



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA


ETSI Aeroespacial y Diseño Industrial

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Aeroespacial
y Diseño Industrial

Detección de anomalías en los sistemas de climatización
de una flota de autobuses basado en IA

Trabajo Fin de Máster

Máster Universitario en Ingeniería del Mantenimiento

AUTOR/A: Cejudo, Federico Ruben

Tutor/a: Tormos Martínez, Bernardo Vicente

Cotutor/a externo: Onaindia de la Rivaherrera, Eva

CURSO ACADÉMICO: 2025/2026



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



Universitat Politècnica de València

Escuela Técnica Superior de Ingeniería Aeroespacial

y Diseño Industrial

Detección de anomalías en los sistemas de climatización de una flota de autobuses basado en IA

Trabajo Fin de Máster

Máster Universitario en Ingeniería del Mantenimiento

Curso 2024/2025

Autor: Federico Ruben Cejudo

Tutores: Bernardo Vicente Tormos Martínez,

Eva Onaindia de la Rivaherrera

Cotutor: Ramón Eduardo Sánchez Márquez

Resumen

Este Trabajo Fin de Máster aborda la problemática de los fallos en el sistema de climatización (HVAC) de los autobuses urbanos de la Empresa Municipal de Transporte (EMT) de Valencia, cuyo funcionamiento es crítico para garantizar el confort de los pasajeros y la continuidad del servicio. Para ello, se recopilaron y analizaron registros operativos procedentes de diferentes fuentes telemáticas y de mantenimiento, estructurando una base de datos sólida con 28 variables relevantes. Se implementó un modelo de aprendizaje profundo (LSTM Autoencoder) con el fin de caracterizar el comportamiento normal del sistema y detectar anomalías a partir de desviaciones en los patrones temporales. Aunque esta primera iteración se limitó por la disponibilidad de datos y tiempo, permitió validar criterios de filtrado, definir una metodología replicable y construir una arquitectura inicial funcional. Los resultados constituyen un primer paso hacia el desarrollo de metodologías de mantenimiento predictivo en el marco de la Industria 4.0, orientadas a mejorar la fiabilidad operativa de la flota, reducir costes de mantenimiento y optimizar la prestación del servicio de transporte urbano.

Palabras claves: Mantenimiento predictivo, Industria 4.0, Autobuses urbanos, Climatización, HVAC, Aprendizaje automático, Deep Learning, Autoencoders, Análisis de anomalías, Inteligencia artificial.

Abstract

This Master's Thesis addresses the issue of failures in the Heating, Ventilation, and Air Conditioning (HVAC) system of urban buses operated by the Municipal Transport Company (EMT) of Valencia, whose proper functioning is essential to ensure passenger comfort and service continuity. Operational records from telematics platforms and maintenance reports were collected and analyzed, resulting in a robust database of 28 key variables. A deep learning model (LSTM Autoencoder) was implemented to characterize the normal behavior of the HVAC system and detect anomalies based on deviations in temporal patterns. Although this first iteration was limited by data availability and time constraints, it validated filtering criteria, established a replicable methodology, and produced a functional initial architecture. The outcomes represent an initial step toward the development of predictive maintenance methodologies within the framework of Industry 4.0, aiming to enhance fleet reliability, reduce maintenance costs, and improve the quality of urban transport services.



Keywords: Predictive maintenance, Industry 4.0, Urban buses, HVAC, Air conditioning, Machine learning, Deep learning, Autoencoders, Anomaly detection, Artificial intelligence.

Table de Contenidos

1	Introducción	6
1.1	Contexto y motivación.....	6
1.2	Averías de autobuses de EMT Valencia de año 2024.....	9
1.3	Objetivos.....	10
2	Revisión de la literatura.....	11
2.1	Industria 4.0 y el Mantenimiento	11
2.2	Digitalización del Mantenimiento en el sector transporte	17
2.3	Uso de Machine Learning y Deep Learning en el mantenimiento vehicular.....	18
2.4	LSTM Autoencoders para detección de anomalías.....	21
2.4.1	Conceptos	21
2.4.2	Casos de aplicación	23
3	Metodología	25
3.1	Problemática de estudio	25
3.1.1	Población y período de estudio.....	26
3.1.2	Conceptos del Sistema de Aire Acondicionado	26
3.1.3	Aspectos constructivos del aire acondicionado	28
3.2	Recopilación de datos e infraestructura disponible	30
3.2.1	Fuentes de datos	31
3.2.2	Visita a Empresa Municipal de Transporte	40
3.2.3	Análisis de fallos	43
3.3	Análisis exploratorio de datos (EDA).....	47
3.3.1	Análisis de correlaciones entre variables.....	47
3.3.2	Ingeniería de características: creación de variables.....	52
3.4	Criterios adoptados	53
3.5	Desarrollo de modelos y validación de resultados.....	56
3.5.1	Selección del enfoque.....	56
3.5.2	Preparación del conjunto de datos.....	57
3.5.3	Entrenamiento y validación del modelo	58
3.5.4	Resultados: detección de anomalías y patrones observados.....	59
4	Objetivos de Desarrollo Sostenible asociado al TFM.....	62
5	Presupuesto para la realización del TFM	63
6	Conclusiones	64
7	Desafíos del Mantenimiento 4.0 y trabajos a futuro	65
8	Bibliografía.....	66
9	Anexos.....	70
9.1	Registro del Estado del Vehículo.....	70

9.2	Histórico de Diagnósis.....	72
-----	-----------------------------	----

Lista de Figuras

Figura 1.	Sistema de postratamiento de vehículos híbridos.	8
Figura 2.	Riesgos específicos asociados a la manipulación de un vehículo eléctrico.	8
Figura 3.	Campos de IA, ML y DL.	16
Figura 4.	Ejemplo de autocodificador.	22
Figura 5.	Flujo de datos en la unidad de tiempo t para una RNN tradicional.	23
Figura 6.	Vehículo Mercedes Benz Citaro Híbrido de EMT.	26
Figura 7.	Esquema de ciclo ideal de refrigeración por compresión de vapor y diagrama T-s.....	27
Figura 8.	Componentes principales del sistema de aire acondicionado.	28
Figura 9.	Conductos de aire del sistema de climatización.....	30
Figura 10.	Porcentaje mensual de registros de Proveedor Externo y Mantenimiento EMT.	39
Figura 11.	Temperatura nominal (zona pasajeros): 18°C	41
Figura 12.	Sensor de “Temperatura externa (°C)”	41
Figura 13.	Sensor de “Temperatura de salida del aire (parte trasera – techo)”	42
Figura 14.	Posición de las compuertas de circulación de aire, aire exterior/aire recirculante 100% cerradas.....	42
Figura 15.	Sensores de presión de líquido refrigerante.	43
Figura 16.	Sensores de presión del líquido refrigerante del sistema de Aire Acondicionado.....	46
Figura 17.	Distribución mensual de códigos de error (%).	47
Figura 18.	Mapa de correlación de variables de posición de la compuerta de circulación de aire.	48
Figura 19.	Mapa de correlación de variables de revoluciones del soplador.	49
Figura 20.	Mapa de correlación de variables de tiempo de servicio.	51
Figura 21.	Fecha de disparo junto a las variables de temperatura.	53
Figura 22.	Porcentaje mensual de registro de la variable Modo “Refrigeración”.	54
Figura 23.	Registro de variables de temperaturas.....	56
Figura 24.	Evolución de la función de pérdida durante el entrenamiento y validación .	60
Figura 25.	Distribución del error de reconstrucción en el entrenamiento	60

Figura 26. Distribución del error de reconstrucción en el conjunto anómalo	61
Figura 27. Los 17 objetivos de Desarrollo Sostenible (ODS).	62

Lista de Tablas

Tabla 1. Averías de autobuses EMT Valencia de año 2024	9
Tabla 2. Uso de Machine Learning y Deep Learning en el mantenimiento vehicular ...	20
Tabla 3. Registro de Estado del Vehículo	33
Tabla 4. Histórico de Diagnosis.....	35
Tabla 5. Registros de Historial de Alarmas.	35
Tabla 6. Registro de Mantenimiento EMT.	38
Tabla 7. Fallos de mayor frecuencia.	44
Tabla 8. Mayor descripción de Fallos.....	45
Tabla 9. Referencias de variables de posición de la compuerta de circulación de aire. .	48
Tabla 10. Referencias de variables de número de revoluciones del soplador.....	50
Tabla 11. Referencias de las variables de tiempo de servicio.....	51
Tabla 12. Franja horaria de mayor demanda del transporte urbano.	54
Tabla 13. Presupuesto para ejecución del TFM.....	63
Tabla 14. Registro completo del Histórico de Diagnosis	72

1 Introducción

1.1 Contexto y motivación

En la actualidad, es muy común hablar de la Industria 4.0, también llamada la cuarta revolución industrial, en la cual las grandes fábricas industriales incorporan en sus procesos de producción la interconexión entre equipos, máquinas y líneas de producción, lo cual les proporciona la ventaja de operar como fábricas flexibles, capaces de adaptarse a distintas circunstancias y de garantizar en todo momento el máximo nivel de eficiencia y rendimiento. Estas nuevas tecnologías se sustentan en la conexión a internet y en la transferencia de datos, procesos que se llevan a cabo de manera digital, es decir, no es necesario realizar intervenciones directas en la maquinaria para obtener mediciones de dichos parámetros físicos, ya que los propios equipos se comunican entre sí. De esta manera, se posibilita la aplicación de estrategias de mantenimiento en el marco de la industria 4.0.

Por lo tanto, el tipo de mantenimiento industrial más adecuado para las fábricas inteligentes es precisamente el mantenimiento predictivo. Gracias al uso de softwares de análisis, es posible disponer en todo momento de los datos relativos al estado de las máquinas. A partir de esta información, el sistema informático contribuye a predecir cuándo un equipo comienza a mostrar signos de degradación o presenta alguna falla o anomalía en su funcionamiento. También ayudan a decidir cuándo es el momento idóneo para hacer una reparación o sustitución antes de que se produzca una avería que ponga en riesgo el buen funcionamiento de la fábrica. Además, gracias a las particularidades de la industria 4.0, asociado a la interconexión entre equipos, líneas de producción, etc, el resto de la maquinaria podrá adaptarse a la circunstancia y conseguir el máximo rendimiento mientras esa parte del proceso de producción está en reparación. (Meraz-Mendez, Lerma-Hernandez, & Corral-Ramirez, 2019)

En el marco de la Industria 4.0, la adopción de estrategias de mantenimiento predictivo en el transporte público ha adquirido una creciente relevancia. Sin embargo, muchas flotas de autobuses urbanos aún se encuentran en etapas iniciales de transformación digital, lo que se traduce en datos históricos limitados e infraestructuras fragmentadas que dificultan la implementación de enfoques basados en datos (Tormos, Bermudez, Sánchez-Márquez, & Alvis, 2025).

A pesar de estas limitaciones, diversos estudios han abordado la temática desde diferentes perspectivas. En “A Reproducible Pipeline for Leveraging Operational Data Through Machine Learning in Digitally Emerging Urban Bus Fleets” (o, Un proceso reproducible para aprovechar datos operativos mediante aprendizaje automático en flotas de autobuses urbanos digitalmente emergentes), se propone una canalización reproducible de aprendizaje automático que facilita la aplicación de mantenimiento predictivo en flotas con información operativa limitada, mediante el uso de algoritmos ligeros e interpretables que fortalecen la fiabilidad del sistema y permiten anticipar fallas (Tormos, Bermudez, Sánchez-Márquez, & Alvis, 2025). De manera complementaria, “Explainable AI Using On-Board Diagnostics Data for Urban Buses Maintenance Management: A Study Case” (o, IA explicable mediante datos de diagnóstico a bordo para la gestión del mantenimiento de autobuses urbanos: un caso de estudio) introduce el uso de inteligencia artificial explicable (XAI) aplicada a datos de diagnóstico a bordo (OBD), con el propósito de clasificar los estados de regeneración del filtro de partículas diésel (DPF) y brindar soporte a las decisiones de mantenimiento a través de modelos comprensibles para los técnicos responsables (Tormos, Pla, Sánchez-Márquez, & Carballo, 2025).

En esta misma línea, “Uso de la Inteligencia Artificial (IA), aplicada al transporte público del cantón Santo Domingo” examina la incorporación de herramientas inteligentes en el contexto latinoamericano, destacando cómo la IA puede optimizar la planificación de rutas, reducir tiempos de inactividad y fortalecer los programas de mantenimiento mediante la detección temprana de fallas (Vaca-Bustos & Sánchez-Parrales, 2024). A su vez, “Predictive Maintenance of Bus Fleet by Intelligent Smart Electronic Board Implementing Artificial Intelligence” (o, Mantenimiento predictivo de flotas de autobuses mediante placa electrónica inteligente que implementa inteligencia artificial) propone un sistema de mantenimiento predictivo basado en una unidad electrónica inteligente capaz de recopilar y procesar datos del vehículo mediante OBD/CAN e IoT, lo que permite anticipar las necesidades de mantenimiento y mejorar la eficiencia operativa de la flota.

Por último, “AI-Driven Approach for Enhancing Sustainability in Urban Public Transportation” (o, Enfoque basado en IA para mejorar la sostenibilidad en el transporte público urbano) presenta un enfoque orientado a la sostenibilidad del transporte urbano, donde la inteligencia artificial se utiliza para optimizar la regularidad de los intervalos de paso y reducir desviaciones operativas, contribuyendo a una gestión más eficiente y ecológicamente responsable. En conjunto, estos estudios evidencian el papel

transformador de la inteligencia artificial en el mantenimiento de autobuses urbanos, al promover la eficiencia, la seguridad y la sostenibilidad de las operaciones de transporte público (Lukic Vujadinovic, y otros, 2024).

Pese a estos avances, aún queda un amplio campo por explorar en la aplicación de técnicas de mantenimiento predictivo. En el caso de los autobuses diésel híbridos, una problemática es la obstrucción progresiva del Filtro de Partículas Diésel (DPF), Figura 1, cuyo correcto funcionamiento resulta esencial para garantizar tanto el cumplimiento de la normativa ambiental como la confiabilidad operativa de los sistemas de transporte público (Tormos, Bermudez, Sánchez-Márquez, & Alvis, 2025). Por su parte, en los autobuses eléctricos, uno de los retos más relevantes se relaciona con la seguridad en la gestión de las baterías, especialmente ante el fenómeno denominado thermal runaway, Figura 2, capaz de provocar incendios difíciles de controlar o incluso explosiones (Mérida Fernández, 2024).




Figura 1. Sistema de postratamiento de vehículos híbridos.

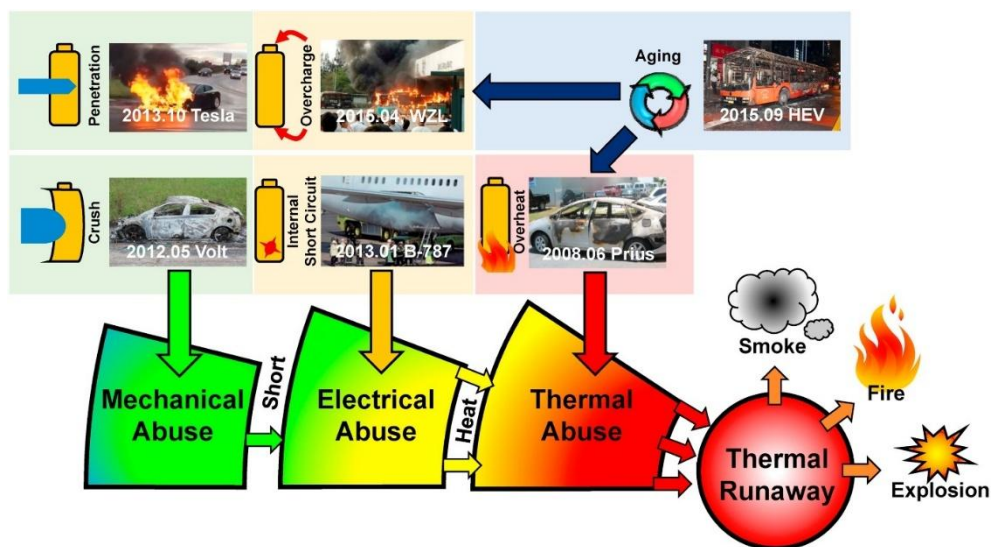


Figura 2. Riesgos específicos asociados a la manipulación de un vehículo eléctrico.

A continuación, y en línea con estas consideraciones, se presentan el conjunto de averías registradas por flota de transporte urbano de la Empresa Municipal de Transportes (EMT) de la ciudad de Valencia.

1.2 Conjunto de averías en autobuses de EMT Valencia año 2024

Dado que la Empresa Municipal de Transportes de Valencia (EMT) cuenta en su flota con vehículos tanto híbridos diésel como eléctricos, en la Tabla 1 se presenta el número de averías registradas en los distintos sistemas de los autobuses durante el año 2024.

Tabla 1. Averías de autobuses EMT Valencia de año 2024

Averías de autobuses de EMT Valencia año 2024		
Orden	Sistema	Cantidad de averías
1	Otras Averías	6,623
2	Sae Soluziona	2,143
3	Puertas	1,845
4	Cuadro De Control	1,368
5	Rampa Discapacidades	1,158
6	Aire Acondicionado	812
7	Inyección	799
8	Equipamiento Interior	689
9	Circuito Refrigeración	474

A continuación, se describe cada uno de los sistemas:

- Otras averías: anomalías en componentes como caja de velocidades, grupo diferencial, dirección, sistema neumático, suspensión, sistema eléctrico y carrocería exterior.
- SAE Soluziona: equipo utilizado por el conductor para controlar el servicio del autobús.
- Puertas: empleados para el acceso y salida de pasajeros y conductor.
- Cuadro de control: panel frontal que permite al conductor supervisar el estado del vehículo.
- Rampa discapacitados: dispositivo de acceso y salida para personas en silla de ruedas.
- Aire acondicionado: sistema destinado a climatizar tanto el espacio de pasajeros como el del conductor.
- Inyección: sistema encargado de la inyección de combustible.
- Equipamiento interior: componentes internos del autobús.
- Circuito de refrigeración: sistema utilizado para refrigerar la unidad motora del vehículo.

Por otra parte, considerando lo expuesto y desde la perspectiva de la criticidad en el confort de pasajeros y conductores, así como la posibilidad de aplicar técnicas de mantenimiento predictivo orientadas a optimizar el funcionamiento y reducir la frecuencia de incidencias, los principales sistemas a priorizar son:

- Puertas
- Rampa discapacitados
- Aire acondicionado

Entre los diferentes sistemas analizados, el aire acondicionado adquiere una especial relevancia, ya que dispone de una mayor cantidad de datos y señales operativas que permiten describir con precisión su comportamiento a lo largo del tiempo. En este sentido, se identifica como el sistema más adecuado para desarrollar un análisis de mantenimiento predictivo en el marco de la Industria 4.0, al ofrecer información suficiente para la aplicación de técnicas basadas en datos. Por este motivo, el presente trabajo se centra en el estudio de las incidencias relacionadas con el sistema de aire acondicionado de la flota de transporte urbano. Cabe destacar que, desde el punto de vista de la adquisición de datos operativos a través de la unidad de control electrónico (ECU) de los vehículos, el aire acondicionado forma parte del sistema de climatización de la flota, conocido por sus siglas en inglés HVAC (Heating, Ventilation, and Air Conditioning o Calefacción, Ventilación y Aire Acondicionado). Por lo tanto, en adelante, se utilizará el término “climatización” para referirse de manera integral al sistema de aire acondicionado.

