



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA


ETSI Aeroespacial y Diseño Industrial

UNIVERSITAT POLITÈCNICA DE VALÈNCIA

Escuela Técnica Superior de Ingeniería Aeroespacial
y Diseño Industrial

Análisis de la degradación de las baterías en vehículos
eléctricos en una flota de autobuses mediante una
aproximación basada en datos

Trabajo Fin de Máster

Máster Universitario en Ingeniería del Mantenimiento

AUTOR/A: Añó Luzuriaga, David

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

Análisis de la degradación de las baterías en vehículos eléctricos en una flota de autobuses mediante una aproximación basada en datos

Trabajo Fin de Máster

Máster Universitario en Ingeniería del Mantenimiento

Curso 2025/2026

Autor: David Añó Luzuriaga

Tutores: Bernardo Vicente Tormos Martínez

Revisor: Ramón Eduardo Sánchez Márquez



Agradecimientos

Quiero expresar mi más sincero agradecimiento a Bernardo Vicente Tormos Martínez por la confianza que depositó en mí al ofrecerme la oportunidad de realizar las prácticas en su departamento de la Universitat Politècnica de València, una experiencia muy enriquecedora que me ha permitido aprender, crecer profesionalmente y adquirir conocimientos que sin duda me acompañarán en mi futuro profesional. Mi agradecimiento también a Ramón Eduardo Sánchez Márquez, revisor de este Trabajo Fin de Máster, por su cercanía, dedicación y paciencia, por estar siempre pendiente de que cada apartado estuviera correctamente explicado y por enseñarme, durante las prácticas, una forma de trabajar más rigurosa y profesional, especialmente en la elaboración de informes. A ambos les agradezco profundamente el tiempo que me han dedicado, el trato recibido y el interés que han mostrado por mi formación, así como el esfuerzo que realizaron para que pudiera finalizar las prácticas y este Trabajo Fin de Máster varios meses antes de los plazos establecidos por el Máster Universitario en Ingeniería del Mantenimiento, permitiéndome regresar a mi ciudad una vez concluida esta etapa. Ha sido un auténtico placer formar parte de este equipo y me llevo un recuerdo extraordinario de esta experiencia. Finalmente, quiero dar las gracias a mi familia por su apoyo incondicional, por la confianza que siempre han depositado en mí y por guiarme en cada paso de este camino. Gracias por estar siempre a mi lado, por enseñarme los valores que me han convertido en la persona que soy hoy y por hacer que este logro sea también vuestro.



Resumen

La electrificación de las flotas de autobuses urbanos se ha convertido en una de las principales estrategias para avanzar hacia modelos de movilidad más sostenibles y reducir las emisiones contaminantes en las ciudades. En este contexto, las baterías representan uno de los componentes más críticos y costosos de los vehículos eléctricos, ya que condicionan directamente la autonomía, la eficiencia operativa y la vida útil del servicio. Su degradación progresiva depende de múltiples factores asociados a las condiciones reales de explotación, como los perfiles de conducción, las características de las rutas urbanas, los ciclos de carga y descarga o las estrategias de recarga empleadas, pudiendo generar diferencias significativas en el comportamiento y la vida útil de las baterías dentro de una misma flota. A partir de esta problemática, el trabajo se centra en el aprovechamiento de datos operativos procedentes de la flota de autobuses eléctricos con el objetivo de analizar el comportamiento y la degradación de las baterías en condiciones reales de servicio, evaluando el impacto que tienen las distintas líneas y condiciones de trabajo sobre el estado de salud y el rendimiento energético de las mismas. De esta manera, el estudio busca contribuir a una mejor comprensión del comportamiento real de estos sistemas y servir como base para futuras estrategias de mantenimiento, gestión energética y optimización operativa de las flotas eléctricas.

Palabras claves: Mantenimiento 4.0; Autobuses eléctricos; Degradación de baterías; Análisis de datos; Estado de salud de baterías; Big Data.



Abstract

The electrification of urban bus fleets has become one of the main strategies for moving towards more sustainable mobility models and reducing pollutant emissions in cities. In this context, batteries represent one of the most critical and expensive components of electric vehicles, as they directly determine vehicle range, operational efficiency, and service continuity. Their progressive degradation depends on multiple factors associated with real operating conditions, such as driving profiles, characteristics of urban routes, charge and discharge cycles, and charging strategies employed, which may lead to significant differences in battery performance and lifespan within the same fleet. Based on this issue, the present work focuses on the use of operational data obtained from electric bus fleets with the aim of analysing battery behaviour and degradation under real service conditions, evaluating the impact that different routes and operating conditions have on battery health and energy performance. In this way, the study seeks to contribute to a better understanding of the real behaviour of these systems and to serve as a basis for future maintenance strategies, energy management, and operational optimisation of electric fleets.

