

**Data Analytics para el monitoreo y seguimiento contractual de KPI's de mantenimiento en
la flota eléctrica de la Operadora Distrital de Transporte**

Luis Enrique Chaves Aguilar

Asesor

Rafael Roberto Ruiz Escorcía

Universidad Nacional Abierta y a Distancia UNAD
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI
Especialización en Ciencia de Datos y Analítica

2025

Nota de Aceptación

Rafael Roberto Ruiz Escorcía

Jurado

Jurado

Dedicatoria

A mi madre, por su amor incondicional, su atención constante y su infinita paciencia, que han sido pilares fundamentales a lo largo de mi vida académica y personal.

A mi esposa, por su compañía inquebrantable y su valioso apoyo, que me han sostenido en cada etapa de este proceso formativo.

A mis hijas, por ser la inspiración y el motor que impulsa cada uno de mis esfuerzos y motivaciones.

Y al Doctor Diego Vargas, por ser el precursor de mis estudios profesionales y por su orientación clave en mi desarrollo académico.

Agradecimientos

Agradezco, en primer lugar, a Dios por brindarme la salud, la fortaleza y la claridad necesarias para culminar esta etapa académica.

A mi madre, por ser ejemplo de amor, entrega y perseverancia; su apoyo incondicional ha sido esencial en cada paso de mi formación.

A mi esposa, por su compañía constante, su comprensión y aliento durante los momentos de mayor exigencia; sin su apoyo este logro no habría sido posible.

A mis hijas, quienes representan la motivación más grande para seguir creciendo personal y profesionalmente; su existencia da propósito a cada uno de mis esfuerzos.

Al Doctor Diego Vargas, por su guía, por haber sido quien incentivó el inicio de mi camino profesional y por su confianza en mis capacidades.

Agradezco de manera especial a los ingenieros Alberth Barrera, Milton Velandia y Diego Trompetero, por su valiosa orientación, disposición y aportes técnicos, que enriquecieron significativamente el desarrollo de este trabajo.

Extiendo también mi gratitud a los docentes, compañeros y directivos de la institución por sus enseñanzas, orientaciones y apoyo a lo largo de esta formación.

Finalmente, expreso mi reconocimiento a todas las personas que, de manera directa o indirecta, contribuyeron al cumplimiento de este objetivo académico.

Resumen

El presente trabajo de grado, titulado "Data Analytics para el Monitoreo y Seguimiento Contractual de KPIs de Mantenimiento en la Flota Eléctrica de la Operadora Distrital de Transporte", tiene como propósito desarrollar una solución analítica que permita transformar datos históricos de mantenimiento en información estratégica para la toma de decisiones. En el entorno actual, caracterizado por la digitalización y la necesidad de optimizar recursos, el uso de herramientas de ciencia de datos se ha convertido en una ventaja competitiva para la gestión de activos y la mejora continua en los procesos de mantenimiento.

La investigación se centra en la flota eléctrica del Sistema Integrado de Transporte Público (SITP), administrada por la Operadora Distrital de Transporte, la cual enfrenta retos importantes relacionados con la consolidación de datos y el análisis oportuno de indicadores contractuales. Estos retos limitan la capacidad de obtener una visión integral del estado operativo de la flota y de implementar estrategias preventivas que garanticen la confiabilidad y disponibilidad del servicio. Para abordar esta problemática, se diseñó un flujo de trabajo basado en Python, para la limpieza y procesamiento de datos, complementado con Power BI y Plotly Express, con el fin de crear visualizaciones dinámicas y Dashboard interactivos.

Se calcularon cuatro indicadores contractuales clave, los cuales fueron seleccionados por su relevancia en la evaluación del desempeño del mantenimiento. A través del análisis de datos históricos (2022-2024), se identificaron tendencias, patrones y anomalías que pueden influir en el cumplimiento de las metas operativas y contractuales. Este enfoque analítico no solo permite una evaluación precisa del estado actual de los indicadores, sino que también facilita la generación de recomendaciones orientadas a optimizar la gestión de mantenimiento.

El producto final no se limita a la creación de Dashboard, sino que incluye un análisis exhaustivo del cumplimiento de cada uno de los KPIs, proporcionando una herramienta integral de apoyo a la toma de decisiones estratégicas. Además, este trabajo sienta las bases para el desarrollo futuro de modelos de mantenimiento predictivo, orientados a mejorar la disponibilidad, reducir costos y aumentar la eficiencia operativa de la flota eléctrica del SITP.

Palabras claves: Analítica de datos, gestión de mantenimiento, KPIs de mantenimiento, flota eléctrica SITP, visualización interactiva.

Abstract

This undergraduate thesis, titled "Data Analytics for the Monitoring and Contractual Tracking of Maintenance KPIs in the Electric Fleet of the District Transport Operator", aims to develop an analytical solution that transforms historical maintenance data into strategic information for decision-making. In today's environment, characterized by digital transformation and the need to optimize resources, the use of data science tools has become a competitive advantage for asset management and the continuous improvement of maintenance processes.

The research focuses on the electric fleet of Bogotá's Integrated Public Transport System (SITP), managed by the District Transport Operator, which faces significant challenges related to data consolidation and the timely analysis of contractual indicators. These challenges limit the ability to obtain a comprehensive view of the fleet's operational condition and to implement preventive strategies that ensure service reliability and availability. To address this issue, data workflow was designed using Python for data cleaning and processing, complemented with Power BI and Plotly Express to create dynamic visualizations and interactive dashboards.

Four key contractual indicators were calculated, selected due to their relevance in evaluating maintenance performance. By analyzing historical data from 2022 to 2024, trends, patterns, and anomalies were identified that could impact the achievement of operational and contractual targets. This analytical approach not only enables an accurate evaluation of the current state of the KPIs but also facilitates the generation of recommendations aimed at optimizing maintenance management.

The final product goes beyond dashboard creation, offering a comprehensive analysis of the current compliance status of each KPI, thus providing a robust decision-support tool. Furthermore, this work lays the foundation for the future development of predictive maintenance

models, aimed at improving fleet availability, reducing costs, and increasing the operational efficiency of the SITP electric fleet.

Keywords: Data Analytics, maintenance management, maintenance KPIs, electric fleet SITP, interactive visualization.

Tabla de Contenido

Introducción	13
Descripción del Problema	15
Planteamiento del Problema	16
Sistematización del Problema	18
Pregunta Central.....	18
Preguntas Específicas.....	18
Justificación	19
Objetivos.....	21
Objetivo General	21
Objetivos Específicos.....	21
Marco de Referencia	22
Estado del Arte.....	22
Marco Teórico.....	25
Indicadores de Gestión de Mantenimiento	28
Vinculación de la Gestión de Activos con la Analítica de Datos.....	29
Marco Conceptual	30
Marco Legal	32
Metodología	34
Comprensión del Negocio.....	34
Comprensión de los Datos	34
Preparación de los Datos.....	35
Modelado	35

	10
Evaluación.....	36
Implementación.....	36
Cierre de la Metodología.....	36
Tipo de Estudio	37
Recolección de los Datos	37
Resultados	40
Limpieza de los Datos	44
Objetivo del Análisis de los Datos	45
Indicadores Clave en la Gestión del Mantenimiento.....	46
Resultados Aplicados a los Indicadores Propuestos	47
Análisis de los Datos	48
Presentación Gráfica de los Indicadores	62
Tablero de Power BI a Través de Colab	62
Presentación de los Datos desde Plotly Express	64
Presentación Gráfica de los Indicadores con Plotly Express	65
Conclusiones	69
Recomendaciones	73
Referencias.....	75

Lista de Tablas

Tabla 1 <i>Comparativo del Uso de los Sistemas de Información en el Mantenimiento</i>	24
Tabla 2 <i>Relación de Tipo de Datos Obtenidos de la Base de Datos</i>	40
Tabla 3 <i>Relación de Cantidad de Datos Nulos por Variable</i>	42
Tabla 4 <i>Presentación de los Datos Aptos para el Análisis</i>	44
Tabla 5 <i>Cantidad de Horas Acumuladas por Actividad y Año</i>	49
Tabla 6 <i>Cálculo Porcentual de las Horas por Actividad y Año</i>	50
Tabla 7 <i>Recuento de Actividades Correctivas por Año y su Componente Porcentual</i>	52
Tabla 8 <i>Presentación Porcentual de las Actividades por Sistema y Año</i>	54
Tabla 9 <i>Recuento de Actividades Preventivas y Correctivas por Año</i>	56
Tabla 10 <i>Cálculo Porcentual de la Eficacia del Mantenimiento Preventivo</i>	58
Tabla 11 <i>Cantidad de Mantenimientos Ejecutados por Frecuencia</i>	60
Tabla 12 <i>Porcentaje de Cumplimiento al Indicador</i>	61

Lista de Figuras

Figura 1 <i>Muestra de la Información a Analizar</i>	39
Figura 2 <i>Características de la Base de Datos a Analizar Obtenida del Dataframe en Colab</i>	41
Figura 3 <i>Imagen del Análisis de Datos en Colab, para la Relación de Datos Nulos</i>	43
Figura 4 <i>Imagen de Google Colab de las Variables, Posterior a su Limpieza</i>	45
Figura 5 <i>Formulación en Google Colab para el Análisis de las Horas Presentadas</i>	49
Figura 6 <i>Cálculo Porcentual de los Datos desde Google Colab</i>	50
Figura 7 <i>Recuento de Actividades por Sistema desde Google Colab</i>	53
Figura 8 <i>Presentación del Cálculo Porcentual desde Google Colab</i>	55
Figura 9 <i>Presentación del Cálculo de Actividades desde Google Colab</i>	57
Figura 10 <i>Cálculo de la Eficacia desde Google Colab</i>	58
Figura 11 <i>Tarjetas de Resumen de Datos</i>	62
Figura 12 <i>Dashboard Interactivo de los Datos</i>	62
Figura 13 <i>Filtro Dinámico de los Datos</i>	63
Figura 14 <i>Vista General de Informe, Gráficos y Tablas Interactivas</i>	63
Figura 15 <i>Vista General de Informe en Plotly Express</i>	64
Figura 16 <i>Presentación Gráfica de las Distribuciones del Mantenimiento por Año</i>	65
Figura 17 <i>Distribución Porcentual del Mantenimiento Correctivo del Año 2022 por Sistema ..</i>	66
Figura 18 <i>Distribución Porcentual del Mantenimiento Correctivo del Año 2023 por Sistema ..</i>	66
Figura 19 <i>Distribución Porcentual del Mantenimiento correctivo del año 2024 por sistema</i>	66
Figura 20 <i>Representación Gráfica de la Eficacia del Mantenimiento Preventivo por Año</i>	67
Figura 21 <i>Presentación Gráfica del Cumplimiento al Plan de Mantenimiento por Rutina</i>	67

Introducción

En el entorno industrial y empresarial actual, la adecuada gestión de los recursos físicos, humanos y tecnológicos es esencial para garantizar la eficiencia operativa y la sostenibilidad organizacional. Estos recursos, cuando se integran de manera sinérgica, permiten el cumplimiento de las funciones propias de cada industria, siendo la gestión de activos una disciplina clave dentro de este proceso. En particular, el mantenimiento de los activos adquiere un rol estratégico, ya que su correcta administración asegura la disponibilidad, confiabilidad y funcionalidad de los equipos y sistemas a lo largo de su ciclo de vida útil.

La gestión del mantenimiento, entendida como un proceso dinámico y sistemático, busca conservar los activos en condiciones óptimas para que cumplan con los requerimientos definidos por sus usuarios. Esto implica establecer estándares mínimos de funcionamiento y monitorear modos de falla que puedan ser medidos, analizados e interpretados. Una gestión eficiente del mantenimiento no solo mejora la operación, sino que también contribuye a la reducción de costos, al aumento de la vida útil de los activos y a la toma de decisiones fundamentadas en datos.

En este contexto, la Operadora Distrital de Transporte, responsable de una parte importante del Sistema Integrado de Transporte en la zona sur de Bogotá, ha implementado un modelo estandarizado de mantenimiento para su flota de buses eléctricos. Este modelo busca garantizar la confiabilidad del servicio, al tiempo que optimiza los costos de mantenimiento a través de prácticas responsables y sostenibles.

El presente trabajo plantea la aplicación de Data Analytics como una herramienta para transformar los datos recopilados durante las labores de mantenimiento entre los años 2022 y 2024 en información estratégica. Para ello, se integra el uso de Python para la limpieza,

depuración y análisis de datos con sistemas de visualización interactiva como Power BI y librerías de Plotly Express, lo que permite generar tableros dinámicos, identificar tendencias y evaluar el cumplimiento de indicadores contractuales clave.

Como producto final, se propone un análisis estadístico que no solo integra los principales indicadores de gestión y confiabilidad, sino que además se presenta en un Dashboard interactivo, ofreciendo a los responsables del mantenimiento una visualización clara y efectiva de las variables más relevantes. Este enfoque facilita una toma de decisiones más asertiva y apoya el mejoramiento continuo de la operación.

Descripción del Problema

La gestión eficiente del mantenimiento es un pilar fundamental para garantizar la confiabilidad, disponibilidad y seguridad de los activos en cualquier sistema de transporte. En el caso de la flota eléctrica de la Operadora Distrital de Transporte, esta tarea enfrenta un desafío importante: la información de mantenimiento no se recolecta ni clasifica de forma óptima, lo que genera vacíos y datos dispersos que dificultan obtener una visión precisa del estado real de los activos. Esta carencia limita el seguimiento efectivo de los indicadores contractuales y obstaculiza la toma de decisiones estratégicas basadas en datos actualizados.

A pesar de contar con un modelo estandarizado de mantenimiento, la ausencia de procesos robustos para transformar los registros de actividades transversales en métricas confiables reduce la capacidad de evaluar el desempeño real del sistema. Esto se traduce en riesgos operativos como fallas inesperadas o “varadas en vía”, que afectan la percepción de calidad del servicio, tal como lo evidencian mediciones realizadas por Transmilenio S.A. (Lara, 2012).