1.3 Objetivos

Objetivo general

Desarrollar una metodología exploratoria para la detección de anomalías en sistemas de climatización de flotas de autobuses urbanos. Esta metodología abarcará el entendimiento del problema, la selección y documentación de variables relevantes, la exploración de datos y el modelado inicial. Para ello, se integrarán y analizarán datos provenientes de sensores operativos, alarmas electrónicas y registros manuales de mantenimiento. Además, se validarán en campo las variables seleccionadas, se identificarán las limitaciones actuales de la infraestructura de adquisición de datos, y se aplicará un enfoque preliminar basado en técnicas de Machine Learning.

Objetivos específicos

Analizar la infraestructura tecnológica disponible en la flota de autobuses urbanos, identificando sus capacidades y limitaciones para la adquisición, transmisión y almacenamiento de datos operativos.

Validar en campo las variables operativas del sistema de climatización, mediante visitas técnicas, revisión del sistema de sensores y entrevistas con el personal de mantenimiento del usuario.

Integrar y estructurar los datos procedentes de sensores embarcados, alarmas electrónicas y registros manuales, identificando inconsistencias y cuellos de botella en el proceso de recopilación.

Aplicar técnicas de limpieza, reducción y exploración de datos (EDA) para garantizar la calidad de la información y facilitar su análisis posterior.

Desarrollar una primera iteración de detección de anomalías del sistema de climatización mediante el entrenamiento y evaluación de un modelo LSTM Autoencoder, con el objetivo de identificar patrones operativos anómalos potencialmente asociados a fallos reales.

2 Revisión de la literatura

2.1 Industria 4.0 y el Mantenimiento

A lo largo de la historia se han desarrollado tres revoluciones industriales. En la primera, se introdujeron los equipos impulsados por vapor para la producción mecánica; en la segunda, la electricidad impulsó la producción en masa y se incorporó el concepto de división de tareas; mientras que en la tercera se añadieron la electrónica y la informática, posibilitando la producción automatizada.

En este contexto, la Industria 4.0 puede considerarse la cuarta revolución industrial. Su rasgo distintivo es el uso de sistemas ciberfísicos que permiten una industria más flexible y reconfigurable, es decir, que la estructura de una fábrica pueda adaptarse para producir distintos productos (Luna-Pérez & Vázquez-Álvarez , 2019). Las grandes fábricas incorporan en sus procesos la intercomunicación entre equipos, máquinas y líneas de producción, lo que ofrece la ventaja de contar con fábricas capaces de adaptarse a

diferentes circunstancias y mantener el máximo rendimiento (Meraz-Mendez, Lerma-Hernandez, & Corral-Ramirez, 2019).

Mantenimiento

Se entiende por mantenimiento el conjunto de acciones o técnicas que permite conservar o restablecer un equipo en un estado específico y asegurar un determinado servicio con un coste mínimo y la máxima seguridad.

Esta definición incluye varios conceptos, entre ellos:

- Conservar: entendido en el sentido de prevenir fallos.
- Restablecer: como corregir o subsanar fallos.
- Estado específico: parámetros de la máquina o sistema.
- Determinado servicio: obtener un nivel de calidad requerido.
- Coste mínimo: para asegurar máxima rentabilidad económica.
- Máxima seguridad: para el usuario, el reparador y la máquina. (Macian Martinez, Tormos Martínez, & Olmeda González , 1999).

Mantenimiento 4.0

El mantenimiento ocupa un papel central en esta cuarta revolución industrial, en la medida en que se ajusta plenamente a los principios de anticipación, eficiencia y eficacia de la “fábrica inteligente”.

Dentro de este contexto, el mantenimiento preventivo se distingue del ya conocido mantenimiento correctivo, el cual actúa únicamente cuando se ha producido una avería. Al anticipar los posibles fallos, el mantenimiento preventivo evita paradas inesperadas de la maquinaria y, con ello, las pérdidas económicas asociadas. De este modo, se asegura no solo la continuidad de la producción, sino también la estabilidad del flujo económico.

Por su parte, el mantenimiento predictivo comprende un conjunto de acciones y técnicas orientadas a detectar de manera temprana los posibles fallos o defectos en los equipos.

Entre sus principales ventajas se destacan tres:

- Planificación y programación de las acciones. Al detectar el fallo con antelación, es posible planificar las reparaciones y realizarlas en momentos programados, como paradas técnicas, evitando así pérdida de operatividad y de producción.

- Aplicación en condiciones de operación (on condition). La mayoría de las técnicas de mantenimiento predictivo se llevan a cabo con la maquinaria en pleno funcionamiento, lo que garantiza la continuidad del servicio.
- Enfoque proactivo. A diferencia del correctivo, permite prever lo que puede suceder y actuar antes de que ocurra, respetando el flujo de trabajo de la empresa y elevando la calidad del servicio. (Luna-Pérez & Vázquez-Álvarez , 2019).

Tecnologías presentes o habilitadoras

Con la llegada de nuevas tecnologías el mantenimiento ha dado pasos sustanciales en estas últimas décadas, dejando de lado la toma de datos manuales. Se han adoptado sistemas automatizados y computarizados más eficientes y confiables, técnicas de inspección predictivas y sistemas de control en tiempo real a distancia. Esto ha permitido a las empresas desarrollar planes específicos de mantenimiento a partir del análisis del flujo de datos recolectado, generando beneficios en términos de tiempo y costo. A continuación, se describen algunas de las tecnologías del mantenimiento actual, las cuales fueron usadas para el presente trabajo.

Internet de las Cosas (IoT)

El mundo está experimentando una rápida incorporación de tecnologías modernas, mientras que las empresas especializadas enfrentan una creciente demanda en el sector de las tecnologías de la información, particularmente en torno al llamado Internet de las Cosas (IoT) o Internet de los Objetos. Este concepto se basa en la integración de los objetos con el mundo digital mediante la incorporación de hardware y software que los dota de inteligencia, permitiéndoles comunicarse entre sí y participar activamente en diversos aspectos de la vida cotidiana. Con ello, surgen nuevas formas de interacción tanto entre personas y objetos como entre los propios objetos, transformando la vida tradicional en un estilo de vida más conectado y sofisticado (Mouha, 2021).

Big Data

El crecimiento en el volumen de datos generados por distintos sistemas y actividades cotidianas en la sociedad ha creado la necesidad de modificar, optimizar y desarrollar nuevos métodos y modelos de almacenamiento y procesamiento que superen las limitaciones de las bases de datos y los sistemas de gestión tradicionales. En respuesta a

ello surge el concepto de Big Data, término que engloba diversas tecnologías orientadas a la administración de grandes volúmenes de datos, provenientes de múltiples fuentes y generados a gran velocidad.

Si bien el término Big Data suele asociarse principalmente con cantidades masivas de información, esta percepción resulta incompleta. Big Data no se refiere únicamente al tamaño, sino que integra tres dimensiones clave: volumen, variedad y velocidad en el acceso y procesamiento de los datos. En la actualidad, se ha pasado de la simple transacción a la interacción, con el objetivo de aprovechar al máximo la información que se genera minuto a minuto (Hernández-Leal, Duque-Méndez, & Moreno Cadavid, 2017).

Inteligencia Artificial (IA)

Definir qué es la inteligencia artificial (IA) resulta un desafío, dado que se trata de un campo complejo y en constante evolución. En la literatura se encuentran múltiples definiciones que intentan abarcar sus diferentes dimensiones. De manera general, la IA puede entenderse como la capacidad de los ordenadores para realizar actividades que normalmente requieren inteligencia humana (Rouhiainen, 2018).

Una definición más precisa plantea que la IA es la capacidad de las máquinas para aplicar algoritmos, aprender a partir de los datos y utilizar ese aprendizaje en la toma de decisiones, de manera análoga al razonamiento humano. A diferencia de las personas, los sistemas basados en IA no requieren descanso, son capaces de analizar grandes volúmenes de información de manera simultánea y, en muchos casos, presentan una proporción de errores significativamente menor al ejecutar tareas comparables con las realizadas por los humanos.

La posibilidad de que los sistemas informáticos no solo procesen información, sino que también aprendan y tomen decisiones, constituye un aspecto central de la IA. Este atributo es particularmente relevante si se considera que sus procesos y aplicaciones están creciendo de forma exponencial con el paso del tiempo. Gracias a estas capacidades, la IA puede asumir en la actualidad múltiples tareas que anteriormente estaban reservadas únicamente a las personas.

En la práctica, las tecnologías basadas en IA ya se aplican en diversos sectores para generar beneficios significativos, incrementando la eficiencia y optimizando recursos en casi todos los ámbitos de la vida cotidiana y profesional.

Machine Learning

Machine Learning (ML) o aprendizaje automático constituye una rama de la inteligencia artificial (IA) orientada al desarrollo de algoritmos y modelos estadísticos que permiten a los sistemas informáticos mejorar su rendimiento en tareas específicas a partir de la experiencia. Este enfoque se fundamenta en la premisa de que un programa puede aprender de los datos y generar decisiones o predicciones sin necesidad de estar programado de manera explícita para cada acción.

Para alcanzar este objetivo, el aprendizaje automático emplea diversas técnicas, entre las que destacan el aprendizaje supervisado, el aprendizaje no supervisado y el aprendizaje por refuerzo, cada una con metodologías y aplicaciones particulares.

En términos prácticos, el aprendizaje automático posibilita que los sistemas informáticos extraigan patrones de grandes volúmenes de información, perfeccionen sus procesos de toma de decisiones y desarrollen capacidades inteligentes que contribuyen a optimizar distintos ámbitos de la vida cotidiana, así como múltiples procesos dentro de la industria (Mitchell, 1997)

Deep Learning

Deep Learning (DP) o aprendizaje profundo constituye un subconjunto del aprendizaje automático que se centra en el uso de redes neuronales artificiales con múltiples capas ocultas. El término profundo hace referencia precisamente al número de capas que conforman la red: mientras que una red superficial cuenta con una sola capa oculta, una red profunda incorpora varias, lo que le permite modelar relaciones más complejas entre los datos. (Shinde & Shah, 2018)

La Figura 3 muestra los antecedentes de investigación que dieron origen al aprendizaje profundo, destacando cómo este enfoque ha evolucionado a partir de desarrollos previos en el campo del aprendizaje automático.

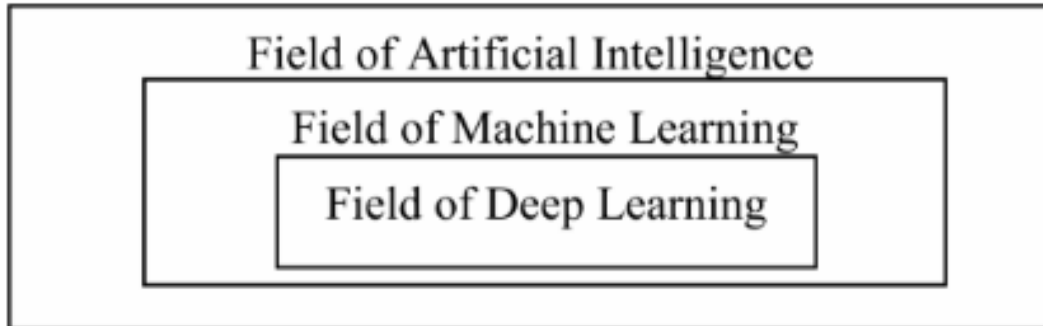


Figura 3. Campos de IA, ML y DL.

Sensores inteligentes y monitorización en tiempo real

Los sensores inteligentes y la monitorización en tiempo real constituyen tecnologías clave que están transformando la forma en que las organizaciones gestionan la confiabilidad de los productos, así como la gestión del ciclo de vida de los equipos.

Los sensores inteligentes son dispositivos capaces de recopilar información del entorno o de un sistema en tiempo real. Los datos obtenidos permiten supervisar el rendimiento, anticipar posibles fallas y respaldar la toma de decisiones en materia de mantenimiento.

Entre las principales variables que pueden registrarse se encuentran:

- Temperatura
- Presión
- Vibración
- Corriente
- Voltaje
- Humedad
- Contaminación

Por su parte, la monitorización en tiempo real consiste en el proceso de recopilación y análisis inmediato de datos, lo que posibilita detectar problemas y aplicar medidas correctivas o preventivas de forma oportuna para evitar fallas inesperadas.

La integración de sensores inteligentes y monitorización en tiempo real permite múltiples aplicaciones en el marco del RCA y el RCM, entre las que destacan:

- Predicción de fallas.
- Optimización del mantenimiento.

- Mejora de la seguridad.
- Incremento de la confiabilidad.
- Reducción de costos.
- Aumento de la eficiencia operativa.

2.2 Digitalización del Mantenimiento en el sector transporte

La adopción del gemelo digital en los sistemas de transporte ofrece un marco para integrar datos de sensores, modelos de simulación y analítica predictiva con el objetivo de mejorar las decisiones de operación y mantenimiento en tiempo real. Los gemelos digitales permiten pasar de mantenimientos programados o reactivos a estrategias basadas en condición y en pronóstico de fallo, al combinar monitorización continua, históricos de operación y modelos de comportamiento del activo; esto reduce tiempos de inactividad, alarga la vida útil de componentes y optimiza repuestos e intervenciones. (Werbińska-Wojciechowska, Giel, & Winiarska, Digital Twin Applications in Internal Transportation Systems Maintenance: A Conceptual Framework, 2024)

El concepto de eMaintenance (digitalización de capacidades de mantenimiento mediante sensores, IoT, plataformas de datos y herramientas de toma de decisiones) no sólo mejora la eficiencia técnica sino que también incorpora dimensiones de sostenibilidad (reducción de consumos y emisiones) y economía de ciclo de vida. Las capacidades clave identificadas incluyen adquisición distribuida de datos, gestión de activos basada en indicadores de salud, algoritmos de diagnóstico/predicción, interfaces para técnicos y la necesidad de arquitecturas abiertas que favorezcan interoperabilidad entre proveedores y flotas heterogéneas (Johansson, Roth, & Reim, 2019).

En casos prácticos de transición digital en empresas de transporte ferroviario se evidencia que la digitalización implica cambios organizativos y de procesos (redefinición de flujos de trabajo, formación de personal, y rediseño de roles de mantenimiento) además de la implantación tecnológica. La experiencia de casos de ferrocarril muestra que un enfoque progresivo, empezando por digitalizar datos críticos y estandarizar registros, ayuda a gestionar la complejidad y a generar rápidamente beneficios operativos que facilitan inversiones posteriores en gemelos digitales más completos. (Todorović, y otros, 2024)

Desde la perspectiva del marco de gestión de activos propuesto por la Unión Internacional de Ferrocarriles (UIC), la digitalización se presenta como un habilitador para implementar prácticas de gestión de activos a lo largo del ciclo de vida: planificación basada en riesgo,

condicionamiento de intervención, y verificación del desempeño. La literatura reciente resalta que la integración entre políticas de gestión de activos y soluciones digitales (monitorización, modelos de gemelos digitales, mantenimiento predictivo) es clave para garantizar conformidad normativa, priorización de intervenciones y mejora continua en redes ferroviarias (Rodríguez-Hernández, Crespo-Márquez, Sánchez-Herguedas, & González-Prida, 2025).

Para cumplir requisitos regulatorios específicos del sector ferroviario (por ejemplo, marcos europeos de certificación y seguridad), la construcción de gemelos digitales destinados al mantenimiento debe contemplar: trazabilidad de datos, verificación de modelos, sincronización segura entre físico y virtual y evidencias que permitan auditar procedimientos. Un caso de aplicación muestra una arquitectura de gemelo que integra adquisición de datos, procesamiento, analítica predictiva y módulos de apoyo a la certificación, esto enfatiza que la digitalización técnica debe ir acompañada de gobernanza documental y criterios de conformidad (Guillén-López, Sanchez-Herguedas, & Rodríguez, 2024).

A pesar de los avances logrados, la digitalización del mantenimiento en el sector transporte aún enfrenta retos significativos. Entre los principales se encuentran la gestión y calidad de los datos provenientes de múltiples fuentes, la interoperabilidad entre plataformas de distintos fabricantes, y la complejidad computacional que implican los modelos de gemelo digital de alta fidelidad. Además, surgen preocupaciones crecientes en torno a la ciberseguridad de los sistemas conectados y a la necesidad de desarrollar nuevas competencias digitales en el personal de mantenimiento. La literatura reciente sugiere que superar estas barreras requiere el diseño de arquitecturas digitales modulares, el establecimiento de protocolos estandarizados de intercambio de datos, la selección de casos de uso con alto retorno operativo y la implementación de programas de capacitación específicos para los distintos niveles organizativos (Werbińska-Wojciechowska, Giel, & Winiarska, Digital Twin Approach for Operation and Maintenance of Transportation System—Systematic Review, 2024).

2.3 Machine Learning y Deep Learning en el mantenimiento vehicular

En los últimos años, la digitalización del mantenimiento vehicular ha experimentado un notable avance gracias a la incorporación de técnicas de Machine Learning (ML) y Deep

Learning (DL), las cuales permiten procesar grandes volúmenes de datos provenientes de sensores, registros históricos y sistemas telemáticos para anticipar fallos y optimizar las estrategias de intervención. Estas herramientas han transformado el paradigma tradicional de mantenimiento correctivo o preventivo hacia un enfoque predictivo y prescriptivo, en el que las decisiones se sustentan en modelos de aprendizaje automático capaces de identificar patrones de degradación, estimar la vida útil remanente de los componentes (Remaining Useful Life, RUL) y clasificar condiciones de operación anómalas en tiempo real.

Diversas investigaciones recientes han abordado esta temática desde diferentes perspectivas metodológicas, aplicando tanto algoritmos supervisados (como árboles de decisión, máquinas de soporte vectorial y redes neuronales) como enfoques no supervisados y modelos híbridos de aprendizaje profundo. Estos estudios buscan no sólo predecir fallos o anomalías, sino también desarrollar modelos interpretables y escalables que puedan integrarse en plataformas de gestión de flotas, contribuyendo a la reducción de costes operativos, aumento de la seguridad y mejora de la disponibilidad de los vehículos.

El análisis de la literatura especializada permite observar que las métricas de desempeño más empleadas incluyen medidas de regresión (R^2 , MAE, RMSE) para estimaciones continuas y métricas de clasificación (accuracy, precision, recall, F1-score y matrices de confusión) para detección de estados de fallo. Asimismo, los autores destacan que el rendimiento de los modelos depende en gran medida de la calidad, cantidad y balance de los datos, así como del entorno de operación y la capacidad computacional disponible.

En la Tabla 2 se presenta una síntesis de los estudios más representativos publicados entre 2019 y 2025 sobre el uso de técnicas de ML y DL en el mantenimiento vehicular. Cada estudio se resume en función de su metodología, variable objetivo, métricas de evaluación, ventajas y limitaciones, con el propósito de identificar tendencias, brechas y oportunidades de investigación futuras en este campo.

