá.

Por su parte, el Ministerio de Tecnologías de la Información y las Comunicaciones (MinTIC, 2023) estima que cada incidente de robo implica un costo promedio de \$2.5 millones de pesos colombianos, únicamente en reposición de materiales. Esta cifra no incluye los costos indirectos asociados, como las pérdidas económicas por interrupciones del servicio, compensaciones a usuarios, gastos logísticos por desplazamiento de cuadrillas técnicas, y el deterioro de la imagen de las empresas prestadoras del servicio entre otro

A ello se suma la alerta emitida por la Asociación Nacional de Empresarios de Colombia (ANDI, 2022), la cual señala que aproximadamente el 79% de las interrupciones no programadas del servicio de internet en Bogotá están directamente relacionadas con robos de cableado de fibra óptica. Esto afecta la productividad económica de diversos sectores, la continuidad académica de instituciones educativas diariamente, y pone en riesgo sistemas críticos como la telemedicina y la atención en salud.

Aunque los operadores de telecomunicaciones como lo son ETB, Movistar, Tigo y Claro han implementado medidas reactivas tradicionales como vigilancia física en diferentes zonas, instalación de cámaras de seguridad, y patrullajes en puntos críticos, estas acciones no han logrado una disminución sostenida de los incidentes que se generan. Parte del problema radica en la ausencia de sistemas predictivos y de monitoreo en tiempo real, que permitan identificar patrones y zonas vulnerables antes de que ocurra un incidente.

En consecuencia, se hace evidente una brecha tecnológica en el manejo de datos operativos y de seguridad, los cuales podrían se utilizan para establecer mecanismos de trazabilidad de incidentes, análisis de tendencias, y generación de alertas proactivas

diariamente, mediante el uso de indicadores clave de rendimiento (KPIs), inteligencia artificial y visualización de datos.

Esta situación exige una solución integral, que es la que se presenta en este proyecto, que no solo se enfoque en reacciones posteriores al robo, sino en la anticipación de este, identificación de patrones, y visualización de riesgos. Así es posible tomar decisiones más rápidas y efectivas por parte de los operadores, la policía y las entidades locales correspondientes.

Con este contexto, este proyecto responde a la siguiente pregunta de investigación: ¿Cómo puede un sistema de indicadores clave de rendimiento (KPI-Key Performance Indicator) basado en análisis de datos en tiempo real contribuir a la mitigación del robo de cableado de fibra óptica en las localidades de Kennedy, y Tunjuelito de Bogotá D.C.

## **2.2 Justificación**

El robo de cableado de fibra óptica se ha convertido en una de las problemáticas más críticas para los operadores de telecomunicaciones en Bogotá, afectando de manera directa la continuidad de los servicios de internet, telefonía y televisión. Según el DANE (2023), las pérdidas económicas asociadas a este delito superan los \$15.000 millones de pesos al año, considerando únicamente los costos de reposición de material, sin incluir los impactos indirectos como interrupciones del servicio, desplazamientos de cuadrillas, compensaciones y deterioro de la percepción del usuario. Esta situación evidencia la necesidad urgente de soluciones más eficientes y tecnológicamente avanzadas que permitan anticipar incidentes y reducir el impacto operativo en zonas altamente afectadas como Kennedy y Tunjuelito.

Actualmente, los operadores cuentan con sistemas OSS (Operation Support System) y NOC (Network Operations Center) capaces de generar grandes volúmenes de datos operativos y alarmas en tiempo real. Sin embargo, estos datos no están siendo aprovechados



para la detección predictiva de patrones asociados al robo de infraestructura, lo que limita la capacidad de reacción ante incidentes. Este proyecto se justifica en la necesidad de transformar dichos datos en información estratégica mediante indicadores clave de rendimiento (KPI) y técnicas analíticas capaces de identificar anomalías, zonas críticas y tendencias temporales de afectación.

El sistema propuesto no requiere infraestructura física adicional, ya que utiliza la información que actualmente generan los operadores. Esto garantiza su viabilidad técnica y económica, reduciendo costos y facilitando la integración dentro de los procesos existentes del NOC. Además, la inversión estimada en el desarrollo del sistema KPI equivale a menos del 0,1 % de las pérdidas anuales reportadas por robo de cable, lo cual permite proyectar un retorno de inversión elevado desde el primer año de implementación.

Desde el punto de vista social, el proyecto contribuye a la garantía del derecho a la comunicación de más de 150.000 usuarios ubicados en las localidades de Kennedy y Tunjuelito, quienes dependen del servicio de fibra óptica para actividades esenciales como educación virtual, teletrabajo, telemedicina, seguridad y servicios digitales. Mejorar la detección y mitigación del robo de cableado significa reducir interrupciones, fortalecer la infraestructura crítica y mejorar la calidad de vida de la comunidad.

Finalmente, desde el ámbito académico, el proyecto aporta una propuesta innovadora que articula análisis estadístico, machine learning y visualización de datos para resolver una problemática real en telecomunicaciones. Además, se alinea con el Objetivo de Desarrollo Sostenible 9 (Industria, Innovación e Infraestructura), al promover el uso de tecnologías avanzadas para proteger sistemas esenciales de conectividad en Bogotá.

## **2.3 Objetivos**

### **Objetivo General**

Desarrollar e implementar un sistema de indicadores clave de rendimiento Key Performance Indicator mediante la integración de datos de sistemas (Operation Support System) (Network Operations Center) existentes, técnicas de análisis en tiempo real y algoritmos de geolocalización, para mitigar los robos de cableado de fibra óptica en las localidades de Kennedy, y Tunjuelito de Bogotá D.C.

### **Objetivos Específicos**

Caracterizar los patrones de robo de cableado de fibra óptica mediante el análisis estadístico de datos históricos de los últimos 12 meses provenientes de los sistemas (Operation Support System) (Network Operations Center) de los operadores de telecomunicaciones en las localidades de Kennedy, y Tunjuelito.

Diseñar e implementar algoritmos de correlación y machine learning utilizando Python y bibliotecas especializadas (Pandas, Scikit-learn, NumPy) para la identificación automática de patrones de robo y la generación de alertas tempranas basadas en variables como ubicación, hora, frecuencia y tipo de alarma obtenida por los reportes de fallas.

Desarrollar una plataforma de visualización de Key Performance Indicator mediante herramientas como Power BI o Grafana que permita el monitoreo en tiempo real de incidentes de robo del cableado de fibra óptica, la generación de reportes automáticos y la identificación visual de zonas críticas a través de mapas interactivos.

Validar la efectividad del sistema a través de pruebas funcionales al software realizadas tanto en Front como en back.

## 2.4 Marco Teórico y Conceptual

### Marco Conceptual:

Indicadores Clave de Rendimiento Key Performance Indicator: Métricas cuantificables que permiten evaluar el desempeño de procesos específicos en relación con objetivos estratégicos organizacionales. En telecomunicaciones, los Key Performance Indicator son fundamentales para el monitoreo de la calidad del servicio, la gestión de recursos y la optimización operacional (Cabrera et al., 2019).

Sistemas OSS/NOC: Los Operation Support Systems (OSS) y Network Operations Centers (NOC) son plataformas tecnológicas que gestionan y monitorean la infraestructura de telecomunicaciones, generando datos operacionales en tiempo real sobre el estado de la red, alarmas y eventos de mantenimiento (Martinez & Salinas, 2020).

Análisis Predictivo en Telecomunicaciones: Aplicación de técnicas estadísticas y algoritmos de machine learning para identificar patrones en datos históricos y predecir eventos futuros, permitiendo la toma de decisiones proactivas en la gestión de redes (Roa, 2021).

### Marco Teórico:

Teoría de Redes de Nueva Generación (NGN - Next Generation Network) las redes de nueva Generación (NGN) constituyen una evolución tecnológica que integra múltiples servicios de comunicación como lo son voz, datos y TV sobre una infraestructura basada en protocolo IP convergente. Estas redes buscan optimizar los recursos para las personas, aumentar la capacidad de transmisión y facilitar la interoperabilidad entre plataformas.

Según Verdecia Peña (2019), las NGN requieren sistemas de, seguridad, monitoreo y gestión más sofisticados, debido a su alta dependencia de la conectividad continua para los usuarios. En este contexto, el monitoreo mediante indicadores de desempeño (KPIs) se vuelve esencial para garantizar la calidad del servicio que se otorga al cliente final y la disponibilidad de la red, especialmente frente a incidentes como el robo o corte de cableado de fibra óptica.

Frente a la teoría de Gestión de Contingencias plantea que los sistemas de telecomunicaciones deben estar preparados para mantener su operación ante eventos inesperados o disruptivos, tales como robos, cortes o daños en la infraestructura física para su correcto funcionamiento.

De acuerdo con Quintero et al. (2023), la efectividad de la respuesta ante una contingencia depende de la capacidad de detección temprana, análisis de impacto y reconfiguración automática de la red que se tiene en telecomunicaciones.

## **2.5 Metodología**

Enfoque de investigación: La investigación adopta un enfoque mixto (cuantitativo-cualitativo) con diseño experimental, orientado a la evaluación del impacto de la implementación del sistema KPI- Key Performance Indicator: en la reducción de robos de cableado de fibra óptica en las localidades de Kennedy y Tunjuelito en Bogotá.

Fases metodológicas:

Fase 1: Análisis de datos históricos (Mes 1-2)

- Recopilación de datos de robos de cableado de los últimos 12 meses de sistemas OSS (Operation Support System) y NOC (Network Operations Center)

- Análisis estadístico descriptivo para identificar patrones temporales y geográficos
- Caracterización de variables críticas (ubicación, hora, tipo de alarma, tiempo de respuesta)

Fase 2: Desarrollo del sistema KPI -Key Performance Indicator: (Mes 2-4)

- Diseño de algoritmos de correlación utilizando Python y bibliotecas especializadas
- Implementación de modelos de machine learning para detección de patrones
- Desarrollo de la plataforma de visualización con dashboards interactivos

Fase 3: Implementación piloto (Mes 4-5)

- Despliegue del sistema en las tres localidades seleccionadas
- Integración con sistemas OSS (Operation Support System) /NOC (Network Operations Center) existentes

Fase 4: Evaluación y validación (Mes 5-6)

- Medición de indicadores de efectividad (tiempo de respuesta, frecuencia de incidentes)
- Análisis comparativo con datos históricos
- Validación de los componentes funcionales del software

Técnicas de recolección de datos:

- Extracción de datos de sistemas OSS (Operation Support System) /NOC (Network Operations Center) mediante APIs (Interfaz de Programación de Aplicaciones) y logs (archivo)

- Búsqueda de información en bases de datos

Técnicas de análisis:

- Análisis estadístico descriptivo e inferencial
- Técnicas de machine learning (clustering, regresión, clasificación)

## **2.6 Marco Teórico y Estado del arte**

### **2.6.1. Problemática global y local del robo de cableado de fibra óptica en Kennedy y Tunjuelito**

El robo de cableado de fibra óptica es un problema creciente a nivel mundial, con impactos significativos en la infraestructura crítica de las empresas de telecomunicaciones, la economía y la seguridad de las redes. Diversos países han reportado incrementos importantes en estos delitos, lo que afecta la continuidad de los servicios de internet, telefonía y datos, generando pérdidas millonarias y afectando a millones de usuarios diariamente.

En Colombia, y particularmente en la ciudad de Bogotá, este problema se ha intensificado en los últimos años. Según la Comisión de Regulación de Comunicaciones (CRC, 2023), el robo de cableado de fibra óptica ha aumentado en un 35% en los últimos dos años, con las localidades de Kennedy y Tunjuelito son las más afectadas. Estos incidentes equivalen a un promedio mensual de 45 y 33 robos respectivamente diarios, evidenciando una alta vulnerabilidad en estas zonas estratégicas para la red de telecomunicaciones de los operadores

El robo de cableado de fibra óptica no solo afecta la operación técnica de las redes, sino que también tiene consecuencias sociales, estudiantiles, médicas, tecnológicas entre muchas otras. La interrupción de servicios de telecomunicaciones vulnera derechos fundamentales como el acceso a la información y la comunicación, afectando a usuarios residenciales, comerciales e institucionales, entre otros.

El daño económico comprende costos directos de reparación y reemplazo, así como pérdidas indirectas por interrupciones en el servicio, afectación a la productividad y a la

seguridad ciudadana, ya que parte de estos cables sustentan servicios de emergencia y vigilancia.

### **2.6.2. Tecnologías y sistemas para la prevención y monitoreo**

En el ámbito de las telecomunicaciones, se utilizan sistemas como OSS (Operation Support System) y NOC (Network Operations Center) para la gestión y monitoreo de redes de los operadores. Estos sistemas permiten vigilar en tiempo real el estado de la red, detectar fallos y responder a incidentes. Sin embargo, su utilización para la prevención específica del robo de cableado es limitada y no está suficientemente desarrollada.

El uso de dashboards interactivos que integran datos de estos sistemas con algoritmos de análisis de tráfico y correlación de eventos representa un avance significativo para las empresas operadoras de telecomunicaciones. La visualización en tiempo real y la generación de alertas automáticas permiten acelerar la detección y la reacción frente a incidentes, mejorando la eficiencia operativa diaria.

### **2.6.3. Indicadores clave de rendimiento (KPIs)**

Los KPIs en telecomunicaciones son métricas fundamentales para medir y gestionar la calidad y desempeño de redes. Para la gestión de incidentes de robo de cableado particularmente, se pueden definir indicadores específicos como tiempo de detección de incidentes, frecuencia de eventos por zona, tiempo de respuesta, entre otros. Estos indicadores permiten no solo monitorear sino también evaluar la efectividad de las estrategias de mitigación y ajuste continuo del sistema en las telecomunicaciones.