Keywords: Maintenance 4.0; Electric buses; Battery degradation; Data analysis; Battery state of health; Big Data.



Contenido

1	Introducción.....	1
1.1	Contexto y motivación.....	1
1.2	Transporte público y movilidad sostenible.....	2
1.3	Objetivos	3
1.4	Alcance del estudio	4
2	Revisión de la literatura	5
2.1	Industria 4.0	5
2.2	Mantenimiento 4.0	7
2.3	IA aplicada al mantenimiento.....	10
2.4	Electrificación del sector automovilístico	13
2.5	Mantenimiento vehicular de flota de autobuses eléctricos utilizando IA.....	19
3	Objetivos de Desarrollo Sostenible	23
3.1	ODS 9. Industria, innovación e infraestructura	23
3.2	ODS 11. Ciudades y comunidades sostenibles	24
3.3	ODS 12. Producción y consumo responsables	24
3.4	ODS 13. Acción por el clima.....	24
4	Metodología.....	24
4.1	Problemática de estudio y descripción de la flota.....	24
4.2	Recopilación de datos e infraestructura disponible.....	27
4.3	Integración y validación de datos.....	30
4.4	Caracterizar comportamiento energético de la flota	37
4.5	Análisis de la degradación de las baterías	46
4.6	Influencia energética en las líneas de operación	53
4.7	Análisis exploratorio mediante clustering	68
5	Presupuesto para la realización del TFM.....	73
6	Conclusiones.....	74
7	Trabajos a futuro	75
8	Bibliografía.....	76

Índice de Tablas

TABLA 1: CARACTERÍSTICAS GENERALES DE LA FLOTA OBJETO DE ESTUDIO.....	27
TABLA 2: VARIABLES MÁS EMPLEADAS PARA CALCULAR LOS RESULTADOS DE DEGRADACIÓN Y PRÓXIMOS ESTUDIOS.	29
TABLA 3: VARIABLES UTILIZADAS DURANTE EL PROCESO DE INTEGRACIÓN.....	31
TABLA 4: PENDIENTES DE LAS RECTAS DE REGRESIÓN Y PORCENTAJE DE DEGRADACIÓN ESTIMADO PARA LOS VEHÍCULOS ESTUDIADOS.	51



TABLA 5: COBERTURA TEMPORAL DE LAS LÍNEAS DE OPERACIÓN.	54
TABLA 6: RESUMEN DE PARÁMETROS OPERATIVOS DE LAS PRINCIPALES LÍNEAS ANALIZADAS.	56
TABLA 7: VALORES MEDIOS DE LAS PRINCIPALES VARIABLES ENERGÉTICAS.	57
TABLA 8: INTERVALO ANUAL DE LAS PRINCIPALES VARIABLES ENERGÉTICAS PARA LAS LÍNEAS ANALIZADAS.	63
TABLA 9: VARIABLES UTILIZADAS EN EL ANÁLISIS EXPLORATORIO MEDIANTE CLUSTERING.	68
TABLA 10: DISTRIBUCIÓN PORCENTUAL DE LOS EVENTOS DE CADA LÍNEA ENTRE LOS CLUSTERS OBTENIDOS MEDIANTE K-MEANS.	69
TABLA 11: PRESUPUESTO PARA EJECUCIÓN DEL TFM.	73