Tabla 2. Uso de Machine Learning y Deep Learning en el mantenimiento vehicular

Uso de Machine Learning y Deep Learning en el mantenimiento vehicular						
Nº	Fuente	Descripción del estudio y método	Variable / Predicción	Métricas utilizadas	Ventajas señaladas	Limitaciones señaladas
1	Machine Learning Applications in Predictive Maintenance for Vehicles: Case Studies	Revisión de casos de ML aplicados a mantenimiento predictivo en vehículos. Métodos: árboles de decisión, SVM, redes neuronales y enfoques híbridos.	Clasificación de estados de salud, detección de anomalías, predicción de fallos.	Accuracy, F1, AUC, MAE, RMSE, R ² .	Mejora en disponibilidad de flotas, reducción de costes y fallos no planificados.	Dificultad de comparar resultados por falta de datasets públicos; desbalance de clases.
2	An integrated deep learning approach for predictive vehicle maintenance	Modelo integrado de Deep Learning + clustering no supervisado para datos vehiculares sin etiquetas.	Predicción de fallos incipientes y agrupación de patrones operativos.	Accuracy, Precision, Recall, F1, RMSE.	Permite usar grandes volúmenes de telemetría sin etiquetado manual.	Sensibilidad del clustering a selección de características y necesidad de validación humana.
3	An integrated deep learning-based approach for automobile maintenance prediction with GIS data	Modelo de deep learning multimodal que integra telemetría, mantenimiento histórico y datos GIS.	Remaining Useful Life (RUL) de vehículos.	MAE, RMSE, R ² .	Mejor precisión al incluir variables ambientales; integración de fuentes diversas.	Requiere datos GIS de calidad y series temporales extensas.
4	Predictive Vehicle Maintenance using Deep Neural Networks	Prototipo de red neuronal profunda (CNN/LSTM) para clasificación de fallos en telemetría vehicular en tiempo real.	Clasificación de modos de fallo (normal, desgaste, falla inminente).	Matriz de confusión, Accuracy, Precision, Recall, F1.	Alta precisión en clases frecuentes y capacidad de alertas tempranas.	Desbalance de clases y posible sobreajuste con series cortas.
5	Automobile Maintenance Prediction Using Deep Learning with GIS Data	Comparación entre modelos estadísticos tradicionales y Deep Learning con datos GIS.	Tiempo entre fallos (TBF) y comportamiento de fallos.	MAE, RMSE.	Mayor precisión en predicción de RUL/TBF con datos heterogéneos.	Necesidad de gran volumen de datos y preprocesado costoso.

6	Methodology for Commercial Vehicle Mechanical Systems Maintenance: Data-Driven and Deep-Learning-Based Prediction	Metodología de predicción data-driven para mantenimiento de sistemas mecánicos en vehículos comerciales; uso de DL y pipelines de datos.	Fallos mecánicos específicos (transmisión, frenos, etc.).	R^2 , MAE, Accuracy, F1.	Enfoque integral reproducible, buena escalabilidad.	Dependencia de etiquetas ruidosas, costo computacional y gobernanza de datos.
7	Vehicle maintenance management based on machine learning in agricultural tractor engines	Clasificación de estados del motor en tractores agrícolas mediante ML. Métodos: SVM y redes neuronales con señales de vibración.	Estado de motor (normal / 3 fallos simulados).	Accuracy, Matriz de confusión.	Bajo costo de implementación, detección temprana de fallos.	Resultados limitados a fallos simulados; requiere validación en condiciones reales.

2.4 LSTM Autoencoders para detección de anomalías

2.4.1 Conceptos

Autoencoders

Un autoencoder o autocodificador es un tipo específico de red neuronal diseñado principalmente para codificar la entrada en una representación comprimida y significativa, y posteriormente decodificarla de nuevo, de modo que la salida reconstruida sea lo más similar posible a la entrada original (Bank, Koenigstein, & Giryas, 2023).

El objetivo principal de este modelo es aprender, de manera no supervisada, una representación informativa de los datos, la cual puede emplearse en diferentes aplicaciones, como la agrupación en clústeres.

Formalmente, el problema consiste en aprender las funciones:

- $A: R^n \rightarrow R^p$ (codificador) y
- $B: R^p \rightarrow R^n$ (decodificador)

que minimicen la función de distorsión global, expresada en la Ecuación 1:

Ecuación 1

$$\min E(A, B) = \min_{A, B} \sum E(x_t) = \min_{A, B} \sum \Delta(A \circ B(x_t), x_t)$$

donde E representa la expectativa sobre la distribución de x y Δ es la función de pérdida de reconstrucción, la cual mide la distancia entre la salida del decodificador y la entrada original (Baldi, 2012).

La Figura 4 ilustra un modelo de autocodificador: la imagen de entrada se transforma en una representación comprimida mediante el codificador, y posteriormente se reconstruye a través del decodificador (Bank, Koenigstein, & Giryes, 2023).




Figura 4. Ejemplo de autocodificador.

Algoritmos LSTM

Una red de memoria a corto y largo plazo (Long Short-Term Memory, LSTM) constituye un tipo de red neuronal recurrente (Recurrent Neural Network, RNN) diseñada para el aprendizaje y procesamiento de datos secuenciales, permitiendo identificar dependencias de largo alcance en series temporales.

Las LSTM representan una extensión especializada de las RNN. Estas últimas emplean información previa para mejorar el procesamiento de entradas actuales y futuras, gracias a la incorporación de un estado oculto y conexiones recurrentes que permiten almacenar información pasada. En su estructura, las RNN disponen de dos conjuntos de pesos: uno asociado al vector del estado oculto y otro a las entradas. Durante la fase de entrenamiento, la red ajusta ambos conjuntos de pesos; al implementarse, la salida se calcula en función tanto de la entrada actual como del estado oculto, el cual a su vez incorpora información proveniente de entradas anteriores.

No obstante, las RNN simples presentan limitaciones en el aprendizaje de dependencias a largo plazo. Esto ocurre porque, durante el entrenamiento, la red puede perder información importante o amplificarla en exceso, lo que compromete su capacidad para capturar relaciones de larga duración.

En la Figura 5 se muestra el flujo de datos en la unidad de tiempo t para una RNN tradicional, donde X_t corresponde a la entrada, Y_t a la salida y h_t al estado oculto (MathWorks, 2025).

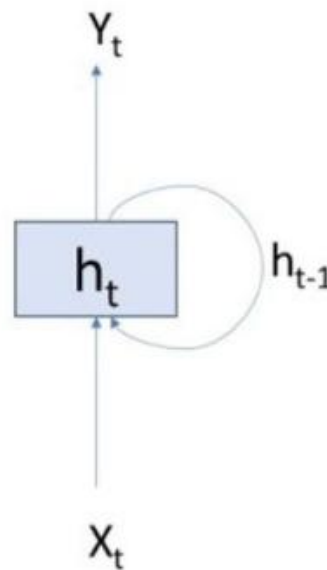


Figura 5. Flujo de datos en la unidad de tiempo t para una RNN tradicional.

2.4.2 Casos de aplicación

En los sistemas modernos de transporte público, la detección temprana de anomalías en los autobuses es esencial para garantizar la seguridad, reducir costos de mantenimiento y mejorar la confiabilidad operativa. En este contexto, los modelos basados en Long Short-Term Memory (LSTM) Autoencoders han demostrado una alta capacidad para identificar comportamientos anómalos en series temporales de datos provenientes de sensores vehiculares. Estos modelos permiten aprender patrones normales de funcionamiento y detectar desviaciones sin requerir información explícita sobre fallas. A continuación, se presentan distintos casos de aplicación de LSTM Autoencoders en el ámbito del transporte inteligente y, particularmente, en vehículos como autobuses y sistemas afines.

En “Anomaly Detection of the Brake Operating Unit on Metro Vehicles Using a One-Class LSTM Autoencoder” se propone un enfoque basado en un LSTM autoencoder entrenado únicamente con datos normales (one-class) para detectar anomalías en la

unidad de freno (Brake Operating Unit, BOU) en trenes de metro. El modelo procesa subsecuencias de presión del cilindro de freno (BC pressure) y calcula el error de reconstrucción (MAE) para decidir anomalías, usando un umbral basado en el máximo error observado durante el entrenamiento. En los experimentos con datos reales del sistema de control de trenes de Corea, el enfoque demostró ser eficaz para detectar anomalías tempranas de liberación de presión retardada (Kang, Kim, Kang, & Gwak, 2021).

El artículo “A Fault Detection Framework Based on LSTM Autoencoder: A Case Study for Volvo Bus Data Set” aborda una aplicación directa en autobuses: los autores desarrollan un marco de detección de fallas basado en un LSTM autoencoder aplicado al conjunto de datos de buses Volvo. En su propuesta, se monitorizan múltiples señales de telemetría del vehículo (sensores motrices, temperatura, velocidad, presión, entre otros), se segmentan las series temporales, y se entrenan autoencoders para reconstrucción de secuencias normales. La desviación entre la señal original y la reconstrucción sirve como score de anomalía (o puntaje de anomalía), permitiendo identificar eventos de falla en los buses (Davari, y otros, 2022).

En “Novel Deep Learning-Enabled LSTM Autoencoder Architecture for Discovering Anomalous Events From Intelligent Transportation Systems” se aplica un LSTM autoencoder para detección de anomalías en redes vehiculares (por ejemplo, bus CAN), como parte de sistemas de transporte inteligente. El modelo procesa secuencias de mensajes del bus interno en múltiples dimensiones y adopta una arquitectura multi-tarea LSTM para capturar anomalías tanto temporales como en el contenido de los datos. En experimentos reportados, se alcanzó una precisión de detección alrededor del 90 % sobre datos simulados o reales del sistema ITS (Intelligent Transportation Systems o, Sistemas de Transporte Inteligentes) (Ashraf, y otros, 2021).

El trabajo “An Anomaly Detection Method Based on Multiple LSTM-Autoencoder Models for In-Vehicle Network” estudia el caso de redes internas del vehículo (bus interno como CAN). Los autores proponen usar múltiples modelos LSTM autoencoders, cada uno especializado en diferentes subconjuntos de señales o contextos de funcionamiento (por ejemplo, por tipo de mensaje o por rango temporal), con el fin de mejorar la sensibilidad y reducir falsos positivos. La reconstrucción de cada secuencia permite cuantificar el error de anomalía y fusionarlo para decidir alertas. Se demuestra

que este esquema modular mejora la precisión frente a un único modelo monolítico (Kim, Kim, & You, 2023).

Finalmente, en “Deep Learning-Based Anomaly Detection for Connected Autonomous Vehicles Using Spatiotemporal Information” se presenta un enfoque híbrido que combina LSTM autoencoders con procesamiento espacio-temporal para detectar anomalías en vehículos conectados. En el contexto del bus CAN se incorpora información espacial de los identificadores de mensajes y relaciones entre señales para reforzar la detección. Los autores reportan mejoras en métricas de precisión y reducción de falsos positivos frente a modelos puramente temporales (Mansourian, Zhang, Jaekel, & Kneppers, 2023).

3 Metodología

En el marco del mantenimiento predictivo, orientado a la detección de posibles fallos o defectos en la flota de autobuses de la Empresa Municipal de Transporte (EMT) de Valencia durante su operación, se propone una metodología para el aprovechamiento de datos, desde las etapas iniciales de identificación del problema hasta el modelado.

3.1 Problemática de estudio

El sistema de climatización los autobuses de la EMT de Valencia, principalmente relacionado al aire acondicionado, presenta fallos que, en condiciones extremas pueden interrumpir su funcionamiento durante el servicio.

Dado que estos vehículos operan en la ciudad de Valencia, donde durante la temporada de verano y en días cercanos se registran temperaturas elevadas, el sistema de aire acondicionado se ve sometido a condiciones ambientales severas. En este contexto, su correcto funcionamiento resulta fundamental para garantizar niveles mínimos de confort tanto a los usuarios como a los conductores.

Una deficiencia en este servicio puede generar reclamos por parte de los pasajeros y afectar negativamente la imagen de la empresa operadora. En situaciones críticas, un fallo total del sistema durante el servicio podría obligar a retirar el vehículo de operación, provocando demoras significativas para los usuarios y obligando al personal de la empresa a realizar una reprogramación de emergencia.

Por lo tanto, considerando que actualmente el sistema de aire acondicionado presenta fallos que pueden interrumpir su funcionamiento durante la operación, el presente trabajo

se enfocará en metodologías y análisis orientados a iniciar el camino hacia su solución mediante el uso de datos operativos.

3.1.1 Población y período de estudio

La población de estudio para el análisis de anomalías en el sistema de climatización, específicamente en el subsistema de aire acondicionado, corresponde a la flota de autobuses de la EMT de Valencia, modelo Mercedes Benz Citaro Hybrid de 12 metros de longitud. Este modelo representa un total de 164 unidades dentro de la flota de transporte. El período de análisis abarca desde finales de junio de 2024 hasta mediados de febrero de 2025. En la Figura 6 se muestra un ejemplo del vehículo objeto de estudio.



Figura 6. Vehículo Mercedes Benz Citaro Hibrid de EMT.

3.1.2 Conceptos del Sistema de Aire Acondicionado

La transferencia de calor desde un medio a baja temperatura hacia otro a mayor temperatura requiere el uso de dispositivos llamados refrigeradores.

Al igual que las bombas de calor, los refrigeradores son dispositivos de funcionamiento cíclico. El fluido de trabajo utilizado en el ciclo de refrigeración se denomina refrigerante. El ciclo de refrigeración que se utiliza con mayor frecuencia es el ciclo de refrigeración por compresión por vapor, en el que intervienen cuatro componentes principales: un compresor, un condensador, una válvula de expansión y un evaporador. El ciclo ideal de

refrigeración por compresión de vapor se muestra de manera esquemática y en un diagrama T-s en la Figura 7; dicho ciclo se compone de cuatro procesos:

- 1-2 Compresión isentrópica en un compresor
- 2-3 Intercambio de calor a presión constante en un condensador
- 3-4 Estrangulamiento en un dispositivo de expansión
- 4-1 Absorción de calor a presión constante en un evaporador

En un ciclo ideal de refrigeración por compresión de vapor, el refrigerante entra al compresor en el estado 1 como vapor saturado y se comprime isentrópicamente hasta la presión del condensador. La temperatura del refrigerante aumenta durante el proceso de compresión isentrópica, hasta un valor bastante superior al de la temperatura del medio circundante. Después el refrigerante entra en el condensador como vapor sobrecalentado en el estado 2 y sale como líquido saturado en el estado 3, como resultado del intercambio de calor hacia los alrededores. La temperatura del refrigerante en este estado se mantendrá por encima de la temperatura de los alrededores.




Figura 7. Esquema de ciclo ideal de refrigeración por compresión de vapor y diagrama T-s.

El refrigerante líquido saturado en el estado 3 se estrangula hasta la presión del evaporador al pasarlo por una válvula de expansión o por un tubo capilar. La temperatura del refrigerante desciende por debajo de la temperatura del espacio refrigerado durante este proceso. El refrigerante entra al evaporador en el estado 4 como un vapor húmedo de baja calidad, y se evapora por completo absorbiendo calor del espacio refrigerado. El

refrigerante sale del evaporador como vapor saturado y vuelve a entrar al compresor, completando el ciclo. (Cengel & Boles, 2012)

3.1.3 Aspectos constructivos del aire acondicionado

El sistema de climatización de los vehículos de la flota de la EMT de Valencia se encarga de aclimatar tanto a la zona de pasajeros como el compartimento del conductor. Como se mencionó anteriormente, este trabajo se centrará en lo relacionado al sistema de aire acondicionado únicamente.

Tanto el puesto del conductor como el compartimento de pasajeros se ventilan por separado. La aspiración del aire exterior se efectúa a través de filtros, con conmutación temporizada a servicio de recirculación de aire (en caso de polución exterior).

Características del equipo:

- Líquido de refrigerante: R134a
- Compresor Bock FK 40

A continuación, en la Figura 8 se observa los componentes principales del sistema de aire acondicionado y el recorrido completo del agente frigorígeno.




Figura 8. Componentes principales del sistema de aire acondicionado.

Referencias de la figura:

1. Condensador
2. Ventilador del condensador
3. Aire del exterior / filtro de recirculación de aire
4. Unidad evaporador-intercambiador de calor

5. Ventilador del evaporador
6. Válvula de expansión
7. Deshidratador
8. Interruptor de presión de los ventiladores del condensador (medio / pleno)
9. Válvula de cierre para trabajos de mantenimiento
10. Empalme para trabajos de mantenimiento
11. Mirilla de agente frigorígeno
12. Válvula Pulldown
13. Colector de agente frigorígeno
14. Desagüe del agua generada por la condensación
15. Compresor de agente frigorígeno
 15. 1 Acoplamiento electromagnético
 15. 2 Mirilla de aceite para máquinas frigoríficas
 15. 3 Tornillo de vaciado de aceite para máquinas frigoríficas
 15. 4 Válvula de cierre para trabajos de mantenimiento de alta presión (HD)
 15. 5 Válvula de cierre para trabajos de mantenimiento de baja presión (ND)
16. Interruptor de alta presión
17. Interruptor de baja presión
18. Evaporador del armario delantero
 18. 1 Ventilador del evaporador del armario delantero
 18. 2 Válvula de expansión del armario delantero
 - A. Baja presión gaseiforme
 - B. Alta presión gaseiforme
 - C. Alta presión líquido
 - D. Agua generada por la condensación

Por otro lado, otro aspecto importante a mencionar dentro de los aspectos constructivos dentro del sistema de climatización son los conductos de aire, a continuación, se observa un esquema en Figura 9.




Figura 9. Conductos de aire del sistema de climatización.

Referencias de la figura:

- a. Aire fresco
- b. Aire calentado
- c. Aire fresco/aire de recirculación, refrigerado o calentado
- d. Recirculación de aire
- e. Aire de escape

3.2 Recopilación de datos e infraestructura disponible

La adquisición de datos se lleva a cabo mediante los sistemas OBDII (On-Board Diagnostics o Diagnóstico a Bordo) de los vehículos y las herramientas de diagnóstico telemático integradas en toda la flota. Estos sistemas electrónicos monitorizan y registran de forma continua una amplia gama de variables provenientes de múltiples ECU (motor, postratamiento, climatización, entre otras).

En el caso específico del sistema de climatización, se dispone de 28 variables, obtenidas a partir de las lecturas de distintos sensores. Entre ellas se incluyen parámetros

relacionados con las temperaturas (sensores y valores de consigna), la posición de las compuertas de circulación de aire, el tiempo de servicio de sopladores y compresor, el número de revoluciones de los sopladores, la presión del líquido refrigerante, los modos de funcionamiento, entre otras.

La infraestructura telemática y de almacenamiento, proporcionada por un proveedor de tecnología externo, permite la descarga de datos en formato XLSX para su posterior procesamiento y análisis, donde la extracción de datos en este estudio fue realizada manualmente. El conjunto de datos se procesó con Python (Jupyter Notebook versión 7.3.2), empleando bibliotecas estándar como pandas, matplotlib y scikit-learn. Una limitación clave del conjunto de datos es su frecuencia de muestreo baja, de 50 minutos en promedio que, si bien es adecuada para la monitorización operativa general, puede dificultar la granularidad y precisión de ciertas visualizaciones y análisis posteriores. Esta limitación se debe a la propia electrónica de a bordo del vehículo (sistema OBDII), ya que su diseño operativo impone un límite en el número de solicitudes que se pueden realizar por unidad de tiempo. Además, no permite la recuperación simultánea de datos de diferentes ECU, lo que restringe aún más la resolución y la sincronización de las señales recopiladas (Tormos, Bermudez, Sánchez-Márquez, & Alvis, 2025).