El modelo de mantenimiento centrado en confiabilidad (RCM), aplicado con éxito en otros sectores como la aviación, destaca la importancia de intervenciones preventivas y predictivas basadas en datos. Sin embargo, la falta de integración de herramientas analíticas, como Python para la depuración y análisis de datos y sistemas de visualización como Power BI, limita la capacidad de identificar tendencias, evaluar el cumplimiento de KPIs y anticipar fallas críticas. En este contexto, se hace evidente la necesidad de un enfoque de Data Analytics que permita transformar la información dispersa en un recurso estratégico para la mejora continua del mantenimiento.

Planteamiento del Problema

La ausencia de un proceso sistemático para la recolección, clasificación y análisis de la información de mantenimiento en la flota eléctrica de la Operadora Distrital de Transporte ha generado una brecha de conocimiento que limita la comprensión del estado real de los activos y del cumplimiento de los indicadores contractuales. Los datos generados por las actividades transversales, aunque disponibles, suelen estar dispersos, carecen de estandarización o no ser actualizados de manera oportuna, lo que impide consolidar métricas confiables para la gestión de mantenimiento.

La mayoría de los modelos de mantenimiento en el transporte público se siguen basando en rutinas preventivas dictadas por los fabricantes, aplicadas bajo frecuencias fijas. Si bien este enfoque responde a una práctica responsable, tiende a ignorar fallas recurrentes que, aunque inicialmente de baja criticidad, pueden derivar en averías graves y costosas si no se atienden a tiempo (Moubrey, 1997; Quintanilla, 2020).

Adicionalmente, se observa una baja sistematización en la recolección, análisis y uso de la información proveniente de los reportes operativos. En muchos casos, los reportes realizados por los conductores no se recopilan o, si lo hacen, su alto volumen dificulta su clasificación y uso efectivo en planes de mantenimiento. En las áreas internas de mantenimiento persiste también una gestión informal de datos, lo que provoca que muchas novedades no sean trazables, programadas ni corregidas (Pérez, 2019). Esto genera fallas recurrentes, sobrecarga en los talleres y pérdidas económicas significativas.

A pesar del potencial que ofrecen herramientas de Data Analytics, la falta de integración de tecnologías como Python para la depuración y análisis, o de plataformas de visualización como Power BI y Plotly, ha limitado la evolución hacia un mantenimiento predictivo y basado en

datos. Esta carencia no solo dificulta la identificación temprana de patrones de falla, sino que también reduce la capacidad de evaluar el cumplimiento de indicadores contractuales y de tomar decisiones oportunas para garantizar la confiabilidad y disponibilidad de la flota.

Sistematización del Problema

Pregunta Central

¿Es posible, mediante técnicas de Data Analytics, aprovechar los datos históricos de mantenimiento para capturar, clasificar y analizar los modos de falla en la flota eléctrica de la Operadora Distrital de Transporte, con el fin de evaluar el cumplimiento de indicadores contractuales y proponer acciones que optimicen el modelo de mantenimiento y su confiabilidad?

Preguntas Específicas

1. ¿Qué tipo de datos de mantenimiento y operación deben limpiarse, estructurarse y estandarizarse para asegurar su trazabilidad desde la operación hasta el taller?
2. ¿Cómo identificar y clasificar los modos de falla más frecuentes y su impacto sobre la confiabilidad y disponibilidad de la flota eléctrica?
3. ¿Qué indicadores contractuales y operativos (KPIs) resultan más relevantes para evaluar el desempeño del mantenimiento y cómo deben calcularse?
4. ¿Cómo la integración de herramientas como Python y sistemas de visualización interactiva (Power BI y Plotly Express) pueden contribuir a la detección temprana de tendencias y al monitoreo continuo del estado de los activos?
5. ¿Qué mejoras operativas y estratégicas se pueden lograr mediante el uso de tableros dinámicos y análisis estadístico orientado al mantenimiento basado en datos (Data-Driven Maintenance)?

Justificación

El presente proyecto surge como respuesta a una problemática crítica en la gestión del mantenimiento de la flota eléctrica de la Operadora Distrital de Transporte: la falta de un tratamiento adecuado de los datos operativos y de mantenimiento, lo que dificulta la consolidación de información confiable para evaluar el cumplimiento de los indicadores contractuales y tomar decisiones estratégicas. Esta situación genera una brecha de conocimiento sobre el estado real de los activos, afectando la capacidad de anticipar fallas, optimizar recursos y garantizar la continuidad y calidad del servicio.

La Operadora Distrital de Transporte, como concesionario de Transmilenio S.A., es responsable de la operación y mantenimiento de 195 buses eléctricos de la Unidad Funcional 08 – Perdomo en Bogotá. Los datos derivados de procesos como recepción, alistamiento y mantenimiento constituyen una fuente de información con un alto potencial analítico, pero actualmente se encuentran dispersos y con baja sistematización. Este proyecto propone transformar dichos datos en información estratégica mediante técnicas de Data Analytics, integrando procesos de limpieza, estructuración, análisis y visualización de datos con herramientas como Python, Power BI y Plotly Express.

La iniciativa se orienta a demostrar que, a través de un análisis estructurado y visualmente interactivo, es posible evaluar el desempeño de los indicadores contractuales, identificar tendencias de falla y apoyar la toma de decisiones operativas y estratégicas. De esta forma, el proyecto no solo optimiza la gestión del mantenimiento, sino que también sienta las bases para evolucionar hacia modelos predictivos, alineados con el enfoque de mantenimiento centrado en confiabilidad (RCM).

En este contexto, el proyecto constituye una solución integral al núcleo problémico, al convertir grandes volúmenes de datos en información útil y accionable, con el objetivo de mejorar la disponibilidad, confiabilidad y eficiencia de la flota eléctrica del SITP.

Objetivos

Objetivo General

Desarrollar una solución de Data Analytics que, mediante el uso de análisis estadístico y visualización interactiva, permita evaluar el comportamiento de la gestión de mantenimiento y el grado de cumplimiento de los indicadores contractuales en la flota eléctrica de la Operadora Distrital de Transporte.

Objetivos Específicos

Implementar procesos de limpieza, transformación y estructuración de datos históricos de mantenimiento (2022-2024) utilizando Python, garantizando su integridad, consistencia e integridad para un análisis confiable.

Calcular y analizar los principales indicadores clave de desempeño (KPIs) relacionados con la gestión de mantenimiento, evaluando su grado de cumplimiento frente a los estándares contractuales.

Diseñar un Dashboard interactivo, integrando herramientas de visualización como Power BI y Plotly Express, que facilite la interpretación de resultados, la identificación de tendencias y la toma de decisiones.

Proporcionar un análisis interpretativo de los hallazgos obtenidos, resaltando áreas de mejora y recomendaciones para optimizar la gestión del mantenimiento con un enfoque basado en datos.

Marco de Referencia

Estado del Arte

La evolución de las metodologías de mantenimiento ha estado fuertemente influenciada por los avances tecnológicos y por la necesidad de aumentar la eficiencia operativa en sectores críticos como el transporte. Inicialmente, el mantenimiento correctivo y preventivo fueron los modelos predominantes. Sin embargo, con el paso del tiempo y la creciente demanda de disponibilidad y confiabilidad en los activos, se desarrollaron modelos más robustos como el mantenimiento centrado en confiabilidad (RCM). Este enfoque, originado en la industria aeronáutica (Moubray, 1997), ha sido adaptado con éxito a diversos sectores, incluido el transporte terrestre, al permitir una evaluación sistemática de los modos de falla y la priorización de intervenciones según su criticidad.

En el ámbito del transporte urbano masivo, varios estudios han abordado la aplicación del RCM en flotas de buses, resaltando los beneficios de integrar datos operativos para mejorar la planificación de las tareas de mantenimiento (Quintanilla, 2020). Sin embargo, en muchos contextos latinoamericanos, incluida la ciudad de Bogotá, las prácticas de mantenimiento aún se basan en rutinas tradicionales impuestas por los fabricantes, sin incorporar plenamente las evidencias operacionales obtenidas durante el servicio.

La tendencia del Big Data y los sistemas de información ha impulsado nuevas formas de entender y gestionar los activos físicos. Romero (2019) destaca que la minería de datos aplicada al mantenimiento permite identificar patrones repetitivos de fallas, prever averías críticas y establecer ciclos de intervención más precisos. En este sentido, el mantenimiento predictivo basado en datos se posiciona como una evolución natural del RCM, en especial cuando se cuenta

con grandes volúmenes de información provenientes de sensores, reportes de operación y registros técnicos.

En cuanto al uso de sistemas de información, investigaciones recientes han demostrado que la digitalización de los procesos de mantenimiento no solo facilita la trazabilidad en el control de los activos, sino que también mejora la calidad de los reportes y la eficiencia en la toma de decisiones. Pérez (2019) advierte que una de las principales debilidades en los operadores del SITP es la informalidad en la recolección de datos, lo que impide el desarrollo de modelos analíticos que generen valor real a partir de la información técnica disponible.

Proyectos similares han implementado Dashboard interactivos como herramientas de visualización de indicadores clave de mantenimiento. Estas interfaces permiten integrar múltiples fuentes de datos, ofrecer análisis en tiempo real y generar alertas tempranas sobre desviaciones operativas. Gómez (2019) subraya que, para que estas herramientas sean efectivas, es necesario establecer procesos previos de limpieza, estructuración y categorización de los datos.

En resumen, el estado del arte evidencia una tendencia creciente hacia la integración de datos en la gestión del mantenimiento, especialmente en sectores donde la confiabilidad del activo es crítica para el servicio, como el transporte público. No obstante, existen vacíos significativos en la adopción de estas prácticas en contextos locales como Bogotá, lo que justifica el desarrollo de proyectos aplicados que articulen el RCM con herramientas de análisis y visualización de datos, contribuyendo así a una operación más eficiente, segura y económica.

Tabla 1*Comparativo del Uso de los Sistemas de Información en el Mantenimiento*

Autor / Año	Enfoque del estudio / Proyecto	Tecnologías o metodologías utilizadas	Resultados o aportes clave
Moubray (1997)	Introducción del mantenimiento centrado en confiabilidad (RCM) en la industria aeronáutica	Análisis funcional, modos de falla, criticidad	Sentó las bases del RCM moderno, enfocado en mantener la funcionalidad de los activos según las condiciones reales.
Romero (2019)	Aplicación de Big Data y ML al mantenimiento industrial	Cloud computing, analítica predictiva	Propone el uso de datos masivos para anticipar fallas y optimizar el mantenimiento preventivo.
Quintanilla (2020)	Evaluación de fallas frecuentes en flotas de transporte público	Análisis de criticidad, clasificación de fallas	Resalta cómo las fallas de baja prioridad derivan en averías mayores si no son atendidas oportunamente.
Pérez (2019)	Diagnóstico de la trazabilidad en reportes de mantenimiento en el SITP	Observación de campo, entrevistas, análisis documental	Identifica deficiencias en la trazabilidad y sistematización de reportes técnicos en el transporte público.

Autor / Año	Enfoque del estudio / Proyecto	Tecnologías o metodologías utilizadas	Resultados o aportes clave
Gómez (2019)	Uso de herramientas de visualización y lenguajes de programación en mantenimiento	Dashboard, Python, estructuración de bases de datos	Presenta beneficios de Dashboard interactivos para evaluar el desempeño de activos y optimizar la toma de decisiones.
Proyecto actual (2025)	Sistema de información para mantenimiento confiable en flota eléctrica del SITP	RCM, análisis estadístico, Dashboard interactivo, análisis de modos de falla	Integra datos reales de operación y mantenimiento para mejorar la confiabilidad y la planificación de intervenciones.

Nota. Comparación de autores en el marco referencial

Marco Teórico

La gestión de activos es un conjunto de prácticas, políticas y estrategias orientadas a maximizar el valor y la confiabilidad de los recursos físicos durante todo su ciclo de vida, garantizando al mismo tiempo la eficiencia operativa y la sostenibilidad económica. En el contexto del transporte público, donde la calidad del servicio depende de la disponibilidad de los vehículos, la gestión de activos se convierte en un elemento estratégico. La norma ISO 55000

establece que la administración eficaz de los activos requiere la integración de datos confiables, indicadores de desempeño y herramientas de apoyo para la toma de decisiones.

En la última década, el desarrollo de tecnologías de la información ha transformado la forma de gestionar los activos, facilitando el uso de Big Data, Internet de las Cosas (IoT) y técnicas de Data Analytics para obtener un conocimiento profundo sobre el estado y el desempeño de los equipos. Estas tecnologías permiten que grandes volúmenes de datos operativos y de mantenimiento se conviertan en información procesable para mejorar la confiabilidad y reducir los costos operativos (Gómez, 2019; Olmo, 2022).

Gestión de Activos y Mantenimiento Basado en Confiabilidad (RCM): el mantenimiento centrado en confiabilidad (RCM) es una metodología que se originó en la industria aeronáutica y que busca garantizar que los sistemas continúen cumpliendo con las funciones deseadas en su contexto operacional. Se enfoca en identificar los modos de falla y sus consecuencias, priorizando las intervenciones preventivas y predictivas sobre las correctivas (Moubray, 1997). El RCM se ha convertido en una estrategia clave para sectores como el transporte público, donde la interrupción de la operación puede generar costos elevados y afectar directamente la calidad del servicio.

Para la Operadora Distrital de Transporte, que gestiona una flota eléctrica dentro del SITP, adoptar un enfoque basado en RCM no solo implica ejecutar rutinas preventivas, sino también aprovechar los datos históricos de fallas, tiempos de reparación, costos y sistemas intervenidos para optimizar los planes de mantenimiento.

En este sentido, el uso de Data Analytics permite realizar análisis profundos de los datos de mantenimiento, identificando tendencias y correlaciones que no son evidentes en reportes tradicionales. El procesamiento de grandes volúmenes de datos (Big Data) y su visualización

mediante herramientas interactivas proporcionan información estratégica para ajustar las frecuencias de mantenimiento, detectar fallas recurrentes y priorizar recursos (Romero, 2019).