### **2.6.4. Modelos predictivos y machine learning aplicados**

El análisis predictivo mediante técnicas estadísticas y algoritmos de machine learning constituye una herramienta avanzada para anticipar eventos futuros basados en patrones

históricos de datos que se tienen. En el contexto de la seguridad de redes, estos modelos pueden identificar patrones de comportamiento que preceden a los ataques o robos, facilitando una intervención proactiva.

Estudios recientes (Roa, 2021) han demostrado la eficacia de algoritmos de clustering, clasificación y regresión en la detección de patrones anómalos en el tráfico de red y eventos asociados al robo de infraestructura de telecomunicaciones. La implementación de estos modelos en sistemas de monitoreo contribuye a mejorar la precisión de las alertas y reduce la dependencia de reacciones meramente reactivas.

### **2.6.5. Análisis espacial mediante GIS**

El análisis espacial mediante Sistemas de Información Geográfica (GIS) se utilizó para identificar la distribución geográfica del robo de cableado y determinar zonas con alta concentración de incidentes. Esta herramienta permitió integrar variables como localidad, barrio, tipo de afectación y frecuencia histórica de robos dentro de un entorno cartográfico, facilitando una interpretación visual más precisa del comportamiento del delito.

Para este proyecto se generaron mapas temáticos donde se representaron:

- Zonas de mayor incidencia, identificadas a partir de la frecuencia de cortes simulados.
- Corredores viales y sectores vulnerables, donde históricamente se presentan mayores robos.
- Distribución espacial de los incidentes por periodos de tiempo, lo que permitió observar patrones repetitivos por semanas o meses.
- Áreas críticas consolidadas, obtenidas mediante técnicas básicas de densidad de puntos (*heatmaps*), que permiten visualizar focos de riesgo.



El uso de GIS facilita que un operador pueda focalizar recursos, priorizar cuadrillas y diseñar acciones preventivas con enfoque geográfico. Además, permite integrar el KPI dentro del mapa para visualizar en tiempo real qué zonas presentan mayor riesgo, lo que fortalece la toma de decisiones operativas y estratégicas.

Este análisis está alineado con lo planteado en la propuesta inicial, donde se mencionaba la necesidad de realizar una caracterización espacial del problema para complementar las métricas del KPI y mejorar la identificación de patrones geográficos asociados al robo de infraestructura.

### **3. Análisis Estadístico de Datos Históricos de Operadores de Telecomunicaciones en las Localidades de Kennedy y Tunjuelito**

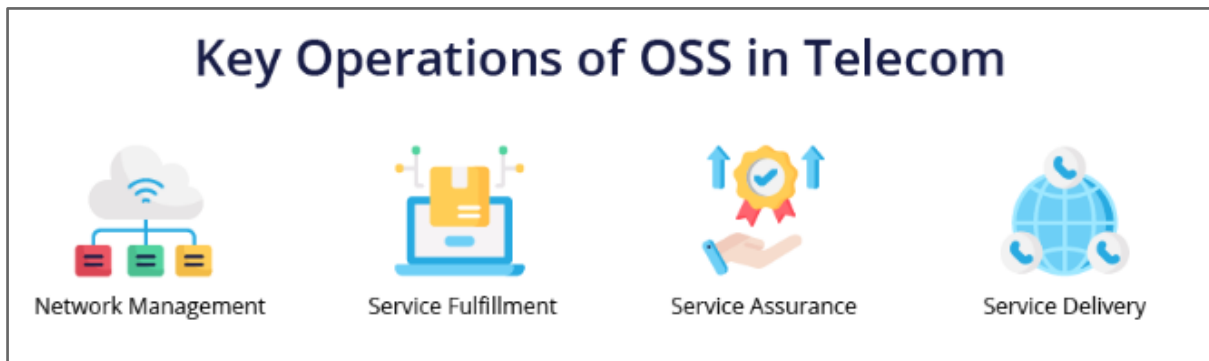
Este capítulo presenta los conceptos principales, sistemas y herramientas fundamentales utilizados en el desarrollo del sistema de monitoreo para mitigar el robo de cableado de fibra óptica en las localidades de Kennedy y Tunjuelito de Bogotá D.C. Se exploran los sistemas de soporte y operación de redes como lo son (OSS y NOC), los principales operadores de telecomunicaciones en la zona de estudio ETB, CLARO, MOVISTAR, la definición y relevancia de los indicadores clave de desempeño (KPIs), y la relación entre estos indicadores y los patrones de robo detectados en la infraestructura crítica de los operadores. Este sirve como base para la propuesta metodológica y el diseño del sistema de trazabilidad basado en análisis de datos.

#### **3.1 Sistemas OSS y NOC**

Los sistemas de soporte a la operación (OSS) y los centros de operación de red (NOC) son componentes esenciales en la gestión y monitoreo de las redes de telecomunicaciones.

- Sistema OSS (Operation Support System): Es un conjunto de herramientas y aplicaciones que soportan las operaciones de la red, facilitando la administración de configuración de equipos, el monitoreo del rendimiento, la gestión de fallos y la provisión de servicios. OSS recopila y procesa grandes cantidades de datos, permitiendo a los operadores mantener la red operativa y confiable diariamente como se ilustra en la figura 1.

**FIGURA 1:**  
**OPERACIONES CLAVE DEL SISTEMA OSS EN TELECOMUNICACIONES**



**Nota.** Tomado de *OSS en telecomunicaciones*, por Tridens Technology (s. f.),

<https://tridens technology.com/es/oss-en-telecomunicaciones/>

Centro de Operación de Red (NOC): Es el lugar desde donde se supervisa en tiempo real la red de telecomunicaciones, con personal especializado que monitorea alertas, fallas, se puede coordinar respuestas ante incidentes y mantiene la continuidad de los servicios. El NOC utiliza información en tiempo real y datos históricos para detectar anomalías y tomar decisiones rápidas de las fallas presentadas representado en la figura 2.

**FIGURA 2:**  
**CENTRO DE OPERACIONES DE RED**



**Nota.** Tomado de *Centro de operaciones de red NOC 3000*, por GDC Technology (s. f.),

<https://www.gdc-tech.com/soluciones/software-empresarial-de-cine/centro-de-operaciones-de-red-noc-3000/?lang=es>

Ambos sistemas generan flujos constantes de información que, cuando son analizados de manera integrada, permiten identificar patrones operativos y comportamientos anómalos asociados al robo de cableado. El OSS aporta información histórica y detallada del rendimiento de la red, mientras que el NOC registra en tiempo real las incidencias, alertas y fluctuaciones que pueden indicar una afectación deliberada. La combinación de estos dos entornos produce un conjunto de datos robusto y trazable, capaz de revelar tendencias específicas como incrementos repentinos en los cortes, reincidencias en puntos críticos o coincidencias entre fallas y horarios de baja supervisión.

Esta sinergia entre OSS y NOC no solo facilita la detección temprana de incidentes, sino que también optimiza la planificación de las respuestas operativas, la priorización de zonas vulnerables y la asignación eficiente de recursos técnicos. Al convertirse en insumos clave para el análisis estadístico y los modelos de machine learning, los datos provenientes de estos sistemas permiten construir una visión predictiva que mejora la capacidad del operador para anticipar robos, reducir el tiempo de reacción y fortalecer la protección de la infraestructura de telecomunicaciones en Bogotá.

### **3.1.1 Articulación de los KPIs con los patrones de robo, la geolocalización y el machine learning**

Los KPIs Key Performance Indicator (Indicador Clave de Desempeño) son métricas cuantificables que evalúan el éxito y desempeño de diversas operaciones dentro de las redes de telecomunicaciones.

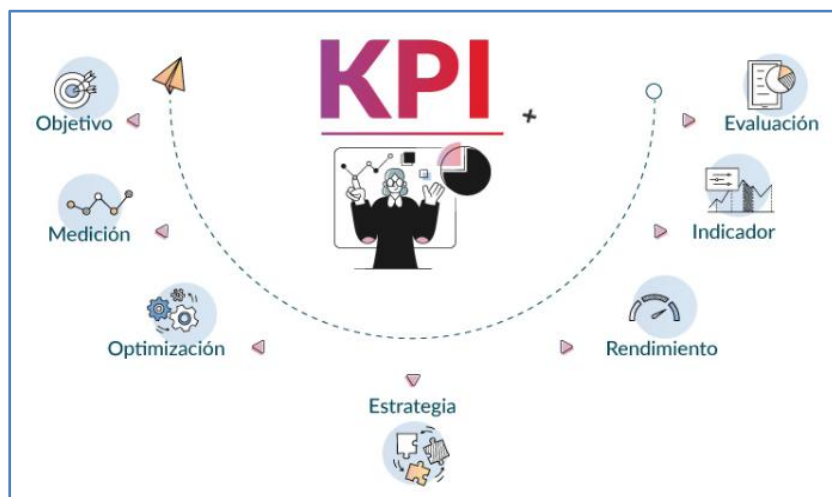
En este proyecto, se han definido KPIs específicos para medir la efectividad del sistema de monitoreo en la detección y mitigación de robos de cableado de fibra óptica, entre ellos:

- Tiempo medio de detección de incidentes diarios: Mide la rapidez con que el sistema identifica un evento de la falla.

- Frecuencia de incidentes por zona geográfica: Indica la cantidad de robos en diferentes áreas, permitiendo identificar zonas críticas en este caso Kennedy y Tunjuelito.
- Número de alertas generadas y gestionadas: Permite valorar la efectividad del sistema de notificaciones automáticas de las fallas presentadas.
- Disponibilidad y calidad del servicio post-incidente: Mide el impacto en la continuidad y calidad del servicio tras un evento de falla.

Estos KPIs son herramientas esenciales para la supervisión continua, análisis de tendencias y ajustes estratégicos que optimicen la efectividad del sistema de monitoreo de los operadores de telecomunicaciones como se ilustra en la figura 3.

**FIGURA 3:**  
**INDICADORES CLAVE DE DESEMPEÑO (KPI)**



**Nota.** Tomado de *KPI marketing digital: qué son, tipos y ejemplos*, por Marketeros Agencia (s. f.), <https://www.marketerosagencia.com/blog/inbound-marketing/kpi-marketing-digital/>

Por otra parte, el machine learning emplea algoritmos que aprenden de datos para identificar patrones y realizar predicciones sin programación explícita para los sistemas operativos, utilizando diferentes técnicas como la clasificación, el clustering y la regresión para poder detectar anomalías en la red para poder anticipar robos, con los modelos de

conjuntos de datos robustos para poder en entregar, validar y probar un desempeño continuo, esto con el fin de poder mejorar la detección temprana de alertas generadas por el hurto del cableado de fibra óptica.

De una forma complementaria, los sistemas de información geográfica (GIS) permiten capturar, representar y analizar datos geoespaciales a través de diferentes mapas interactivos que pueden mostrar la distribución de las alarmas detectadas. Estos sistemas posibilitan definir zonas críticas, analizar patrones geográficos y optimizar recursos destinados únicamente para prevención y respuesta.

El análisis de la información histórica y en tiempo real recopilada por los sistemas OSS y NOC, combinado con técnicas avanzadas como machine learning y sistemas de información geográfica (GIS), facilita la identificación de patrones temporales y espaciales en la ocurrencia de robos de cableado. Los cuales se traducen en diferentes variaciones en los KPIs , que al momento de ser monitoreados continuamente permiten detectar anomalías capaces de poder predecir futuros eventos en Colombia, dado que la evolución de la fibra óptica ha transformado la conectividad digital en la masificación de servicios como la telefonía, el internet, la televisión, entre muchos otros , sin embargo para la ciudad de Bogotá en las localidades de Kennedy y Tunjuelito , la constante creciente de telecomunicaciones ha comprometido la seguridad física de la misma.

La correlación entre los KPIs y los patrones de robo posibilita la generación automática de alertas, asimismo posibilita la generación automática de alertas, con diseño de mapas, interactivos y la planificación de intervenciones preventivas, para que el sistema propuesto no solo responda a los incidentes, si no que se llegue anticipar a los mismos, de esta manera se optimizan recursos técnicos y lógicos para proteger la infraestructura de telecomunicaciones.

### **3.1.2 Contexto de los operadores de telecomunicaciones**

En las localidades de Kennedy y Tunjuelito operan múltiples proveedores de servicios de telecomunicaciones como ETB, Claro y Movistar, quienes suministran internet, telefonía, televisión y otros servicios a una población aproximada de 150.000 usuarios en estas zonas (Min TIC, 2023). Estos operadores se encuentran regulados por el Ministerio de Tecnologías de la Información y las Comunicaciones (Min TIC) y supervisados por la Comisión de Regulación de Comunicaciones (CRC), entidades responsables de garantizar la adecuada prestación y continuidad de los servicios en Colombia (CRC, 2023).

El aumento significativo del robo de cableado de fibra óptica afecta de manera considerable la operación de estos proveedores, ya que genera interrupciones masivas, sobrecostos operativos y disminución en la calidad del servicio ofrecido a los usuarios. La colaboración con los operadores es fundamental para acceder a información precisa y actualizada, indispensable para el desarrollo del sistema de monitoreo y la implementación de acciones preventivas en las zonas más vulnerables como Kennedy y Tunjuelito.