3.2.1 Fuentes de datos

Para la realización del presente trabajo se utilizaron cuatro fuentes de información relacionadas con el sistema de aire acondicionado de la flota de autobuses. Tres de ellas provienen de una plataforma online de un proveedor externo y la restante corresponde a los registros de operaciones de mantenimiento de la EMT. A continuación, se detallan los registros considerados, agrupados según su fuente de origen:

- Proveedor externo
 - Diagnósis
 1. Estado del vehículo
 2. Histórico de diagnóstico
 - Alarmas
 3. Histórico
- Empresa Municipal de Transporte (EMT)
 4. Registro de Mantenimiento EMT

A continuación, y organizados según su fuente de origen, se presentará la descripción de cada uno de los registros, junto con su estructura y las limitaciones actuales que presentan.

3.2.1.1 *Proveedor externo*

3.2.1.1.1 Descripción

A través de un proveedor externo es posible extraer datos reales de los vehículos y de sus unidades de control de forma remota y en tiempo real, lo que otorga al usuario una capacidad excepcional para la gestión de la flota. Esto permite conocer el estado actual del vehículo en todo momento y, en caso de presentarse una anomalía, acceder al sistema de alarmas generado a partir de las lecturas de los sensores embarcados.

3.2.1.1.2 Estructura

Como se indicó anteriormente, a través del proveedor externo se accede a tres de las cuatro fuentes de información, las cuales provienen de la diagnosis y de los informes de alarmas generados por la propia plataforma online. Estas son:

- Diagnósis
 1. Estado del vehículo
 2. Histórico de diagnóstico
- Alarmas
 3. Histórico

Estado del Vehículo

El “Estado del Vehículo” corresponde al registro de 28 variables del sistema de climatización, obtenidas a partir de las lecturas de diferentes sensores. Entre ellas se incluyen variables asociadas a temperaturas (sensores y *setpoints*), posición de las compuertas de circulación de aire, tiempo de servicio de sopladores y compresor, número de revoluciones de los sopladores, presión del líquido refrigerante, modos de funcionamiento, entre otras.

En la Tabla 3, de manera simplificada, se presenta un ejemplo de este registro. Allí se consignan la matrícula o número de identificación del vehículo de la flota, la fecha de registro (día y hora) y, posteriormente, se enumeran del 1 al 28 las variables correspondientes, acompañadas de su respectivo valor (numérico o de tipo texto).

Un aspecto relevante es la frecuencia de muestreo, es decir, el intervalo de tiempo entre registros, que en promedio es cercano a los 50 minutos, tal como se indicó anteriormente.

Esto permite analizar, mediante la evolución temporal de cada variable, el comportamiento del sistema de climatización de los vehículos de la flota de transporte.

Tabla 3. Registro de Estado del Vehículo

Estado del Vehículo																													
Matrícula	Fecha	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28
6401	28/06/2024 05:38:06	18	50	50	100	65	65	65	65	30	53	53	51	30	30	13	ACTIVADO	DESACTIVADO	ACTIVADO	74	21	15619	13670	6149	5733	24	7	19	
6401	28/06/2024 06:21:18	9	50	50	100	65	65	65	65	30	52	52	50	60	60	15	ACTIVADO	DESACTIVADO	ACTIVADO	77	21					23	8	14	
6401	28/06/2024 07:27:59	4	50	50	100	65	65	65	65	30	52	52	50	34	34	15	ACTIVADO	DESACTIVADO	ACTIVADO	77	21					23	8	11	
6401	28/06/2024 08:21:18	11	50	50	100	65	65	65	65	30	52	52	50	50	42	42	15	ACTIVADO	DESACTIVADO	ACTIVADO	77	21				23	7	10	
6401	28/06/2024 09:27:59	4	50	50	100	65	65	65	65	30	53	53	51	41	41	15	ACTIVADO	DESACTIVADO	ACTIVADO	76	21					24	6	11	
6401	28/06/2024 10:21:18	8	50	50	100	65	65	65	65	30	54	54	52	41	41	15	ACTIVADO	DESACTIVADO	ACTIVADO	76	21					25	6	11	
6401	28/06/2024 11:27:58	4	50	50	100	0	0	0	0	40	61	61	52	31	31	14	ACTIVADO	DESACTIVADO	ACTIVADO	77	19					26	4	10	
6401	28/06/2024 12:21:17	6	50	50	100	0	0	0	0	40	61	61	53	35	35	14	ACTIVADO	DESACTIVADO	ACTIVADO	76	19					27	4	11	
6401	28/06/2024 13:27:58	5	50	50	100	0	0	0	0	40	69	69	54	54	48	15	ACTIVADO	DESACTIVADO	ACTIVADO	76	19					28	4	12	

Finalmente, a continuación, se presenta la numeración de referencia de dichas variables:

1. Temperatura del evaporizador (parte trasera, techo) (°C)
2. Posición de la compuerta de circulación de aire, parabrisas, valor nominal (%)
3. Posición de la compuerta de circulación de aire, zona reposapiés, valor nominal (%)
4. Posición de la compuerta de circulación de aire, aire exterior/aire recirculante, valor nominal (%)
5. Posición de la compuerta de circulación de aire (parte delantera, techo, derecha), valor nominal (%)
6. Posición de la compuerta de circulación de aire (parte delantera, techo, izquierda), valor nominal (%)
7. Posición de la compuerta de circulación de aire (parte trasera, techo, derecha), valor nominal (%)
8. Posición de la compuerta de circulación de aire (parte trasera, techo, izquierda), valor nominal (%)
9. Número de revoluciones del soplador, área del conductor (valor nominal) (%)
10. Número de revoluciones del soplador (parte delantera, techo, delante), valor nominal (%)
11. Número de revoluciones del soplador (parte delantera, techo, detrás), valor nominal (%)

12. Número de revoluciones del soplador (parte trasera, techo, detrás), valor nominal (%)
13. Número de revoluciones del soplador (parte trasera, techo, delante), valor nominal (%)
14. Número de revoluciones del soplador, soplador del condensador (parte delantera), valor nominal (%)
15. Número de revoluciones del soplador, soplador del condensador (parte trasera), valor nominal (%)
16. Circuito de agente frigorígeno (parte trasera), presión (bar)
17. Modo "refrigeración"
18. Modo descongelación
19. Función ahorro de energía
20. Temperatura del líquido refrigerante (°C)
21. Temperatura nominal (zona de pasajeros) (°C)
22. Sopladores (lado del conductor), tiempo de servicio (h)
23. Sopladores (techo), tiempo de servicio (h)
24. Sopladores (condensador), tiempo de servicio (h)
25. Compresor, tiempo de servicio (h)
26. Temperatura externa (°C)
27. Temperatura de salida del aire (parte trasera - techo), valor nominal (°C)
28. Temperatura de salida del aire (parte trasera - techo) (°C)

Historial de Diagnóstico

Por su parte, el “historial de diagnóstico” representa la acumulación de reportes generados por la ECU del vehículo, los cuales registran de manera sistemática los fallos detectados en sus distintos sistemas. Cada registro incluye el número de vehículo, la fecha de lectura, el tipo de sistema (climatización en este caso), así como el código y la descripción del fallo. En la Tabla 4 se presenta un ejemplo de dicho historial y, luego en Anexos, se presenta una versión completa de los códigos de error y su descripción.

Tabla 4. Histórico de Diagnosis.

Histórico de Diagnosis				
Numero Vehículo	Fecha Lectura	Tipo Sistema	Código Error	Descripción
6404	10/12/2024 7:20 PM	Climatización	95F0F5	Agente frigorígeno. Circuito. Presión baja inaceptable.
6404	10/12/2024 8:27 PM	Climatización	95F0F5	Agente frigorígeno. Circuito. Presión baja inaceptable.
6404	11/22/2024 11:55 AM	Climatización	60F0F3	Unidad de control Multiplexor 1 (MUX1). El mensaje CAN falta o es incorrecto.
6404	11/22/2024 11:55 AM	Climatización	85F0F3	Unidad de control de instrumentación. El mensaje CAN falta o es incorrecto.
6404	11/22/2024 11:55 AM	Climatización	63F0F3	Función de detección de día/noche de la unidad de control de la instrumentación. El mensaje CAN falta o es incorrecto.
6404	11/22/2024 11:55 AM	Climatización	9FF0F3	Bus CAN del habitáculo. Error de comunicación.
6404	11/22/2024 11:55 AM	Climatización	9EF0F3	Bus CAN del habitáculo. Error de comunicación.

Histórico de alarmas

Finalmente, en “Histórico de alarmas” se accede a las alertas generadas desde la ECU, específicamente al momento en que se originan y procesan (en este caso, referido al sistema de climatización. En la Tabla 5 se muestra un ejemplo de este registro correspondiente al vehículo número 6401.

Tabla 5. Registros de Historial de Alarmas.

Historial de Alarmas				
Tipo	Nombre	Vehículo/ Conductor	Fecha de disparo	Fecha de procesamiento
Alarma por diagnosis remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	22/10/2024 14:20:53	23/10/2024 07:04:53
Alarma por diagnosis remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	24/10/2024 17:24:57	25/10/2024 09:15:08
Alarma por diagnosis remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	25/10/2024 19:26:30	28/10/2024 07:50:55
Alarma por diagnosis remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	01/11/2024 03:43:09	04/11/2024 07:33:06
Alarma por diagnosis remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	04/11/2024 07:32:39	06/11/2024 08:55:27

Alarma por diagnóstico remota	Alarma por errores en el sistema Climatización - Mercedes E6 HIB - S54	6401	06/11/2024 11:27:23	07/11/2024 08:33:54
-------------------------------	---	------	------------------------	------------------------

Vinculando los últimos dos registros mencionados, puede señalarse que el Histórico de alarmas consigna las fechas de disparo y de procesamiento de una alarma en un vehículo en particular, mientras que el Historial de diagnóstico registra los códigos de error y su correspondiente descripción.

3.2.1.1.3 Limitaciones actuales

Dentro de las limitaciones identificadas en las fuentes de información, se pueden mencionar las siguientes, según cada caso:

- Estado del vehículo (Diagnosis):
 - Como se indicó previamente, este registro presenta una frecuencia de muestreo muy baja. Esto genera una pérdida de información crítica de las señales, lo que afecta directamente la capacidad de detectar fallas incipientes y dificulta el análisis del comportamiento transitorio de las variables.
- Histórico de diagnóstico (Diagnosis):
 - Obtención de datos: La adquisición de estos registros fue limitada, por lo que fue necesario solicitar apoyo al personal de la EMT para su obtención. La plataforma permite descargar solo una fracción de los registros existentes, ya que al visualizar la base completa, se evidencia que el volumen total de datos es muy superior al que es posible extraer.
 - Calidad de la información: Si bien se obtuvieron los códigos de error, sus descripciones asociadas son escasas y poco detalladas, lo que dificulta significativamente identificar la causa raíz de los problemas.
- Historial de Alarmas
 - Aunque este registro documenta el momento exacto en que se genera una alerta, carece de información sobre la causa que la originó, lo que limita su interpretación y utilidad para el análisis.
 - Otro punto crítico es la falta de claridad respecto a la "fecha de procesamiento". No existe información documentada sobre cómo opera este campo, cómo se origina su registro o qué acciones concretas se llevan a cabo para dar por "procesada" una alarma.

Un desafío importante es la falta general de documentación sobre el funcionamiento y la metodología de generación de los registros del Historial de Diagnóstico y el Historial de Alarmas. Tampoco se cuenta con información que explique cómo estos dos sistemas interactúan entre sí para proporcionar una visión integral de los fallos en el sistema de climatización. Actualmente, la información se obtiene de forma separada; por un lado, las fechas de disparo de las alarmas y, por el otro, los códigos de error, sin una guía clara para su correlación e interpretación conjunta.

3.2.1.2 Empresa Municipal de Transporte (EMT)

3.2.1.2.1 Descripción

A través del vínculo estratégico entre la entidad CMT – Clean Mobility & Thermofluids y la EMT de Valencia, se obtuvo acceso a los registros de las operaciones de mantenimiento realizadas por la empresa. Estos registros constituyen una fuente de información relevante, ya que fueron elaborados por personal especializado de la propia organización. En ellos se incluyen los datos aportados por los conductores de los vehículos, la información registrada en el sistema de gestión interno y las intervenciones efectuadas en el taller de mantenimiento relacionadas con el aire acondicionado de los autobuses. Este conjunto de datos recibe el nombre de “Registro de Mantenimiento EMT”.

3.2.1.2.2 Estructura

Como se mencionó anteriormente, estos registros son elaborados por el personal de la EMT. En primer lugar, los conductores, al detectar alguna anomalía, la registran en el sistema de gestión junto con una breve descripción del síntoma. Posteriormente, el personal de mantenimiento revisa dicho reporte y evalúa si corresponde o no generar una solicitud de trabajo, asignándole un número y una fecha de registro.

A continuación, el sistema de gestión emite una orden de trabajo, también con su respectiva numeración y fecha de creación. Finalmente, en el taller de reparaciones se ejecutan las órdenes de trabajo y, tras su realización, se registran la fecha de operación (ejecución), la tarea realizada o acción aplicada, así como la pieza o repuesto intervenido en el autobús correspondiente.

En la Tabla 6 se presenta, de forma simplificada, un ejemplo de este tipo de registro con lo antes mencionado.

Tabla 6. Registro de Mantenimiento EMT.

Registro de Mantenimiento EMT								
Matrícula	Núm. Solicitud	Fecha Solicitud	Síntoma	Núm. Orden	Fecha Orden	Fecha Operación	Acción	Pieza
6401	2348059	22/10/2024 18:16:00	Aire Acond. No funciona.	634961	22/10/2024 22:09:00	23/10/2024 04:01:00	Diagnosis Simple	(Circuito Anterior) Aire Acond.
6401	2350199	24/10/2024 16:43:00	Aire Acond. No funciona.	635151	24/10/2024 16:43:00	25/10/2024 03:47:00	Comprobar	(Circuito Anterior) Aire Acond.
6401	2354758	03/11/2024 07:54:00	Aire Acond. no enfría	635877	03/11/2024 07:54:00	04/11/2024 04:34:00	Diagnosis Simple	(Circuito Anterior) Aire Acond.
6403	2304949	22/08/2024 11:33:00	Aire Acond. no enfría	628411	22/08/2024 11:33:00	23/08/2024 05:49:00	Comprobar. No funciona	(Circuito Anterior) Aire Acond.
6405	2345072	20/10/2024 18:11:00	Aire Acond. gotea	634698	20/10/2024 22:23:00	21/10/2024 02:29:00	Diagnosis Simple	(Circuito Anterior) Aire Acond.
6411	2369839	21/11/2024 18:42:00	Mando selec. temp aa-calef. No funciona.	637983	21/11/2024 23:40:00	22/11/2024 04:09:00	Comprobar	(Circuito Anterior) Aire Acond.

3.2.1.2.3 Limitaciones actuales

Una limitación importante de este registro radica en el momento en que los conductores reportan, a través del sistema de gestión interno de la empresa, su percepción de anomalías en el funcionamiento del aire acondicionado. El lapso que transcurre entre la ocurrencia de la incidencia y su registro puede ser considerable, ya que queda a criterio de cada conductor decidir cuándo informar la anomalía. Posteriormente, el personal de mantenimiento evalúa si corresponde o no generar una solicitud de trabajo, como se indicó anteriormente.

Dado que los autobuses constituyen el lugar de trabajo de los conductores, quienes permanecen en ellos durante largas jornadas, son los primeros en detectar cualquier irregularidad en el sistema de climatización. Sin embargo, el registro en el sistema siempre se realiza después del evento y, en algunos casos, puede no llegar a efectuarse.

Debido a esta incertidumbre inicial, esta fuente de datos se organiza para ser utilizada en el futuro como un recurso complementario de información para validación.

Además, los reportes suelen describirse de manera muy general, como se observa en la columna “Síntomas” de la Tabla 6. Al no especificarse con detalle el motivo del fallo, se dificulta identificar con precisión la causa de la incidencia.

3.2.1.3 Comparativo de registros

En la Figura 10 se indica la distribución mensual de los registros indicados anteriormente, en el período de estudio. Según su fuente de información, ellos:

- Proveedor Externo
 - Histórico de diagnosis (Diagnosis)
 - Histórico (Alarmas)
- Empresa Municipal de Transporte (EMT)
 - Registro de Mantenimiento EMT

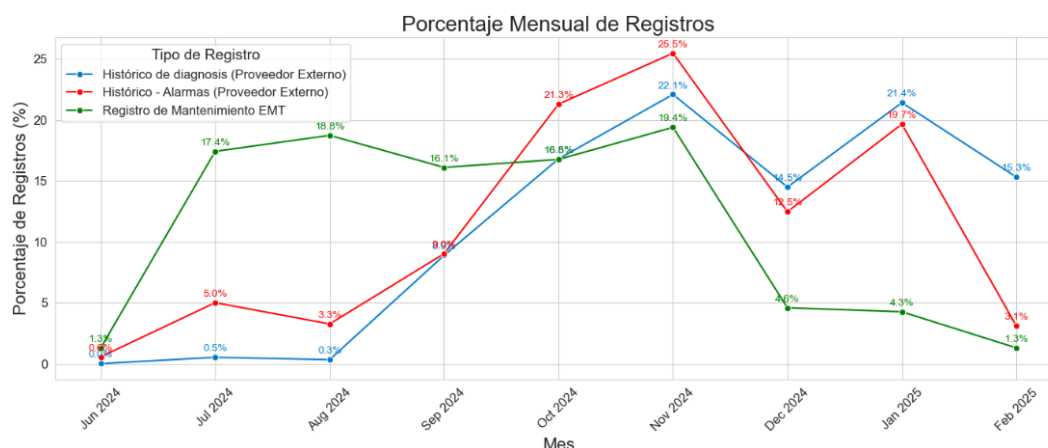


Figura 10. Porcentaje mensual de registros de Proveedor Externo y Mantenimiento EMT.

Tanto los registros de color azul y rojo, correspondiente al Histórico de diagnosis (Diagnosis) e Histórico (Alarmas), respectivamente, se observa que presentan un comportamiento similar, referido a que cuando uno de ellos aumenta o disminuye su porcentaje de registros de un mes al siguiente, el otro lo refleja de igual manera. Este comportamiento similar es de gran importancia dado que son los dos registros principales con los que se llevará a cabo el estudio de anomalías en el sistema de climatización.

Por otro lado, con un comportamiento muy diferente a los dos registros anteriores, se observa el caso de Registro de Mantenimiento EMT.

En consecuencia, para este primer análisis se priorizará el uso de los registros del Histórico de Diagnosis y del Histórico de Alarmas, ambos generados de manera sistemática y organizada por la plataforma del proveedor externo. En contraste, el Registro de Mantenimiento EMT no presentan el mismo nivel de estandarización, ya que se basan en las observaciones de los conductores y suelen consignarse una vez que el fallo ya se ha manifestado. No obstante, aunque su carácter reactivo limita su utilidad para el presente estudio, dichos registros podrían constituir una fuente complementaria de información de gran valor en trabajos posteriores orientados a la validación de resultados.