Índice de Figuras

FIGURA 1: PRINCIPALES TECNOLOGÍAS ASOCIADAS A LA INDUSTRIA 4.0.	5
FIGURA 2: EVOLUCIÓN DE LAS ESTRATEGIAS DE MANTENIMIENTO HACIA EL MANTENIMIENTO 4.0 BASADO EN MONITORIZACIÓN Y ANÁLISIS DE DATOS.	8
FIGURA 3: PROCESO GENERAL DE APLICACIÓN DE TÉCNICAS DE INTELIGENCIA ARTIFICIAL Y MINERÍA DE DATOS EN MANTENIMIENTO PREDICTIVO.	11
FIGURA 4: ZONA DE ESTUDIO Y RELACIÓN ENTRE LA INTENSIDAD DEL TRÁFICO Y LAS CONCENTRACIONES DE NOX EN VALENCIA. ADAPTADO DE (M. G. FOLGADO ET AL., 2025).	14
FIGURA 5: RESULTADOS DE LA PREDICCIÓN DEL ESTADO DE SALUD (SOH) PARA EL CONJUNTO DE DATOS UDDS. EXTRAÍDO DE DING ET AL. (2025).	21
FIGURA 6: VARIACIÓN DEL ESTADO DE SALUD (SOH) BAJO DIFERENTES CONDICIONES DE TEMPERATURA Y CARGA-DESCARGA. EXTRAÍDO DE DING ET AL. (2025).	22
FIGURA 7: ESQUEMA GENERAL DE LA METODOLOGÍA EMPLEADA PARA LA INTEGRACIÓN Y ANÁLISIS DE LOS DATOS PROCEDENTES DE LAS MÚLTIPLES PLATAFORMAS UTILIZADAS.	25
FIGURA 8: DISTRIBUCIÓN DEL SOC INICIAL REGISTRADO COMO COMPROBACIÓN PRELIMINAR DE COMPATIBILIDAD ENTRE PLATAFORMAS.	32
FIGURA 9: DISTRIBUCIÓN DEL SOC FINAL REGISTRADO COMO COMPROBACIÓN PRELIMINAR DE COMPATIBILIDAD ENTRE PLATAFORMAS.	33
FIGURA 10: SOC MEDIO INICIAL Y FINAL POR AUTOBÚS.	33
FIGURA 11: NÚMERO DE REGISTROS DISPONIBLES POR VEHÍCULO EN DATOS OPERATIVOS.	34
FIGURA 12: EJEMPLO ILUSTRATIVO DEL PROCESO DE SELECCIÓN DE LA CARGA ASOCIADA A UN EVENTO DE DESCARGA.	36
FIGURA 13: DIAGRAMA DE FLUJO DEL ALGORITMO DE EMPAREJAMIENTO DESARROLLADO.	37
FIGURA 14: DISTRIBUCIÓN DEL CONSUMO TOTAL DE LA FLOTA.	38
FIGURA 15: DISTRIBUCIÓN DEL CONSUMO ESPECÍFICO DE LA FLOTA.	39
FIGURA 16: DISTRIBUCIÓN DEL DELTA DE SOC.	41
FIGURA 17: RELACIÓN ENTRE DISTANCIA RECORRIDA Y CONSUMO ENERGÉTICO TOTAL.	42
FIGURA 18: RELACIÓN ENTRE DISTANCIA RECORRIDA Y VARIACIÓN DEL ESTADO DE CARGA DE LA BATERÍA.	43
FIGURA 19: RELACIÓN ENTRE VELOCIDAD MEDIA Y CONSUMO ENERGÉTICO TOTAL.	44
FIGURA 20: DISTRIBUCIÓN DEL PORCENTAJE DE CONSUMO DE CLIMATIZACIÓN RESPECTO AL	