Estos operadores también soportan infraestructura crítica necesaria para servicios esenciales en la ciudad, como comunicaciones de emergencia, teletrabajo, educación virtual y servicios de salud. Por esta razón, proteger su red resulta vital para el desarrollo social, la estabilidad operativa y la continuidad del servicio en Bogotá (Min TIC, 2023).

### **3.1.3 Impacto social y económico del robo de cableado, con patrones y evidencia de datos históricos**

El robo de cableado afecta no solo técnicamente sino también social y económicamente, estas afectaciones se pueden evidenciar como:

- Interrupción de servicios esenciales a hogares, empresas, colegios, hospitales entre muchos otros.

- Afectación al derecho fundamental de comunicación.
- Elevados costos de reparación y mantenimiento debido a las fallas.
- Incremento en la percepción de inseguridad.

Implementar sistemas avanzados de monitoreo contribuye a minimizar estos impactos, mejorando la calidad de vida y estabilidad económica tanto de los usuarios como de los operadores de telecomunicaciones, también los operadores han optado por marcar los puntos de tapas para indicar que no se cuenta con cableado como se muestra en la figura 4.

**FIGURA 4:**

***MÉTODOS DE MARCACIÓN EN TAPAS DE TELECOMUNICACIONES ANTIRROBO EN BOGOTÁ***



**Nota.** Tomado de *Capturan a cinco personas por robar fibra óptica de cables en el norte de Bogotá*, por *El Tiempo* (2024), <https://www.eltiempo.com/bogota/capturan-a-cinco-personas-por-robar-fibra-optica-de-cables-en-el-norte-de-bogota-3465635>

Los hallazgos relacionados con los patrones de robo de cableado de fibra óptica, las características de los incidentes más comunes y la evidencia estadística se obtiene a partir del



análisis de datos históricos de 12 meses provenientes de las plataformas OSS y NOC de los operadores.

El procesamiento de los datos recolectados en las plataformas OSS y NOC permitió elaborar un conjunto de indicadores estadísticos clave que muestran la distribución porcentual de incidentes por localidad y la frecuencia mensual de robos y cortes. A continuación, se evidencia las estadísticas.


#### **3.1.4 Distribución porcentual de incidentes por localidad**

El análisis porcentual de los incidentes registrados durante el periodo de estudio de enero a junio evidencia una concentración significativamente mayor de eventos en la localidad de Kennedy frente a Tunjuelito. En términos cuantitativos, Kennedy aportó aproximadamente el 64.1% del total de cortes de fibra óptica simulados, mientras que Tunjuelito representó el 35.9% restante. Esta diferencia refleja un comportamiento disímil entre ambas zonas, lo cual sugiere que los factores geográficos, poblacionales y operativos pueden influir en la frecuencia y el tipo de incidentes que afectan la infraestructura de telecomunicaciones en Bogotá.

Como se observa en la Figura 5, la representación mediante un gráfico de tipo torta permite visualizar con claridad la proporción relativa entre ambas localidades, destacando la mayor incidencia en la localidad de Kennedy. Esta predominancia puede estar asociada a características de la zona, como su tamaño poblacional, la extensión de su red desplegada o la presencia de corredores viales donde la infraestructura es más vulnerable a afectaciones de robo. Por otro lado, aunque Tunjuelito presenta un porcentaje menor, su participación del 35.9% continúa siendo relevante, dado que representa más de un tercio del total de los eventos analizados en los meses de enero a junio.

Este tipo de visualización es particularmente útil para los equipos técnicos y de supervisión en campo, ya que permite identificar rápidamente las áreas que requieren mayor atención o priorización en los planes de mantenimiento preventivo, asignación de recursos o despliegue de personal técnico para su validación. En conjunto, la distribución porcentual confirma la necesidad de desarrollar estrategias diferenciadas por localidad y de considerar el comportamiento histórico de cada una para mejorar la efectividad de la gestión operativa del KPI.

**FIGURA 5:**  
***DISTRIBUCIÓN PORCENTUAL DE INCIDENTES POR LOCALIDAD***



**Nota.** Elaboración propia a partir de los datos analizados en el proyecto.

#### **Frecuencia mensual de robos y cortes:**

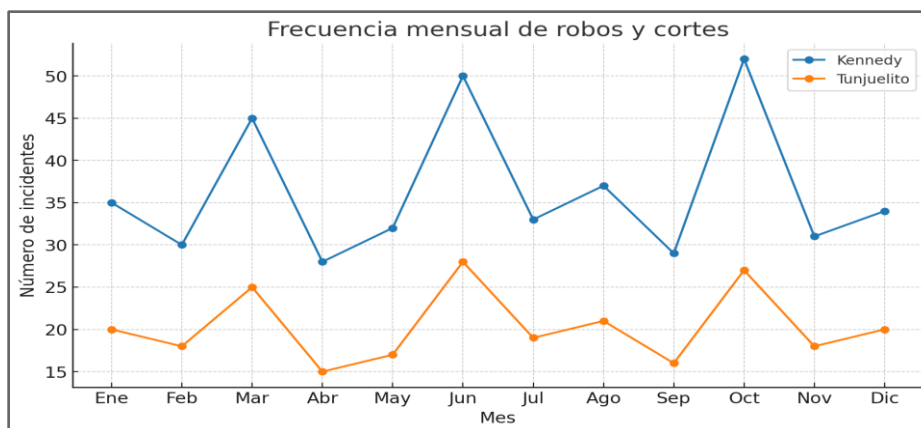
El análisis temporal de los incidentes evidencia variaciones importantes en la frecuencia de robos y cortes de fibra óptica en los meses de enero a junio. Los datos muestran incrementos significativos durante los meses de marzo, junio, los cuales corresponden a picos de afectación simultáneos en ambas localidades analizadas. Estos repuntes pueden estar

asociados a condiciones operativas, estacionales o de comportamiento delictivo que influyen directamente en la vulnerabilidad de la red de telecomunicaciones.

La Figura 6 presenta la evolución mensual de los incidentes mediante una gráfica de línea con puntos, la cual permite identificar con claridad los patrones ascendentes y los cambios abruptos en el comportamiento del KPI. Este tipo de visualización es especialmente útil para resaltar la tendencia general del año, así como para detectar meses críticos donde se concentran más eventos. En particular, los incrementos visibles en los periodos mencionados sugieren la presencia de factores recurrentes que podrían estar relacionados con horarios de mayor exposición, zonas con obras civiles, o incluso dinámicas delictivas específicas para las localidades de Kennedy y Tunjuelito.

El seguimiento de esta frecuencia mensual resulta fundamental para los equipos de supervisión de red de las empresas de telecomunicaciones, ya que permite anticipar posibles comportamientos futuros, programar intervenciones preventivas y asignar recursos técnicos estratégicamente. Además, estos patrones temporales sirven como insumo clave para los modelos predictivos, ya que facilitan la identificación de estacionalidad y contribuyen a mejorar la precisión de los algoritmos de aprendizaje automático aplicados al KPI.

**FIGURA 6:**  
***DISTRIBUCIÓN DE INCIDENTES POR LOCALIDAD***



**Nota.** Elaboración propia a partir de los datos analizados en el proyecto.

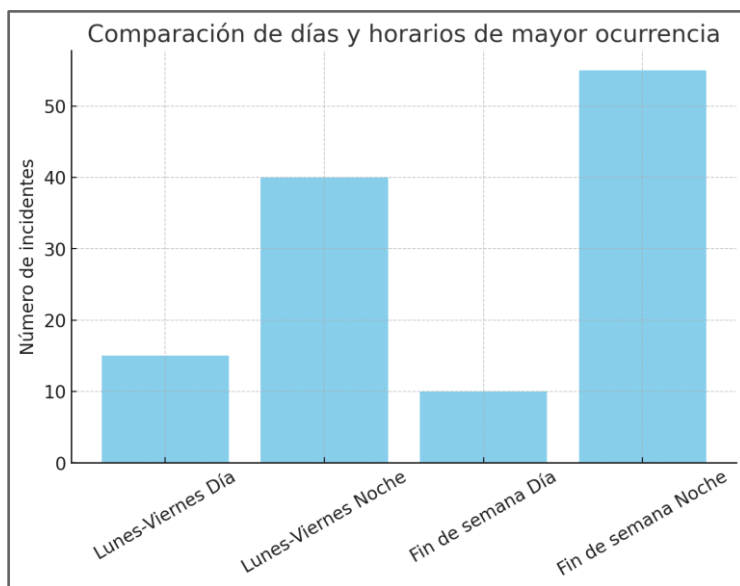
Adicionalmente, se pudo observar una comparación de días y horarios de mayor ocurrencia. Allí se destaca que los fines de semana y las madrugadas fueron los periodos de mayor vulnerabilidad, coincidiendo con la reducción en patrullajes y vigilancia comunitaria en las localidades.

Por último, mediante mapas interactivos se identificaron áreas específicas en Kennedy y Tunjuelito con mayor recurrencia de robos, lo que constituye un insumo fundamental para la priorización de acciones preventivas frente a estos robos.

El análisis de los KPIs permitió identificar tendencias claras en la ocurrencia de los incidentes tales como:

Los robos se concentran principalmente en horas nocturnas y de madrugada (entre 11:00 p.m. y 3:00 a.m.), debido a la reducción en los niveles de vigilancia en las zonas de Kennedy y Tunjuelito como se evidencia en la figura 7.

**FIGURA 7:**  
**IDENTIFICACIÓN DE ROBOS EN DÍAS Y HORAS**



**Nota.** Elaboración propia a partir de los datos analizados en el proyecto.

Las zonas con mayor recurrencia de incidentes corresponden a barrios periféricos y sectores con deficiente iluminación pública entre calles.

Se evidenció reincidencia en puntos críticos, donde los robos se repitieron en periodos cortos de tiempo como dos horas o cinco horas, lo que refleja ausencia de medidas correctivas efectivas.

La mayor cantidad de incidentes se registró en la localidad de Kennedy, aunque Tunjuelito también presentó una incidencia significativa en robos.

Estos patrones demuestran que los KPIs son una herramienta eficaz para anticipar eventos y priorizar recursos de seguridad y respuesta.

Del análisis detallado de los reportes se pueden destacar las siguientes características:

En la mayoría de los casos, el tipo de infraestructura afectada corresponde a la fibra óptica de las empresas de telecomunicaciones en Bogotá la cual se encuentra instalada en cámaras subterráneas y portería de fácil acceso, lo que facilita la labor de los delincuentes al momento de cometer los robos en las localidades de Kennedy y Tunjuelito. La motivación principal detrás de estos hechos es de carácter económico, dado que los materiales como el cobre, la fibra, el plástico y otros metales presentes en el cableado continúan representando un alto valor en el mercado ilegal para estos delincuentes, convirtiéndose en el principal incentivo para el hurto del cableado

Estos incidentes suelen concentrarse en sectores con deficiente iluminación, zonas industriales poco transitadas y áreas residenciales sin vigilancia constante de fácil acceso, que se convierten en puntos estratégicos para los delincuentes debido a la baja probabilidad de ser descubiertos. Asimismo, se ha identificado reincidencia en las localidades de Kennedy y Tunjuelito, donde se han reportado múltiples eventos en periodos cortos de tiempo, lo que evidencia la falta de medidas de refuerzo posteriores a los primeros incidentes. Esta situación demuestra la facilidad con la que los delincuentes logran acceder nuevamente a la infraestructura para sustraer el cableado, tal como se observa en la figura 8.

**ACROBACIAS Y MANIOBRAS DE LADRONES PARA HURTAR CABLEADO**

**Nota.** Tomado de *Ladrones arriesgan su vida trepando postes de luz para robar cables de fibra óptica en Bogotá*, por Citytv – El Tiempo (2024),

<https://citytv.eltiempo.com/noticias/seguridad/ladrones-arriesgan-su-vida-trepando-postes-de-luz-para-robar-cables-de-fibra-optica-en-bogota>

En conclusión, la integración del análisis estadístico con los KPIs operativos permitió construir una comprensión detallada y multidimensional de la dinámica del robo de cableado en las localidades estudiadas de Kennedy y Tunjuelito. Los datos evidencian que los incidentes no ocurren de manera aleatoria, sino que presentan patrones temporales, espaciales y operativos que se repiten y que pueden ser anticipados mediante un monitoreo adecuado por parte del NOC. La concentración de eventos durante la noche y la madrugada, la recurrencia en puntos críticos con baja iluminación, y la mayor incidencia en sectores periféricos de Kennedy confirman que existen condiciones estructurales y ambientales que incrementan la vulnerabilidad de la red de los operadores de telecomunicaciones.

Asimismo, la distribución porcentual de incidentes por localidad y la evolución mensual del KPI revelan comportamientos diferenciados entre Kennedy y Tunjuelito, lo cual indica que cada zona requiere estrategias de intervención específicas. Kennedy muestra picos de alta magnitud en periodos breves, mientras que Tunjuelito refleja un comportamiento más estable, pero con fluctuaciones recurrentes. Esta dualidad aporta elementos claves para priorizar recursos, definir rutas de inspección y ajustar los protocolos de seguridad de la infraestructura.

La evidencia visual, obtenida a través de gráficas de torta, líneas de tiempo y mapas de calor, refuerza la utilidad de los KPIs como herramientas para interpretar la afectación real sobre la red. Su capacidad para señalar incrementos anormales, ubicar puntos de reincidencia y mostrar tendencias históricas hace posible la anticipación de riesgos y la planificación táctica dentro del NOC.