3.2.2 Visita a Empresa Municipal de Transporte

Teniendo en cuenta las fuentes de información previamente mencionadas, en particular el registro de “Estado del Vehículo”, correspondiente a las 28 variables del sistema de climatización (asociadas a temperaturas, posición de las compuertas de circulación de aire, tiempo de servicio de sopladores y compresor, número de revoluciones de los sopladores, presión del líquido refrigerante, modos de funcionamiento, entre otras), y dada la falta de documentación disponible, se realizó una visita a las instalaciones de la EMT de Valencia con el objetivo de analizar e interpretar el funcionamiento de dicho registro en un vehículo de la flota bajo estudio.

Durante los ensayos fue posible:

- Identificar la ubicación de sensores o elementos asociados a las variables.
- Verificar el funcionamiento mediante el comando con el que el conductor interactúa con el sistema.
- Interpretar experimentalmente aquellas variables que no cuentan con un sensor asociado.
- Determinar variables que, si bien son registradas, no presentan una relevancia significativa en el sistema.
- Comprobar el funcionamiento conjunto de determinados grupos de variables.

La descripción detallada de estos aspectos se encuentra documentada en los Anexos. A continuación, se presentan algunas imágenes ilustrativas:

- Figura 11: Comando donde el conductor define la “Temperatura nominal (zona pasajeros) (°C)”, en este caso fijada en 18 °C.



Figura 11. Temperatura nominal (zona pasajeros): 18°C

- Figura 12: Sensor de “Temperatura externa (°C)”, situado en la parte frontal del vehículo.



Figura 12. Sensor de “Temperatura externa (°C)”

- Figura 13: Sensor de “Temperatura de salida del aire (parte trasera – techo) (°C)”, ubicado en el conducto entre el evaporador y la zona de pasajeros, que mide la temperatura del aire antes de su ingreso al habitáculo.




Figura 13. Sensor de “Temperatura de salida del aire (parte trasera – techo)”

- Figura 14: Comando que indica la “Posición de las Compuertas de Circulación de Aire (Aire Exterior/Aire Recirculante, Valor Nominal [%])”, en este caso cerradas en su totalidad, lo que da lugar a la recirculación interna tanto en la zona de pasajeros como en la del conductor.



Figura 14. Posición de las compuertas de circulación aire, aire exterior/aire recirculante 100% cerradas.

- Figura 15: Sensores asociados a la presión del líquido refrigerante, localizados en la parte trasera del vehículo, en el compartimiento del motor.




Figura 15. Sensores de presión de líquido refrigerante.

En conjunto, estas observaciones permitieron comprender el funcionamiento del sistema de climatización de los autobuses y sus componentes, y de esta forma interpretar adecuadamente los registros de “Estado del Vehículo”.

Finalmente, a partir de entrevistas con el personal técnico de la EMT, se identificaron las principales problemáticas recurrentes del sistema de aire acondicionado en los autobuses, las cuales están asociadas a:

- Fallas en el circuito de baja presión, ocasionadas por una disminución de la presión del refrigerante, que por medidas de seguridad del sistema, genera la interrupción del servicio del sistema de climatización.
- Fallas derivadas del deterioro o sulfatación de los materiales de los conductores responsables de la comunicación del sistema de aire acondicionado.

3.2.3 Análisis de fallos

A partir de las fuentes de información previamente mencionadas, en particular el “Historial de Diagnóstico” (véase sección 3.2.1.1.2), que corresponde a la acumulación de reportes generados por la ECU del vehículo y que registran de manera sistemática los fallos detectados, en este caso con interés en el sistema de climatización, se analizaron los datos disponibles. Cada registro incluye, entre otros, el número de vehículo, la fecha de lectura, el código de error o fallo presente y su descripción.

En la Tabla 7 se presentan los fallos más frecuentes, que representan el 95% de las ocurrencias totales, ordenados según su porcentaje de aparición. De forma particular, los primeros tres códigos de fallo con mayor incidencia concentran el 63,10% del total. Dado

que la documentación disponible es limitada, se recurrió a fuentes complementarias que permitieron ampliar la descripción de estos fallos, sintetizada en la Tabla 8.

Tabla 7. Fallos de mayor frecuencia.

Fallos de mayor frecuencia			
Código de Error	Descripción	Ocurrencia [%]	Acum. [%]
D6F0E2	Unidad de control calefacción, ventilación y climatización. Parámetros incorrectos.	30.04%	30.04%
95F0F5	Agente frigorígeno. Circuito. Presión baja inaceptable.	18.82%	48.85%
1BF2E7	Servomotor para la compuerta del techo. Aire. (Exterior.). Posición incorrecta.	14.25%	63.10%
15F2E7	Unidad de control. Pin X1/32-23. Compuerta. Zona de reposapiés. Posición incorrecta.	7.57%	70.67%
0BF0E2	Válvula de agua. Circuito de calefacción. Lado del conductor. No responde.	4.30%	74.97%
14F2E2	Subestación 0. Pin X2/10-11. Válvula de agua del circuito de refrigeración. En el techo. Izquierda. Señal de retorno. Los datos recibidos son inválidos.	3.98%	78.95%
18F0E7	Servomotor de la trampilla. Parte delantera. Posición incorrecta.	3.31%	82.26%
2BF2E4	Subestación 0. Pin X1/36. Sensor de formación de hielo. En el techo. Cortocircuito a masa.	3.03%	85.28%
0FF0E5	Válvula de agua. Circuito de calefacción. Lado del conductor. Circuito abierto.	2.42%	87.70%
0FF2E7	Subestación 0. Pin X1/32-23. Válvula de agua del circuito de refrigeración. En el techo. Derecha. Posición incorrecta.	2.19%	89.90%
0CF0E7	Válvula de agua. Circuito de calefacción. Lado del conductor. Posición incorrecta.	1.90%	91.80%
17F0E2	Servomotor de la trampilla. Parte delantera. No responde.	1.53%	93.33%
1AF2E2	Trampilla de ventilación. En el techo. Parte trasera.	1.16%	94.49%
0EF2E2	Subestación 0. Pin X1/32-23. Válvula de agua del circuito de refrigeración. En el techo. Derecha. Señal de retorno. Los datos recibidos son inválidos.	0.75%	95.25%

Tabla 8. Mayor descripción de Fallos.

Mayor Descripción de Fallos		
Código de Error	Descripción	Mayor Descripción
D6F0E2	Unidad de control calefacción, ventilación y climatización. Parámetros incorrectos.	Componente 'CU Error de suma de comprobación de EEPROM Aplicación'. Es decir, la Unidad de Control (CU) tiene un error en la memoria EEPROM (Electrically Erasable Programmable Read-Only Memory)
95F0F5	Agente frigorígeno. Circuito. Presión baja inaceptable.	Perturbación de baja presión en el circuito de agente frigorígeno
1BF2E7	Servomotor para la compuerta del techo. Aire. (Exterior.). Posición incorrecta.	El motor eléctrico "51M01" de la trampilla de aire frío del exterior, tiene un error de posicionamiento.

La Tabla 8 desprende que tanto el primer como el tercer código de error (D6F0E2 y 1BF2E7, respectivamente) están asociados a componentes electrónicos del sistema de climatización y a motor eléctrico responsable del movimiento y posicionamiento de las compuertas ubicadas en el techo del autobús, las cuales regulan el ingreso de aire exterior al habitáculo. Por su parte, el código 95F0F5 está relacionado con una perturbación de baja presión en el circuito del agente frigorígeno. Tal como se indicó en la sección 3.2.2, durante las entrevistas realizadas con personal técnico de la EMT, se confirmó la recurrencia de esta problemática.

En la Figura 16 se muestran los sensores que monitorean las presiones del líquido refrigerante en los ramales de alta y baja presión, ubicados en el compartimiento del motor, en la parte trasera del autobús. En dicha figura, el elemento identificado con el número 1 corresponde al conmutador de presión (lado de baja presión), mientras que el número 2 corresponde al sensor de presión (lado de alta presión), este último asociado a una de las variables de “Estado del Vehículo” (véase sección 3.2.1.1.2), denominada “Circuito de agente frigorígeno (parte trasera), presión (bar)”.



Figura 16. Sensores de presión del líquido refrigerante del sistema de Aire Acondicionado.

Un conmutador de presión, también denominado presostato o interruptor de presión es un dispositivo de seguridad que detecta y controla la presión del refrigerante en el sistema de aire acondicionado. Su función principal es proteger el compresor y otros componentes del sistema al desactivarlo si la presión se encuentra fuera de los valores admisibles, asegurando así un funcionamiento eficiente y previniendo daños. En particular, frente al código de fallo 95F0F5, asociado a la perturbación de baja presión en el circuito, el conmutador actúa interrumpiendo el funcionamiento del sistema cuando la presión desciende por debajo del mínimo aceptable.

Por otro lado, en la Figura 17 se presenta la distribución mensual de los tres códigos de error mencionados durante el período de estudio. Se observa que el código D6F0E2 alcanza sus valores máximos en agosto y diciembre de 2024; el código 95F0F5 muestra un crecimiento sostenido en los primeros meses de 2024, alcanzando su máximo en noviembre y posteriormente decreciendo; mientras que el código 1BF2E7 mantiene un comportamiento más estable, con un leve incremento a partir de octubre de 2024.

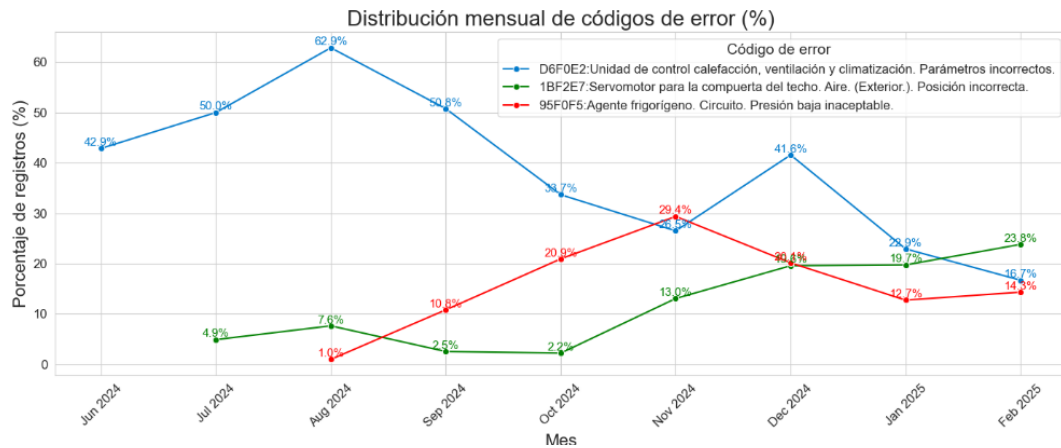


Figura 17. Distribución mensual de códigos de error (%).

3.3 Análisis exploratorio de datos (EDA)

Las etapas de análisis exploratorio de datos (EDA) y preprocesamiento son fundamentales en cualquier flujo de trabajo de Machine Learning, ya que garantizan la consistencia, la calidad y la usabilidad de la información. De hecho, las tareas de preparación, incluidas la limpieza, transformación y estructuración de datos, suelen representar más del 60 % del esfuerzo total en proyectos de aprendizaje automático, lo que pone de manifiesto la relevancia de esta fase (Sarih, Tchangani, Medjaher, & Pere, 2019).

En este contexto, el análisis exploratorio se aplicará a los registros del “Estado del Vehículo”, que, como se mencionó anteriormente, incluyen variables relacionadas con temperaturas, posición de las compuertas de circulación de aire, tiempo de servicio de sopladores y compresor, entre otras. Estas variables constituyen el objeto de estudio de la presente sección.

3.3.1 Análisis de correlaciones entre variables

A continuación, se estudian las relaciones lineales entre diferentes variables. Este análisis se lleva a cabo mediante mapas de correlación, los cuales constituyen una herramienta visual que permite reflejar el grado de asociación entre variables numéricas a través del coeficiente de correlación.

➤ Posición De La Compuerta De Circulación De Aire

En el caso de las variables relacionadas con la posición de la compuerta de circulación de aire, los resultados se presentan en el mapa de la Figura 18.

Correlaciones de Posición de la Compuerta de Circulación de Aire

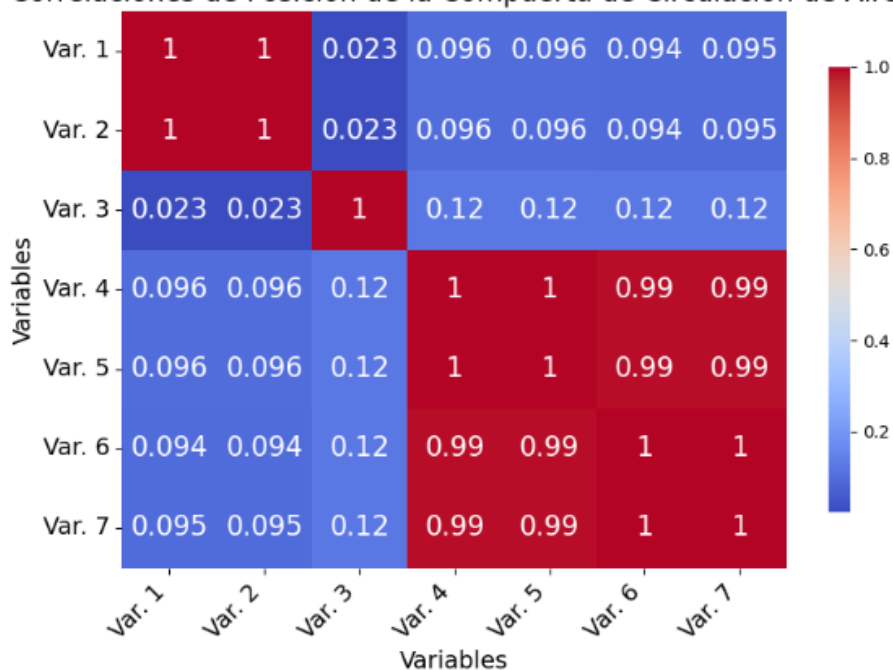


Figura 18. Mapa de correlación de variables de posición de la compuerta de circulación de aire.

Las referencias de cada una de las variables (Var.) se presentan en la Tabla 9.

Tabla 9. Referencias de variables de posición de la compuerta de circulación de aire.

Tabla de referencia de variables:	
Var. N°	Variable Original
Var. 1	Posición De La Compuerta De Circulación De Aire, Parabrisas, Valor Nominal (%)
Var. 2	Posición De La Compuerta De Circulación De Aire, Zona Reposapiés, Valor Nominal (%)
Var. 3	Posición De La Compuerta De Circulación De Aire, Aire Exterior/Aire Recirculante, Valor Nominal (%)
Var. 4	Posición De La Compuerta De Circulación De Aire (Parte Delantera, Techo, Derecha), Valor Nominal (%)
Var. 5	Posición De La Compuerta De Circulación De Aire (Parte Delantera, Techo, Izquierda), Valor Nominal (%)
Var. 6	Posición De La Compuerta De Circulación De Aire (Parte Trasera, Techo, Derecha), Valor Nominal (%)
Var. 7	Posición De La Compuerta De Circulación De Aire (Parte Trasera, Techo, Izquierda), Valor Nominal (%)

De forma gráfica se observa un coeficiente de correlación elevado (igual o cercano a 1) en los siguientes casos:

- Var. 1 con Var. 2,

- Var. 4 con:
 - Var. 5,
 - Var. 6,
 - Var. 7

Es decir, de las siete variables iniciales, únicamente con los registros de tres de ellas (Var. 1, 3 y 4) se obtiene la misma información. Esto implica la eliminación del 14 % del total de variables, lo que contribuye a la simplificación del caso de estudio.

Las 3 variables resultantes son:

- Var. 1: Posición De La Compuerta De Circulación De Aire, Parabrisas, Valor Nominal (%),
- Var. 3: Posición De La Compuerta De Circulación De Aire, Aire Exterior/Aire Recirculante, Valor Nominal (%),
- Var. 4: Posición De La Compuerta De Circulación De Aire (Parte Delantera, Techo, Derecha), Valor Nominal (%).

➤ **Número de Revoluciones del Soplador**

Por otra parte, al estudiar las variables relacionadas con el número de revoluciones del soplador, los resultados se presentan en el mapa de la Figura 19.




Figura 19. Mapa de correlación de variables de revoluciones del soplador.

Las referencias de cada una de las variables se presentan a continuación en la

Tabla 10.

Tabla 10. Referencias de variables de número de revoluciones del soplador.

Tabla de referencia de variables	
Var. N°	Variable Original
Var. 1	Número De Revoluciones Del Soplador, Área Del Conductor, Valor Nominal (%)
Var. 2	Número De Revoluciones Del Soplador (Parte Delantera, Techo, Delante), Valor Nominal (%)
Var. 3	Número De Revoluciones Del Soplador (Parte Delantera, Techo, Detrás), Valor Nominal (%)
Var. 4	Número De Revoluciones Del Soplador (Parte Trasera, Techo, Detrás), Valor Nominal (%)
Var. 5	Número De Revoluciones Del Soplador (Parte Trasera, Techo, Delante), Valor Nominal (%)
Var. 6	Número De Revoluciones Del Soplador, Soplador Del Condensador (Parte Delantera), Valor Nominal (%)
Var. 7	Número De Revoluciones Del Soplador, Soplador Del Condensador (Parte Trasera), Valor Nominal (%)

De forma gráfica se observa un coeficiente de correlación elevado (igual o cercano a 1) en los siguientes casos:

- Var. 2 con:
 - Var. 3,
 - Var. 4,
 - Var. 5,
- Var. 6 con Var. 7.

Tal como el caso anterior, de las siete variables iniciales, únicamente con los registros de tres de ellas (Var. 1, 2 y 6) se obtiene la misma información. Esto implica la eliminación del 14 % del total de variables, lo que contribuye a la simplificación del caso de estudio.

Las 3 variables resultantes son:

- Var. 1: Número De Revoluciones Del Soplador, Área Del Conductor (Valor Nominal) (%),
- Var. 2: Número De Revoluciones Del Soplador (Parte Delantera, Techo, Delante), Valor Nominal (%),
- Var. 6: Número De Revoluciones Del Soplador, Soplador Del Condensador (Parte Delantera), Valor Nominal (%).

➤ **Variables de Tiempo de Servicio de Sopladores y Compresor**

Por otra último, las variables relacionadas con el Tiempo De Servicio, los resultados se presentan en el mapa de la Figura 20.