CONSUMO ENERGÉTICO TOTAL.....	45
FIGURA 21: COMPARATIVA DEL COMPORTAMIENTO ENERGÉTICO DURANTE LA RECARGA PARA EL VEHÍCULO 2204 UTILIZANDO DATOS DE DICIEMBRE DE 2023 Y DICIEMBRE DE 2025.....	47
FIGURA 22: COMPARATIVA DEL COMPORTAMIENTO ENERGÉTICO DURANTE LA RECARGA PARA EL VEHÍCULO 2214 UTILIZANDO DATOS DE DICIEMBRE DE 2023 Y DICIEMBRE DE 2025.....	48
FIGURA 23: COMPARATIVA DEL COMPORTAMIENTO ENERGÉTICO DURANTE LA RECARGA PARA EL VEHÍCULO 2205 UTILIZANDO DATOS DE DICIEMBRE DE 2023 Y DICIEMBRE DE 2025.....	49
FIGURA 24: COMPARATIVA DEL COMPORTAMIENTO ENERGÉTICO DURANTE LA RECARGA PARA EL VEHÍCULO 2213 UTILIZANDO DATOS DE DICIEMBRE DE 2023 Y DICIEMBRE DE 2025.....	50
FIGURA 25: RANKING DE DEGRADACIÓN ESTIMADA DE LA FLOTA DE AUTOBUSES ELÉCTRICOS.....	52
FIGURA 26: NÚMERO DE EVENTOS REGISTRADOS POR LÍNEA.....	53
FIGURA 27: RELACIÓN ENTRE IC95 % (KWH – ENERGÍA DE CARGA) Y EL NÚMERO DE EVENTOS OBTENIDA MEDIANTE BOOTSTRAP.....	55
FIGURA 28: VALIDACIÓN DE LA REPRESENTATIVIDAD DE LAS LÍNEAS MEDIANTE EL SEGUNDO ANÁLISIS BOOTSTRAP.....	56
FIGURA 29: DIAGRAMAS DE CAJA DEL CONSUMO ENERGÉTICO TOTAL PARA LAS LÍNEAS ELEGIDAS.....	58
FIGURA 30: DIAGRAMAS DE CAJA DEL CONSUMO DE ENERGÍA DEL TREN MOTRIZ PARA LAS LÍNEAS SELECCIONADAS.....	59
FIGURA 31: DIAGRAMAS DE CAJA DEL CONSUMO DE ENERGÍA DE CLIMATIZACIÓN PARA LAS LÍNEAS SELECCIONADAS.....	60
FIGURA 32: DIAGRAMAS DE CAJA DE LA ENERGÍA RECUPERADA MEDIANTE FRENADO REGENERATIVO PARA LAS LÍNEAS SELECCIONADAS.....	61
FIGURA 33: DIAGRAMAS DE CAJA DE LA VARIACIÓN DEL ESTADO DE CARGA DE LA BATERÍA (Δ SOC) PARA LAS LÍNEAS SELECCIONADAS.....	62
FIGURA 34: HISTOGRAMA DEL CONSUMO ENERGÉTICO TOTAL DURANTE EL MES DE ENERO PARA LAS LÍNEAS SELECCIONADAS.....	64
FIGURA 35: HISTOGRAMA DEL CONSUMO ENERGÉTICO TOTAL DURANTE EL MES DE JULIO PARA LAS LÍNEAS SELECCIONADAS.....	65
FIGURA 36: HISTOGRAMA DEL CONSUMO ENERGÉTICO DE CLIMATIZACIÓN DURANTE EL MES DE JULIO PARA LAS LÍNEAS SELECCIONADAS.....	66
FIGURA 37: DIAGRAMAS DE CAJA DE LA VARIACIÓN DEL ESTADO DE CARGA DE LA BATERÍA (Δ SOC) DURANTE EL MES DE JULIO PARA LAS LÍNEAS SELECCIONADAS.....	67
FIGURA 38: DISTRIBUCIÓN DEL CONSUMO DE SOC POR KILÓMETRO PARA LOS TRES CLUSTERS IDENTIFICADOS MEDIANTE EL ALGORITMO K-MEANS.....	69
FIGURA 39: RELACIÓN ENTRE EL CONSUMO DE SOC POR KILÓMETRO Y EL CONSUMO DEL TREN MOTRIZ SEGÚN EL CLÚSTER.....	70
FIGURA 40: RELACIÓN ENTRE EL CONSUMO DE SOC POR KILÓMETRO Y EL CONSUMO DEL SISTEMA HVAC SEGÚN EL CLÚSTER.....	71

1 Introducción

1.1 Contexto y motivación

El transporte constituye uno de los sectores con mayor impacto energético y ambiental a nivel mundial. El crecimiento de las áreas urbanas y el aumento de la demanda de movilidad han provocado un incremento significativo del transporte por carretera durante las últimas décadas, contribuyendo al aumento de las emisiones de gases de efecto invernadero y al deterioro de la calidad del aire en las ciudades (Ibrahim et al., 2025; Lipman, 2025). Como consecuencia, la reducción del impacto ambiental asociado al transporte se ha convertido en uno de los principales objetivos de las políticas orientadas hacia la sostenibilidad y la descarbonización del sector (Lipman, 2025).

En este contexto, la electrificación del transporte se ha consolidado como una de las alternativas más prometedoras para avanzar hacia modelos de movilidad más sostenibles (Lipman, 2025). La incorporación de vehículos eléctricos permite reducir las emisiones contaminantes asociadas a los motores de combustión interna, mejorar la eficiencia energética y disminuir la dependencia de los combustibles fósiles (Lipman, 2025). Dentro de este proceso de transformación, el transporte público urbano desempeña un papel especialmente relevante debido a su capacidad para mover grandes volúmenes de pasajeros de forma eficiente y con un menor impacto ambiental.

Sin embargo, la transición hacia sistemas de transporte electrificados no implica únicamente la sustitución de vehículos convencionales por vehículos eléctricos. La incorporación de nuevas tecnologías de almacenamiento energético, sistemas electrónicos avanzados y plataformas de monitorización genera nuevos retos relacionados con la gestión operativa, la disponibilidad de los vehículos y el mantenimiento de componentes críticos como las baterías (Ibrahim et al., 2025).