Finalmente, este análisis demuestra que los KPIs no solo permiten medir la magnitud del problema, sino que además ofrecen un insumo estratégico para los futuros modelos de machine learning del proyecto. Al identificar estacionalidad, ciclos de recurrencia y correlaciones entre horarios, zonas y frecuencia de eventos, se fortalece la base para desarrollar un sistema predictivo capaz de generar alertas tempranas y mejorar la capacidad de respuesta ante robos de infraestructura. En conjunto, estos hallazgos consolidan el valor operativo del KPI y justifican la necesidad de avanzar hacia sistemas automatizados que integren datos históricos, análisis estadístico y modelado predictivo dentro de una misma plataforma de supervisión.



#### **4. Identificación automática de patrones de robo y generación de alertas tempranas mediante analítica avanzada y machine learning**

Este capítulo presenta el desarrollo del modelo propuesto para la identificación automática de patrones asociados al robo y corte de cableado en redes de fibra óptica, enfocado en las localidades de Kennedy y Tunjuelito en Bogotá D.C.

A diferencia de enfoques tradicionales basados únicamente en umbrales, el modelo implementado adopta una arquitectura híbrida que integra técnicas estadísticas, análisis de correlación y algoritmos de machine learning, con el fin de mejorar la precisión en la detección de eventos anómalos.

En este capítulo se describe la estructura general del sistema, iniciando con la adquisición de datos (reales o simulados), seguido de su procesamiento y generación de variables derivadas que permiten enriquecer el análisis. Posteriormente, se aplican técnicas estadísticas para identificar patrones de comportamiento y relaciones entre zonas.

Como componente central, se incorporan algoritmos de aprendizaje no supervisado, específicamente Isolation Forest para la detección de anomalías y K-Means para la clasificación de niveles de riesgo, permitiendo segmentar los eventos en categorías como normal, alerta y crítico

Finalmente, se integra un sistema de indicadores clave de desempeño (KPI) que combina los resultados del análisis estadístico y del modelo de machine learning, generando alertas automáticas que facilitan la detección temprana de incidentes y contribuyen a la optimización en la toma de decisiones operativas, así como al fortalecimiento de las estrategias de seguridad en la infraestructura de telecomunicaciones.

## 4.1 Diseño del modelo de machine learning

El modelo de machine learning fue diseñado con el propósito de identificar automáticamente patrones asociados al robo y corte de cableado en redes de fibra óptica, así como generar alertas tempranas a partir del análisis de indicadores clave de desempeño (KPI) y variables derivadas del comportamiento de la red.

A diferencia de enfoques tradicionales basados únicamente en comparaciones históricas, la propuesta implementa un enfoque híbrido que integra simulación de datos, análisis estadístico y algoritmos de aprendizaje no supervisado, permitiendo una detección más robusta y adaptable a cambios en el comportamiento de las fallas.

El diseño del modelo sigue una estructura modular compuesta por cuatro fases principales:

1. Entrada de datos:

Se realiza la carga de datos provenientes de fuentes OSS/NOC o, en su defecto, la generación de datos sintéticos que simulan eventos de cortes de fibra óptica en las localidades de Kennedy y Tunjuelito, garantizando la continuidad del análisis durante la fase de desarrollo.

2. Procesamiento y generación de variables:

Se construyen variables derivadas a partir de los datos originales, tales como variación diaria de cortes (Delta), promedio móvil de 7 días (MA7), acumulados (KPI\_Acum), día de la semana y segmentación temporal. Estas variables permiten enriquecer el análisis y capturar patrones temporales relevantes.

3. Detección de anomalías y segmentación de riesgo:

Se implementa el algoritmo Isolation Forest para identificar comportamientos atípicos en los datos, asignando un puntaje de anomalía a cada observación.

Posteriormente, se utiliza K-Means para clasificar los eventos en niveles de riesgo (normal, alerta y crítico), facilitando la interpretación operativa de los resultados.

#### 4. Visualización y generación de alertas KPI:

Se integran los resultados del modelo en un sistema de visualización que permite identificar tendencias, anomalías y niveles de riesgo. Adicionalmente, se establecen umbrales dinámicos basados en percentiles (P75 y P90) y en el score de anomalía, generando alertas automáticas que apoyan la toma de decisiones en tiempo real.

Este diseño permite una fácil escalabilidad del sistema, facilitando su integración futura con datos reales provenientes de plataformas OSS y NOC, y su aplicación directa en entornos operativos para la gestión proactiva de incidentes en la red.

##### **4.1.1. Variables consideradas**

Para la construcción del modelo propuesto basado en KPI y machine learning, fue necesario identificar un conjunto de variables clave que permitieran representar de manera adecuada el comportamiento de los incidentes asociados al robo y corte de fibra óptica en las localidades de Kennedy y Tunjuelito.

Estas variables constituyen la base estructural del análisis, integrando dimensiones temporales, espaciales y operativas que influyen directamente en la ocurrencia de los eventos. En la Tabla 1 se presentan las variables principales empleadas en el modelo, junto con su descripción.

**TABLA 1:**  
**VARIABLES EMPLEADAS PARA EL MODELO**

<b>Variable</b>	<b>Descripción</b>
<b>Fecha</b>	Periodo comprendido entre enero y junio de 2025, utilizado para la simulación y análisis temporal
<b>Zona</b>	Localidades de Kennedy y Tunjuelito
<b>Numero de Cortes diarios</b>	La cantidad de eventos de corte registrados por día.
<b>Total, de Cortes (KPI)</b>	Métrica agregada que refleja el nivel de afectación de la red
<b>Score de anomalía</b>	Valor generado por el algoritmo Isolation Forest que indica el grado de anormalidad
<b>Nivel de riesgo</b>	Clasificación generada mediante K-Means (normal, alerta, crítico)

Fuente: Elaboración propia

Estas variables permiten modelar patrones espaciotemporales asociados al comportamiento de las fallas. La variable Fecha posibilita el análisis de estacionalidad y fue transformada en variables derivadas como día de la semana, número de semana y un indicador de fin de semana, facilitando la identificación de patrones periódicos.

La variable Zona aporta la dimensión geográfica del análisis, permitiendo identificar diferencias en el comportamiento de las fallas entre localidades. Durante el preprocesamiento, esta variable fue codificada para su uso en los algoritmos de machine learning.

El número de cortes diarios y el KPI de cortes permiten analizar tanto el comportamiento granular como el impacto agregado en la operación de la red.

A diferencia de enfoques tradicionales, el modelo no se basa en umbrales fijos ni promedios históricos. En su lugar, se emplea un enfoque de aprendizaje no supervisado, donde el algoritmo Isolation Forest genera un *score de anomalía* para cada observación, permitiendo identificar comportamientos atípicos sin necesidad de etiquetas previas.

Adicionalmente, se implementa el algoritmo K-Means para segmentar los datos en niveles de riesgo (normal, alerta y crítico), facilitando la interpretación operativa de los resultados.

Se generaron variables derivadas que fortalecen la capacidad predictiva del modelo, entre ellas:

- Variación diaria de cortes (Delta)
- Promedio móvil de 7 días (MA7)
- KPI acumulado (KPI\_Acum)
- Segmentación temporal (día de la semana y fines de semana)

Estas variables permiten capturar cambios bruscos y tendencias en el comportamiento de la red.

Para garantizar la calidad del dataset, se aplicaron técnicas de limpieza y tratamiento de datos, incluyendo imputación de valores faltantes mediante mediana para variables numéricas y moda para variables categóricas. Asimismo, se documentaron registros incompletos para análisis de sensibilidad.

En conjunto, estas variables y transformaciones permiten construir un modelo más robusto, capaz de anticipar eventos críticos y mejorar la capacidad de respuesta ante incidentes en la infraestructura de telecomunicaciones.

#### **4.1.2. Bibliotecas empleadas**

La implementación del modelo se desarrolló utilizando bibliotecas de Python especializadas en análisis de datos, visualización y machine learning, las cuales permiten garantizar eficiencia, escalabilidad y reproducibilidad en el procesamiento de la información.

Estas herramientas facilitan la manipulación de datos, la generación de variables derivadas, la aplicación de algoritmos de aprendizaje no supervisado y la visualización de resultados. En la Tabla 2 se presentan las principales bibliotecas utilizadas y su función dentro del modelo.

**TABLA 2:**  
**BIBLIOTECAS EMPLEADAS EN EL MODELO MACHINE LEARNING**

<b>Biblioteca</b>	<b>Función principal</b>
<b>Pandas</b>	gestión y manipulación de datos en estructuras tipo DataFrame
<b>NumPy</b>	generación de distribuciones de probabilidad y operaciones matemáticas.
<b>Matplotlib</b>	construcción de gráficos para analizar el comportamiento del KPI.
<b>Scikit-learn:</b>	Implementación de algoritmos de machine learning como Isolation Forest (detección de anomalías) y K-Means (segmentación de riesgo)

Fuente: Elaboración Propia (2025)

Estas bibliotecas permiten estructurar un flujo de trabajo eficiente para el análisis de datos, desde la carga y transformación de la información hasta la aplicación de modelos analíticos avanzados.

En particular, la biblioteca Scikit-learn desempeña un papel fundamental al proporcionar los algoritmos de aprendizaje no supervisado utilizados en el modelo, permitiendo identificar comportamientos atípicos en los datos y clasificar los eventos según su nivel de riesgo sin necesidad de etiquetas previas.

El uso de estas herramientas no solo garantiza la correcta implementación del modelo, sino que también facilita su futura integración con sistemas reales provenientes de plataformas OSS y NOC, permitiendo su escalabilidad en entornos operativos.

#### **4.1.3. Procesos de machine learning involucrados**

El modelo implementado se basa en un enfoque de aprendizaje no supervisado, orientado a la detección de anomalías y segmentación de comportamientos en los datos asociados a cortes de fibra óptica. A diferencia de los modelos supervisados tradicionales, este enfoque no requiere datos etiquetados previamente, lo cual resulta adecuado para escenarios donde los eventos de robo no siempre están claramente identificados.

El sistema se estructura en una serie de procesos analíticos que permiten transformar los datos en información útil para la toma de decisiones. En la Tabla 3 se presentan los procesos principales involucrados en el modelo.



**TABLA 3:**  
**PROCESOS DE MACHINE LEARNING INVOLUCRADOS PARA EL MODELO PROPUESTO**

Proceso	Descripción
<b>Preparación de datos</b>	Limpieza, transformación y generación de variables derivadas (Delta, MA7, KPI_Acum, variables temporales)
<b>Detección de anomalías</b>	Aplicación de Isolation Forest para identificar comportamientos atípicos en los datos
<b>Segmentación de riesgo</b>	Uso de K-Means para clasificar los eventos en niveles de riesgo (normal, alerta, crítico)
<b>Generación de alertas</b>	Activación de alertas automáticas basadas en el score de anomalía y umbrales dinámicos (percentiles)

Fuente: Elaboración propia (2025)

Estos procesos constituyen la estructura central del modelo analítico propuesto. En primer lugar, la preparación de datos permite mejorar la calidad de la información mediante la limpieza, imputación de valores faltantes y la construcción de variables derivadas que capturan patrones temporales y operativos relevantes.

Posteriormente, se implementa el algoritmo Isolation Forest, el cual permite identificar observaciones anómalas dentro del conjunto de datos, asignando un puntaje que representa el grado de desviación respecto al comportamiento normal de la red.

Adicionalmente, se emplea el algoritmo K-Means para segmentar los datos en diferentes niveles de riesgo, facilitando la interpretación de los resultados desde una perspectiva operativa.

A diferencia de enfoques predictivos tradicionales, el modelo no busca estimar eventos futuros de manera directa, sino detectar de forma temprana comportamientos inusuales que puedan estar asociados a incidentes de robo o fallas en la infraestructura.

Finalmente, el sistema de generación de alertas traduce los resultados del modelo en acciones concretas, permitiendo notificar automáticamente a los sistemas de supervisión del NOC cuando se identifican patrones críticos, lo cual contribuye a reducir los tiempos de respuesta y mejorar la gestión operativa de la red.

#### **4.2 Algoritmo implementado para la simulación del KPI de cortes de fibra óptica.**

El desarrollo del algoritmo se realizó en lenguaje Python, utilizando el entorno colaborativo Google Colab, el cual permite integrar el procesamiento de datos, la ejecución de código y la visualización gráfica en un mismo espacio de trabajo. Este entorno facilita la trazabilidad del proceso, la replicación del experimento y la posterior integración con herramientas de análisis más avanzadas.

Para el diseño del modelo se emplearon las bibliotecas Pandas, NumPy y Matplotlib, seleccionadas por su eficiencia y amplio uso en entornos de análisis de datos y desarrollo científico.

El algoritmo implementado, presentado en la Figura 9, tiene como propósito simular el comportamiento del KPI de cortes de fibra óptica en las localidades de Kennedy y Tunjuelito durante el periodo comprendido entre enero y junio de 2025. A partir de estos datos simulados, se generan indicadores como el promedio histórico, las variaciones

temporales del KPI y la identificación de periodos con incrementos significativos en el número de eventos registrados.

Este proceso permite comprender la dinámica del fenómeno incluso antes de disponer de datos reales, lo cual resulta fundamental para validar las primeras fases del modelo, como se evidencia en el Anexo A.