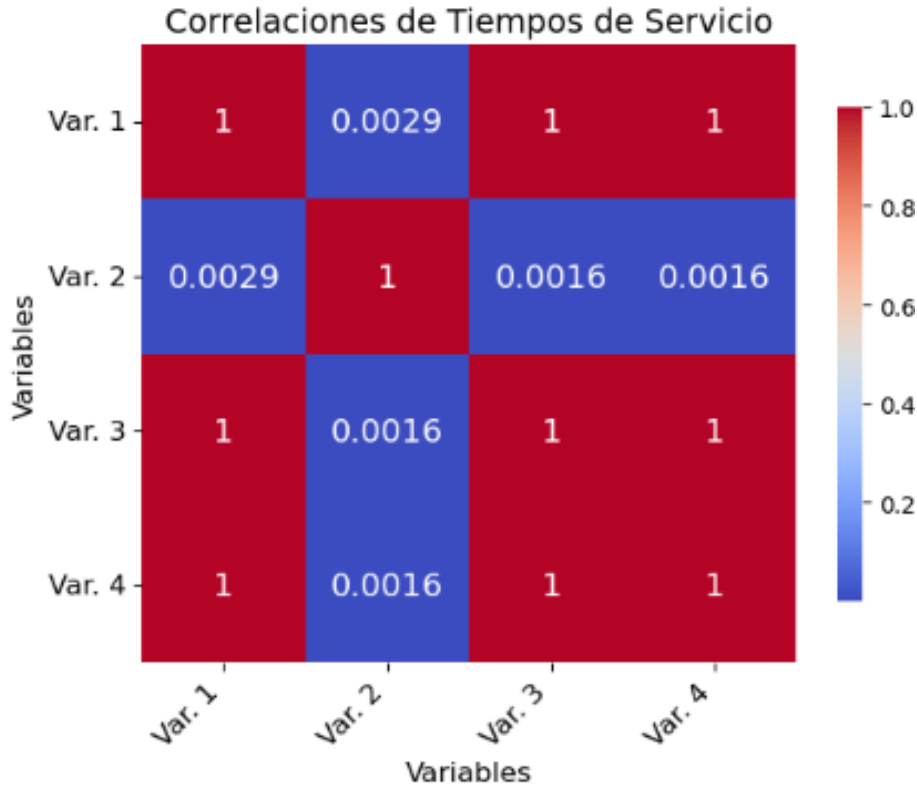


Figura 20. Mapa de correlación de variables de tiempo de servicio.

Las referencias de cada una de las variables se presentan a continuación en la Tabla 11.

Tabla 11. Referencias de las variables de tiempo de servicio.

Tabla de referencia de variables:	
Var. N°	Variable Original
Var. 1	Sopladores (Lado Del Conductor), Tiempo De Servicio (h)
Var. 2	Sopladores (Techo), Tiempo De Servicio (h)
Var. 3	Sopladores (Condensador), Tiempo De Servicio (h)
Var. 4	Compresor, Tiempo De Servicio (h)

De forma gráfica se observa un coeficiente de correlación elevado (igual o cercano a 1) en los siguientes casos:

- Var. 1 con:
 - Var. 3,
 - Var. 4.

En este caso, de las cuatro variables iniciales, únicamente con los registros de dos de ellas (Var. 1 y 2) se obtiene la misma información. Esto implica la eliminación del 7 % del total de variables, lo que contribuye a la simplificación del caso de estudio.

Las 2 variables resultantes son:

- Var. 1: Sopladores (Lado Del Conductor), Tiempo De Servicio (h),
- Var. 2: Sopladores (Techo), Tiempo De Servicio (h).

Como conclusión de lo expuesto por los tres grupos, se identificó que 10 de las 28 variables aportan información redundante. En otras palabras, es posible prescindir de dichas variables: 4 relacionadas con la posición de las compuertas de circulación de aire, 4 con el número de revoluciones de los sopladores y 2 al tiempo de servicio. Esta reducción equivale al 35 % del total de variables y contribuye de manera significativa a la simplificación del caso de estudio."

3.3.2 Ingeniería de características: creación de variables

Otro aspecto relevante en el Análisis Exploratorio de Datos (EDA) es la ingeniería de características (feature engineering), paso crucial en el aprendizaje automático que implica la transformación de datos sin procesar en características significativas para mejorar la capacidad predictiva de un modelo. Al aprovechar la experiencia en el dominio y el análisis empírico, este proceso busca enriquecer el conjunto de datos mediante la creación de variables que representen eficazmente la dinámica clave del sistema, capturando patrones y relaciones subyacentes que, de otro modo, podrían permanecer ocultos. Por ejemplo, facilita la integración de patrones temporales o métricas derivadas, añadiendo contexto valioso al sistema analizado. Si bien la ingeniería de características suele generar mejoras significativas en el rendimiento, como una mayor precisión e interpretabilidad del modelo, también presenta desafíos. En concreto, la creación de características derivadas excesivas puede aumentar la complejidad del modelo, lo que aumenta el riesgo de sobreajuste y reduce la generalización. (Tormos, Pla, Sánchez-Márquez, & Carballo, 2025).

En este trabajo se desarrollaron dos enfoques con el objetivo de generar nuevas variables:

1. Franja horaria de mayor demanda: se incorporó información sobre el horario de mayor utilización del transporte, diferenciando entre días laborales y fines de semana. De esta forma, se busca otorgar mayor relevancia a los datos operativos

del Estado del Vehículo (véase sección 3.2.1.1.2) dentro de los periodos de mayor demanda de los usuarios, enriqueciendo el conjunto de datos para los modelos de aprendizaje.

2. Diferencial de temperatura: se consideró el comportamiento derivado de las diferencias entre variables de temperatura del sistema de climatización, con el fin de generar una nueva perspectiva que aporte información adicional al modelo de aprendizaje.

3.4 Criterios adoptados

Dado que se pretende determinar las condiciones de funcionamiento normal, o representativas de este, del sistema de aire acondicionado de los vehículos de la flota de transporte, se establecieron criterios específicos para filtrar y excluir situaciones anómalas a partir de los registros de “Estado del Vehículo” (véase sección 3.2.1.1.2)

En primer lugar, con base en la información del 'Histórico de Alarmas' (véase sección 3.2.1.1.2) y tomando como referencia la fecha de disparo, se consideró condición anómala el intervalo comprendido entre seis horas antes y seis horas después de dicho evento. En otras palabras, se definió como rango anormal un período de 12 horas alrededor del disparo de la alerta. La Figura 21 ilustra de manera esquemática este criterio aplicado a las variables de temperatura."




Figura 21. Fecha de disparo junto a las variables de temperatura.

En segundo lugar, dentro del Estado del Vehículo se encuentra la variable “Modo Refrigeración”, que refleja el estado operativo del sistema de aire acondicionado a través

de sus dos estados: activado y desactivado. Dado que las condiciones normales de funcionamiento solo pueden observarse cuando el sistema está en modo activado, únicamente se tuvieron en cuenta los casos en este estado. Tal como se observa en la Figura 22, entre los meses de diciembre y febrero, el modo activado representa un valor menor al 4 %, por lo que el sistema permanece mayormente desactivado en dicho período. En consecuencia, estos meses no se incluyen dentro de las condiciones normales de funcionamiento.




Figura 22. Porcentaje mensual de registro de la variable Modo “Refrigeración”.

En tercer lugar, como se mencionó en la sección anterior, mediante una primera aproximación se identificaron los horarios de mayor demanda del servicio que representan una mayor carga térmica, es decir, las franjas horarias en las que el sistema de climatización, principalmente el aire acondicionado, opera a plena carga. Estos periodos se presentan en la Tabla 12.

Tabla 12. Franja horaria de mayor demanda del transporte urbano.

Franja horaria de mayor demanda			
Mes	Día	Franja Horaria	Observaciones
Junio	Laborable	07:00–09:30, 13:30–15:30, 17:00–20:00	Alta movilidad por trabajo y ocio. Inicio verano.
Junio	Fin de semana	10:30–14:00, 17:30–21:00	Turismo y ocio aumentan, menor uso temprano.
Julio	Laborable	07:30–10:00, 13:00–15:00, 18:00–20:30	Movilidad más tardía. Vacaciones escolares.
Julio	Fin de semana	11:00–14:30, 18:00–22:00	Mucho ocio y playa.
Agosto	Laborable	08:00–10:00, 18:00–21:00	Bajísima demanda laboral. Uso turístico.

Agosto	Fin de semana	11:00–14:30, 18:30–22:30	Máxima demanda ocio. Fallas de agosto en barrios.
Septiembre	Laborable	07:00–09:00, 13:30–15:30, 17:00–20:00	Vuelta a trabajo y colegios.
Septiembre	Fin de semana	10:30–14:00, 17:00–20:30	Ocio y familias.
Octubre	Laborable	07:00–09:00, 13:30–15:30, 17:00–20:00	Ritmo laboral completo.
Octubre	Fin de semana	10:00–13:30, 17:00–20:00	Clima templado mantiene ocio.
Noviembre	Laborable	07:00–09:00, 13:00–15:00, 17:00–19:30	Menos luz solar: picos más definidos.
Noviembre	Fin de semana	10:00–13:00, 16:30–19:30	Menor movilidad general.

En cuarto lugar, se analizaron los registros de las siguientes variables:

- Temperatura del evaporador (parte trasera, techo) (°C)
- Temperatura externa (°C)
- Temperatura de salida del aire (parte trasera - techo) (°C)

De acuerdo con lo expuesto en las secciones 3.1.2 y 3.1.3, relativo a las variables de temperatura, durante la estación de verano debe cumplirse la relación de la Ecuación 2:

Ecuación 2. Relación de las Temperaturas.

$$\text{Temp. del Evaporador} < \text{Temp. de Salida del Aire} < \text{Temp. Externa}$$

Es decir, la temperatura externa corresponde al valor más alto, la del evaporador al menor y la de salida del aire se ubica en un punto intermedio. Cabe señalar que la variable “Temperatura de salida del aire (parte trasera - techo) (°C)” está asociada al sensor ubicado en el conducto entre el evaporador y la zona de pasajeros, midiendo la temperatura el aire que fluye hacia el interior del vehículo.

Por lo tanto, únicamente se consideran como condiciones normales los casos en los que se cumple la relación expresada en la Ecuación 2. En caso contrario, los datos deben descartarse, pues no reflejan un funcionamiento adecuado del sistema. En la Figura 23 se muestra un ejemplo donde dicha relación no se cumple, dado que la temperatura del evaporador aparece como la más alta y, en determinados momentos, la temperatura externa resulta ser la menor. En consecuencia, aquellas situaciones con comportamientos

similares no se incluyen dentro de las condiciones normales de operación del aire acondicionado.

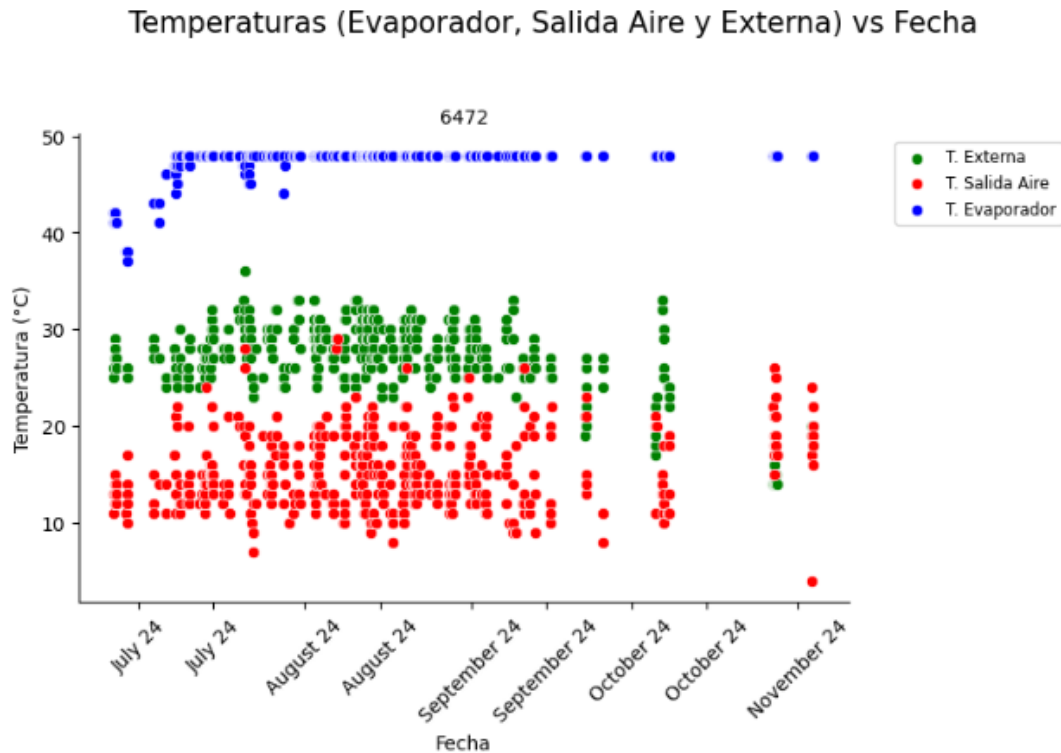


Figura 23. Registro de variables de temperaturas.

3.5 Desarrollo de modelos y validación de resultados

3.5.1 Selección del enfoque

Para abordar la detección de anomalías en el sistema de climatización, se decidió emplear un modelo LSTM Autoencoder, dada su capacidad para aprender el comportamiento normal del sistema y detectar desviaciones sin necesidad de etiquetas explícitas de fallo.

Este enfoque responde a dos factores clave. En primer lugar, el objetivo del estudio es modelar el funcionamiento normal del sistema climatización a partir de variables operativas multivariantes. En este contexto, los autoencoders resultan adecuados, ya que su arquitectura permite comprimir la información relevante en un espacio latente y luego reconstruir los datos originales, lo que facilita la detección de anomalías a partir de errores de reconstrucción.

En segundo lugar, los datos presentan una marcada dependencia temporal: el estado actual del sistema depende de sus valores pasados. Por ello, se incorporaron capas LSTM (Long Short-Term Memory), capaces de capturar relaciones secuenciales, algo que los enfoques tradicionales punto a punto no logran representar eficazmente.

El modelo se entrena exclusivamente con secuencias asociadas al comportamiento normal del sistema climatización, previamente filtradas según criterios operativos definidos. Una vez entrenado, el modelo aprende a reconstruir con precisión este tipo de secuencias, capturando los patrones temporales que definen el funcionamiento esperado.

Cuando se le presentan nuevas secuencias, si estas son similares a las vistas durante el entrenamiento (es decir, reflejan condiciones normales), el error de reconstrucción permanece bajo. En cambio, si contienen desviaciones significativas, por ejemplo, debido a fallos incipientes, lecturas anómalas o condiciones operativas inusuales, el error de reconstrucción tiende a aumentar, ya que el modelo no ha aprendido a representarlas.

Para distinguir qué errores son “anormalmente altos”, se define un umbral estadístico sobre el error de reconstrucción utilizando el percentil 90 del conjunto de entrenamiento. Esto implica que se considera como potencialmente anómalo cualquier caso cuyo error esté en el 10 % superior de los valores observados en el entrenamiento.

Esta decisión no supone que el conjunto de entrenamiento contenga fallos explícitos, sino que reconoce que incluso dentro de un conjunto “normal” pueden existir valores atípicos, errores de sensado o secuencias no representativas del comportamiento estándar. El percentil 90 actúa entonces como frontera práctica para filtrar estos casos poco frecuentes, permitiendo una detección más robusta y adaptada al comportamiento dominante del sistema.

3.5.2 Preparación del conjunto de datos

Una vez realizado el análisis exploratorio de los datos, se definió un conjunto de entrenamiento representativo del comportamiento normal del sistema climatización. Durante el preprocesamiento se aplicaron distintas estrategias para asegurar la calidad de los datos:

- Selección de variables: Se eligieron 14 variables operativas tras eliminar aquellas con alta correlación redundante o escasa relevancia, así como variables con alta cardinalidad que dificultaban el modelado (por ejemplo, ciertos modos de funcionamiento categóricos).
- Eliminación de valores atípicos: Se descartaron registros de vehículos con comportamiento anómalo conocido. En particular, se eliminaron los valores extremos en la temperatura del evaporador que podrían estar distorsionando el análisis.

- Limpieza de registros nulos: Se eliminaron todas las filas que presentaban valores nulos en las variables seleccionadas para asegurar coherencia en la entrada del modelo.
- Filtrado por condiciones operativas normales: Se eliminaron ventanas cercanas a disparos de alertas electrónicas (ECU) y se aplicaron filtros relacionados con el modo de funcionamiento del sistema (modo refrigeración activado) y las franjas horarias con alta carga térmica.

Para capturar la dependencia temporal del sistema, los datos fueron transformados en ventanas deslizantes de tamaño 5, es decir, secuencias de 5 registros consecutivos por vehículo. Esta longitud equivale a unas 4 horas de operación aproximadamente, dado que la frecuencia de muestreo promedio es de unos 50 minutos. Solo se consideraron ventanas que conservaran continuidad temporal (sin saltos mayores a 1.5 horas), con lo cual se garantiza la validez de la secuencia.

Finalmente, los datos fueron escalados utilizando un RobustScaler, una técnica especialmente útil en contextos industriales donde pueden aparecer valores extremos no representativos.

Este conjunto preprocesado, que representa las condiciones normales de funcionamiento del sistema, fue utilizado como entrada para el entrenamiento del modelo. Para definir qué se considera un comportamiento anómalo, se emplearon las alarmas registradas por la ECU. En concreto, se identificaron como potencialmente anómalas todas aquellas ventanas de tiempo que abarcan desde seis horas antes hasta seis horas después del disparo de cada alarma. Este criterio se aplicó de forma sistemática a todas las alarmas disponibles en el conjunto de datos.

3.5.3 Entrenamiento y validación del modelo

Como se mencionó anteriormente, se empleó una arquitectura simétrica de tipo LSTM Autoencoder para modelar el comportamiento normal del sistema de climatización. Esta arquitectura está compuesta por:

- Capa codificadora LSTM: reduce la secuencia de entrada a una representación comprimida en el espacio latente, capturando los patrones temporales del sistema.
- RepeatVector: repite la representación latente para que coincida con la longitud de la secuencia de salida esperada.

- Capa decodificadora LSTM: reconstruye la secuencia a partir de la representación latente.
- Capa TimeDistributed: genera la reconstrucción final de cada elemento de la secuencia, permitiendo comparar la salida con los datos originales.

Para adaptar la arquitectura a las características del problema, se llevó a cabo un proceso de búsqueda de hiperparámetros (grid search), evaluando distintas combinaciones de:

- Número de neuronas en las capas LSTM.
- Número de capas LSTM.
- Funciones de activación: ReLU y tanh.
- Tamaño del batch: 32 y 64.

Cada combinación se evaluó en función del comportamiento del error de reconstrucción sobre los conjuntos de entrenamiento y validación. El entrenamiento se realizó utilizando el optimizador Adam y la función de pérdida MSE (mean squared error). Para prevenir el sobreajuste y garantizar la convergencia del modelo, se incorporó una estrategia de early stopping con paciencia de 5 epochs, deteniendo el entrenamiento si no se observaba mejora en la pérdida de validación.

Una vez entrenado cada modelo, se calcularon los errores de reconstrucción (MSE) para las secuencias normales. Estos umbrales permitieron clasificar como anómalas aquellas secuencias cuyo error de reconstrucción superaba el valor correspondiente.

El rendimiento de cada configuración se validó utilizando el conjunto de ventanas potencialmente anómalas, es decir, aquellas cercanas a disparos de alarmas registradas por la ECU. Para cada combinación de hiperparámetros se evaluó el porcentaje de ventanas anómalas correctamente detectadas, el cual funcionó como una métrica indirecta del desempeño del modelo, permitiendo comparar la capacidad de cada configuración para discriminar entre comportamiento normal y anómalo.