Paralelamente, el desarrollo de la Industria 4.0 ha impulsado la digitalización de los sistemas industriales y de transporte mediante la integración de tecnologías como el Internet de las Cosas (IoT), el Big Data, la computación en la nube, los sistemas ciberfísicos y la inteligencia artificial (Mahale et al., 2025; Nagy et al., 2025). Estas herramientas permiten recopilar, almacenar y analizar grandes cantidades de información procedente de sensores y dispositivos conectados, facilitando la supervisión y la optimización de los procesos operativos (Mahale et al., 2025).

La combinación entre electrificación y digitalización ha abierto nuevas oportunidades para el desarrollo de estrategias de mantenimiento predictivo basadas en datos. Gracias a la monitorización continua de los vehículos es posible detectar anomalías, identificar patrones de comportamiento y apoyar la toma de decisiones relacionadas con la gestión y el mantenimiento de las flotas (Agredano et al., 2023; Ibrahim et al., 2025). En este sentido, el análisis de datos procedentes de autobuses eléctricos constituye una herramienta de gran interés para mejorar la eficiencia operativa, reducir costes y aumentar la fiabilidad del servicio.

Por todo ello, resulta necesario estudiar cómo las tecnologías asociadas a la Industria 4.0 y las técnicas de análisis de datos pueden contribuir a optimizar la gestión de las flotas de autobuses eléctricos y facilitar la implantación de estrategias de mantenimiento más avanzadas y eficientes (Agredano et al., 2023; Mahale et al., 2025).

1.2 Transporte público y movilidad sostenible

El transporte público constituye uno de los pilares fundamentales para el desarrollo de sistemas de movilidad sostenible. Su capacidad para reducir el uso del vehículo privado contribuye a disminuir la congestión del tráfico, mejorar la eficiencia energética de los desplazamientos y reducir las emisiones contaminantes generadas en las áreas urbanas (Lipman, 2025).

Entre los diferentes modos de transporte público, los autobuses desempeñan un papel especialmente importante debido a su flexibilidad operativa y a su capacidad para adaptarse a las necesidades de movilidad de diferentes ciudades y regiones. No obstante, las flotas tradicionales basadas en motores de combustión interna continúan siendo una fuente significativa de emisiones contaminantes, especialmente en entornos urbanos con elevada densidad de tráfico (Lipman, 2025).

Ante esta situación, numerosas administraciones están promoviendo la electrificación progresiva de las flotas de transporte público mediante la incorporación de autobuses eléctricos. Estos vehículos permiten reducir significativamente las emisiones directas de contaminantes atmosféricos y contribuyen a mejorar la calidad del aire y la sostenibilidad de las ciudades (Lipman, 2025).

La implantación de autobuses eléctricos requiere, además, el desarrollo de infraestructuras de recarga, sistemas de monitorización y herramientas de gestión capaces

de garantizar la disponibilidad operativa de la flota (Ibrahim et al., 2025). Como consecuencia, la movilidad sostenible no depende únicamente de la utilización de tecnologías de propulsión más limpias, sino también de la capacidad para gestionar de forma eficiente los recursos energéticos y los activos asociados al sistema de transporte.

En este contexto, la digitalización y el análisis de datos adquieren una importancia creciente, ya que permiten supervisar continuamente el funcionamiento de los vehículos y apoyar la toma de decisiones orientadas a mejorar la eficiencia energética, la disponibilidad del servicio y la planificación de las operaciones de mantenimiento (Agredano et al., 2023; Mahale et al., 2025)

1.3 Objetivos

Objetivo general:

Desarrollar una metodología basada en el análisis de datos operativos de una flota de autobuses eléctricos que permita caracterizar su comportamiento energético y evaluar la influencia de las condiciones de explotación sobre el uso de las baterías.

Objetivos específicos:

1. Analizar los datos operativos disponibles de una flota de autobuses eléctricos y las variables asociadas a los procesos de carga y descarga de las baterías.
2. Integrar y preparar los datos procedentes de las distintas fuentes de información para su posterior análisis.
3. Caracterizar el comportamiento energético de la flota mediante el estudio de indicadores relacionados con el consumo, los procesos de carga y el estado de carga de las baterías.
4. Analizar la influencia de las condiciones de operación sobre el comportamiento energético de los vehículos.
5. Comparar el comportamiento energético de los diferentes vehículos y líneas de servicio de la flota.
6. Evaluar el impacto de las diferentes líneas de servicio sobre la utilización de las baterías.
7. Valorar posibles estrategias de asignación de vehículos a líneas que

contribuyan a una utilización más equilibrada de las baterías y a una mejora de la gestión de la flota.