Data Analytics en la Gestión del Mantenimiento: la analítica de datos aplicada al mantenimiento vehicular combina varias etapas:

1. Limpieza y depuración de datos, para eliminar inconsistencias, duplicados o registros erróneos.
2. Transformación y estructuración, mediante bases de datos relacionales que permiten una mejor organización de la información.
3. Cálculo de indicadores clave (KPIs), que evalúan el desempeño de las actividades de mantenimiento y la confiabilidad de los equipos.
4. Visualización interactiva, a través de Dashboard que permiten a los gestores identificar problemas críticos y tomar decisiones oportunas.

Herramientas como Python (para el preprocesamiento y análisis estadístico) y Power BI o Plotly Express (para la visualización dinámica) han demostrado ser efectivas para integrar estas etapas en un flujo continuo. El uso de estos entornos posibilita reproducir análisis de forma sistemática, automatizar cálculos complejos y garantizar la trazabilidad del dato desde su captura hasta su visualización.

El valor agregado de un enfoque analítico radica en que el mantenimiento deja de basarse únicamente en la experiencia o en rutinas fijas dictadas por el fabricante, para evolucionar hacia una estrategia basada en datos y confiabilidad. Esto es particularmente relevante en los buses eléctricos del SITP, cuyo diseño incorpora componentes como baterías de litio y electrónica avanzada, donde los fallos no previstos pueden ser costosos y disruptivos.

Indicadores de Gestión de Mantenimiento

El análisis de indicadores clave permite evaluar la eficacia y eficiencia de las políticas de mantenimiento implementadas. Entre los más relevantes para la flota eléctrica de la Operadora Distrital de Transporte, se encuentran:

Índice de proporción de mantenimiento preventivo vs. Correctivo: este indicador mide la proporción entre las tareas preventivas y correctivas realizadas, siendo su objetivo principal determinar el grado de proactividad en la gestión de mantenimiento:

$$X = \frac{(\textit{Preventivo})}{(\textit{Preventivo} + \textit{Correctivo})} \times 100$$

Un valor alto indica una estrategia preventiva sólida, mientras que un valor bajo sugiere una tendencia reactiva con mayores riesgos de indisponibilidad (Sánchez & Rodríguez, 2021).

Porcentaje de correctivos por sistema: analiza la frecuencia de intervenciones correctivas clasificadas por los sistemas del bus, tales como frenos, tracción eléctrica, climatización, suspensión, entre otros:

$$X = \frac{(\textit{Correctivos por sistema})}{(\textit{Correctivos totales})} \times 100$$

La identificación de los sistemas con mayor número de fallas permite priorizar inspecciones, rediseñar estrategias preventivas o anticipar compras de repuestos (Vargas, 2018).

Índice de eficacia del mantenimiento preventivo por sistema: evalúa si las tareas preventivas logran reducir fallas posteriores:

$$X = 1 - \frac{(\textit{Correctivos})}{(\textit{Preventivos})} \times 100$$

Un bajo índice de eficacia sugiere ajustes en las frecuencias, inspecciones o en la capacitación técnica del personal (Pérez, 2019).

Cumplimiento del plan de mantenimiento: indica el porcentaje de actividades preventivas que se ejecutan en el tiempo o kilometraje planificado:

$$X = \frac{(\textit{Preventivos ejecutados})}{(\textit{Preventivos planeados})} \times 100$$

El incumplimiento puede provocar acumulación de fallas y afectar la confiabilidad de la flota (Gómez, 2019).

Estos indicadores no deben evaluarse de forma aislada, sino de manera conjunta, para obtener una visión integral de la gestión del mantenimiento. Su análisis longitudinal permite identificar tendencias, puntos críticos y oportunidades de mejora.

Vinculación de la Gestión de Activos con la Analítica de Datos

La unión entre la gestión de activos y la analítica de datos permite evolucionar de modelos reactivos a enfoques predictivos y prescriptivos. Esta integración proporciona una base sólida para la toma de decisiones estratégicas, tales como:

1. Redefinir los planes de mantenimiento con base en la frecuencia real de fallas.
2. Predecir la necesidad de intervenciones antes de que se produzcan fallas críticas.
3. Optimizar costos operativos mediante la asignación más eficiente de recursos.
4. Mejorar la disponibilidad de la flota, garantizando así un servicio de transporte más confiable.

El presente proyecto combina Python como lenguaje de análisis, Power BI para la visualización y técnicas estadísticas que permiten explorar datos históricos del periodo 2022–2024. Esta sinergia hace posible la generación de Dashboard interactivos que, además de mostrar el estado actual de los KPIs, permiten proponer recomendaciones estratégicas fundamentadas en datos reales y trazables.

Marco Conceptual

La correcta administración del mantenimiento y la operación de una flota vehicular requiere de un enfoque integral que permita transformar los datos en conocimiento útil para la toma de decisiones estratégicas. En el caso del transporte público urbano, la confiabilidad de los vehículos y la optimización de los recursos dependen directamente de una gestión de activos efectiva, soportada por la analítica de datos.

Gestión de Activos La gestión de activos es el conjunto de actividades planificadas y coordinadas que permiten maximizar el valor de los recursos físicos a lo largo de su ciclo de vida. La norma ISO 55000 establece que la gestión de activos no solo abarca la adquisición y uso de estos, sino también su monitoreo, mantenimiento y disposición final, asegurando que se cumplan los objetivos organizacionales con la mayor eficiencia posible. En el contexto del SITP, esto implica garantizar que los buses eléctricos estén disponibles, seguros y confiables para prestar un servicio continuo y de calidad.

Mantenimiento Centrado en Confiabilidad (RCM): El RCM (Reliability Centered Maintenance) es una metodología que busca identificar los modos de falla de cada activo y establecer estrategias de mantenimiento que prioricen la seguridad, disponibilidad y confiabilidad. Esta técnica no se basa exclusivamente en rutinas preventivas, sino en un análisis de riesgos y consecuencias, lo que permite diseñar intervenciones más efectivas (Moubray, 1997).

En los sistemas de transporte, el RCM ha cobrado importancia para reducir fallas en vía, optimizar costos y prolongar la vida útil de los componentes críticos. Para ello, resulta clave la captura y clasificación de datos históricos de fallas, reparaciones y repuestos, con el fin de ajustar los planes de mantenimiento según el comportamiento real de los activos.

Analítica de Datos (Data Analytics): La analítica de datos en mantenimiento consiste en el uso de métodos estadísticos, herramientas de programación y técnicas de visualización para analizar grandes volúmenes de datos generados en las operaciones diarias. Este enfoque permite encontrar patrones ocultos, predecir fallas y evaluar la efectividad de las tareas ejecutadas.

Lenguajes como Python permiten realizar procesos de limpieza de datos (data cleaning), estructuración y cálculo de indicadores clave (KPIs). Complementariamente, herramientas de visualización como Power BI y librerías como Plotly Express facilitan la creación de Dashboard interactivos que muestran, en tiempo real, el estado de los activos y el cumplimiento de los objetivos de mantenimiento.

Indicadores de Gestión de Mantenimiento (KPIs): Los indicadores de mantenimiento son métricas que permiten evaluar la efectividad y eficiencia de las estrategias aplicadas. Algunos de los más relevantes para la flota eléctrica de la Operadora Distrital de Transporte son:

1. Índice de proporción de mantenimiento preventivo vs. correctivo: mide la proporción de intervenciones preventivas frente al total, reflejando el grado de anticipación frente a las fallas.
2. Porcentaje de correctivos por sistema: identifica los sistemas con mayores fallas para priorizar recursos.
3. Índice de eficacia del mantenimiento preventivo por sistema: evalúa si las acciones preventivas cumplen su función de evitar fallas recurrentes.
4. Cumplimiento del plan de mantenimiento: verifica si las tareas se ejecutan conforme a la programación establecida.

Estos KPIs, analizados en conjunto, permiten una evaluación integral de la operación y orientan las mejoras continuas, tanto en la planificación de las intervenciones como en la gestión de recursos.

Integridad e Integralidad del Dato: La integridad del dato hace referencia a la exactitud, consistencia y confiabilidad de la información registrada en los sistemas de mantenimiento, mientras que la integralidad del dato se relaciona con la capacidad de capturar y representar la totalidad de los eventos relevantes (fallas, inspecciones, repuestos usados, tiempos de intervención, entre otros). En la práctica, contar con datos íntegros e integrales es fundamental para garantizar que el análisis estadístico y la visualización en Dashboard reflejen la realidad operacional.

Marco Legal

El presente proyecto se enmarca en la normatividad vigente Colombiana, relacionada con la operación del transporte público, la gestión de activos, la planeación del mantenimiento y el uso de tecnologías de la información en el sector público. A continuación, se presentan los principales referentes normativos que sustentan su desarrollo.

Ley 105 de 1993: establece los principios generales del transporte en Colombia, dentro de los cuales se incluye la eficiencia, seguridad, calidad del servicio y sostenibilidad. Esta ley sirve como base para las políticas de operación del sistema de transporte público en el país.

Ley 336 de 1996 Estatuto Nacional del Transporte: reglamenta la prestación del servicio público de transporte en todas sus modalidades. En su articulado se reconoce la importancia de garantizar un servicio continuo y confiable, lo cual se relaciona directamente con la necesidad de una gestión adecuada del mantenimiento de los vehículos utilizados.

Ley 872 de 2003: Establece el Sistema de Gestión de la Calidad en las entidades públicas. Esta ley exige a las entidades del Estado (incluyendo operadores públicos de transporte) implementar mecanismos que garanticen la eficiencia en sus procesos, lo que incluye la gestión técnica de sus activos y la trazabilidad de la información.

Ley 1581 de 2012 – Protección de datos personales: regula el tratamiento de datos personales en Colombia. En el contexto del proyecto, esta ley es relevante frente al manejo de la información recopilada y analizada dentro del sistema de mantenimiento, especialmente cuando se vinculan datos de operación o personal de mantenimiento.

Decreto 1079 de 2015 – Decreto Único Reglamentario del Sector Transporte: Compila y reglamenta las disposiciones legales del sector transporte. Entre otros aspectos, establece la necesidad de adoptar medidas que garanticen la seguridad operacional, la continuidad del servicio y el cumplimiento de estándares de calidad.

Resoluciones de Transmilenio S.A. y Contratos de Concesión: Los contratos de concesión firmados entre el Ente Gestor Transmilenio S.A. y los operadores del Sistema Integrado de Transporte Público (SITP) establecen condiciones específicas sobre la operación y mantenimiento de la flota, incluyendo indicadores contractuales que deben ser medidos y reportados periódicamente mediante herramientas de gestión como la Evaluación Mensual Integral de la Calidad (EMIC).

Normas técnicas aplicables (ISO 55000, ISO 14224): la norma ISO 55000 proporciona lineamientos sobre la gestión de activos, incluyendo políticas de mantenimiento y evaluación del desempeño. Por su parte, la norma ISO 14224 establece requisitos para la recopilación y estructuración de datos de confiabilidad y mantenimiento, fundamentales en el diseño de un sistema de información técnico-operativo.

Metodología

El presente proyecto se fundamenta en la metodología CRISP-DM (Cross Industry Standard Process for Data Mining), ampliamente reconocida por su enfoque estructurado y flexible para el análisis de datos. Esta metodología permite transformar grandes volúmenes de información en conocimiento estratégico, mediante seis fases principales: comprensión del negocio, comprensión de los datos, preparación de los datos, modelado, evaluación e implementación.

Su aplicación en el análisis de la flota eléctrica de la Operadora Distrital de Transporte asegura el cumplimiento del objetivo general (analizar y visualizar el comportamiento del mantenimiento y el grado de cumplimiento de los indicadores contractuales) y de los objetivos específicos, relacionados con la construcción de una base de datos estructurada, el diseño de KPIs y la creación de un Dashboard interactivo.

Comprensión del Negocio

En esta fase se llevó a cabo un diagnóstico integral del entorno operativo de la Operadora Distrital de Transporte, evaluando su modelo de mantenimiento y el comportamiento histórico de la flota (2022–2024). Se identificaron deficiencias en el análisis de información, baja sistematización de reportes y la necesidad de fortalecer la confiabilidad de la flota eléctrica.

Esta fase da respuesta al objetivo general, al definir el marco estratégico sobre el cual se desarrollará el análisis de datos, y orienta los objetivos específicos al establecer los indicadores contractuales relevantes para Transmilenio S.A.

Comprensión de los Datos

Se realizó un inventario exhaustivo de las fuentes de información:

1. Registros de fallas en vía y correctivos en taller.

2. Historial de mantenimiento preventivo y correctivo.
3. Bitácoras de vehículos (hojas de vida).

Mediante Python y bibliotecas como Pandas, Numpy y Plotly Express, se evaluaron aspectos como la completitud, consistencia y duplicidad de datos, así como su relevancia para el análisis. Esta etapa contribuye al objetivo de construir una base de datos estructurada, garantizando la integridad e integralidad de los datos desde el inicio del proyecto.

Preparación de los Datos

En esta fase se ejecutaron procesos de limpieza, normalización y homogenización de formatos (fechas, kilometraje, tipos de mantenimiento). Se definieron variables críticas como el modo de falla y sistema intervenido, consolidando una base de datos relacional lista para el análisis.

Este paso cumple directamente con el objetivo específico de construir una base de datos estructurada, asegurando que los indicadores calculados se basen en datos confiables y trazables.

Modelado

Con la base consolidada, se aplicaron técnicas de análisis exploratorio y estadístico en Python para identificar patrones en los modos de falla y su relación con variables como kilometraje, frecuencia de intervención y tipo de vehículo. Se diseñaron y calcularon los indicadores clave de desempeño (KPIs):

1. Índice de proporción de mantenimiento preventivo vs correctivo.
2. Porcentaje de correctivos por sistema.
3. Índice de eficacia del mantenimiento preventivo por sistema.
4. Cumplimiento del plan de mantenimiento.

Este paso responde al objetivo específico de diseñar los indicadores, permitiendo una medición objetiva del desempeño de mantenimiento.