**FIGURA 9:**  
**ALGORITMO IMPLEMENTADO**

```

print(df[["Fecha", "Zona", "Cortes"]].mean().to_string(index=False))

# =====
# FASE 1 - PREPARACIÓN Y VARIABLES DERIVADAS
# =====
print("\n" + "=" * 60)
print("FASE 1: Preparación y variables derivadas")
print("=" * 60)

df["DiaSemana"] = df["Fecha"].dt.dayofweek
df["NombreDia"] = df["Fecha"].dt.day_name()
df["Semana"] = df["Fecha"].dt.isocalendar().week.astype(int)
df["Mes"] = df["Fecha"].dt.month
df["EsFinSemana"] = (df["DiaSemana"] >= 5).astype(int)
df["Delta"] = df.groupby("Zona")["Cortes"].diff().fillna(0)
df["KPI_Acum"] = df.groupby("Zona")["Cortes"].cumsum()
df["MA7"] = df.groupby("Zona")["Cortes"].transform(
    lambda x: x.rolling(7, min_periods=1).mean())

print(f" Variables generadas: {list(df.columns)}")
print(f"\n Resumen por zona:")
print(df.groupby("Zona")["Cortes"].agg(["sum", "mean", "max", "std"]).round(2))

# =====
# FASE 2 - ANÁLISIS ESTADÍSTICO Y CORRELACIÓN
# =====
print("\n" + "=" * 60)
print("FASE 2: Análisis estadístico y correlación")
print("=" * 60)

print("\n Estadística descriptiva por zona:")
print(df.groupby("Zona")["Cortes"].describe().round(2))

k = df[df["Zona"] == "Kennedy"]
t = df[df["Zona"] == "Tunjuelito"]
dias = ["Lunes", "Martes", "Miércoles", "Jueves", "Viernes", "Sábado", "Domingo"]
print("\n Promedio de cortes por día de semana:")
for i, dia in enumerate(dias):
    mk = k[k["DiaSemana"] == i]["Cortes"].mean()
    mt = t[t["DiaSemana"] == i]["Cortes"].mean()
    print(f" {dia:12s} Kennedy: {mk:.2f} Tunjuelito: {mt:.2f}")

pivot = df.pivot_table(index="Fecha", columns="Zona", values="Cortes", aggfunc="sum")
if "Kennedy" in pivot.columns and "Tunjuelito" in pivot.columns:
    r_pearson, p_pearson = stats.pearsonr(pivot["Kennedy"], pivot["Tunjuelito"])
    r_spearman, p_spearman = stats.spearmanr(pivot["Kennedy"], pivot["Tunjuelito"])
    print(f"\n Correlación Pearson : r={r_pearson:.4f} p={p_pearson:.4f}")

```

Nota. Creación propia.

### 4.3 Diseño general del software y análisis de requerimientos

Además del análisis del modelo y la arquitectura general, el sistema requiere un conjunto de funcionalidades que permitan operar de forma coherente con el enfoque implementado en el algoritmo, el cual se basa en el cálculo de indicadores KPI y la detección de anomalías mediante métodos estadísticos.

En este sentido, el software incorpora procesos de captura, limpieza, procesamiento y análisis de datos, orientados a identificar variaciones significativas en el comportamiento del KPI de cortes de fibra óptica.

El sistema no se limita al cálculo del indicador, sino que transforma datos operativos en información útil para la toma de decisiones, permitiendo detectar incrementos anómalos en los eventos registrados en las localidades de Kennedy y Tunjuelito.

Desde el punto de vista funcional, el software permite la carga de registros de incidentes provenientes de sistemas OSS o reportes del NOC. Una vez ingresados, los datos son sometidos a un proceso de limpieza y organización, donde se clasifican según variables como fecha, localidad y número de cortes.

Posteriormente, el sistema ejecuta el algoritmo implementado, el cual calcula el KPI de cortes diarios, obtiene un promedio histórico y compara los valores actuales frente a dicho promedio. A partir de esta comparación, se identifican desviaciones significativas que son interpretadas como posibles anomalías asociadas a eventos de robo de cableado.

Los resultados del análisis son presentados en un entorno de visualización, donde el usuario puede observar la evolución temporal del KPI, identificar picos anormales y reconocer patrones de comportamiento en cada localidad. Adicionalmente, el sistema resalta

los periodos críticos donde se superan los valores esperados, facilitando la interpretación de los datos.

Las funcionalidades del sistema se alinean con los perfiles de usuario identificados:

- Analista NOC: consulta el KPI actualizado y monitorea variaciones diarias.
- Supervisor de cuadrillas: identifica rápidamente los periodos con mayor número de cortes para priorizar atención.
- Ingeniero de red: analiza tendencias históricas del KPI para la toma de decisiones preventivas.

El modelo de datos soporta el almacenamiento de información simulada y procesada, incluyendo registros diarios, valores promedio y resultados del análisis de desviación. Esto garantiza la trazabilidad del cálculo del KPI y la identificación de eventos anómalos.

El flujo del sistema sigue una estructura secuencial acorde con el algoritmo implementado. Inicialmente, los datos son ingresados y validados; posteriormente, se calcula el KPI diario y el promedio histórico. Luego, se realiza la comparación estadística para detectar anomalías. Finalmente, los resultados son visualizados mediante gráficos que permiten analizar el comportamiento del sistema en el tiempo.

Aunque en esta etapa el modelo se basa en simulación y análisis estadístico, el diseño del software permite una evolución futura hacia la integración de técnicas de machine learning, donde el sistema podrá aprender automáticamente de datos reales y mejorar la precisión en la detección de eventos asociados al robo de cableado.

## **5. Plataforma de visualización de los indicadores de desempeño para monitorear los incidentes de robo de cableado de fibra óptica.**

En este capítulo se presenta el diseño y desarrollo de la plataforma de visualización orientada al monitoreo de los indicadores clave de desempeño (KPI) asociados a los incidentes de robo de cableado de fibra óptica en las localidades de Kennedy y Tunjuelito.

Se describe la arquitectura general del sistema, la cual está estructurada en tres capas principales: datos, procesamiento y visualización. Estas permiten organizar la información desde su generación hasta su representación gráfica, garantizando trazabilidad y facilidad de análisis.

Asimismo, se propone el diseño de un dashboard que facilita la interpretación del comportamiento del KPI, permitiendo a los analistas del NOC identificar variaciones, tendencias y posibles anomalías en los datos. Esta visualización se basa en los resultados obtenidos a partir del algoritmo implementado, el cual calcula el KPI y lo compara con su promedio histórico para detectar desviaciones significativas.

Finalmente, se presenta el funcionamiento del prototipo desarrollado en Google Colab, donde se integran los procesos de simulación, cálculo del KPI y generación de gráficos, evidenciando cómo la herramienta permite monitorear de forma sencilla y efectiva los incidentes asociados al robo de cableado

### **5.1 Arquitectura general de la plataforma**

La plataforma de visualización propuesta se diseñó bajo una arquitectura modular organizada en tres capas principales, con el objetivo de optimizar el flujo de información,

garantizar la trazabilidad de los datos y mejorar la capacidad de monitoreo frente a incidentes de robo o corte de fibra óptica en las localidades de Kennedy y Tunjuelito.

Esta estructura permite separar de manera lógica los procesos de captura, procesamiento y visualización de la información, facilitando la escalabilidad del sistema y su futura integración con datos reales provenientes de entornos operativos.

### **Capa de datos:**

Esta capa integra los registros provenientes de sistemas OSS (Operation Support Systems) y del NOC (Network Operations Center), así como los datos simulados utilizados en esta fase del proyecto. Aquí se gestionan alarmas, reportes de fallas y eventos históricos relacionados con cortes de fibra óptica. La transferencia de datos puede realizarse mediante APIs o archivos estructurados, garantizando disponibilidad y actualización de la información.

### **Capa de procesamiento:**

Corresponde al núcleo analítico de la plataforma. En esta capa se ejecuta el algoritmo implementado, el cual calcula el KPI de cortes diarios, determina el promedio histórico y evalúa las variaciones del comportamiento del indicador. A partir de este análisis, se identifican desviaciones significativas que son interpretadas como posibles anomalías asociadas a eventos de robo de cableado.

Adicionalmente, se realizan procesos de limpieza, normalización y transformación de datos, con el fin de asegurar consistencia y calidad en la información procesada.

### **Capa de visualización:**

Esta capa representa la interfaz orientada al usuario del NOC. Aquí se presenta de forma gráfica el comportamiento del KPI, incluyendo su evolución temporal, los valores promedio y los periodos donde se detectan anomalías. La visualización permite identificar tendencias,

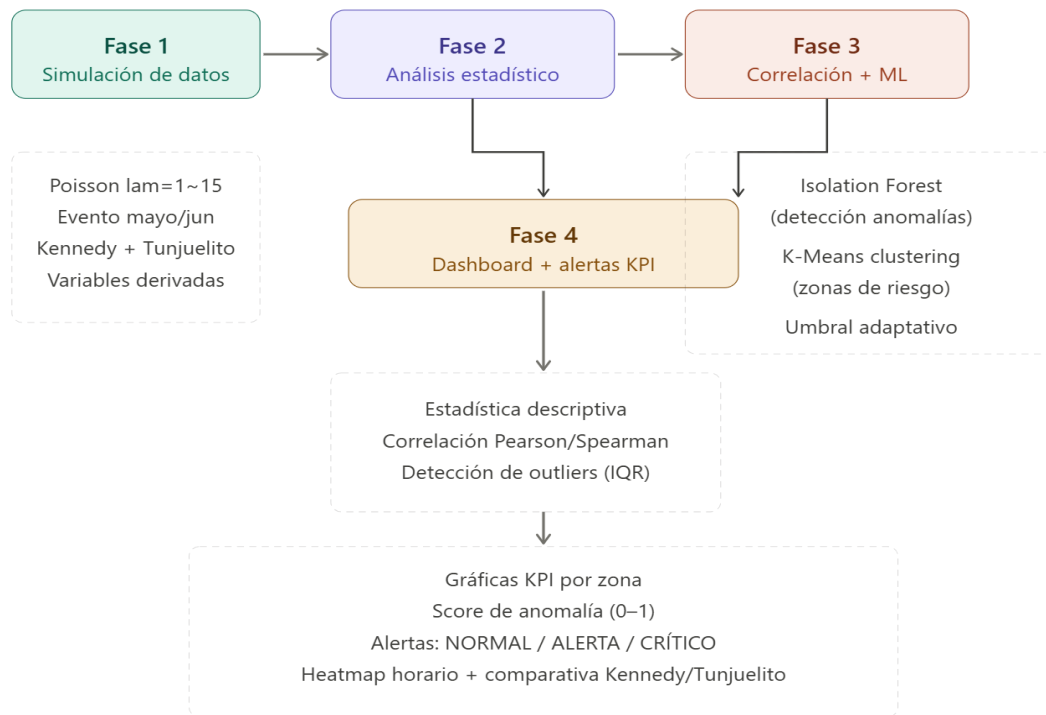
comparar localidades y resaltar eventos críticos, facilitando la toma de decisiones operativas en tiempo real.

La Figura 10 representa la arquitectura modular del sistema mediante una disposición vertical de tres capas. En la parte superior se encuentra la capa de datos, donde se originan los registros. Esta se conecta con la capa de procesamiento, donde se ejecuta el cálculo del KPI y la detección de anomalías. Finalmente, la información fluye hacia la capa de visualización, donde los resultados son presentados de manera gráfica para su interpretación por parte del usuario.

La interacción entre estas capas garantiza un flujo continuo de información, desde la captura del dato hasta su análisis y visualización, fortaleciendo los procesos de monitoreo y permitiendo una mejor gestión de los incidentes en la red de telecomunicaciones.



**FIGURA 10:**  
**ARQUITECTURA GENERAL DE LA PLATAFORMA DE VISUALIZACIÓN PROPUESTA**



Nota. Elaboración propia (2025).

### 5.1.2 Interfaz del dashboard y propuesta de desarrollo del frontend

El sistema contempla su evolución hacia una plataforma de monitoreo interactiva, inicialmente desarrollada como un prototipo funcional en el entorno de programación Google Colab. En esta fase, la interfaz permite visualizar el comportamiento de los indicadores clave de desempeño (KPI) asociados a cortes y posibles eventos de robo de fibra óptica en las localidades de Kennedy y Tunjuelito.

A través de este prototipo, los analistas pueden observar la evolución temporal del KPI, identificar variaciones significativas respecto al promedio histórico y detectar anomalías

durante el periodo comprendido entre enero y junio de 2025. En este sentido, la interfaz no solo cumple una función de visualización, sino que también actúa como un medio de validación del algoritmo implementado, el cual incorpora criterios estadísticos y técnicas básicas de detección de anomalías propias del enfoque de machine learning adoptado en el modelo.

Aunque actualmente la solución se ejecuta en Google Colab, el diseño fue planteado con el objetivo de migrar hacia un frontend más robusto y escalable. Para ello, se propone el uso de tecnologías como HTML5, CSS3 y JavaScript, junto con frameworks especializados en visualización de datos como Dash o Streamlit. Esta evolución permitiría integrar actualizaciones dinámicas, interacción en tiempo real y conexión directa con APIs provenientes de sistemas OSS y NOC, facilitando su implementación en entornos operativos reales.

La interfaz del dashboard fue diseñada bajo principios de simplicidad e interpretación rápida, priorizando la claridad en la visualización del KPI y su relación con el comportamiento histórico. El panel principal permite analizar la evolución temporal de los cortes de fibra óptica, contrastar los valores observados frente a los promedios de referencia e identificar desviaciones significativas que son interpretadas por el algoritmo como posibles eventos anómalos. Asimismo, facilita la comparación entre las localidades de Kennedy y Tunjuelito, lo que permite reconocer diferencias en la frecuencia e intensidad de los incidentes y, por tanto, identificar zonas con mayor nivel de riesgo.