1.4 Alcance del estudio

El presente Trabajo Fin de Máster tiene como objeto de estudio una flota de 20 autobuses eléctricos. La población analizada está constituida por estos vehículos, sobre los que se dispone de información operativa y energética registrada durante su explotación diaria.

La información disponible incluye variables relacionadas con la operación de los vehículos y el comportamiento de sus baterías, entre las que se encuentran el estado de carga (SOC), la energía suministrada durante las recargas, la energía consumida durante la operación, la duración de los procesos de carga y descarga, el tiempo de servicio, la distancia recorrida, la velocidad de circulación y otros parámetros asociados al funcionamiento diario de la flota. Estas variables permiten caracterizar el uso de los vehículos y analizar su comportamiento energético desde diferentes perspectivas.

La base de datos empleada comprende el periodo comprendido entre el 23 de noviembre de 2023 y el 31 de mayo de 2026. No obstante, se ha excluido del análisis el intervalo comprendido entre el 10 y el 31 de enero de 2025, debido a la ausencia o falta de fiabilidad de los datos disponibles durante dicho periodo.

El objetivo del estudio es analizar el comportamiento energético y operativo de la flota mediante el estudio de los procesos de carga y descarga, los patrones de utilización de los vehículos y las diferencias existentes entre ellos. Asimismo, se pretende identificar los factores operativos que influyen en el consumo energético y establecer una metodología de análisis que permita extraer información útil para apoyar la gestión y el mantenimiento de flotas de autobuses eléctricos, sirviendo además como base para futuras investigaciones sobre la degradación de las baterías.

2 Revisión de la literatura

2.1 Industria 4.0

El concepto de Industria 4.0 hace referencia a la transformación digital de los sistemas productivos mediante la integración de tecnologías avanzadas capaces de conectar procesos, máquinas, dispositivos y personas dentro de un mismo entorno inteligente. Esta nueva revolución industrial surge como consecuencia de la evolución tecnológica experimentada durante las últimas décadas y representa un cambio significativo respecto a los modelos tradicionales de producción (Elnadi & Abdallah, 2024; F. J. Folgado et al., 2024)

La incorporación de tecnologías como la Inteligencia Artificial (IA), el Internet de las Cosas (IoT), el Big Data, la computación en la nube y los sistemas ciberfísicos ha permitido desarrollar fábricas inteligentes caracterizadas por un elevado nivel de automatización, conectividad y capacidad de análisis de información en tiempo real (F. J. Folgado et al., 2024; Sipho et al., 2025)

En la Figura 1 se muestra de manera esquemática las principales tecnologías asociadas a la Industria 4.0 y su interrelación dentro de los sistemas productivos inteligentes.



Figura 1: Principales tecnologías asociadas a la Industria 4.0.

La Industria 4.0 tiene su origen en la evolución de las anteriores revoluciones industriales. La primera revolución industrial estuvo marcada por la mecanización de los procesos productivos gracias al uso de la máquina de vapor; posteriormente, la segunda revolución industrial introdujo la producción en masa y el uso de la electricidad, mientras que la tercera revolución industrial incorporó la automatización y la electrónica en los sistemas de fabricación. Finalmente, la cuarta revolución industrial supone la digitalización completa de la industria mediante la integración de tecnologías inteligentes capaces de intercambiar información de forma autónoma y optimizar continuamente los procesos productivos. Este nuevo paradigma industrial combina automatización avanzada, conectividad digital y análisis de datos para desarrollar sistemas más eficientes, flexibles e inteligentes (Folgado et al., 2024; Yang & Gu, 2021).

Dentro de las tecnologías asociadas a la Industria 4.0, el Internet de las Cosas (IoT) desempeña un papel fundamental al permitir la conexión e intercambio continuo de información entre dispositivos, sensores, máquinas y sistemas de monitorización. Gracias a esta interconectividad es posible capturar datos en tiempo real sobre el estado y funcionamiento de los procesos industriales, facilitando la supervisión de las operaciones y la detección temprana de incidencias. Como consecuencia, las organizaciones pueden mejorar la flexibilidad de producción, reducir tiempos de parada y optimizar el uso de recursos materiales y energéticos (F. J. Folgado et al., 2024; Yang & Gu, 2021).