Evaluación

Los resultados de los indicadores fueron validados comparándolos con datos históricos, umbrales contractuales y estándares de confiabilidad exigidos por Transmilenio S.A. Esta fase permitió identificar tendencias, alertas tempranas y brechas operativas.

Su relación con el objetivo general es directa, ya que asegura que el análisis estadístico refleje el estado real del mantenimiento, apoyando la toma de decisiones basadas en datos.

Implementación

Finalmente, se desarrolló un Dashboard interactivo en Power BI y Plotly Express, con conexión automatizada a la base de datos procesada en Python. Esta herramienta permite:

1. Visualizar el cumplimiento en tiempo real de los KPIs.
2. Filtrar información por sistema, tipo de mantenimiento o periodo.
3. Apoyar la planificación de recursos técnicos y humanos.

Este paso responde directamente al objetivo específico de presentar resultados mediante un Dashboard interactivo, complementando el análisis interpretativo de los indicadores con visualizaciones dinámicas y comprensibles.

Cierre de la Metodología

La aplicación de la metodología CRISP-DM en este proyecto garantiza una alineación total entre los objetivos y las fases de análisis de datos, desde la comprensión del negocio hasta la implementación de herramientas visuales. Cada fase contribuye al propósito de convertir los datos de mantenimiento en una fuente de valor estratégico, con impacto directo en la confiabilidad, disponibilidad y sostenibilidad operativa de la flota eléctrica.

Tipo de Estudio

El presente proyecto se enmarca en un estudio aplicado con enfoque cuantitativo y diseño no experimental. Su propósito es transformar datos históricos de operación y mantenimiento de la flota eléctrica de la Operadora Distrital de Transporte en conocimiento útil, a través del diseño e implementación de un sistema de información que permita optimizar la gestión del mantenimiento centrado en confiabilidad.

Se trata de un proyecto de carácter descriptivo y analítico, ya que busca, por un lado, caracterizar el comportamiento histórico de los activos mediante indicadores clave de desempeño (KPI), y por otro, identificar patrones repetitivos en los modos de falla para facilitar la toma de decisiones operativas en la ejecución del mantenimiento. Asimismo, adopta un enfoque tecnológico y funcional, pues utiliza herramientas de análisis estadístico, tratamiento de bases de datos y visualización dinámica (Dashboard) como soporte a la planificación y evaluación de los procesos de mantenimiento.

El diseño del estudio es no experimental y longitudinal, dado que se trabaja con datos recolectados entre los años 2022 y 2024, sin manipulación deliberada de variables, pero con análisis retrospectivo y proyectivo sobre los resultados de gestión. El proyecto no busca validar hipótesis estadísticas, sino desarrollar una solución práctica y sustentada técnicamente, alineada con las necesidades reales del operador y los requerimientos del ente regulador Transmilenio S.A.

Recolección de los Datos

La recolección de datos para el presente proyecto se realizó a partir de fuentes internas vinculadas directamente con los procesos operativos y de mantenimiento de la flota. Específicamente, los datos fueron obtenidos a través de dos frentes principales:

Proceso de inspección de flota: este componente proporcionó información relevante sobre las novedades operativas identificadas durante las inspecciones diarias o programadas de los vehículos. Estas inspecciones incluyen revisiones visuales, mecánicas y funcionales, en las cuales se registran hallazgos relacionados con el estado general del vehículo, condiciones de seguridad, cumplimiento de estándares técnicos y posibles desviaciones del funcionamiento esperado.

Procesos de mantenimiento preventivo y alistamiento: los datos también fueron recolectados durante las actividades de mantenimiento preventivo, alistamiento de flota y a partir del registro de novedades encontradas durante dichos procedimientos. Esta información incluye intervenciones realizadas, repuestos utilizados, tiempos de alistamiento y observaciones técnicas sobre el estado de cada unidad antes de su puesta en operación.

Toda la información recopilada, incluidas las solicitudes de mantenimiento, fue digitalizada y organizada en una base de datos estructurada, diseñada para contener los datos relevantes asociados a la gestión del mantenimiento. Esta base de datos incluye campos como:

1. Identificación y descripción del vehículo.
2. Variable de control
3. Fecha y hora de generación de la actividad.
4. Duración de la intervención o proceso.
5. Clasificación o segregación por sistema afectado (motor, frenos, eléctrico, etc.).
6. Descripción general del modo de falla identificado.
7. Solución implementada o acción correctiva realizada.

Esta digitalización permitió asegurar la trazabilidad, consistencia y disponibilidad de la información para su posterior análisis, facilitando el desarrollo del modelo analítico propuesto en el proyecto.

Figura 1

Muestra de la Información a Analizar

CONSECUTIVO	MÓVIL	KILOMETRAJE	FECHA DE SOLICITUD	TEMPORAL	TÉCNICO ASIGNADO	ESTADO DE LA OT	TIPO DE MANTENIMIENTO	DESCRIPCIÓN DE LA NOVEDAD	SISTEMA	CORRECCIÓN
1	Z37-4008	492	10/09/2022	1,0	JANQUI MARTIN	CERRADA	CORRECTIVO	DILPES Y RAYONES FUERTES EN CARROCERÍA	CARROCERÍA	CARROCERÍA + SE REPARA Y SE PINTA BOCARUEDA POSICIÓN 5-6
2	Z37-4022	896	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
3	Z37-4083	395	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
4	Z37-4072	395	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
5	Z37-4040	393	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
6	Z37-4076	472	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
7	Z37-4075	421	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
8	Z37-4082	383	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
9	Z37-4038	399	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
10	Z37-4041	399	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
11	Z37-4065	404	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
12	Z37-4003	536	13/09/2022	3,0	BYD	CERRADA	CORRECTIVO	FALLA EN PLATAFORMA	ELECTRICIDAD DE BAJA	ELECTRICIDAD DE BAJA + AJUSTE MICRO DE PLATAFORMA
13	Z37-4003	536	13/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
14	Z37-4083	396	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
15	Z37-4090	396	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
16	Z37-4093	421	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
17	Z37-4113	387	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
18	Z37-4137	412	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
19	Z37-4194	402	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
20	Z37-4132	422	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
21	Z37-4161	401	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE
22	Z37-4002	649	14/09/2022	1,0	BYD	CERRADA	CORRECTIVO	AJUSTE DE SUSPENSIÓN	SUSPENSIÓN	SUSPENSIÓN + SE AJUSTA SUSPENSIÓN EN GENERAL
23	Z37-4113	387	14/09/2022	1,0	BYD	CERRADA	CORRECTIVO	SUSPENSIÓN CAÍDA	SUSPENSIÓN	SUSPENSIÓN + SE REALIZA AJUSTE DE ALTURA SUSPENSIÓN
24	Z37-4113	387	14/09/2022	1,0	BUSSCAR	CERRADA	CORRECTIVO	FUGA DE AIRE SILLA OPERADOR	CARROCERÍA	CARROCERÍA + SE REUBICA MANGUERA VÁLVULA NEUMÁTICA SILLA OPERADOR
25	Z37-4122	414	14/09/2022	3,0	BYD	CERRADA	PREVENTIVO	CAMPAÑA COMPRESOR Y ENGRASE	NEUMÁTICO	NEUMÁTICO + CAMPAÑA COMPRESOR Y ENGRASE

Resultados

Basados en la metodología propuesta, se realizó un análisis de las variables de la base de datos de mantenimiento de la Operadora Distrital de Transporte, donde, a través de Google Colab y utilizando Python, se identificaron las siguientes características de la base de datos:

Tabla 2

Relación de Tipo de Datos Obtenidos de la Base de Datos

#	Column	Non-Null	Count	Dtype
0	CONSECUTIVO	57947	non-null	int64
1	MÓVIL	57865	non-null	Object
2	KILOMETRAJE	57857	non-null	Object
3	PLACA	57861	non-null	Object
4	FECHA DE SOLICITUD	57947	non-null	datetime64[ns]
5	FECHA DE CIERRE	57947	non-null	datetime64[ns]
6	MES	57947	non-null	Object
7	AÑO	57947	non-null	int64
8	TEMPARIO	57865	non-null	Object
9	TÉCNICO ASIGNADO	57865	non-null	Object
10	ESTADO DE LA OT	57865	non-null	Object
11	TIPO DE MANTENIMIENTO	57865	non-null	Object
12	EMP.RESPONSABLE	57865	non-null	Object
13	APROBADOR	57865	non-null	Object
14	DESCRIPCIÓN DE LA NOVEDAD	57864	non-null	Object
15	SISTEMA	57864	non-null	Object

#	Column	Non-Null	Count	Dtype
16	CORRECCIÓN	57864	non-null	Object
17	VALOR TOTAL REPUESTOS	57874	non-null	float64
18	VALOR SERVICIO	57874	non-null	float64
19	VALOR GRÚA	57873	non-null	float64
20	VALOR TOTAL	57946	non-null	float64

Nota. Se presentan los tipos de datos encontrados en la base de datos analizada.

Figura 2

Características de la Base de Datos a Analizar Obtenida del Dataframe en Colab

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 57947 entries, 0 to 57946
Data columns (total 21 columns):
#   Column                Non-Null Count  Dtype
---  -
0   CONSECUTIVO           57947 non-null  int64
1   MÓVIL                 57865 non-null  object
2   KILOMETRAJE          57857 non-null  object
3   PLACA                 57861 non-null  object
4   FECHA DE SOLICITUD   57947 non-null  datetime64[ns]
5   FECHA DE CIERRE      57947 non-null  datetime64[ns]
6   MES                  57947 non-null  object
7   AÑO                  57947 non-null  int64
8   TEMPARIO             57865 non-null  object
9   TÉCNICO ASIGNADO     57865 non-null  object
10  ESTADO DE LA OT      57865 non-null  object
11  TIPO DE MANTENIMIENTO 57865 non-null  object
12  EMP. RESPONSABLE     57865 non-null  object
13  APROBADOR            57865 non-null  object
14  DESCRIPCIÓN DE LA NOVEDAD 57864 non-null  object
15  SISTEMA              57864 non-null  object
16  CORRECCIÓN           57864 non-null  object
17  VALOR TOTAL REPUESTOS 57874 non-null  float64
18  VALOR SERVICIO       57874 non-null  float64
19  VALOR GRÚA           57873 non-null  float64
20  VALOR TOTAL          57946 non-null  float64
dtypes: datetime64[ns](2), float64(4), int64(2), object(13)
memory usage: 9.3+ MB
```

Como se observa, la base de datos cuenta con 57.947 registros, compuestos por 2 variables de tipo tiempo, 4 variables numéricas con decimales, 2 variables numéricas enteras y 13 variables de tipo objeto. Estos datos provienen de los procesos previamente descritos en este

documento y corresponden a la ejecución de actividades de mantenimiento realizadas entre los años 2022 y 2024.

En el proceso de adecuación de los datos, es fundamental identificar la cantidad de valores nulos (datos inexistentes) presentes en cada una de las variables a analizar.

Usando la función Isnull podemos determinar la cantidad de valores nulos de nuestra base de datos, a continuación, se presentan la cuantificación de datos nulos por variable:

Tabla 3

Relación de Cantidad de Datos Nulos por Variable

Variable	Cantidad de Nulos
CONSECUTIVO	0
MÓVIL	82
KILOMETRAJE	90
PLACA	86
FECHA DE SOLICITUD	0
FECHA DE CIERRE	0
MES	0
AÑO	0
TEMPARIO	82
TÉCNICO ASIGNADO	82
ESTADO DE LA OT	82
TIPO DE MANTENIMIENTO	82
EMP. RESPONSIBLE	82
APROBADOR	82
DESCRIPCIÓN DE LA NOVEDAD	83
SISTEMA	83
CORRECCIÓN	83
VALOR TOTAL REPUESTOS	73
VALOR SERVICIO	73

Variable	Cantidad de Nulos
VALOR GRÚA	74
VALOR TOTAL	1

Nota. Muestra la cantidad de datos nulos en las columnas de la base de datos

Figura 3

Imagen del Análisis de Datos en Colab, para la Relación de Datos Nulos

The image shows a Jupyter Notebook cell with the following code and output:

```
df.isnull().sum()
```

CONSECUTIVO	0
MÓVIL	82
KILOMETRAJE	90
PLACA	86
FECHA DE SOLICITUD	0
FECHA DE CIERRE	0
MES	0
AÑO	0
TEMPARIO	82
TÉCNICO A SIGNADO	82
ESTADO DE LA OT	82
TIPO DE MANTENIMIENTO	82
EMP. RESPONSABLE	82
APROBADOR	82
DESCRIPCIÓN DE LA NOVEDAD	83
SISTEMA	83
CORRECCIÓN	83
VALOR TOTAL REPUESTOS	73
VALOR SERVICIO	73
VALOR GRÚA	74
VALOR TOTAL	1

Limpieza de los Datos

Si bien la cantidad de datos nulos no parece ser elevada, es importante considerar que el total de registros corresponde a la información de 195 buses. Esto implica que, si los datos se analizaran por vehículo de manera individual, los valores nulos podrían adquirir una mayor relevancia. Por esta razón, se aplicó una técnica de imputación de valores basada en la media de los datos, lo cual permite completar estos campos nulos de forma adecuada, ya sea para variables categóricas o numéricas.

Esto, al final, permite que nuestros datos se encuentren, posterior al proceso de limpieza, de la siguiente forma:

Tabla 4

Presentación de los Datos Aptos para el Análisis

Variable	Cantidad de Nulos
CONSECUTIVO	0
MÓVIL	0
KILOMETRAJE	0
PLACA	0
FECHA DE SOLICITUD	0
FECHA DE CIERRE	0
MES	0
AÑO	0
TEMPARIO	0
TÉCNICO ASIGNADO	0
ESTADO DE LA OT	0
TIPO DE MANTENIMIENTO	0
EMP. RESPONSIBLE	0
APROBADOR	0
DESCRIPCIÓN DE LA NOVEDAD	0

Variable	Cantidad de Nulos
SISTEMA	0
CORRECCIÓN	0
VALOR TOTAL REPUESTOS	0
VALOR SERVICIO	0
VALOR GRÚA	0
VALOR TOTAL	0

Nota. Se presentan los resultados de la limpieza de los datos

Figura 4

Imagen de Google Colab de las Variables, Posterior a su Limpieza