La Figura 11 presenta el panel principal del dashboard, donde se evidencia la evolución del KPI junto con los puntos críticos detectados por el algoritmo. Esta representación permite al usuario identificar de manera inmediata los picos de afectación y comprender su comportamiento dentro del contexto operativo de la red.

**FIGURA 11:**  
**PANEL PRINCIPAL DASHBOARD**

```

# =====
# PROYECTO DE GRADO - SISTEMA KPI FIBRA ÓPTICA
# Autora: Laura Calderón | C.C. 1033758214
# UNAD - Ingeniería de Telecomunicaciones
# Kennedy y Tunjuelito, Bogotá D.C. - 2025
# =====
# ESTRUCTURA:
# FASE 0 - Carga de datos reales (CSV/Excel) o simulación
# FASE 1 - Preparación y variables derivadas
# FASE 2 - Análisis estadístico y correlación
# FASE 3 - Algoritmos de ML (Isolation Forest + K-Means)
# FASE 4 - Dashboard KPI con alertas automáticas
# =====

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.gridspec as gridspec
from scipy import stats
from sklearn.ensemble import IsolationForest
from sklearn.cluster import KMeans
from sklearn.preprocessing import StandardScaler
import os
import warnings
warnings.filterwarnings('ignore')

plt.rcParams['figure.figsize'] = (14, 6)
plt.rcParams['font.size'] = 11

# =====
# FASE 0 - CARGA DE DATOS REALES O SIMULACIÓN
# =====
# El sistema acepta un archivo CSV o Excel con datos
# reales provenientes de sistemas OSS/NOC.
#
# FORMATO ESPERADO DEL ARCHIVO:
#
#   Fecha      Zona      Cortes
#   -----
#   2025-01-01 Kennedy      3
#   2025-01-01 Tunjuelito  1
#   2025-01-02 Kennedy      2
#   ...        ...        ...
#
#
#
#

```


Nota. Elaboración propia (2025).

El dashboard principal constituye la vista central del sistema, en la cual el personal del NOC puede analizar el comportamiento diario de los cortes de fibra óptica. A través de esta visualización, es posible identificar incrementos abruptos en el KPI que superan el umbral definido, los cuales son interpretados como posibles eventos de robo o afectación significativa en la infraestructura.

La Figura 12 muestra un ejemplo de este comportamiento para la localidad de Kennedy, donde se observa la serie de cortes diarios junto con el promedio histórico. En esta

gráfica se destaca un punto crítico en el que el KPI presenta un aumento considerable, evidenciando una anomalía detectada por el modelo. Este tipo de representación permite reconocer eventos críticos, comparar el comportamiento real frente a valores esperados y analizar la aparición de patrones atípicos a lo largo del tiempo.


**FIGURA 12:**  
**DASHBOARD DE MONITOREO DE CORTES DE FIBRA ÓPTICA PARA LAS LOCALIDADES DE KENNEDY Y TUNJUELITO (ENERO–JUNIO 2025)**



Nota. Elaboración propia (2025).

Adicionalmente, el sistema incorpora visualizaciones comparativas entre localidades, lo que permite analizar diferencias en el comportamiento del KPI y reconocer zonas con mayor incidencia de fallas. La Figura 13 presenta un ejemplo de comparación entre Kennedy y Tunjuelito, facilitando el análisis territorial del problema y fortaleciendo la toma de decisiones basada en datos.

**FIGURA 13:**  
**COMPARACIÓN DE CORTES DE FIBRA**



Nota. Elaboración propia (2025).

Los gráficos generados mediante las librerías Pandas y Matplotlib permiten representar de forma clara las variaciones del KPI, destacando tendencias, picos y periodos de estabilidad. Estas visualizaciones constituyen el núcleo del sistema, ya que transforman datos numéricos en información interpretable que apoya directamente la gestión operativa del NOC.


Asimismo, el dashboard permite identificar zonas críticas a partir de los periodos en los que el KPI presenta desviaciones significativas respecto al comportamiento esperado, lo cual facilita la priorización de incidentes y la planificación de acciones correctivas o preventivas por parte del personal técnico.

Las Figuras 14 y 15 presentan la visualización mensual de los cortes de fibra óptica para las localidades de Kennedy y Tunjuelito, respectivamente, permitiendo analizar la evolución del KPI durante el periodo evaluado y evidenciar diferencias en el comportamiento entre ambas zonas.

Finalmente, aunque la implementación actual corresponde a un prototipo académico, demuestra la viabilidad de construir una herramienta funcional para el monitoreo de incidentes sin requerir infraestructura compleja. Este desarrollo constituye una base sólida


para futuras versiones orientadas a entornos reales, donde el sistema pueda integrarse directamente con plataformas operativas del NOC y evolucionar hacia un modelo de analítica avanzada con capacidades predictivas.

**FIGURA 14:**  
*NIVELES DE RIESGO POR MES EN KENNEDY*



Nota. Elaboración propia (2025).

**FIGURA 15:**  
**NIVELES DE RIESGO POR MES EN TUNJUELITO**



Nota. Elaboración propia (2025).

Finalmente, el sistema incorpora un mapa interactivo que permite visualizar la distribución geográfica de los incidentes de corte de fibra óptica en las localidades de Kennedy y Tunjuelito. En esta representación, cada evento es mostrado mediante marcadores dinámicos cuyo color indica el nivel de alerta del KPI (normal, alerta y crítico), mientras que el tamaño del punto está asociado al nivel de anomalía detectado por el modelo.

Adicionalmente, el mapa integra funcionalidades como agrupación de eventos (clustering), visualización por capas y ventanas emergentes con información detallada de cada incidente, lo que facilita el análisis espacial y la identificación de zonas críticas.


La Figura 16 presenta el mapa interactivo del sistema, donde se evidencia la localización de los incidentes, la diferenciación por niveles de alerta y la concentración de eventos en determinadas zonas, permitiendo complementar el análisis temporal del KPI con una perspectiva geográfica.





**FIGURA 17:**

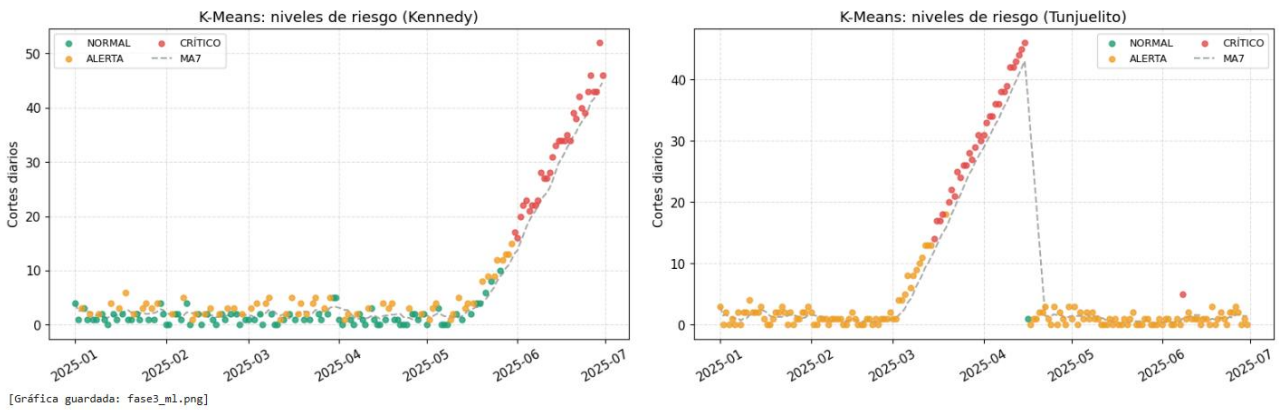
**RESULTADO DEL ALGORITMO: GRÁFICA DE KPI DE CORTES DE FIBRA ÓPTICA EN KENNEDY Y TUNJUELITO**



Nota. Elaboración propia (2025).

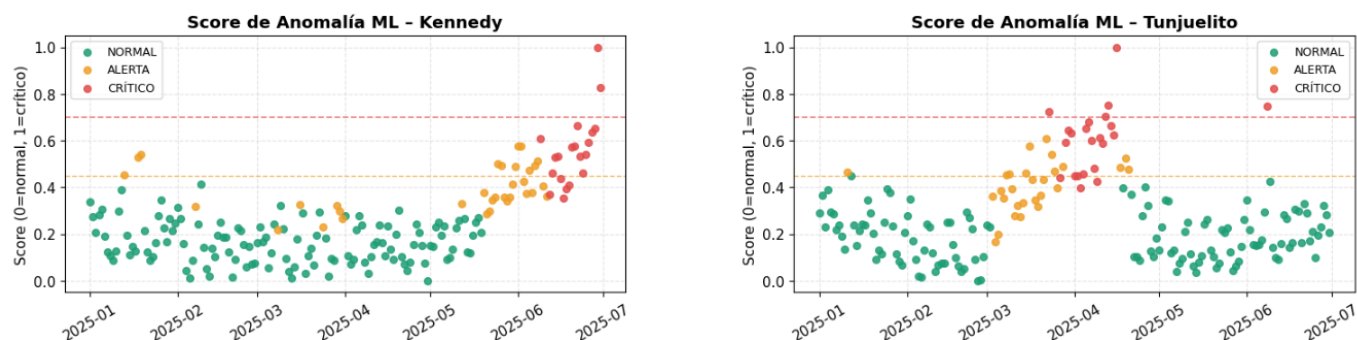
**FIGURA 18:**

**DISTRIBUCIÓN DE FRECUENCIA DE CORTES DE FIBRA ÓPTICA EN LA LOCALIDAD DE KENNEDY**



Nota. Elaboración propia (2025).

**FIGURA 19:**  
**PROMEDIO MÓVIL DE CORTES DE FIBRA ÓPTICA EN LA LOCALIDAD DE KENNEDY**



Nota. Elaboración propia (2025).

determinados rangos y reconocer patrones de comportamiento en cada zona. A partir de estos resultados, es posible establecer umbrales más precisos para el KPI y orientar estrategias de mitigación basadas en el comportamiento histórico de los eventos.

En la localidad de Kennedy se evidencia un incremento significativo a partir del mes de mayo, con un crecimiento cercano al 30 % respecto al promedio de los meses anteriores. Este aumento no solo es abrupto, sino que se mantiene de forma sostenida en el tiempo, lo que sugiere la presencia de eventos recurrentes asociados a robo de cableado o intervenciones no autorizadas. La tendencia ascendente del KPI indica un comportamiento concentrado y de alto impacto, posiblemente relacionado con condiciones de vulnerabilidad en la infraestructura o dinámicas delictivas específicas en la zona.

Por otro lado, la localidad de Tunjuelito presenta un comportamiento más estable en términos de magnitud, aunque con fluctuaciones constantes durante el periodo analizado. A diferencia de Kennedy, donde los picos son pronunciados, en Tunjuelito se observan variaciones menores pero recurrentes, las cuales pueden estar asociadas a daños progresivos,

fallas técnicas o eventos de menor escala. Este patrón refleja una afectación continua que, aunque menos crítica en el corto plazo, impacta la calidad del servicio de manera acumulativa.

Las Figuras 20 y 21 muestran el promedio móvil de cortes de fibra óptica para ambas localidades, lo que permite suavizar la variabilidad de los datos y analizar la tendencia general del KPI. A partir de estas gráficas, se confirma que Kennedy concentra eventos de mayor intensidad en periodos cortos, mientras que Tunjuelito mantiene una tendencia más uniforme con variaciones moderadas en el tiempo.

Esta diferenciación es clave para la operación del NOC, ya que permite priorizar acciones correctivas en zonas con eventos críticos y definir estrategias de mantenimiento preventivo en sectores con afectación recurrente.

En conjunto, los resultados demuestran que el modelo propuesto es capaz de identificar anomalías, tendencias críticas y patrones de comportamiento en los indicadores de desempeño. Esto evidencia su potencial como herramienta de apoyo en la supervisión de redes de telecomunicaciones en Bogotá, especialmente al integrarse con plataformas NOC para la generación de alertas tempranas y la optimización de los tiempos de respuesta ante incidentes de robo o cortes en infraestructura FTTH.

**FIGURA 20:**  
**PROMEDIO MÓVIL DE CORTES EN KENNEDY**

```

=====
REPORTE FINAL - ALERTAS KPI GENERADAS
=====

Kennedy - Top 5 días más críticos:
Fecha          Cortes   Score Nivel_Riesgo
-----
2025-06-29     52    1.000 CRÍTICO
2025-06-30     46    0.827 CRÍTICO
2025-06-22     42    0.662 CRÍTICO
2025-06-28     43    0.652 CRÍTICO
2025-06-27     43    0.638 CRÍTICO

Tunjuelito - Top 5 días más críticos:
Fecha          Cortes   Score Nivel_Riesgo
-----
2025-04-16      1    1.000 NORMAL
2025-04-13     44    0.750 CRÍTICO
2025-06-08      5    0.748 CRÍTICO
2025-03-23     25    0.723 CRÍTICO
2025-04-12     43    0.704 CRÍTICO

=====
PROCESO COMPLETADO | MODO: SIMULACIÓN
Archivos generados:
fase2_correlacion.png
fase3_ml.png
fase4_dashboard_kpi.png

```

Nota. Elaboración propia (2025).