La información generada por estos sistemas conectados da lugar a grandes volúmenes de datos que requieren herramientas específicas para su almacenamiento, procesamiento y análisis. En este contexto surge el concepto de Big Data, que engloba las tecnologías y metodologías necesarias para gestionar conjuntos masivos de información procedentes de múltiples fuentes. El análisis de estos datos permite obtener información relevante para la toma de decisiones, identificar patrones de comportamiento, detectar anomalías y optimizar el funcionamiento de los sistemas productivos de manera más precisa y eficiente (Rejeb et al., 2025; Yang & Gu, 2021).

Por otro lado, la transformación digital asociada a la Industria 4.0 no solo implica cambios tecnológicos, sino también modificaciones en la estructura y gestión de las organizaciones. Las empresas deben adaptarse a nuevos modelos de producción basados en la automatización, la digitalización y la conectividad, lo que requiere implementar estrategias orientadas a la innovación y a la mejora continua. En este sentido, la gestión

de la calidad también ha evolucionado hacia enfoques más inteligentes y automatizados, integrando tecnologías digitales que permiten supervisar y controlar los procesos productivos de manera más eficiente (Elnadi & Abdallah, 2024; Sipho et al., 2025).

2.2 Mantenimiento 4.0

La evolución de los sistemas productivos impulsada por la Industria 4.0 ha transformado profundamente las estrategias tradicionales de mantenimiento. Durante gran parte del desarrollo industrial, las actividades de mantenimiento se basaron principalmente en enfoques correctivos, donde las intervenciones se realizaban únicamente tras la aparición de una avería. Posteriormente surgieron estrategias preventivas fundamentadas en intervenciones programadas según intervalos de tiempo o uso. Sin embargo, el desarrollo de tecnologías digitales avanzadas ha permitido evolucionar hacia modelos más inteligentes capaces de supervisar continuamente el estado de los activos y anticipar posibles fallos antes de que estos ocurran (Jasiulewicz-Kaczmarek, 2024).

En este contexto surge el concepto de Mantenimiento 4.0, entendido como la aplicación de las tecnologías habilitadoras de la Industria 4.0 a la gestión del mantenimiento industrial. Este enfoque integra herramientas como el Internet de las Cosas (IoT), el Big Data, la inteligencia artificial, el aprendizaje automático, los sistemas ciberfísicos y la computación en la nube con el objetivo de mejorar la fiabilidad, disponibilidad y eficiencia de los activos productivos. La principal característica de este paradigma es la utilización de información obtenida en tiempo real para apoyar la toma de decisiones relacionadas con la operación y el mantenimiento de los equipos (Bouyahrouzi et al., 2025).

Una de las transformaciones más relevantes introducidas por el Mantenimiento 4.0 es la evolución desde estrategias basadas principalmente en la experiencia de los operadores hacia enfoques fundamentados en el análisis de datos. La incorporación de sensores y dispositivos conectados permite recopilar información de forma continua sobre el estado y funcionamiento de los equipos, generando grandes volúmenes de datos que pueden ser procesados mediante técnicas de analítica avanzada. Esto facilita el desarrollo de sistemas de apoyo a la toma de decisiones capaces de identificar patrones de comportamiento, detectar anomalías y anticipar posibles fallos, mejorando así la eficiencia y fiabilidad de los procesos de mantenimiento (Rosati et al., 2023).

La monitorización continua constituye uno de los pilares fundamentales del Mantenimiento 4.0. A través de redes de sensores distribuidos es posible registrar variables operativas como temperatura, vibraciones, presión, consumo energético, corriente eléctrica o ciclos de funcionamiento. Estos datos proporcionan una representación en tiempo real del estado de los activos, permitiendo conocer su condición operativa y detectar desviaciones respecto a los patrones normales de funcionamiento. De esta manera, las intervenciones de mantenimiento pueden planificarse en función del estado real de los equipos y no únicamente mediante calendarios preestablecidos (Mallioris et al., 2024).

Como se observa en la Figura 2, las estrategias de mantenimiento han evolucionado desde modelos correctivos, en los que las intervenciones se realizaban únicamente tras la aparición de fallos, hacia enfoques preventivos basados en inspecciones periódicas y actuaciones programadas.



Figura 2: Evolución de las estrategias de mantenimiento hacia el Mantenimiento 4.0 basado en monitorización y análisis de datos.