```

▶ print("valores nulos despues de la limpieza:")
print(df.isnull().sum())

```

↔ Valores nulos despues de la limpieza:

```

CONSECUTIVO      0
MÓVIL            0
KILOMETRAJE     0
PLACA            0
FECHA DE SOLICITUD  0
FECHA DE CIERRE  0
MES              0
AÑO              0
TEMPARIO        0
TÉCNICO ASIGNADO  0
ESTADO DE LA OT  0
TIPO DE MANTENIMIENTO  0
EMP. RESPONSABLE  0
APROBADOR       0
DESCRIPCIÓN DE LA NOVEDAD  0
SISTEMA          0
CORRECCIÓN       0
VALOR TOTAL REPUESTOS  0
VALOR SERVICIO   0
VALOR GRÚA       0
VALOR TOTAL      0
dtype: int64

```

Objetivo del Análisis de los Datos

El análisis de esta base de datos tiene como propósito visualizar de forma gráfica e interactiva el grado de cumplimiento contractual de diversos indicadores clave frente al Ente

Gestor Transmilenio S.A. A continuación, se presenta la definición de cada uno de estos indicadores.

Indicadores Clave en la Gestión del Mantenimiento

1. Índice de proporción de mantenimiento preventivo vs correctivo

$$X = \frac{(\text{Preventivo})}{(\text{Preventivo} + \text{Correctivo})} \times 100$$

Indicador de cumplimiento, método de evaluación:

Meta recomendada:

Mantenimiento Preventivo $\geq 70\%$

Mantenimiento Correctivo $\leq 30\%$

Interpretación:

$\geq 70/30$: gestión eficiente; prevención priorizada, bajo riesgo operativo.

Entre 60/40 y 50/50: nivel aceptable, requiere ajustes en programación.

$< 50/50$: gestión reactiva, alta dependencia de correctivos, riesgo alto.

2. Porcentaje de correctivos por sistema

Este indicador mide la proporción de actividades de mantenimiento correctivo realizadas en un sistema específico respecto al total de mantenimientos correctivos ejecutados en un periodo determinado. Permite identificar los sistemas con mayor incidencia de fallas y, por tanto, los más críticos en términos de confiabilidad operativa.

Fórmula de cálculo

$$X = \frac{(\text{Correctivos por sistema})}{(\text{Correctivos totales})} \times 100$$

Esto ayuda a priorizar intervenciones o rediseñar planes de mantenimiento preventivo específicos para los sistemas que generan una mayor afectación.

3. Índice de eficacia del mantenimiento preventivo por sistema

Evalúa si el mantenimiento preventivo está logrando reducir correctivos por sistema.

Fórmula de cálculo

$$X = 1 - \frac{(\text{Correctivos})}{(\text{Preventivos})} \times 100$$

Método de evaluación

Si el índice es alto, el preventivo está siendo eficaz.

Si es bajo o negativo, hay indicios de fallas no evitadas.

4. Cumplimiento del plan de mantenimiento

Mide el grado en que las actividades de mantenimiento planificadas (preventivas y programadas) se ejecutan dentro de los tiempos y condiciones establecidas, comparando las tareas realizadas frente a las planificadas en un periodo determinado.

Fórmula de cálculo

$$X = \frac{(\text{Preventivos ejecutados})}{(\text{Preventivos planeados})} \times 100$$

Resultados Aplicados a los Indicadores Propuestos

Basados en el análisis de los datos recopilados por la Operadora Distrital de Transporte entre los años 2022 y 2024, se presentan a continuación las métricas obtenidas y el estado actual de cumplimiento de los indicadores propuestos. El procesamiento de esta información permitió evaluar el comportamiento de la flota de buses eléctricos en términos de confiabilidad y eficiencia del mantenimiento, identificando tendencias relevantes en los principales KPIs, como el índice de proporción de mantenimiento preventivo vs. correctivo, el porcentaje de correctivos por sistema, el índice de eficacia del mantenimiento preventivo y el cumplimiento del plan de mantenimiento.

La visualización de estos indicadores se realizó a través de paneles interactivos desarrollados en Power BI y Plotly Express, lo que facilita un análisis dinámico, segmentado por periodo, sistema intervenido o tipo de intervención. De esta forma, se logra una comprensión más profunda del desempeño operativo, permitiendo identificar fortalezas, posibles desviaciones y oportunidades de mejora en los procesos de mantenimiento.

Análisis de los Datos

1. Índice de proporción de mantenimiento preventivo vs correctivo

Para evaluar el comportamiento operativo de la flota, se analizaron los datos históricos de mantenimiento correspondientes a los años 2022 a 2024, con un enfoque en la cantidad de horas hombre invertidas en cada tipo de mantenimiento (preventivo y correctivo). Este análisis fue desarrollado utilizando la biblioteca Pandas de Python, lo que permitió organizar, agrupar y sumar los registros de manera eficiente, garantizando precisión en el cálculo de tiempos acumulados por año y por tipo de intervención.

La información resultante se estructuró en una tabla resumen que muestra la distribución anual de las horas invertidas, facilitando la comparación entre los mantenimientos preventivos, diseñados para minimizar fallas y asegurar la confiabilidad de la flota, y los correctivos, que responden a fallas imprevistas. Este enfoque permite identificar tendencias de carga laboral, evaluar la proporción de recursos destinados a cada estrategia y detectar posibles desviaciones en la planeación de las intervenciones.

Además, este análisis constituye un insumo clave para la medición de los indicadores de gestión, como el índice de proporción de mantenimiento preventivo vs. correctivo, ya que permite correlacionar las horas invertidas con la efectividad de las acciones preventivas y la frecuencia de fallas que generan trabajos correctivos.

Tabla 5*Cantidad de Horas Acumuladas por Actividad y Año*

AÑO	ALISTAMIENTO	ASISTENCIA EN VÍA	CORRECTIVO	PREVENTIVO
2022	24.0	17.0	4735.01	2075.4
2023	2240.0	79.3	30453.36	11561.46
2024	2168.0	127.18	24631.91	38439.12

Nota. Muestra la suma de horas acumuladas por actividad a través de los años 2002 – 2024

Figura 5*Formulación en Google Colab para el Análisis de las Horas Presentadas*

```
# Convertir los valores tempario a numéricos.
df_limpiar['TEMPARIO'] = pd.to_numeric(df_limpiar['TEMPARIO'], errors='coerce')

# Existen valores preventivo con espacios.
df_limpiar['TIPO DE MANTENIMIENTO'] = df_limpiar['TIPO DE MANTENIMIENTO'].replace('PREVENTIVO ', 'PREVENTIVO')

# Crear una tabla con los valores tipo de mantenimiento y año
Tabla_resumen_1 = df_limpiar.groupby(['AÑO', 'TIPO DE MANTENIMIENTO'])['TEMPARIO'].sum().reset_index()

# Trasponer la tabla
Tabla_resumen = Tabla_resumen_1.pivot_table(index='AÑO', columns='TIPO DE MANTENIMIENTO', values='TEMPARIO', fill_value=0)