**FIGURA 21:**  
**PROMEDIO MÓVIL DE CORTES EN TUNJUELITO**

```

[Gráfica guardada: fase3_ml.png]

=====
FASE 4: Dashboard KPI con alertas automáticas
=====

Umbrales Kennedy:  Media=7.70  P75=5.00 (ALERTA)  P90=28.00 (CRÍTICO)

Umbrales Tunjuelito:  Media=6.76  P75=4.00 (ALERTA)  P90=28.00 (CRÍTICO)

Resumen de alertas KPI generadas:
Alerta_KPI  ALERTA  CRÍTICO  NORMAL
Zona
Kennedy     33      20      128
Tunjuelito  28      22      131

```

Nota. Elaboración propia (2025).

### **5.1.4 Impacto operativo y beneficios esperados**

La implementación del sistema de monitoreo y su futura adaptación a una plataforma web representan un avance significativo en los procesos operativos de los operadores de telecomunicaciones en Bogotá. La posibilidad de contar con un modelo que identifique incrementos inusuales en el KPI de cortes de cableado en campo permite disminuir de manera considerable los tiempos de detección de fallas. Al consolidar en una misma interfaz la visualización de los indicadores asociados a robos y afectaciones, se facilita la interpretación del estado general de la red y se optimiza el flujo de información para los equipos del NOC.

Adicionalmente, el sistema ofrece un mecanismo para priorizar zonas críticas a partir de la frecuencia y magnitud de los incidentes detectados para los meses evaluados de enero a junio. Esto contribuye a una asignación más eficiente de recursos humanos y técnicos, permitiendo enfocar las operaciones de mantenimiento en áreas donde los eventos generan mayor impacto operativo. Del mismo modo, la centralización del historial de comportamiento del KPI proporciona una base sólida para identificar tendencias prolongadas, anticipar escenarios de riesgo y fortalecer la capacidad predictiva del operador para el servicio continuo al cliente final.

En general, los beneficios esperados de esta herramienta se alinean con la necesidad de mejorar la supervisión de la infraestructura de fibra óptica y de fortalecer las estrategias de prevención frente a robos y sabotajes, aportando eficiencia, claridad operativa y un soporte analítico que facilite la toma de decisiones en tiempo real.

### 5.1.5 Trabajo Futuro

El desarrollo realizado en este proyecto constituye una primera aproximación al monitoreo inteligente de cortes de fibra óptica mediante la construcción de un KPI y el análisis del comportamiento histórico de incidentes. Sin embargo, este trabajo abre la puerta a varias líneas de mejora y ampliación que podrían fortalecer significativamente su aplicación en escenarios reales. Una de las proyecciones más importantes consiste en integrar datos provenientes directamente de los sistemas OSS y NOC mediante APIs o servicios automatizados, lo que permitiría que el análisis se ejecute en tiempo real sin necesidad de cargar o procesar información manualmente. Esta integración convertiría el sistema en una herramienta operativa capaz de reaccionar al instante ante anomalías o incrementos inesperados.

Otra línea de trabajo futuro se orienta a mejorar los modelos predictivos incorporando técnicas avanzadas de machine learning como redes neuronales recurrentes, modelos LSTM o algoritmos de clasificación que permitan anticipar eventos de robo con base en patrones temporales y espaciales más complejos. De igual manera, sería pertinente ampliar el análisis a más localidades de Bogotá o incluso a diferentes regiones del país, con el objetivo de construir un mapa de riesgo más completo que facilite decisiones estratégicas para los operadores.

También se proyecta la posibilidad de desarrollar una plataforma web completa que consolide el dashboard, las alertas automáticas y la georreferenciación de incidentes. Esto permitiría que los equipos del NOC, mantenimiento y supervisión de campo accedan a la información desde cualquier dispositivo y mantengan una gestión coordinada de los incidentes. Finalmente, el sistema podría complementarse con módulos de seguridad que

integren información de cámaras, sensores o reportes ciudadanos, creando un ecosistema integral de prevención frente al robo de cableado.

## 6. Conclusiones

El desarrollo de este proyecto permitió diseñar y evaluar un modelo de análisis orientado a la identificación de patrones asociados al robo de cableado de fibra óptica en las localidades de Kennedy y Tunjuelito, mediante un enfoque basado en indicadores KPI, análisis estadístico y simulación de datos. A partir de los resultados obtenidos, se evidenció que el comportamiento de los incidentes no es aleatorio, sino que presenta tendencias temporales y espaciales que pueden ser monitoreadas y analizadas a través de herramientas tecnológicas.

La implementación del algoritmo en Python, junto con la construcción del dashboard en Google Colab, permitió validar la viabilidad de una plataforma ligera para la visualización del KPI. Este entorno integra el análisis de datos, la generación de gráficas y la representación geográfica básica mediante mapas, facilitando la interpretación de los eventos y su distribución en las zonas analizadas. Aunque se trata de un prototipo, su diseño establece una base clara para futuras implementaciones en entornos operativos del NOC.

Uno de los principales aportes del proyecto fue la definición de un KPI capaz de reflejar variaciones significativas en la frecuencia de cortes de fibra óptica. Este indicador permitió identificar picos anómalos, analizar tendencias y diferenciar comportamientos entre las localidades estudiadas. En particular, se evidenció que Kennedy presenta incrementos más pronunciados en determinados periodos, mientras que Tunjuelito muestra un comportamiento más estable, aunque con variaciones constantes.

Asimismo, el uso de herramientas como Pandas, NumPy y Matplotlib facilitó la simulación y el análisis de los datos, permitiendo generar visualizaciones como series temporales, histogramas, promedios móviles y mapas de localización. Estas representaciones aportan valor al proceso de monitoreo, al permitir una comprensión más clara del comportamiento del KPI y apoyar la toma de decisiones.



No obstante, el proyecto presenta algunas limitaciones. La simulación se realizó con datos generados artificialmente, lo cual restringe la validación del modelo en escenarios reales. Además, no se incorporaron variables externas que pueden influir en los eventos de robo, como factores sociales, condiciones del entorno o niveles de seguridad en las zonas analizadas.

Finalmente, aunque el dashboard desarrollado incluye visualización de datos y representación geográfica básica, aún no integra funcionalidades avanzadas como correlación automática de eventos, analítica predictiva robusta ni despliegue en una plataforma web independiente. Como trabajo futuro, se propone la integración con datos reales provenientes de sistemas OSS y NOC, la incorporación de modelos de aprendizaje automático para la detección de anomalías, el uso de herramientas GIS para un análisis geoespacial más detallado y el desarrollo de una plataforma operativa que permita monitoreo en tiempo real y generación de alertas tempranas.

En conjunto, los resultados obtenidos demuestran que el modelo propuesto constituye una base sólida para el desarrollo de soluciones de monitoreo y análisis aplicadas al control de incidentes de robo de infraestructura en redes de telecomunicaciones.

## 7. Referencias

Agencia Periodismo Investigativo. (2025, 22 de junio). *Cinco capturados por hurto de cable en Usaquén: van 487 detenidos en Bogotá en 2025 por este delito.*

Agencia PI.

Citytv – El Tiempo. (2024). *Ladrones arriesgan su vida trepando postes de luz para robar cables de fibra óptica en Bogotá.*

[https://citytv.eltiempo.com/noticias/seguridad/ladrones-arriesgan-su-vida-trepando-postes-de-luz-para-robar-cables-de-fibra-optica-en-bogota\\_83070](https://citytv.eltiempo.com/noticias/seguridad/ladrones-arriesgan-su-vida-trepando-postes-de-luz-para-robar-cables-de-fibra-optica-en-bogota_83070)

El Tiempo. (2024). *Capturan a cinco personas por robar fibra óptica de cables en el norte de Bogotá.*

<https://www.eltiempo.com/bogota/capturan-a-cinco-personas-por-robar-fibra-optica-de-cables-en-el-norte-de-bogota-3465635>

GDC Tecnología. (s.f.). *Centro de operaciones de red NOC 3000.*

<https://www.gdc-tech.com/soluciones/software-empresarial-de-cine/centro-de-operaciones-de-red-noc-3000/?lang=es>

Peña, N. (2024, 26 de julio). *Robo de cable de cobre en Bogotá, una problemática poco visible.* Canal Capital.

<https://www.canalcapital.gov.co/servicios/robo-cable-de-cobre-bogota> Canal Capital

Redacción Bogotá. (2024, 29 de octubre). *Puente Aranda consolidó una*

*infraestructura de internet 100 % de fibra óptica para evitar robo de*

*cableado*. El Espectador.

<https://www.elespectador.com/bogota/puente-aranda-consolido-una-infraestructura-de-internet-100-de-fibra-optica-pare-evitar-robo-de-cableado-bogota-noticias-hoy/> ELESPECTADOR.COM

Redacción Bogotá. (2025, 23 de julio). *Por hurto de fibra óptica en Suba, cinco personas fueron privadas de libertad*. Radio Santa Fe.

<https://www.radiosantafe.com/2025/07/23/por-hurto-de-fibra-optica-en-suba-cinco-personas-fueron-privadas-de-libertad/> Radio Santafé

Redacción Bogotá. (2025, 14 de febrero). *Capturan a seis sujetos por robar cable de fibra óptica en Fontibón*. El Espectador.

<https://www.elespectador.com/bogota/seis-sujetos-capturados-tras-hurtar-56-metros-de-cable-de-fibra-optica-en-fontibon/> ELESPECTADOR.COM

Tridens Tecnología. (s.f.). *OSS en telecomunicaciones*.

<https://tridens technology.com/es/oss-en-telecomunicaciones/>

## Anexos

### Anexo A – Implementación del algoritmo en Python

La Figura A1 presenta la estructura inicial del algoritmo desarrollado en Python, donde se realiza la importación de las bibliotecas necesarias para el procesamiento y análisis de datos, tales como Pandas, NumPy y Matplotlib. Asimismo, se definen las variables base utilizadas en la simulación del KPI, incluyendo el rango temporal (enero a junio de 2025), las localidades de estudio (Kennedy y Tunjuelito) y los parámetros iniciales del modelo.

#### Figura A1

*Encabezado del código: importación de librerías y definición de variables*

---

```

# =====
# PROYECTO DE GRADO - SISTEMA KPI FIBRA ÓPTICA
# Autora: Laura Calderón | C.C. 1033758214
# UNAD - Ingeniería de Telecomunicaciones
# Kennedy y Tunjuelito, Bogotá D.C. - 2025
# =====
# ESTRUCTURA:
# FASE 0 - Carga de datos reales (CSV/Excel) o simulación
# FASE 1 - Preparación y variables derivadas
# FASE 2 - Análisis estadístico y correlación
# FASE 3 - Algoritmos de ML (Isolation Forest + K-Means)
# FASE 4 - Dashboard KPI con alertas automáticas
# =====

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import matplotlib.gridspec as gridspec
from scipy import stats
from sklearn.ensemble import IsolationForest
from sklearn.cluster import KMeans
from sklearn.preprocessing import StandardScaler
import os
import warnings
warnings.filterwarnings('ignore')

plt.rcParams['figure.figsize'] = (14, 6)
plt.rcParams['font.size'] = 11

```

Fuente: Elaboración propia

## Figura A2

La Figura A2 muestra el bloque central del algoritmo, en el cual se realiza la generación de datos simulados, el cálculo del KPI y la obtención del promedio histórico. En esta etapa se procesan los eventos de cortes de fibra óptica y se estructuran los datos para su posterior análisis.

Adicionalmente, se incorporan condiciones para la identificación de incrementos significativos en el número de cortes, permitiendo detectar posibles anomalías asociadas a eventos de robo de cableado.

## Figura A2

### *Bloque de procesamiento y cálculo del KPI de cortes de fibra óptica*

```

)
    par.fParamos[ 'UNIT_SIZE' ] = 11
)

# =====
# FASE 0 - CARGA DE DATOS REALES O SIMULACIÓN
# =====
# El sistema acepta un archivo CSV o Excel con datos
# reales provenientes de sistemas OSS/NOC.
#
# FORMATO ESPERADO DEL ARCHIVO:
#
#   Fecha      Zona      Cortes
#   -----
#   2025-01-01 Kennedy     3
#   2025-01-01 Tunjuelito  1
#   2025-01-02 Kennedy     2
#   ...        ...        ...
#
# COLUMNAS REQUERIDAS:
# - Fecha      : formato YYYY-MM-DD (ej: 2025-01-15)
# - Zona      : texto (ej: "Kennedy" o "Tunjuelito")
# - Cortes     : número entero (ej: 5)
#
# CÓMO USAR CON DATOS REALES:
# Opción A - CSV : guarda tu archivo como "datos_reales.csv"
#                  en la misma carpeta que este script,
#                  o en Google Drive si usas Colab.
# Opción B - Excel : guarda tu archivo como "datos_reales.xlsx"
#                   con los mismos nombres de columna.
#
# Si no se encuentra ningún archivo, el sistema genera
# datos sintéticos automáticamente para demostración.
# =====

print("=" * 60)
print("FASE 0: Carga de datos")
print("=" * 60)

# --- Parámetros de carga
ARCHIVO_CSV = "datos_reales.csv" # + cambia el nombre si es necesario
ARCHIVO_EXCEL = "datos_reales.xlsx" # + cambia el nombre si es necesario
COLUMNA_FECHA = "Fecha" # + nombre exacto de la columna de fecha
COLUMNA_ZONA = "Zona" # + nombre exacto de la columna de zona
COLUMNA_CORTES = "Cortes" # + nombre exacto de la columna de cortes
# -----

```

Fuente: Elaboración propia

### Figura A3

La Figura A3 presenta el fragmento del algoritmo encargado de la generación de visualizaciones comparativas mediante subgráficas (subplots). En este bloque se representan de forma paralela los datos correspondientes a las localidades de Kennedy y Tunjuelito, incluyendo el comportamiento diario de los cortes, la línea de promedio histórico y el sombreado de eventos relevantes.