3.5.4 Resultados: detección de anomalías y patrones observados

Cada combinación de hiperparámetros fue entrenada sobre el conjunto de datos normalizado utilizando un conjunto de validación para aplicar parada temprana (early stopping) y evitar sobreajuste. Para cada configuración, se calculó el error de reconstrucción (MSE) obtenido en los datos normales.

El mejor desempeño se obtuvo con la arquitectura más compleja: una red LSTM de 2 capas con 128 y 64 neuronas respectivamente, función de activación ReLU y tamaño de batch de 64. La Figura 24 muestra la función de pérdida durante el entrenamiento y la validación para dicha estructura.




Figura 24. Evolución de la función de pérdida durante el entrenamiento y validación

Esta configuración presentó una mayor sensibilidad en la detección de desviaciones, con un 13,06% de ventanas clasificadas como anómalas al aplicar el umbral correspondiente al percentil 90 (MSE > 0.0023). Las Figura 25 y Figura 26 muestran las distribuciones del error de reconstrucción para el conjunto de entrenamiento y de prueba, junto con el umbral definido.

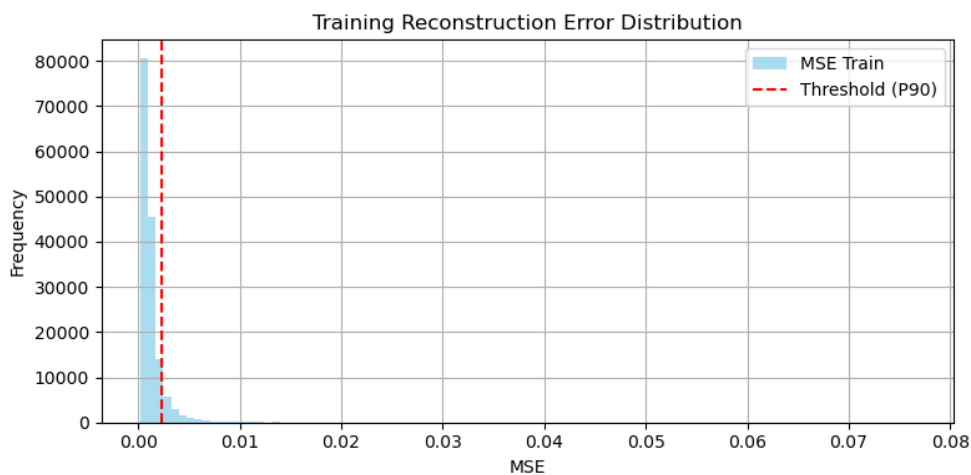


Figura 25. Distribución del error de reconstrucción en el entrenamiento




Figura 26. Distribución del error de reconstrucción en el conjunto anómalo

Durante el análisis comparativo, se observó que las redes con mayor número de neuronas tendieron a ofrecer una mayor capacidad de discriminación, logrando detectar un porcentaje más alto de anomalías en el conjunto de prueba. Esta tendencia sugiere que arquitecturas más profundas permiten capturar mejor las relaciones temporales y no lineales entre las variables operativas del sistema climatización.

En términos generales, las distribuciones del error de reconstrucción para los conjuntos de entrenamiento y de prueba (supuesto como anómalo) presentan formas similares. En el caso específico del conjunto anómalo, al aplicar el umbral definido a partir del conjunto de entrenamiento (percentil 90), el porcentaje de ventanas que superan dicho valor es cercano, aunque ligeramente superior, al percentil de referencia. Esto indica que la mayoría de los datos en dicho conjunto siguen un patrón muy similar al observado durante el entrenamiento.

Desde una perspectiva física, esta similitud sugiere que una parte significativa de las alarmas registradas por la ECU podrían no estar asociadas a desviaciones térmicas relevantes, sino más bien a eventos de diagnóstico sin impacto directo sobre el comportamiento dinámico del sistema. Es decir, el modelo no detecta una anomalía térmica significativa en muchos de los casos donde se generó una alarma electrónica.

Desde un punto de vista estadístico, el incremento del 3,06 % en la proporción de ventanas clasificadas como anómalas al emplear el percentil 90 como umbral puede deberse a dos posibles causas:

- La aparición más frecuente de patrones previamente aprendidos durante el entrenamiento.

- La manifestación de comportamientos nuevos no representados en el conjunto de entrenamiento, que podrían corresponder a fallos incipientes.

A partir de estos resultados, se plantea como siguiente paso una nueva iteración del modelo que considere no solo las alarmas electrónicas provenientes de la ECU, sino también los registros manuales de mantenimiento de la empresa de transporte como fuente complementaria para definir de forma más precisa los períodos de comportamiento anómalo. Además, un análisis exploratorio más profundo que integre ambos conjuntos de datos permitiría realizar una primera depuración de las condiciones que realmente reflejan un fallo, diferenciándolas de aquellas asociadas a ruido o eventos sin impacto operativo. Esta futura fase permitirá incrementar la precisión del modelo, mejorar la interpretación de las alertas generadas y fortalecer su aplicabilidad en un entorno real de operación.

4 Objetivos de Desarrollo Sostenible asociado al TFM

El presente Trabajo Fin de Máster (TFM) se enmarca dentro del Objetivo de Desarrollo Sostenible (ODS) N.º 9 (Figura 27), cuyo propósito es construir infraestructuras resilientes, promover una industrialización inclusiva y sostenible, y fomentar la innovación.



Figura 27. Los 17 objetivos de Desarrollo Sostenible (ODS).

La temática abordada, titulada “Detección de anomalías en el sistema de climatización de una flota de autobuses basada en inteligencia artificial”, se orienta al desarrollo de metodologías innovadoras que permitan mejorar y optimizar las técnicas de mantenimiento predictivo a partir de las tecnologías emergentes propias de la Industria 4.0. Esta nueva etapa industrial se caracteriza por la automatización, la digitalización y la incorporación de un conjunto de herramientas disruptivas destinadas a optimizar procesos y recursos mediante la recolección, análisis y aprovechamiento de datos.

En este sentido, el presente TFM contribuye al cumplimiento del ODS 9 al impulsar la inversión en investigación, desarrollo e innovación (I+D+i), fomentando el progreso tecnológico y la innovación en las actividades empresariales. Asimismo, busca generar un impacto positivo en pequeñas y medianas empresas que formen parte de la cadena de valor, proporcionándoles formación y apoyo en sus procesos de digitalización. Todo ello se plantea desde un enfoque de sostenibilidad, mediante la aplicación de tecnologías disruptivas como el big data, la inteligencia artificial (IA) y el internet de las cosas (IoT).

5 Presupuesto para la realización del TFM

El presupuesto detallado a continuación corresponde a la planificación financiera para la realización del Trabajo de Fin de Máster (TFM). Este presupuesto ha sido diseñado para cubrir todos los aspectos necesarios para la correcta implementación de este proyecto, desde el análisis de las problemáticas, asesoramiento académico y personal externo, hasta la redacción y presentación final de trabajo.

Este presupuesto detalla los costos asociados con la realización del TFM, desglosado en varias categorías que incluyen recursos humanos, recursos materiales y servicios. A continuación, en la Tabla 13, se describe cada sección.

Tabla 13. Presupuesto para ejecución del TFM.

Presupuesto de ejecución del TFM					
Capítulo	Unidad	Descripción	Cantidad	Precio Unitario	Importe
1. Recursos humanos					
1.1	Hora	Asesoramiento de los directores académico	48	96 €	4,608.00 €
1.2	Hora	Recolección de datos operativos mediante software	15	20 €	300.00 €
1.3	Hora	Asesoramiento de personal de EMT	48	80 €	3,840.00 €

1.4	Hora	Asesoramiento en Software de Procesamiento (Python)	20	25 €	500.00 €
1.5	Hora	Redacción del proyecto	150	30 €	4,500.00 €
2. Recursos materiales					
2.1	MES	Amortización del equipo informático	6	33 €	200.00 €
2.2	MES	Amortización del software	6	42 €	252.00 €
2.3	N/A	Materiales de oficina	1	40 €	40.00 €
3. Servicios					
3.1	-	Servicio de internet	1	50 €	50.00 €
3.2	-	Servicio de luz	1	50 €	50.00 €
EJECUCIÓN DEL PROYECTO					14,340.00 €
Gastos Generales (7%)					1,003.80 €
Beneficios industriales (8%)					1,147.20 €
Total Presupuesto sin I.V.A					16,491.00 €
I.V.A (21%)					3,463.11 €
TOTAL PRESUPUESTO					19,954.11 €

6 Conclusiones

El presente trabajo constituyó un primer acercamiento a la aplicación de modelos de Machine Learning, específicamente de Deep Learning, para la detección de anomalías en el sistema de climatización de la flota de autobuses de transporte urbano. Este proyecto representa una fase exploratoria inicial dentro de un proceso de investigación y desarrollo más amplio.

Durante su desarrollo, se otorgó especial relevancia a la preparación del entorno y el análisis previo de los datos. Esto incluyó la validación técnica en campo, la recopilación y estructuración de la información, el análisis detallado de las variables disponibles y la construcción de una base de datos operativa sólida.

Si bien la implementación del modelo LSTM Autoencoder se limitó a una única iteración por restricciones de tiempo, los resultados obtenidos sientan las bases para futuras investigaciones. Como producto de este trabajo, se dispone de una arquitectura inicial funcional, criterios de filtrado validados y una metodología replicable que facilitará el desarrollo de enfoques más precisos y robustos.

Adicionalmente, se logró una comprensión integral de la infraestructura informática de la industria 4.0 aplicada a los autobuses. Este conocimiento tiene potencial para ser

extrapolado a otras áreas del mantenimiento industrial orientadas a la detección temprana de fallos en equipos.

7 Desafíos del Mantenimiento 4.0 y trabajos a futuro

Desafíos del Mantenimiento 4.0

A partir de la experiencia adquirida en el desarrollo del presente trabajo sobre la detección de anomalías en el sistema de climatización de la flota de autobuses, se identifican una serie de desafíos que resultan claves para avanzar hacia una gestión de mantenimiento más eficiente bajo el enfoque de Mantenimiento 4.0.

En primer lugar, se requiere la implementación de un entorno informático a bordo de los autobuses que permita una recolección de datos con una frecuencia de muestreo superior a la actual (50 minutos en promedio). Una mayor resolución temporal posibilitaría disponer de información más detallada sobre la evolución de las variables, mejorando la capacidad de análisis y aumentando la sensibilidad en la detección temprana de anomalías.

En segundo lugar, el proceso de recolección de datos, actualmente dependiente de descargas manuales desde la plataforma del proveedor externo, constituye una limitación operativa. La automatización o mejora de este mecanismo permitiría optimizar los tiempos de obtención de información y reducir riesgos asociados, como la pérdida parcial de registros o los retrasos vinculados a la validación manual.

Trabajos a futuro

Respecto a los trabajos futuros, se plantea dar continuidad a la línea de investigación desarrollada en este proyecto, profundizando en la arquitectura LSTM Autoencoder con el objetivo de optimizar su desempeño y robustez. En este sentido, se propone dar énfasis en el análisis a los resultados obtenidos en la distribución del error de reconstrucción (MSE) del conjunto anómalo, Figura 26, especialmente en el rango comprendido entre los valores 0,0023 (percentil 90) y 0,02, donde se identifican los valores máximos.

Por otro lado, con el propósito de mejorar la capacidad predictiva del modelo, resulta fundamental incorporar nuevas fuentes de información, particularmente los registros históricos de mantenimiento de la empresa de transporte. Esta integración permitirá

validar los resultados del modelo, enriquecer la detección de patrones anómalos y fortalecer la correlación entre los eventos operativos y las fallas reales del sistema.

Finalmente, se propone el desarrollo de una metodología basada en algoritmos de Machine Learning orientada a la definición de condiciones límite de funcionamiento del sistema de climatización, con el fin de anticipar posibles fallos y avanzar hacia un modelo predictivo de mantenimiento que incremente la confiabilidad operativa y la eficiencia global de la flota de transporte urbano.

8 Bibliografía

- Ahmed, U., Carpitella, S., Certa, A., & Izquierdo, J. (2023). A Feasible Framework for Maintenance Digitalization. *MDPI*.
- Ashraf, J., Bakhshi, A., Moustafa, N., Khurshid, H., Javed, A., & Beheshti, A. (2021). Novel Deep Learning-Enabled LSTM Autoencoder Architecture for Discovering Anomalous Events From Intelligent Transportation Systems. *IEEE Xplore*.
- Baldi, P. (2012). Autoencoders, Unsupervised Learning, and Deep Architectures. *PMLR*.
- Bank, D., Koenigstein, N., & Giryas, R. (2023). Autoencoders. *Springer Nature Link*.
- Castro, R., Herrera, N., Quezada, L., Sánchez, K., & Silva, C. (2023). Aplicación de las herramientas de la industria 4.0 para mejorar los procesos de Análisis Causa Raíz (RCA) y el Mantenimiento Centrado en Confiabilidad (RCM). *ResearchGate*.
- Cengel, Y., & Boles, M. (2012). *Termodinámica. Séptima Edición*.
- Davari, N., Pashami, S., Veloso, B., Nowaczyk, S., Fan, Y., Mota Pereira, P., . . . Gama, J. (2022). A Fault Detection Framework Based on LSTM Autoencoder: A Case Study for Volvo Bus Data Set. *Springer Nature Link*.
- Dolli, V., Jally, S., Rawal, Y., Madhusudhana, H., Satish, G., & Lakkundi, A. (2025). A review on tool condition monitoring in CNC turning process using digital twin technology. *AIP Publishing*.
- Espósito, M., Lazoi, M., Margarito, A., & Quarta, L. (2019). Innovando la fase de mantenimiento, reparación y revisión mediante la digitalización. *MDPI*.
- Feng, X., Ouyang, M., Liu, X., Lu, L., Xia, Y., & He, X. (2018). Thermal runaway mechanism of lithium ion battery for electric vehicles: A review. *Science Direct*.

- Guillén-López, A., Sanchez-Herguedas, A., & Rodríguez, M. (2024). Application of Digital Twin Technology for the Digitization of Railway Maintenance Services in compliance with European Regulation EU 779/2019. *ScienceDirect*.
- Hernández-Leal, E., Duque-Méndez, N., & Moreno Cadavid, J.-C. (2017). Big Data: an exploration of research, technologies and application cases. *Scientific Electronic Library Online*.
- Jaltest Telematic. (Septiembre de 2025). *Jaltest By Cojali*. Obtenido de Jaltest By Cojali: <https://www.jaltest.com/es/>
- Johansson, N., Roth, E., & Reim, W. (2019). Smart and Sustainable eMaintenance: Capabilities for Digitalization of Maintenance. *MDPI*.
- Kang, J., Kim, C.-S., Kang, J., & Gwak, J. (2021). Anomaly Detection of the Brake Operating Unit on Metro Vehicles Using a One-Class LSTM Autoencoder. *MDPI*.
- Kim, T., Kim, J., & You, I. (2023). An Anomaly Detection Method Based on Multiple LSTM-Autoencoder Models for In-Vehicle Network. *MDPI*.
- Lukic Vujadinovic, V., Damnjanovic, A., Cakic, A., Petkovic, D., Prelevic, M., Pantovic, V., . . . Bodolo, I. (2024). AI-Driven Approach for Enhancing Sustainability in Urban Public Transportation. *MDPI*.
- Luna-Pérez , M., & Vázquez-Álvarez , G. (2019). Metodología de mantenimiento predictivo 4.0 para asegurar procesos de producción. *Revista Iberoamericana de Sistemas, Cibernética e Informática*.
- Macian Martinez, V., Tormos Martínez, B., & Olmeda González , P. (1999). *Fundamentos de Ingeniería del Mantenimiento*.
- Mansourian, P., Zhang, N., Jaekel, A., & Kneppers, M. (2023). Deep Learning-Based Anomaly Detection for Connected Autonomous Vehicles Using Spatiotemporal Information. *IEEE Xplore*.
- Massaro, A., Selicato, S., & Galiano, Á. (2020). Predictive Maintenance of Bus Fleet by Intelligent Smart Electronic Board Implementing Artificial Intelligence. *MDPI*.
- MathWorks. (2025). *Introducción a la memoria a corto-largo plazo (LSTM)*. Obtenido de MathWorks: <https://la.mathworks.com/discovery/lstm.html>

- Meraz-Mendez, M., Lerma-Hernandez, C., & Corral-Ramirez, G. (2019). Industry 4.0 in Industrial Maintenance. *Revista de Ingeniería Industrial*.
- Mérida Fernández, J. (2024). Riesgos asociados a la intervención en siniestro viales con implicación de vehículos eléctricos. *Revista Logos Guardia Civil*.
- Mitchell, T. (1997). *Machine Learning*. McGraw-Hill Science/Engineering/Math.
- Mouha, R. A. (2021). Internet de las cosas (IoT). *Scientific Research Publishing*.
- Rausand, M., & Oien, K. (1996). The basic concepts of failure analysis. *Reliability Engineering & System Safety*.
- Ribeiro, D., Rakoczy, A. M., Cabral, R., Hoskere, V., Narazaki, Y., Santos, R., . . . Futai, M. (2025). Methodologies for Remote Bridge Inspection—Review. *MDPI*.
- Rodríguez-Hernández, M., Crespo-Márquez, A., Sánchez-Herguedas, A., & González-Prida, V. (2025). Digitalization as an Enabler in Railway Maintenance: A Review from “The International Union of Railways Asset Management Framework” Perspective. *MDPI*.
- Rouhiainen, L. (2018). *Inteligencia artificial. 101 cosas que debes saber hoy sobre nuestro futuro*.
- Sánchez Márquez, R. (2024). *Maintenance 4.0 applied to vehicle fleets: current status and proposal for practical use in urban transport fleets*.
- Sánchez Márquez, R. E. (2024). *TFM - Maintenance 4.0 applied to vehicle fleets: current status and proposal for practical use in urban transport fleets*. Valencia.
- Sarih, H., Tchangani, A., Medjaher, K., & Pere, E. (2019). Data preparation and preprocessing for broadcast systems monitoring in PHM framework. *Institute of Electrical and Electronics Engineers* .
- Shinde, P., & Shah, S. (2018). A Review of Machine Learning and Deep Learning Applications. *IEEE Xplore*.
- Sthephens, D., Shawcross, P., Stout, G., Sullivan, E., Saunders, J., Risser, S., & Sayre, J. (2017). *Lithium-ion Battery Safety Issues for Electric and Plug-in Hybrid Vehicles*.