# Muestro valores con un solo decimal
formato_resumen = Tabla_resumen.applymap('{:.1f}'.format)

# Muestra del resumen
display(Tabla_resumen)
```

/tmp/ipython-input-14-1860348969.py:15: FutureWarning: DataFrame.applymap has been deprecated. Use DataFrame.map instead.
formato_resumen = Tabla_resumen.applymap('{:.1f}'.format)

TIPO DE MANTENIMIENTO	ALISTAMIENTO	ASISTENCIA EN VÍA	CORRECTIVO	PREVENTIVO
AÑO				
2022	24.0	17.00	4735.010000	2075.40
2023	2240.0	79.30	30453.361000	11561.46
2024	2168.0	127.18	24631.917194	38439.12

Basados en los datos anteriores, tenemos la siguiente distribución porcentual:

Tabla 6

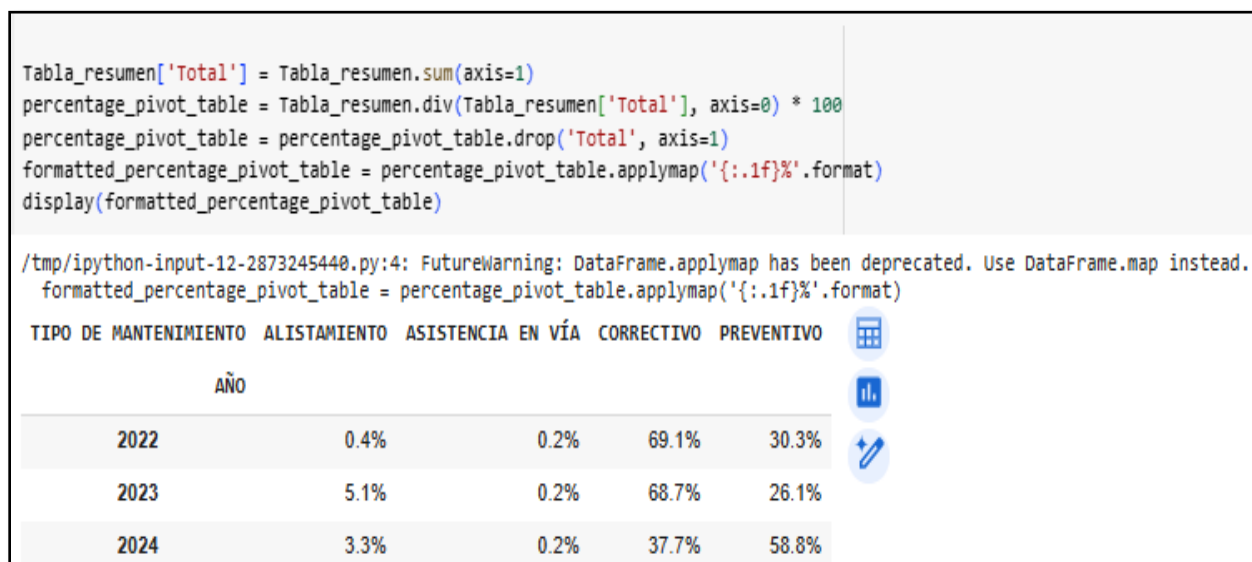
Cálculo Porcentual de las Horas por Actividad y Año

TIPO DE MANTENIMIENTO/AÑO	ALISTAMIENTO	ASISTENCIA EN VÍA	CORRECTIVO	PREVENTIVO
2022	0.4%	0.2%	69.1%	30.3%
2023	5.1%	0.2%	68.7%	26.1%
2024	3.3%	0.2%	37.7%	58.8%

Nota. Se presentan los datos porcentuales obtenidos de los temparios por año

Figura 6

Cálculo Porcentual de los Datos desde Google Colab



Resultados del indicador: entonces, basados en el cumplimiento de los indicadores podemos resumir:

Los años 2022 y 2023 presentan una “Gestión reactiva. Alta dependencia de correctivos. Riesgo alto”, dado que, el mantenimiento correctivo siempre superó el 50% de la totalidad de las horas utilizadas en el mantenimiento.

En el año 2024 se presenta un “Nivel aceptable. Requiere ajustes en programación”, ya que el mantenimiento preventivo se encuentra en 60,9 % si calculamos únicamente las variables “correctivo y preventivo”, más no llegó al 70% como nivel óptimo.

Esta situación no solo evidencia debilidades en la planificación y programación de mantenimiento preventivo, sino que además sugiere posibles fallas estructurales en la identificación temprana de modos de falla, en la calidad de las inspecciones o en la disponibilidad de recursos para ejecutar mantenimientos planificados.

Este comportamiento es típico de organizaciones que se encuentran en fases inmaduras de gestión de activos, donde la cultura de mantenimiento aún no ha transitado hacia enfoques predictivos o proactivos. La consecuencia de este patrón no es menor: mayor probabilidad de fallas críticas, interrupciones no planificadas, costos operativos elevados y afectación al ciclo de vida de los activos.

En contraste, para el año 2024 se observa una mejoría significativa, alcanzando un 60,9% de mantenimiento preventivo (considerando solo las categorías correctivo y preventivo). Aunque esta cifra supera el umbral de riesgo (50%) y permite clasificar la gestión como “aceptable”, aún no alcanza el estándar de referencia internacional, que sugiere un mínimo del 70% de mantenimiento preventivo para considerarse eficiente y sostenible en el largo plazo.

Además, vale la pena destacar que este 60,9% puede ocultar ciertas debilidades si no se evalúa en conjunto con otros indicadores, como el índice de fallas repetitivas, la eficacia del mantenimiento preventivo (fallas post-intervención), o el nivel de criticidad de los activos

atendidos de forma reactiva. Por tanto, aunque se percibe un avance, es probable que la mejora responda más a una intensificación de actividades preventivas que a una transformación integral del modelo de gestión.

2. Porcentaje de correctivos por sistema.

Para el cálculo del porcentaje de correctivos por sistema, se llevó a cabo un proceso en dos etapas. En primer lugar, se realizó el recuento de todas las actividades de mantenimiento correctivo, clasificándolas por sistema y por año, con el fin de identificar las áreas con mayor frecuencia de intervenciones. En segundo lugar, se calculó la ocupación porcentual anual de cada sistema frente al total de correctivos realizados, lo que permite establecer una visión comparativa y detectar tendencias o sistemas críticos que requieren una mayor atención.

Este análisis proporciona información clave para priorizar recursos y diseñar estrategias de mantenimiento más efectivas, enfocadas en reducir las fallas recurrentes y mejorar la confiabilidad de la flota.

Tabla 7

Recuento de Actividades Correctivas por Año y su Componente Porcentual

AÑO	SISTEMA	CORRECTIVO	CORR_YEAR	PORCENTAJE
2022	CARROCERÍA	2167	3116	69.544.288
2022	CHASIS	3	3116	0.096277
2022	DIRECCIÓN	68	3116	2.182.285
2022	ELECTRICIDAD_DE_ALTA	24	3116	0.770218
2022	ELECTRICIDAD_DE_BAJA	301	3116	9.659.820
2022	FRENOS	43	3116	1.379.974
2022	ITS	115	3116	3.690.629
2022	LLANTAS	100	3116	3.209.243
2022	NEUMÁTICO	151	3116	4.845.956
2022	REFRIGERACIÓN	45	3116	1.444.159

AÑO	SISTEMA	CORRECTIVO	CORR_YEAR	PORCENTAJE
2022	SUSPENSIÓN	84	3116	2.695.764
2022	TRANSMISIÓN_DE_POTENCIA	15	3116	0.481386
2023	ASEO	3	17659	0.016989
2023	CARROCERÍA	7971	17659	45.138.456
2023	CHASIS	375	17659	2.123.563
2023	DIRECCIÓN	375	17659	2.123.563
2023	ELECTRICIDAD_DE_ALTA	259	17659	1.466.674
2023	ELECTRICIDAD_DE_BAJA	1703	17659	9.643.808
2023	FRENOS	547	17659	3.097.571
2023	INFRAESTRUCTURA	2	17659	0.011326

Nota. Muestra el recuento de las actividades por sistema y año

Figura 7

Recuento de Actividades por Sistema desde Google Colab

AÑO	SISTEMA	Correctivo_Count	Total_Correctivo_Year	Percentage_Correctivo	Percentage_Correctivo
0 2022	CARROCERÍA	2167	3116	69.544288	69.544288
1 2022	CHASIS	3	3116	0.096277	0.096277
2 2022	DIRECCIÓN	68	3116	2.182285	2.182285
3 2022	ELECTRICIDAD_DE_ALTA	24	3116	0.770218	0.770218
4 2022	ELECTRICIDAD_DE_BAJA	301	3116	9.659820	9.659820
5 2022	FRENOS	43	3116	1.379974	1.379974
6 2022	ITS	115	3116	3.690629	3.690629
7 2022	LLANTAS	100	3116	3.209243	3.209243
8 2022	NEUMÁTICO	151	3116	4.845956	4.845956
9 2022	REFRIGERACIÓN	45	3116	1.444159	1.444159
10 2022	SUSPENSIÓN	84	3116	2.695764	2.695764
11 2022	TRANSMISIÓN_DE_POTENCIA	15	3116	0.481386	0.481386
12 2023	ASEO	3	17659	0.016989	0.016989
13 2023	CARROCERÍA	7971	17659	45.138456	45.138456
14 2023	CHASIS	375	17659	2.123563	2.123563
15 2023	DIRECCIÓN	375	17659	2.123563	2.123563
16 2023	ELECTRICIDAD_DE_ALTA	259	17659	1.466674	1.466674
17 2023	ELECTRICIDAD_DE_BAJA	1703	17659	9.643808	9.643808
18 2023	FRENOS	547	17659	3.097571	3.097571
19 2023	INFRAESTRUCTURA	2	17659	0.011326	0.011326

Ahora, transformamos los resultados de nuestra tabla en datos porcentuales por año, que nos permitan obtener una presentación adecuada el indicador.

Tabla 8

Presentación Porcentual de las Actividades por Sistema y Año

SISTEMA	2022	2023	2024
ASEO	0.00	0.01	4.42
CARROCERÍA	69.54	45.13	52.24
CHASIS	0.09	2.12	0.42
DIRECCIÓN	2.18	2.12	2.52
ELECTRICIDAD_DE_ALTA	0.77	1.46	0.45
ELECTRICIDAD_DE_BAJA	9.65	9.64	5.28
FRENOS	1,37	3.09	3.02
INFRAESTRUCTURA	0.00	0.011	0.00
ITS	3.69	3.09	9.27
LLANTAS	3.20	13.53	13.61
LUBRICACIÓN	0.00	8.63	0.01
MANTENIMIENTO_DE_KILOMETRAJE	0.00	0.18	0.27
NEUMÁTICO	4.84	5.60	2.08
REFRIGERACIÓN	1.44	0.37	0.52
SIRCI	0.00	0.00	0.00
SUSPENSIÓN	2.69	4.36	2.82
TRANSMISIÓN_DE_POTENCIA	0.48	0.58	2.99

Nota. Presentación tabulada de los datos de las actividades por sistema y año

Figura 8

Presentación del Cálculo Porcentual desde Google Colab

	AÑO	2022	2023	2024
SISTEMA				
ASEO		0.000000	0.016989	4.429496
CARROCERÍA		69.544288	45.138456	52.246478
CHASIS		0.096277	2.123563	0.425181
DIRECCIÓN		2.182285	2.123563	2.525701
ELECTRICIDAD_DE_ALTA		0.770218	1.466674	0.456911
ELECTRICIDAD_DE_BAJA		9.659820	9.643808	5.286204
FRENOS		1.379974	3.097571	3.020688
INFRAESTRUCTURA		0.000000	0.011326	0.000000
ITS		3.690629	3.091908	9.277827
LLANTAS		3.209243	13.539838	13.612134
LUBRICACIÓN		0.000000	8.635823	0.012692
MANTENIMIENTO_DE_KILOMETRAJE		0.000000	0.181211	0.272877
NEUMÁTICO		4.845956	5.600544	2.081482
REFRIGERACIÓN		1.444159	0.373747	0.526717
SIRCI		0.000000	0.005663	0.006346
SUSPENSIÓN		2.695764	4.366046	2.823962
TRANSMISIÓN_DE_POTENCIA		0.481386	0.583272	2.995304

Si bien el análisis evidencia una alta proporción de mantenimiento correctivo en los años 2022 y 2023, y una persistencia moderada de este tipo de actividades en 2024, es importante considerar que este comportamiento se encuentra parcialmente influenciado por el envejecimiento natural de la flota y su operación continua en condiciones exigentes. A medida que los activos mecánicos y electrónicos alcanzan mayores ciclos de uso, es esperable un aumento en la frecuencia de fallas no previstas, especialmente en sistemas críticos sujetos a desgaste. Este fenómeno, propio del ciclo de vida de los equipos, tiende a elevar de forma progresiva la carga correctiva, aun cuando existan planes preventivos estructurados. Por tanto, el incremento observado no debe interpretarse exclusivamente como una falla en la gestión del mantenimiento, sino también como un reflejo de las condiciones operacionales y la madurez del parque vehicular.

3. Índice de eficacia del mantenimiento preventivo por sistema

Este indicador permite evidenciar la relación directa entre el mantenimiento preventivo y la ocurrencia del mantenimiento correctivo, destacando cómo una adecuada gestión preventiva puede reducir la frecuencia de intervenciones correctivas. Para su cálculo, se realizó un recuento detallado de las actividades de mantenimiento preventivo y correctivo ejecutadas durante cada año del periodo analizado.

Posteriormente, se aplicó la fórmula establecida previamente, con el objetivo de determinar la proporción entre ambos tipos de mantenimiento. Los resultados obtenidos a partir de este análisis ofrecen una visión clara del comportamiento de la estrategia de mantenimiento implementada, permitiendo identificar oportunidades de mejora y ajustar los planes de intervención para incrementar la confiabilidad y disponibilidad operativa de la flota.

Tabla 9

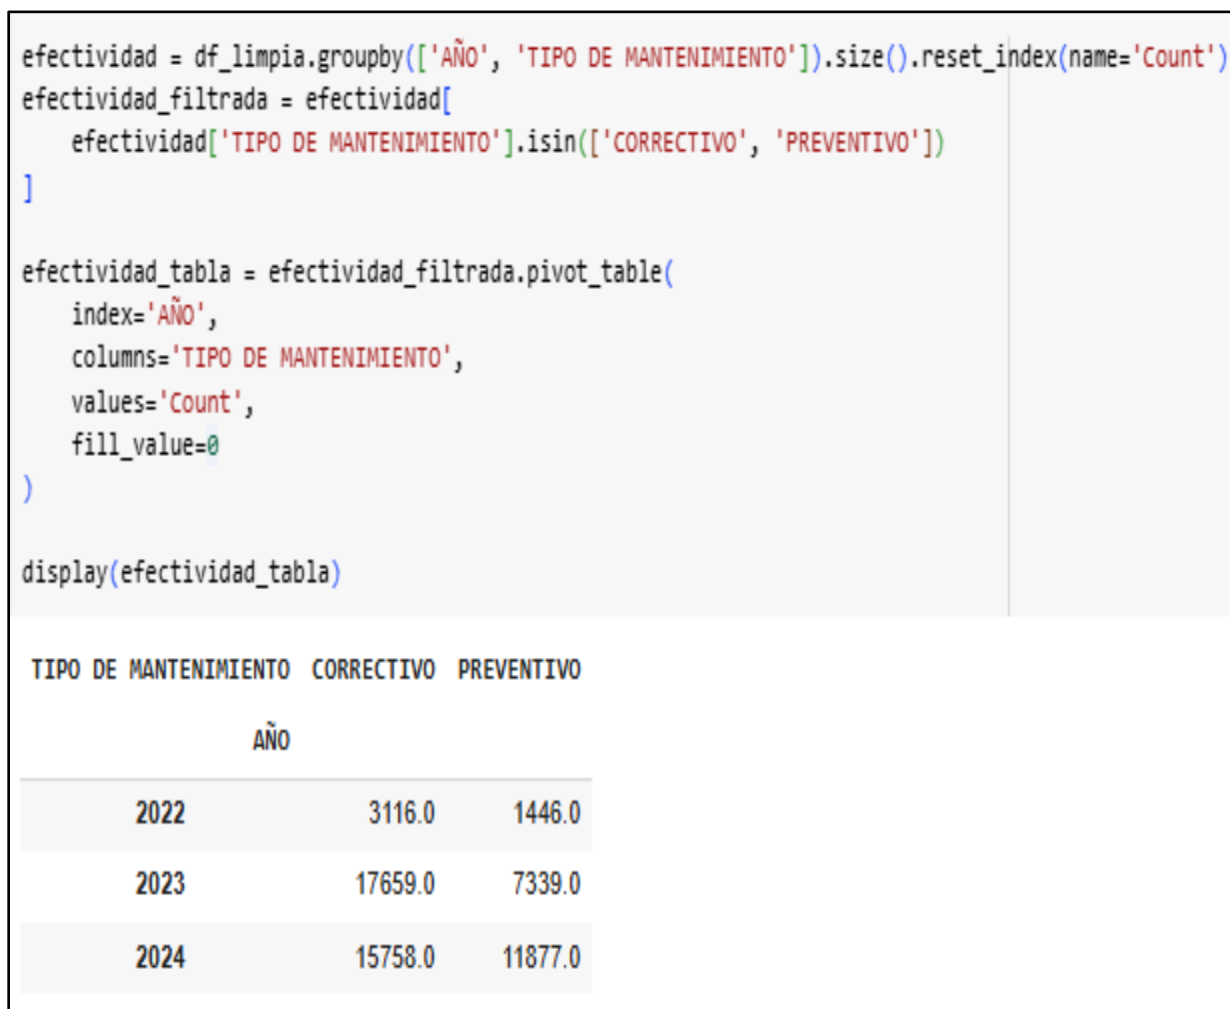
Recuento de Actividades Preventivas y Correctivas por Año

TIPO DE MANTENIMIENTO/AÑO	CORRECTIVO	PREVENTIVO
2022	3116.0	1446.0
2023	17659.0	7339.0
2024	15758.0	11877.0

Nota. Muestra la cantidad de actividades ejecutadas por año entre correctivas y preventivas

Figura 9

Presentación del Cálculo de Actividades desde Google Colab



Ahora bien, basados en la fórmula de cálculo del indicador, puede presentarse la eficacia del mantenimiento realizado por la Operadora Distrital entre los años 2022- 2024.

Presentación del del indicador: entonces, basados en la suma de las horas aplicadas al mantenimiento correctivo y preventivo como un total, podemos obtener los siguientes resultados.

$$X = 1 - \frac{(\text{Correctivos})}{(\text{Preventivos})} \times 100$$

Tabla 10*Cálculo Porcentual de la Eficacia del Mantenimiento Preventivo*

TIPO DE MANTENIMIENTO /AÑO	CORRECTIVO	PREVENTIVO	EFICACIA (%)
2022	3116.0	1446.0	-115.491.010
2023	17659.0	7339.0	-140.618.613
2024	15758.0	11877.0	-32.676.602

Nota. Muestra los datos calculados bajo la fórmula del indicador

Figura 10*Cálculo de la Eficacia desde Google Colab*