Esta visualización permite analizar diferencias en la dinámica del KPI entre ambas zonas, facilitando la interpretación de patrones y tendencias.

### Figura A3

*Bloque de visualización comparativa del KPI entre localidades*

```
print(df[["Fecha","Zona","Cortes"]].head().to_string(index=False))

# =====
# FASE 1 - PREPARACIÓN Y VARIABLES DERIVADAS
# =====
print("\n" + "=" * 60)
print("FASE 1: Preparación y variables derivadas")
print("=" * 60)

df["DiaSemana"] = df["Fecha"].dt.dayofweek
df["NombreDia"] = df["Fecha"].dt.day_name()
df["Semana"] = df["Fecha"].dt.isocalendar().week.astype(int)
df["Mes"] = df["Fecha"].dt.month
df["EsFinSemana"] = (df["DiaSemana"] >= 5).astype(int)
df["Delta"] = df.groupby("Zona")["Cortes"].diff().fillna(0)
df["KPI_Acum"] = df.groupby("Zona")["Cortes"].cumsum()
df["MA7"] = df.groupby("Zona")["Cortes"].transform(
    lambda x: x.rolling(7, min_periods=1).mean())

print(f" Variables generadas: {list(df.columns)}")
print(f"\n Resumen por zona:")
print(df.groupby("Zona")["Cortes"].agg(["sum","mean","max","std"]).round(2))
```

```

# =====
# FASE 3 - ALGORITMOS DE ML
# =====
print("\n" + "=" * 60)
print("FASE 3: Machine Learning - Isolation Forest + K-Means")
print("=" * 60)

features_if = ["Cortes", "Delta", "MA7", "EsFinSemana", "DiaSemana", "Mes"]
resultados = []
print("\n 3.1 Isolation Forest (detección de anomalías)")

for zona in df["Zona"].unique():
    subset = df[df["Zona"] == zona].copy().reset_index(drop=True)
    X = subset[features_if].values
    X_scaled = StandardScaler().fit_transform(X)

    iso = IsolationForest(n_estimators=200, contamination=0.1, random_state=42)
    subset["Anomalia_IF"] = iso.fit_predict(X_scaled)
    subset["Score_IF"] = iso.score_samples(X_scaled)
    s = subset["Score_IF"]
    subset["Score_Norm"] = 1 - (s - s.min()) / (s.max() - s.min())
    subset["Zona"] = zona
    resultados.append(subset)

    n_an = (subset["Anomalia_IF"] == -1).sum()
    print(f"\n    Zona: {zona}")
    print(f"    Anomalías detectadas : {n_an} / {len(subset)} días ({n_an/len(subset)*100:.1f}%)")
    print(f"    Score medio normales : {subset[subset['Anomalia_IF']==1]['Score_Norm'].mean():.3f}")
    print(f"    Score medio anómalos : {subset[subset['Anomalia_IF']==-1]['Score_Norm'].mean():.3f}")

df_ml = pd.concat(resultados, ignore_index=True)

print("\n 3.2 K-Means (clustering de niveles de riesgo)")
features_km = ["Cortes", "Delta", "Score_Norm"]
resultados_km = []

for zona in df_ml["Zona"].unique():
    subset = df_ml[df_ml["Zona"] == zona].copy().reset_index(drop=True)
    X_km_scaled = StandardScaler().fit_transform(subset[features_km].values)

    kmeans = KMeans(n_clusters=3, random_state=42, n_init=10)
    subset["cluster"] = kmeans.fit_predict(X_km_scaled)
    centroides = pd.Series(
        {c: subset[subset["cluster"]==c]["Cortes"].mean() for c in range(3)}
    ).sort_values()
    etiquetas = {centroides.index[0]: "NORMAL",
                 centroides.index[1]: "ALERTA",
                 centroides.index[2]: "CRÍTICO"}
    subset["Nivel_Riesgo"] = subset["cluster"].map(etiquetas)
    resultados_km.append(subset)

```

Fuente: Elaboración propia

## Anexo B – Visualización geoespacial de los eventos

La Figura B1 presenta el bloque del algoritmo encargado de la construcción del mapa geoespacial, en el cual se ubican los eventos simulados de cortes de fibra óptica sobre una representación geográfica de las localidades de Kennedy y Tunjuelito.

Para ello, se emplean coordenadas geográficas simuladas (latitud y longitud), las cuales permiten posicionar cada evento dentro del mapa. Esta representación complementa el análisis temporal del KPI, incorporando una dimensión espacial clave para la identificación de zonas críticas.

### Figura B1

#### *Generación del mapa geoespacial de eventos de cortes de fibra óptica*

```

)
# -----
# 5.2 ASIGNAR COORDENADAS SIMULADAS A CADA INCIDENTE
#
# Para cada registro en df_ml se genera una coordenada
# aleatoria dentro del área de la localidad correspondiente.
# Los días con más cortes tienen mayor dispersión para reflejar
# que el evento fue más extendido geográficamente.
# -----

np.random.seed(99)

lats, lons = [], []
for _, row in df_ml.iterrows():
    geo = ZONAS_GEO.get(row["Zona"], ZONAS_GEO["Kennedy"])
    # Más cortes → mayor dispersión del punto en el mapa
    escala = min(1.0, row["Cortes"] / 20.0)
    lat = row["Zona"] and (
        geo["lat_centro"]
        + np.random.uniform(-geo["lat_rango"], geo["lat_rango"]) * (0.4 + 0.6 * escala)
    )
    lon = geo["lon_centro"] \
        + np.random.uniform(-geo["lon_rango"], geo["lon_rango"]) * (0.4 + 0.6 * escala)
    lat = geo["lat_centro"] \
        + np.random.uniform(-geo["lat_rango"], geo["lat_rango"]) * (0.4 + 0.6 * escala)
    lats.append(lat)
    lons.append(lon)

df_ml["Latitud"] = lats
df_ml["Longitud"] = lons

print(f" Coordenadas asignadas: {len(df_ml)} registros")
print(f" Rango latitud : {df_ml['Latitud'].min():.4f} → {df_ml['Latitud'].max():.4f}")
print(f" Rango longitud: {df_ml['Longitud'].min():.4f} → {df_ml['Longitud'].max():.4f}")

# -----
# 5.3 CONSTRUIR EL MAPA BASE
# -----

# Centro del mapa: punto medio entre Kennedy y Tunjuelito
lat_centro_mapa = (ZONAS_GEO["Kennedy"]["lat_centro"] +
                  ZONAS_GEO["Tunjuelito"]["lat_centro"]) / 2
lon_centro_mapa = (ZONAS_GEO["Kennedy"]["lon_centro"] +
                  ZONAS_GEO["Tunjuelito"]["lon_centro"]) / 2

mapa = folium.Map(
    location=[lat_centro_mapa, lon_centro_mapa],
    zoom_start=13,
    tiles="cartoDB positron" # fondo limpio, ideal para datos
)

# -----

```



Fuente: Elaboración propia

## Figura B2

La Figura B2 muestra la visualización tipo mapa de calor, donde se representa la concentración de eventos de cortes de fibra óptica en función de su ubicación geográfica. Las zonas con mayor intensidad de color indican una mayor frecuencia de incidentes, lo cual facilita la identificación de áreas con alta reincidencia.

Este tipo de análisis permite reconocer patrones espaciales y priorizar zonas para intervención técnica o estrategias de mitigación.

## Figura B2

### *Mapa de calor (heatmap) de concentración de eventos*

```
# -----
# 5.4 CAPA 1: MARCADORES POR NIVEL DE ALERTA
#
# Cada incidente se representa como un círculo coloreado.
# Al hacer clic se muestra la fecha, zona, cortes y nivel.
# Los puntos se agrupan (cluster) para no saturar el mapa
# cuando hay muchos incidentes en la misma área.
# -----

# Grupo de cluster por zona
clusters = {
    zona: MarkerCluster(name=f"Incidentes - {zona}").add_to(mapa)
    for zona in df_ml["Zona"].unique()
}

# Agregar solo días con al menos 1 corte (evitar ruido visual)
df_mapa = df_ml[df_ml["Cortes"] > 0].copy()

for _, row in df_mapa.iterrows():
    nivel = row["Alerta_KPI"]
    color = COLORES_ALERTA.get(nivel, "#888780")
    radio = 6 + int(row["Score_Norm"] * 10) # tamaño ∝ score de anomalía

    popup_html = f"""
<div style="font-family: Arial, sans-serif; font-size: 13px; min-width: 180px;">
  <b style="font-size:14px;">● Incidente de corte</b><br><br>
  <b>Fecha:</b> {row['Fecha'].date()}<br>
  <b>Zona:</b> {row['Zona']}<br>
  <b>Cortes:</b> {int(row['Cortes'])}<br>
  <b>Nivel de alerta:</b>
  <span style="color:{color}; font-weight:bold;">{nivel}</span><br>
  <b>Score anomalía:</b> {row['Score_Norm']:.3f}<br>
  <b>Nivel de riesgo (ML):</b> {row['Nivel_Riesgo']}
</div>
"""

    folium.CircleMarker(
        location=[row["Latitud"], row["Longitud"]],
        radius=radio,
        color=color,
        fill=True,
        fill_color=color,
        fill_opacity=0.65,
        weight=1.2,
        popup=folium.Popup(popup_html, max_width=220),
        tooltip=f"{row['Zona']} | {row['Fecha'].date()} | {nivel}"
    ).add_to(clusters[row["Zona"]])

print(f" Marcadores agregados: {len(df_mapa)} incidentes")

# -----
```

Fuente: Elaboración propia

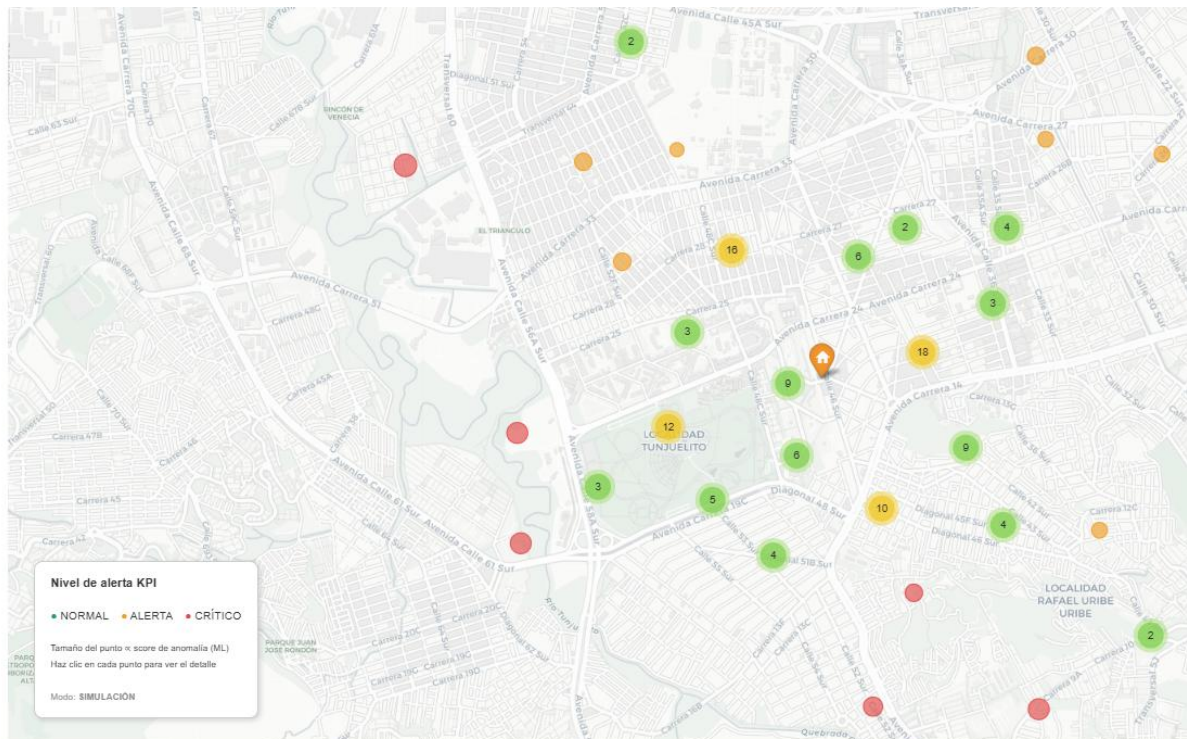
### Figura B3

La Figura B3 presenta el resultado final de la visualización geoespacial, donde se integran los eventos de ambas localidades en un mismo mapa, diferenciados mediante marcadores o colores. Esta representación permite comparar la distribución espacial de los cortes entre Kennedy y Tunjuelito.

Además, el mapa puede incluir elementos interactivos como etiquetas o información emergente de cada evento, lo cual mejora la capacidad de análisis y facilita la toma de decisiones en entornos operativos como el NOC.

### Figura B3

*Mapa interactivo de eventos con diferenciación por localidad*



Fuente: Elaboración propia