- Todorović, I., Jovanović, M., Krivokapić, J., Dragutin Milkovic, D., Lucanin, V., & Tanasković, J. (2024). Digital Transition of the Maintenance Process: Case of Rail Transport Company. *43RD INTERNATIONAL CONFERENCE ON ORGANIZATIONAL SCIENCE DEVELOPMENT: GREEN AND DIGITAL TRANSITION – CHALLENGE OR OPPORTUNITY*, (págs. 988-998).
- Tormos, B., Bermudez, V., Sánchez-Márquez, R., & Alvis, J. (2025). A Reproducible Pipeline for Leveraging Operational Data Through Machine Learning in Digitally Emerging Urban Bus Fleets. *MDPI*.
- Tormos, B., Pla, B., Sánchez-Márquez, R., & Carballo, J. (2025). Explainable AI Using On-Board Diagnostics Data for Urban Buses Maintenance Management: A Study Case. *MDPI*.
- Vaca-Bustos, L., & Sánchez-Parrales, L. (2024). *Uso de la Inteligencia Artificial (IA), aplicada al transporte público del cantón Santo Domingo, Provincia Santo Domingo de los Tsáchilas, año 2024*.
- Waditwar, P. (2025). Agentic AI and sustainable procurement: Rethinking anti-corrosion strategies in oil and gas. *World Journal of Advanced Research and Reviews*.
- Werbińska-Wojciechowska, S., Giel, R., & Winiarska, K. (2024). Digital Twin Applications in Internal Transportation Systems Maintenance: A Conceptual Framework. *IEEE Xplore*.
- Werbińska-Wojciechowska, S., Giel, R., & Winiarska, K. (2024). Digital Twin Approach for Operation and Maintenance of Transportation System—Systematic Review. *MDPI*.
- Zeng, Z., Wang, S., & Qu, X. (2022). On the role of battery degradation in en-route charge scheduling for an electric bus system. *Transportation Research Part E: Logistics and Transportation Review*.

9 Anexos

9.1 Registro del Estado del Vehículo

Las 28 variables del sistema de climatización, junto con su respectiva descripción, presentes en los informes de Diagnóstico de la plataforma del proveedor externo, que conforman los registros del Estado del Vehículo, son las siguientes:

1. Temperatura Del Evaporizador (Parte Trasera, Techo) (°C): es la temperatura indicada por el sensor ubicado sobre la superficie del evaporador.
2. Temperatura Del Líquido Refrigerante (°C): es la temperatura indicada por el sensor ubicado en la entrada al condensador.
3. Temperatura Nominal (Zona De Pasajeros) (°C): no representa un sensor específico, pero se expresa como función de otra variable.
4. Temperatura Externa (°C): es la temperatura indicada por el sensor ubicado en el exterior del vehículo, sobre la zona frontal.
5. Temperatura De Salida Del Aire (Parte Trasera - Techo), Valor Nominal (°C): no representa un sensor específico, pero se expresa como función de otra variable.
6. Temperatura De Salida Del Aire (Parte Trasera - Techo) (°C): es la temperatura indicada por el sensor ubicado sobre conducto de aire proveniente de evaporador hasta zona de pasajeros.
7. Posición De La Compuerta De Circulación De Aire, Parabrisas, Valor Nominal (%): indica el porcentaje de apertura/cierre según la posición de la compuerta que dirige aire hacia la zona del parabrisas.
8. Posición De La Compuerta De Circulación De Aire, Zona Reposapiés, Valor Nominal (%): indica el porcentaje de apertura/cierre según la posición de la compuerta que dirige aire hacia la zona del reposapiés del conductor.
9. Posición De La Compuerta De Circulación De Aire, Aire Exterior/Aire Recirculante, Valor Nominal (%): indica el porcentaje de apertura/cierre según la posición de las compuertas ubicadas en el techo del vehículo, que permiten el paso o no, de aire desde el exterior hacia el interior del mismo.
10. Posición De La Compuerta De Circulación De Aire (Parte Delantera, Techo, Derecha), Valor Nominal (%): indica el porcentaje de

apertura/cierre al paso de aire, según la posición de las compuertas ubicadas entre, los evaporadores (exterior) y la zona de pasajeros (interior). Dicha variable opera en conjunto con las N° 11, 12 y 13.

11. Posición De La Compuerta De Circulación De Aire (Parte Delantera, Techo, Izquierda), Valor Nominal (%).
12. Posición De La Compuerta De Circulación De Aire (Parte Trasera, Techo, Derecha), Valor Nominal (%).
13. Posición De La Compuerta De Circulación De Aire (Parte Trasera, Techo, Izquierda), Valor Nominal (%).
14. Sopladores (Lado Del Conductor), Tiempo De Servicio (h): indica el tiempo de servicio, en horas, de sopladores que inyectan aire al conductor.
15. Sopladores (Techo), Tiempo De Servicio (h): indica el tiempo de servicio, en horas, de sopladores ubicados próximos a los evaporadores.
16. Sopladores (Condensador), Tiempo De Servicio (h): indica el tiempo de servicio, en horas, de sopladores del condensador.
17. Compresor, Tiempo De Servicio (h): indica el tiempo de servicio, en horas, del compresor.
18. Número De Revoluciones Del Soplador, Área Del Conductor (Valor Nominal) (%): indicado a través de porcentaje, la velocidad de giro del soplador de conductor.
19. Número De Revoluciones Del Soplador (Parte Delantera, Techo, Delante), Valor Nominal (%): indicado a través de porcentaje, la velocidad de giro de sopladores de evaporador. Dicha variable opera en conjunto con las N° 20, 21 y 22.
20. Número De Revoluciones Del Soplador (Parte Delantera, Techo, Detrás), Valor Nominal (%).
21. Número De Revoluciones Del Soplador (Parte Trasera, Techo, Detrás), Valor Nominal (%).
22. Número De Revoluciones Del Soplador (Parte Trasera, Techo, Delante), Valor Nominal (%).
23. Número De Revoluciones Del Soplador, Soplador Del Condensador (Parte Delantera), Valor Nominal (%): indicado a través de porcentaje, la velocidad de giro de sopladores del condensador. Dicha variable opera en conjunto con las N° 24.

24. Número De Revoluciones Del Soplador, Soplador Del Condensador (Parte Trasera), Valor Nominal (%).
25. Circuito De Agente Frigorígeno (Parte Trasera), Presión (bar): indica la presión del líquido refrigerante, en bar, a la salida del compresor.
26. Modo "Refrigeración": indica cuando el equipo de aire acondicionado este operando o no, indicando como "activado" o "desactivado", respectivamente.
27. Modo Descongelación: indica cuando la función de desempañante del parabrisa está operando o no, indicando con "activado" o "desactivado", respectivamente.
28. Función Ahorro De Energía: esta función opera automáticamente cuando el modo "refrigeración" esta "activado", se emplea en el sistema de climatización para optimizar los recursos del sistema de climatización.

9.2 Histórico de Diagnosis

A continuación, en la Tabla 14 se presenta el registro completo del "Histórico de Diagnosis", que incluye los códigos de fallo, su descripción y la información complementaria correspondiente.

Tabla 14. Registro completo del Histórico de Diagnosis

Histórico de Diagnosis			
Nro.	Código de fallo	Error	Información extra
1	95F0F5	Agente frigorígeno. Circuito. Presión baja inaceptable.	Perturbación de baja presión en el circuito de agente frigorígeno
2	1BF2E7	Servomotor para la compuerta del techo. Aire. (Exterior.). Posición incorrecta.	El motor eléctrico '51M01: Motor Frischluftklappe Dachanlage' tiene un error de posicionamiento.
3	18F0E7	Servomotor de la trampilla. Parte delantera. Posición incorrecta.	Componente 'CU X2/10,11 Solapa del parabrisas Error de posicionamiento'
4	60F0F3	Unidad de control Multiplexor 1 (MUX1). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje MUX1 HVAC Gr1 Interrupción de la comunicación'
5	85F0F3	Unidad de control de instrumentación. El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje Cmd de Panel Lmp Interrupción de la comunicación'

6	63F0F3	Función de detección de día/noche de la unidad de control de la instrumentación. El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de Día y Noche Interrupción de la comunicación'
7	9FF0F3	Bus CAN del habitáculo. Error de comunicación.	La comunicación con el CAN del habitáculo tiene una irregularidad de funcionamiento.
8	9EF0F3	Bus CAN del habitáculo. Error de comunicación.	Componente 'CU CAN - Mensaje EngCrk Interrupción de la comunicación'
9	86F0F3	Unidad de control de instrumentación. El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Panel Lmp Dim Message Interrupción de la comunicación'
10	5EF0F3	Unidad de control de la gestión del motor (MCM). "Arranque del motor." El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje MCM C02 Interrupción de la comunicación'
11	5DF0F3	Unidad de control Multiplexor 1 (MUX1). "Terminal 15. Estado de encendido." El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje SCA de IgnSw Interrupción de la comunicación'
12	53F0F3	Unidad de control calefacción, ventilación y climatización. Unidad de control de regulación de marcha (CPC). Error en las comunicaciones CAN.	Componente 'CU CAN - Mensaje CCVS Pkt Interrupción de la comunicación'
13	64F0F3	Problema de comunicación del bus CAN: Recepción Fecha / hora. Unidad de control de instrumentación. El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Disp Date Tm Md Message Interrupción de la comunicación'
14	D6F0E2	Unidad de control calefacción, ventilación y climatización. Parámetros incorrectos.	Componente 'CU Error de suma de comprobación de EEPROM Aplicación'
15	58F2E8	Subestación 0. Pin X1/24. Señal PWM. Señal no plausible.	La señal PWM del componente 'SU0 X1/24' no es plausible.
16	28F2E5	Subestación 0. Pin X1/26. Sensor de temperatura exterior. Parte delantera. En el techo. Circuito abierto.	Componente 'SU0 X1/26 sensor de temperatura de salida de aire TopAir roof front Circuito abierto'
17	08F2E2	Subestación 0. Pin X1/22-31. Válvula de agua del circuito de refrigeración. Zona del suelo. Puerta de acceso. (2). Señal de retorno. Los datos recibidos son inválidos.	Componente 'SU0 X1/22,31 Piso de la válvula de agua segunda entrada Comentarios no válidos'

18	OCF2E5	Subestación 0. Pin X1/22-31. Válvula de agua del circuito de refrigeración. Zona del suelo. Puerta de acceso. (2). Circuito abierto.	Componente 'SU0 X1/22,31 Piso de la válvula de agua segunda entrada Circuito abierto»
19	29F2E5	Subestación 0. Pin X1/17. Sensor de temperatura exterior. Parte trasera. En el techo. Circuito abierto.	Componente 'SU0 X1/17 sensor de temperatura de salida de aire TopAir roof rear Circuito abierto»
20	03F2E5	Subestación 0. Pin X1/2. Calefacción adicional. Solicitud de estado económico. Circuito abierto.	Componente 'SU0 X1/2 Modo económico del calentador adicional cableado (solo opcional) Circuito abierto'
21	01F1E4	Subestación 0. Pin X1/16. Cortocircuito a masa.	El componente 'SU0 X1/16' tiene cortocircuito contra masa.
22	0BFOE2	Válvula de agua. Circuito de calefacción. Lado del conductor. No responde.	Componente 'CU X1/22,31 Calefacción de la caja frontal de la válvula de agua Comentarios no válidos'
23	0CFOE7	Válvula de agua. Circuito de calefacción. Lado del conductor. Posición incorrecta.	Componente 'CU X1/22,31 Calefacción de la caja frontal de la válvula de agua Error de posicionamiento'
24	17FOE2	Servomotor de la trampilla. Parte delantera. No responde.	Componente 'CU X2/10,11 Solapa del parabrisas Comentarios no válidos'
25	59F0F3	Unidad de control de la calefacción adicional. (IBH). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje estadístico de IBH Actv Rdy Interrupción de la comunicación'
26	5CF0F3	Unidad de control de la calefacción adicional. (IBH). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de estadísticas IBH Interrupción de la comunicación'
27	52F0F3	Unidad de control calefacción, ventilación y climatización. Unidad de control de la cerradura electrónica de encendido. Error en las comunicaciones CAN.	Componente 'CU CAN - Mensaje EIS AuxHt Rq Interrupción de la comunicación'
28	5AF0F3	Señal CAN Temperatura líquido refrigerante. Unidad de control de la calefacción adicional. (IBH). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - IBH Mensaje de temperatura del agua fría Interrupción de la comunicación'
29	84F0F3	Estado del calefactor auxiliar de la bomba de agua. Unidad de control de la calefacción adicional. (IBH). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje estadístico de la bomba de circuito IBH Interrupción de la comunicación'

30	F8F0E7	Subestación 2. Pin X1/18. Ventilador del condensador. Al menos uno de los módulos de control tiene un error.	Componente 'SU2 X1/18 Soplador de condensador de diagnóstico el soplador no gira'
31	39F0E4	Unidad de control calefacción, ventilación y climatización. Baja tensión.	Componente 'CU X2/22 ECU Supply Under Voltage'
32	2EF2E4	Subestación 0. Pin X2/22. Alimentación de tensión. Tensión demasiado baja.	Componente 'SU0 X2/22 ECU Supply Under Voltage'
33	57F0F3	Unidad de control Multiplexor 1 (MUX1). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de requisito de reducción del techo del ventilador HVAC Interrupción de la comunicación'
34	55F0F3	Unidad de control de regulación de marcha (CPC). Señal CAN Temperatura líquido refrigerante. El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - ET1 Mensaje Pkt Interrupción de la comunicación'
35	5FF0F3	Unidad de control de regulación de marcha (CPC). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de unidad métrica Interrupción de la comunicación'
36	62F0F3	Unidad de control Multiplexor 1 (MUX1). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de requerimiento de área de AC Drv de gestión de energía HVAC Interrupción de la comunicación'
37	50F0F3	Unidad de control de instrumentación. Error de comunicación.	Componente 'CU CAN - Mensaje de desplazamiento de hora local de ICUC Interrupción de la comunicación'
38	54F0F3	Unidad de control calefacción, ventilación y climatización. Unidad de control de instrumentación. Error en las comunicaciones CAN.	Componente 'CU CAN - CurrLang Pkt Mensaje Interrupción de la comunicación'
39	51F0F3	Unidad de control de instrumentación. Error de comunicación.	Componente 'CU CAN - Mensaje de Hora ICUC Interrupción de la comunicación'
40	58F0F3	Unidad de control Multiplexor 1 (MUX1). El mensaje CAN falta o es incorrecto.	Componente 'CU CAN - Mensaje de reducción de la bomba de agua fría HVAC Power Mgmt Interrupción de la comunicación'
41	16F1F3	Bus CAN del habitáculo. Error de comunicación.	La comunicación con el CAN del habitáculo tiene una irregularidad de funcionamiento.
42	89F0F3	Bus CAN del habitáculo. Error de comunicación.	Componente 'CU CAN - Mensaje de distribución total del vehículo Interrupción de la comunicación'

43	88F0F3	Bus CAN del habitáculo. Error de comunicación.	La comunicación con el CAN del habitáculo tiene una irregularidad de funcionamiento.
44	04F2E5	Subestación 0. Pin X2/20. Embrague compresor. Circuito abierto.	Componente 'SU0 X2/20 embrague del compresor Circuito abierto'
45	95F0F4	Agente frigorígeno. Sistema de alta presión. .	Perturbación de alta presión en el circuito de agente frigorígeno
46	0FF2E7	Subestación 0. Pin X1/32-23. Válvula de agua del circuito de refrigeración. En el techo. Derecha. Posición incorrecta.	El motor eléctrico 'SU0 X1/32,23 51M86 (Motor válvula de agua circuito de calefacción techo, delante)' tiene un error de posicionamiento.
47	15F2E7	Unidad de control. Pin X1/32-23. Compuerta. Zona de reposapiés. Posición incorrecta.	Componente 'CU X1/32,23 Solapa para los pies error de posición'
48	14F2E2	Subestación 0. Pin X2/10-11. Válvula de agua del circuito de refrigeración. En el techo. Izquierda. Señal de retorno. Los datos recibidos son inválidos.	Componente 'SU0 X2/10,11 Válvula de agua calefacción de techo izquierda Comentarios no válidos'
49	8BF0E3	Válvula de agua. Circuito de calefacción. Lado del conductor. Cortocircuito a positivo.	Componente 'CU X1/22 Calefacción de la caja frontal de la válvula de agua Corto a VBA'
50	46F0E4	Servomotor de la trampilla. Parte delantera. Respuesta errónea o inexistente.	Componente 'CU X2/14 PotiRef 1 Bajo voltaje '
51	8CF0E3	Válvula de agua. Circuito de calefacción. Lado del conductor. Cortocircuito a positivo.	Componente 'CU X1/31 Calefacción de la caja frontal de la válvula de agua Corto a VBAT'
52	0FF0E5	Válvula de agua. Circuito de calefacción. Lado del conductor. Circuito abierto.	Componente 'CU X1/22,31 Calefacción de la caja frontal de la válvula de agua Circuito abierto»
53	46F0E3	Servomotor de la trampilla. Parte delantera. Respuesta errónea o inexistente.	Componente 'CU POTIRB Sobretensión'
54	8CF0E4	Válvula de agua. Circuito de calefacción. Lado del conductor. Cortocircuito a masa.	Componente 'CU X1/31 Calefacción de la caja frontal de la válvula de agua Corto a GND'
55	8BF0E4	Válvula de agua. Circuito de calefacción. Lado del conductor. Cortocircuito a masa.	Componente 'CU X1/22 Calefacción de la caja frontal de la válvula de agua Corto a GND'
56	1AF2E2	Trampilla de ventilación. En el techo. Parte trasera.	Componentes 'aletas de ventilación traseras'

57	2BF2E4	Subestación 0. Pin X1/36. Sensor de formación de hielo. En el techo. Cortocircuito a masa.	Componente 'SU0 X1/36 Unidad de techo con sensor de formación de hielo Corto a GND'
58	1EF2E5	Subestación 0. Servomotor. Pin X2/1-2. Circuito abierto.	Componente 'Subestación0 Servomotor X2/1,2 Circuito abierto»
59	F6F0E7	Subestación 0. Pin X1/18. Soplador de las cajas del techo. Parte delantera. Componente atascado.	Componente 'SU0 X1/18 Unidad de techo de soplantes de diagnóstico colectivo TopAir frontal al menos un soplador no gira»
60	F7F0E7	Subestación 1. Pin X1/18. Soplador de las cajas del techo. Parte delantera. Componente atascado.	Componente 'SU1 X1/18 Unidad de techo de soplantes de diagnóstico colectivo TopAir frontal al menos un soplador no gira»
61	02F2E5	Subestación 0. Pin X1/1. Calefacción adicional. Circuito abierto.	Componente 'SU0 X1/1 calefacción adicional Calefacción máxima Circuito abierto'
62	2BF2E5	Subestación 0. Pin X1/36. Sensor de formación de hielo. En el techo. Circuito abierto.	Componente 'SU0 X1/36 Unidad de techo con sensor de formación de hielo Circuito abierto'
63	37F0E3	Sensor de temperatura. Calefacción. Habitáculo interior. Cortocircuito a positivo.	El componente '53B11 (Sensor térmico calefacción de ambiente, ventilar)' tiene cortocircuito contra el polo positivo.
64	42F0E8	Unidad de control calefacción, ventilación y climatización. Pin X1/24. Señal PWM. Señal no plausible.	La señal PWM del componente 'CU X1/24' no es plausible.
65	30F0E3	Sensor de temperatura de soplado. Lado del conductor. Cortocircuito a positivo.	Componente 'CU X1/35 Sensor de temperatura de salida de aire Frontbox Corto a VBAT'
66	37F0E4	Sensor de temperatura. Calefacción. Habitáculo interior. Cortocircuito a masa.	El componente '53B11 (Sensor térmico calefacción de ambiente, ventilar)' tiene cortocircuito contra masa.
67	0EF2E2	Subestación 0. Pin X1/32-23. Válvula de agua del circuito de refrigeración. En el techo. Derecha. Señal de retorno. Los datos recibidos son inválidos.	Componente 'SU0 X1/32,23 válvula de agua calefacción de techo derecha Comentarios no válidos'