```
efectividad_tabla['Eficacia (%)'] = (1 - (efectividad_tabla['CORRECTIVO'] / (efectividad_tabla['PREVENTIVO'] + 1e-9))) * 100
display(efectividad_tabla)
```

TIPO DE MANTENIMIENTO	CORRECTIVO	PREVENTIVO	Eficacia (%)
AÑO			
2022	3116.0	1446.0	-115.491010
2023	17659.0	7339.0	-140.618613
2024	15758.0	11877.0	-32.676602

El valor negativo del indicador de eficacia en el mantenimiento refleja una desviación significativa entre la planeación y la ejecución de las intervenciones, y puede atribuirse a múltiples factores interrelacionados. En primer lugar, se identificaron inconsistencias en la clasificación de órdenes de trabajo, donde actividades preventivas fueron registradas incorrectamente como correctivas, generando una lectura distorsionada de la proporción real

entre ambos tipos de mantenimiento. Esta situación no solo afecta la trazabilidad de los datos, sino que también reduce la visibilidad sobre la efectividad real de las acciones preventivas.

Adicionalmente, se detectaron deficiencias en la asignación y planeación de actividades correctivas, incluyendo demoras en la atención de fallas, falta de repuestos disponibles en el momento requerido, y programación de recursos técnicos sin priorización por criticidad. Estas fallas de gestión operativa propician intervenciones reactivas que no logran restituir completamente las condiciones funcionales de los activos, lo cual aumenta la reincidencia de fallas y, por ende, disminuye la percepción de eficacia.

También se observan causas estructurales, como la ausencia de protocolos estandarizados para la retroalimentación técnica tras cada intervención, lo cual limita el aprendizaje organizacional y la mejora continua. Asimismo, en algunos casos, la falta de actualización o calibración en los criterios de evaluación del mantenimiento preventivo ha llevado a ejecutar tareas con baja pertinencia técnica o en momentos inadecuados del ciclo de vida del activo.

No obstante, en 2024 se vislumbra un panorama de mejora: se han iniciado procesos de depuración de registros, fortalecimiento en la capacitación del personal técnico en la clasificación de órdenes, y ajustes en la programación basada en criticidad y análisis de fallas. Estas acciones, de mantenerse y consolidarse, permitirán recuperar progresivamente la confiabilidad de los datos y aumentar la eficacia real del mantenimiento en los próximos ciclos operativos.

4. Cumplimiento del plan de mantenimiento

En el cálculo de este indicador, se ha realizado una cuenta de la totalidad de ejecuciones de mantenimiento preventivo por rutina, donde la meta es intervenir los 195 buses de la Unidad Funcional, a continuación se muestran los resultados:

Tabla 11*Cantidad de Mantenimientos Ejecutados por Frecuencia*

Descripción de mantenimiento	Cantidad
5.000	195
10.000	195
15.000	195
20.000	195
25.000	195
30.000	195
35.000	195
40.000	196
45.000	195
50.000	195
55.000	195
60.000	195
65.000	195
70.000	195
75.000	195
80.000	195
85.000	195
90.000	195
95.000	195
100.000	195
105.000	192
110.000	187
115.000	154
120.000	104
125.000	54
130.000	5

Nota. Muestra el conteo de mantenimientos ejecutados entre 2022 y 2024 por frecuencia

Tabla 12*Porcentaje de Cumplimiento al Indicador*

Descripción	Cantidad	Porcentaje de Cumplimiento (%)
5.000	195	100.00%
10.000	195	100.00%
15.000	195	100.00%
20.000	195	100.00%
25.000	195	100.00%
30.000	195	100.00%
35.000	195	100.00%
40.000	196	100.51%
45.000	195	100.00%
50.000	195	100.00%
55.000	195	100.00%
60.000	195	100.00%
65.000	195	100.00%
70.000	195	100.00%
75.000	195	100.00%
80.000	195	100.00%
85.000	195	100.00%
90.000	195	100.00%
95.000	195	100.00%
100.000	195	100.00%
105.000	192	98.46%
110.000	187	95.90%
115.000	154	78.97%
120.000	104	53.33%
125.000	54	27.69%
130.000	5	2.56%

Nota. Muestra el cálculo y resultado porcentual de cumplimiento al indicador presentado

Presentación Gráfica de los Indicadores

Los resultados del análisis fueron presentados mediante dos interfaces interactivas: la primera, a través de Google Colab utilizando la integración con Power BI Client, y la segunda mediante visualizaciones desarrolladas en Plotly Express, una biblioteca de código abierto en Python. Ambas herramientas permiten generar filtros interactivos que facilitan la visualización parcial o total de los datos, brindando al usuario una exploración dinámica y enfocada de los indicadores analizados.

Tablero de Power BI a través de Colab

A través de la interfaz de Python con Power BI client, es posible presentar los datos en Power BI fabric o desde el usuario de escritorio, donde se presentan visualizaciones interactivas de los datos e indicadores propuestos, a continuación se presentan dichas funcionalidades.

Figura 11

Tarjetas de Resumen de Datos



Figura 12

Dashboard Interactivo de los Datos




Figura 13

Filtro Dinámico de los Datos



Figura 14

Vista General de Informe, Gráficos y Tablas Interactivas



De forma general, nuestro tablero interactivo cuenta con todas las funcionalidades interactivas de Power BI, a continuación algunas de ellas:

1. Conectar y transformar datos desde múltiples fuentes.
2. Modelar y analizar datos de forma eficiente.

3. Crear visualizaciones interactivas (gráficas, mapas, tablas).
4. Diseñar y presentar Dashboard dinámicos para monitorear indicadores clave (KPI).
5. Compartir informes en la nube de forma segura y colaborativa.
6. Automatizar actualizaciones de datos en tiempo real.


Presentación de los Datos desde Plotly Express

Plotly Express es una biblioteca de visualización de datos en Python que permite:

1. Crear gráficos interactivos de forma rápida y sencilla con pocas líneas de código.
2. Soportar una amplia variedad de visualizaciones como gráficos de barras, líneas, dispersión, mapas, cajas, pastel, entre otros.
3. Integrarse fácilmente con pandas, lo que facilita el uso de DataFrames como fuente de datos.
4. Personalizar visuales con colores, tamaños, etiquetas y animaciones.
5. En nuestro caso, Plotly Express nos permite sobre los gráficos de Google Colab generar filtros interactivos (2) compatibles con listas desplegables (1), que permiten una visualización amplia de los datos (3).

Figura 15

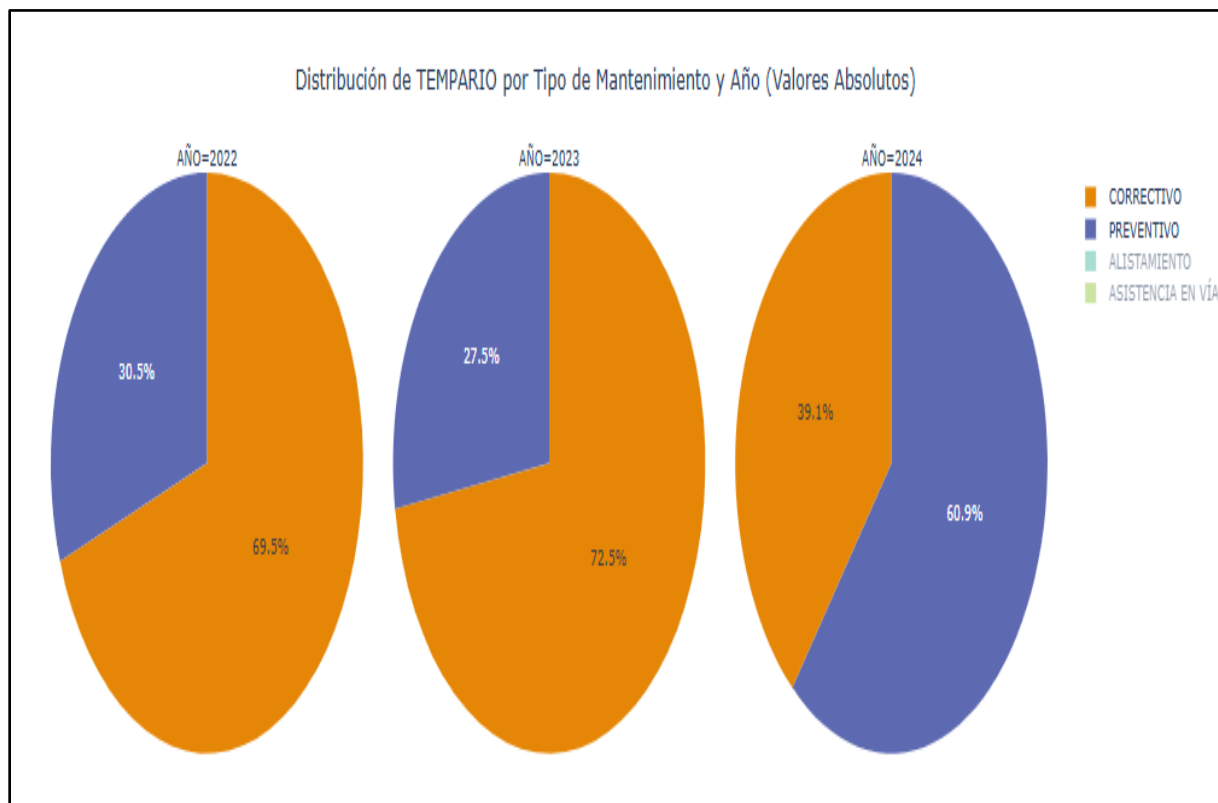
Vista General de Informe en Plotly Express



Presentación Gráfica de los Indicadores con Plotly Express.

Figura 16

Presentación Gráfica de las Distribuciones del Mantenimiento por Año



Entonces, basados en el cumplimiento de los indicadores podemos resumir:

Los años 2022 y 2023 presentan una “Gestión reactiva. Alta dependencia de correctivos. Riesgo alto”, dado que, el mantenimiento correctivo siempre superó el 50% de la totalidad de las horas utilizadas en el mantenimiento.

En el año 2024 se presenta un “Nivel aceptable. Requiere ajustes en programación”, ya que el mantenimiento preventivo se encuentra en 60,9 %, más no llegó al 70% como nivel óptimo.

Figura 17

Distribución Porcentual del Mantenimiento Correctivo del Año 2022 por Sistema




Figura 18

Distribución Porcentual del Mantenimiento Correctivo del Año 2023 por Sistema




Figura 19

Distribución Porcentual del Mantenimiento Correctivo del Año 2024 por Sistema


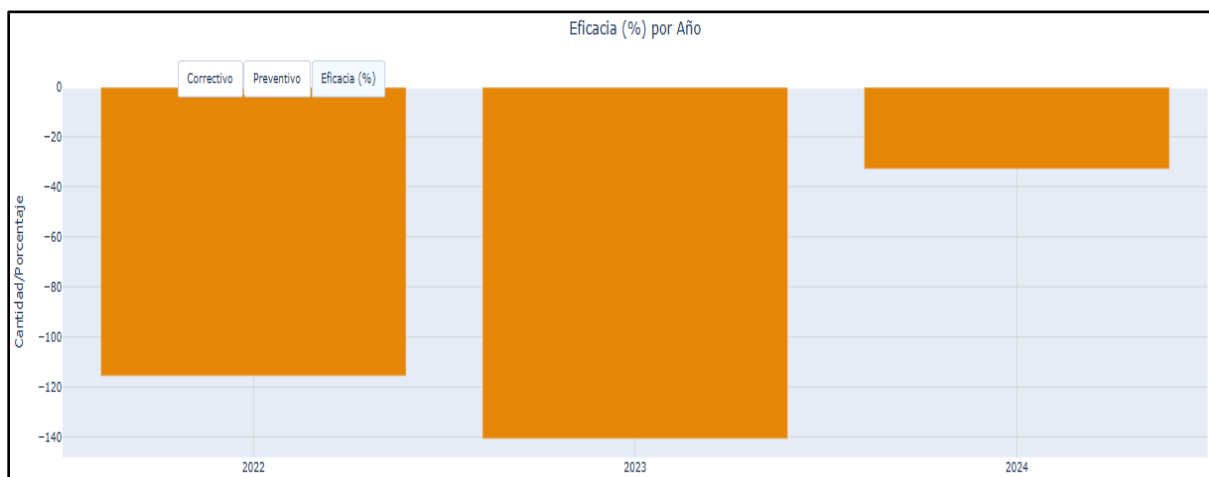


Figura 20

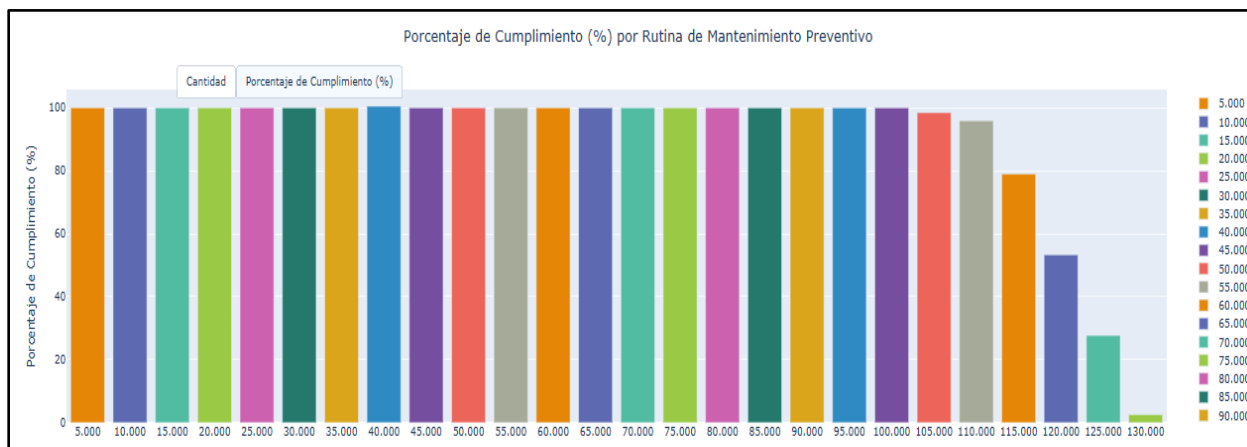
Representación Gráfica de la Eficacia del Mantenimiento Preventivo por Año



Respecto al criterio de evaluación propuesto en el indicador, vemos que el resultado para los años 2022, 2023 y 2024 es “bajo o negativo, hay indicios de fallas no evitadas”, en resumen, no se cumplió con los mínimos criterios de aceptación de efectividad del mantenimiento preventivo vs el correctivo, por las razones expuestas en el análisis de datos realizado líneas atrás.

Figura 21

Presentación Gráfica del Cumplimiento al Plan de Mantenimiento por Rutina



Frente a los resultados, es importante aclarar que para el cierre de año 2024 se encontraban en ejecución los mantenimientos de 105000 km a 130000 km, por lo que, muchas de las actividades tuvieron continuidad en el año 2025, asimismo, se puede observar duplicidad en una actividad de mantenimiento de 40000 km.

Entonces, basados a los resultados, podemos interpretar un resultado superior al 95%, lo que muestra un resultado excelente en la gestión del cumplimiento al plan de mantenimiento.

Conclusiones

Tras analizar la base de datos de mantenimiento recopilada por la Operadora Distrital de Transporte entre los años 2022 y 2024, se identifican diversas oportunidades de mejora en los procesos de recolección, procesamiento y almacenamiento de la información. A continuación, se detallan los hallazgos encontrados:

Datos nulos

Durante el proceso de depuración de la información, se identificaron hasta 90 registros con datos inexistentes en la variable de control de mantenimiento “Kilometraje”, la cual es fundamental para la generación de órdenes de trabajo dentro de la gestión del mantenimiento.

Asimismo, en 82 registros se evidencian valores nulos en todas las columnas relacionadas con la descripción de las labores realizadas, tales como: tempario, técnico asignado, estado de la orden de trabajo (OT), tipo de mantenimiento, empresa responsable, aprobador, descripción de la novedad, sistema y acción correctiva. Esta falta de información impide realizar un análisis preciso y efectivo sobre el número y la naturaleza de las intervenciones realizadas a los vehículos.

Estandarización

Se evidencian inconsistencias significativas en la clasificación de los sistemas dentro de la base de datos. Por ejemplo, se registran denominaciones duplicadas con ligeras variaciones en su formato, como “Electricidad_ de _alta” y “Electricidad de alta”, o “Electricidad de baja” y “Electricidad_de_baja”. Estas diferencias, aunque mínimas a nivel visual, representan valores distintos para las herramientas de análisis, lo cual complica la consolidación y el tratamiento automatizado de la información.

De igual manera, la columna “corrección” tuvo que ser descartada del análisis debido a la falta de estandarización en su contenido. En ella se encontraron múltiples problemas: redacciones inconsistentes, errores ortográficos frecuentes, uso de terminología no unificada y descripciones extensas que superan los 255 caracteres permitidos por algunas herramientas de procesamiento. Esta situación impide aplicar procesos eficientes de limpieza, categorización y análisis de texto, limitando su utilidad para la evaluación técnica de las intervenciones.

Errores en “tipo de mantenimiento”

Las estrategias y resultados en la gestión del mantenimiento dependen en gran medida de una correcta clasificación de las tareas ejecutadas. Esta clasificación es especialmente crítica para la construcción de indicadores como: el índice de proporción de mantenimiento preventivo vs correctivo, el porcentaje de mantenimientos correctivos por sistema, y el índice de eficacia del mantenimiento preventivo por sistema. Todos ellos requieren que se asigne correctamente el tipo de mantenimiento correspondiente a cada intervención.

Durante la revisión de los registros de mantenimiento preventivo programado por frecuencia fija, se identificó que 1.602 intervenciones, que correspondían a actividades preventivas, fueron clasificadas erróneamente como correctivas. Esta mala categorización impacta negativamente en el cálculo y alcance de los indicadores mencionados, generando una subestimación del mantenimiento preventivo realizado. Además, se presume que un número aún mayor de tareas preventivas de frecuencia variable también podrían haber sido clasificadas como correctivas, lo cual distorsiona aún más la evaluación del desempeño del mantenimiento.

Clasificación y duplicidad de órdenes de trabajo

Durante el proceso de análisis del cumplimiento del plan de mantenimiento, se identificaron varias inconsistencias que afectan la calidad y precisión de los datos registrados. En

particular, se detectaron discrepancias en la nomenclatura utilizada para los mantenimientos programados a los 40.000 y 120.000 kilómetros, lo cual genera confusión al momento de consolidar y analizar la información.

Adicionalmente, se evidenció la presencia de actividades adicionales no previstas en el mantenimiento de 40.000 km, representadas en 196 órdenes de trabajo, lo que sugiere una desviación respecto a los lineamientos establecidos en el plan original. Por otra parte, en las actividades asociadas al mantenimiento de plataformas, se identificó una duplicación de tareas, reflejada en 197 órdenes de trabajo, lo que podría estar relacionado con errores de programación o con una falta de estandarización en la ejecución de estas labores.

Estas irregularidades impactan negativamente en la confiabilidad de la información recopilada, ya que generan una percepción de inexactitud y dificultan el seguimiento efectivo del cumplimiento del plan de mantenimiento, así como la toma de decisiones basada en datos precisos y consistentes.

En general, el análisis realizado sobre la base de datos del mantenimiento de la Operadora Distrital de Transporte permitió identificar una serie de hallazgos relevantes tanto a nivel de calidad de los datos como en relación con la evolución del mantenimiento preventivo y correctivo, en el proceso y como se menciona anteriormente, se detectaron inconsistencias como duplicidad de registros, datos nulos, repetidos y una categorización insuficiente de las variables clave asociadas a las actividades de mantenimiento. Estas condiciones afectan la integridad y confiabilidad de la información, limitando inicialmente la precisión de los análisis.

Sin embargo, a pesar de estas deficiencias, fue posible caracterizar el estado actual de la gestión del mantenimiento y evidenciar una tendencia positiva de mejora progresiva. En particular, se observó un incremento sostenido en la ejecución de actividades tanto preventivas

como correctivas, lo cual indica un fortalecimiento de la cultura de mantenimiento y una mayor capacidad operativa de respuesta.

Este análisis ha permitido establecer una línea base clara para la toma de decisiones informadas, orientadas a la mejora continua en la recolección, almacenamiento y gestión de los datos. Asimismo, sienta las bases para la implementación de estrategias que permitan estandarizar procesos, categorizar adecuadamente las variables críticas y reducir al mínimo los errores de registro.

Con base en este trabajo, se proyecta que, en un horizonte de uno a dos años, la Operadora Distrital de Transporte podrá contar con una base de datos sólida, estructurada y confiable, lo cual será clave para consolidar una gestión de mantenimiento eficiente, trazable y alineada con los principios de confiabilidad operativa.

Recomendaciones

A continuación, se presentan una serie de recomendaciones para el fortalecimiento de la gestión de mantenimiento y la consolidación de una base de datos sólida, que permita al sistema de información generar información más efectiva de la realidad del mantenimiento de la Operadora Distrital de Transporte.

Estandarizar la categorización de los tipos de mantenimiento

Definir de manera clara y documentada los criterios para clasificar las actividades en mantenimiento preventivo, correctivo y predictivo, alineados con las buenas prácticas del sector.

Establecer un catálogo único de actividades por tipo de mantenimiento, con códigos estandarizados que eviten la ambigüedad o duplicación en los registros.

Capacitar al personal operativo y técnico en la aplicación de esta clasificación para asegurar su correcta implementación en el sistema.

Definir y aplicar variables clave de control e identificación

Incorporar variables obligatorias para cada orden de trabajo, tales como: tipo de mantenimiento, sistema intervenido, componente afectado, causa raíz, tiempo de ejecución, recurso asignado, y frecuencia programada.

Automatizar la validación de estas variables en el sistema de gestión de mantenimiento (CMMS), de forma que se impida guardar registros incompletos o con valores inconsistentes.

Implementar procesos de control de calidad de los datos

Diseñar rutinas de auditoría mensual de la base de datos, enfocadas en la detección y corrección de duplicidades, campos nulos o inconsistentes.

Integrar indicadores de calidad de datos como parte del seguimiento del plan de mantenimiento, permitiendo visibilizar avances o retrocesos en la depuración de la información.

Fortalecer la trazabilidad y seguimiento de las intervenciones

Establecer mecanismos de trazabilidad que permitan relacionar cada intervención con su historial, frecuencia, responsable y resultado de ejecución.

Incorporar el uso de tecnologías como códigos QR o lectores móviles para facilitar el registro en campo y reducir errores humanos.

Promover una cultura de gestión basada en datos

Fomentar la toma de decisiones apoyada en análisis sistemáticos de la base de datos, mediante reportes periódicos con indicadores clave como: cumplimiento del plan de mantenimiento, proporción preventivo/correctivo, repetitividad de fallas y costos asociados.

Asegurar que los responsables de las distintas áreas (operaciones, mantenimiento, planeación) comprendan la importancia de la calidad de los datos y participen activamente en su mejora continua.

Diseñar una hoja de ruta para la madurez de la base de datos

Establecer un cronograma por etapas para alcanzar una base de datos sólida en menos de dos años, con metas semestrales de depuración, categorización y automatización de registros.

Priorizar sistemas críticos (vehículos, plataformas, sistemas eléctricos, etc.) en la primera fase para garantizar impacto temprano en la confiabilidad operativa.

Estas acciones, implementadas de manera articulada, permitirán a la operadora distrital avanzar hacia una gestión de mantenimiento inteligente, con información robusta que facilite decisiones estratégicas, reduzca tiempos de inactividad y aumente la confiabilidad de los activos.

Referencias

- Aparicio, L. S. (2010). El impacto del transporte en el ordenamiento de la ciudad: El caso de Transmilenio en Bogotá. *Territorios*, 22, 33–64.
<https://www.redalyc.org/pdf/357/35714236003.pdf>
- Ardila Marín, J. G., Ardila Marín, M. I., Rodríguez Gaviria, D., & Hincapié Zuluaga, D. A. (2016). La gerencia del mantenimiento: Una revisión. *Dimensión Empresarial*, 14(2), 127–142. <http://www.scielo.org.co/pdf/diem/v14n2/v14n2a09.pdf>
- Arrocha, Y. Y. (2021). *Normas APA Séptima Edición*, 2020.
<http://repositorio2.udelas.ac.pa/handle/123456789/333>
- Cabrera-Moya, R. R. D. (2017). Hacia un marco de referencia para la generación de ventajas competitivas sostenibles en los Sistemas Integrados de Transporte Público–SITP en Colombia. *Aporte de las capacidades dinámicas de innovación*.
<https://revistas.unal.edu.co/index.php/dyna/article/view/54118/58958>
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. (2019). Una revisión sistemática de la literatura sobre métodos de aprendizaje automático aplicados al mantenimiento predictivo. *Computers & Industrial Engineering*, 137, 106024. <https://www.sciencedirect.com/science/article/abs/pii/S0360835219304838>
- Coba, J. A. A., Barrera, L. F. A., & Sánchez, K. P. M. (2022). Perspectivas del Big Data. *Alfa Publicaciones*, 4(1.1), 514–531. <https://repository.eafit.edu.co/items/5f15f5db-5434-45fb-b222-73a9e56056de>

- Correa, J. (2015). *Escritura e investigación académica: Una guía para la elaboración del trabajo de grado* (pp. 20–32).
<https://bibliotecavirtual.unad.edu.co/login?url=https://search.ebscohost.com/login.aspx?direct=true&db=nlebk&AN=2014981&lang=es&site=eds-live&scope=site>
- Cortés, S. B. (2022). *Guía citación normas APA séptima edición (Tesis doctoral, Facultad de Filosofía y Ciencias Humanas, Universidad Libre)*.
<https://www.unilibre.edu.co/bogota/pdfs/2022/facultad-de-filosofia-y-ciencias-humanas-guia-apa-septima-edicion.pdf>
- Del Olmo, M., & Domingo, R. (2022). *Revisión a la planificación de recursos inteligente en mantenimiento, reparación y overhaul*.
http://dspace.aeipro.com/xmlui/bitstream/handle/123456789/3189/AT03-030_22.pdf?sequence=1&isAllowed=y
- Dimas Pastrana, D. A. (2022). *Impacto económico de la automatización en procesos de mantenimiento, para la industria manufacturera en Colombia: Una revisión bibliográfica [Trabajo de grado, Universidad Distrital Francisco José de Caldas]*.
<https://repository.udistrital.edu.co/bitstream/handle/11349/30940/DimasPastranaDiegoArmando2022.pdf?sequence=1&isAllowed=y>
- ECBTI. (2016). *Líneas de investigación ECBTI Universidad Nacional Abierta y a Distancia UNAD*. <https://academia.unad.edu.co/investigacion-y-productividad-ecbti/lineas>
- Gómez, M. G. (2019). *Aplicaciones industriales Big Data para mantenimiento predictivo y control de calidad*.
https://scholar.google.es/scholar?hl=es&as_sdt=0%2C5&q=big+data+en+mantenimiento&oq=

- Lara, Y. A., & Gutiérrez, E. R. (2012). La implementación del Sistema Integrado de Transporte Público (SITP) de Bogotá y sus retos en el futuro. *Tecnogestión: Una mirada al ambiente*. <https://revistas.udistrital.edu.co/index.php/tecges/article/view/5649>
- Meraz-Méndez, M., Lerma-Hernández, C., & Corral-Ramírez, G. (2019). La industria 4.0 en el mantenimiento industrial. *Revista de Ingeniería*, 3(7), 17–24.
https://www.researchgate.net/profile/Claudia-Lerma-Hernandez/publication/337457160_La_industria_40_en_el_mantenimiento_industrial/links/602e94eb4585158939b45770/La-industria-40-en-el-mantenimiento-industrial.pdf
- Moubray, J. (2004). *Mantenimiento centrado en confiabilidad (RCM)*. Aladon LLC.
https://scholar.google.es/scholar?hl=es&as_sdt=0%2C5&q=rcm&btnG=
- Parra, C., & Crespo, A. (2012). Ingeniería de mantenimiento y fiabilidad aplicada a la gestión de activos. *Ingecon*. <https://books.google.es/books?hl=es&lr=&id=8xsnQ1aMg2gC>
- Pérez, M. A. L., Zacatenco, S. E., & Álvarez, G. V. (2019). Metodología de mantenimiento predictivo 4.0. *Sistemas, Cibernética e Informática*, 16(2).
http://scielo.sld.cu/scielo.php?pid=S1815-59362023000300017&script=sci_arttext&tlng=en
- Poveda Guevara, A. J., & Lozano, M. (2012). *Aplicación de la metodología de mantenimiento centrado en confiabilidad para el desarrollo de planes de mantenimiento*.
<https://www.dspace.espol.edu.ec/handle/123456789/20586>
- Romero Betancur, A. A., & Cujar Montes, J. M. (2019). *Uso del Big Data y recursos Cloud en el proceso de mantenimiento de maquinaria en la empresa Ferromotores*.
<http://hdl.handle.net/10823/1863>

Schröer, C., Kruse, F., & Gómez, J. M. (2021). Una revisión sistemática de la literatura sobre la aplicación del modelo de proceso CRISP-DM. *Procedia Computer Science*, 181, 526–534. <https://www.sciencedirect.com/science/article/pii/S1877050921002416>

Quintanilla, C. F. (2020). *Metodología del mantenimiento predictivo para la mejora en los equipos en una empresa entre los años 2011–2019: Una revisión sistemática de la literatura científica [Trabajo de investigación, Universidad Privada del Norte]*. <https://hdl.handle.net/11537/26423>