Posteriormente, el desarrollo de tecnologías de monitorización y adquisición de datos permitió avanzar hacia estrategias basadas en la condición de los equipos, donde las decisiones de mantenimiento se fundamentan en información obtenida en tiempo real sobre el estado de los activos. Finalmente, la integración de datos procedentes de múltiples fuentes junto con la aplicación de técnicas de análisis de datos e inteligencia artificial ha dado lugar al mantenimiento predictivo, considerado uno de los principales pilares del Mantenimiento 4.0. Este enfoque permite anticipar posibles fallos, optimizar la planificación de las intervenciones y mejorar la disponibilidad y fiabilidad de los sistemas productivos (Mallioris et al., 2024; Rosati et al., 2023).

Dentro de este paradigma, el mantenimiento predictivo ocupa una posición central. Según (Mallioris et al., 2024), el mantenimiento predictivo se ha consolidado como una de las aplicaciones más relevantes de la Industria 4.0 debido a su capacidad para anticipar fallos y optimizar la gestión de activos. Mediante el uso de algoritmos de inteligencia artificial y aprendizaje automático, los sistemas predictivos pueden analizar tendencias históricas, identificar patrones de degradación y estimar la probabilidad de fallo de los equipos. Esto permite programar las intervenciones en el momento más adecuado, reduciendo costes de mantenimiento, minimizando tiempos de inactividad y aumentando la disponibilidad de los sistemas productivos.

Además de sus beneficios operativos, el Mantenimiento 4.0 desempeña un papel importante en la sostenibilidad industrial. (Jasiulewicz-Kaczmarek, 2024) señala que las tecnologías asociadas a este enfoque contribuyen a optimizar el uso de recursos, mejorar la eficiencia energética y prolongar la vida útil de los activos industriales. La capacidad para detectar ineficiencias operativas y actuar de forma temprana sobre posibles problemas reduce el desperdicio de materiales y energía, favoreciendo procesos productivos más sostenibles.

La literatura reciente también destaca la estrecha relación existente entre Industria 4.0 y Mantenimiento 4.0. (Bouyahrouzi et al., 2025) concluyen que la integración de tecnologías digitales dentro de las estrategias de mantenimiento constituye uno de los principales factores para alcanzar sistemas de fabricación sostenibles y competitivos. La combinación de conectividad, análisis de datos y automatización permite desarrollar modelos de mantenimiento más eficientes y adaptables a las condiciones reales de operación.

Por otra parte, (Mouhib et al., 2025) destacan la importancia de integrar los principios del mantenimiento productivo total (TPM) con las tecnologías de Industria 4.0 para desarrollar marcos de actuación estandarizados. La digitalización de los procesos de mantenimiento no solo implica la incorporación de nuevas tecnologías, sino también la adaptación de las metodologías de gestión y de los procedimientos organizativos a un entorno cada vez más conectado e inteligente.

En el ámbito de los vehículos eléctricos, los principios del Mantenimiento 4.0 adquieren una relevancia especial debido a la gran cantidad de información generada por los sistemas embarcados y los dispositivos de monitorización. La disponibilidad de datos

operativos permite supervisar continuamente el comportamiento de componentes críticos como las baterías, facilitando el desarrollo de estrategias de mantenimiento predictivo orientadas a mejorar la fiabilidad del servicio, optimizar el rendimiento energético y prolongar la vida útil de los sistemas de almacenamiento de energía. En este sentido, el análisis de datos procedentes de flotas de autobuses eléctricos constituye una aplicación directa de los principios del Mantenimiento 4.0 y representa una de las líneas de investigación con mayor potencial dentro de la movilidad sostenible (Jasiulewicz-Kaczmarek, 2024; Mallioris et al., 2024; Rosati et al., 2023).

2.3 IA aplicada al mantenimiento

La Inteligencia Artificial (IA) se ha consolidado como una de las tecnologías habilitadoras más relevantes dentro del paradigma de la Industria 4.0, permitiendo transformar la forma en que se supervisan, analizan y gestionan los activos industriales. La creciente digitalización de los procesos productivos y la incorporación de sensores, dispositivos IoT y sistemas de adquisición de datos han generado grandes volúmenes de información que pueden ser aprovechados mediante técnicas avanzadas de análisis para apoyar la toma de decisiones relacionadas con el mantenimiento (Elnadi & Abdallah, 2024; Folgado et al., 2024; Rejeb et al., 2025).

A diferencia de las estrategias tradicionales, basadas principalmente en inspecciones periódicas o intervenciones programadas, la IA permite desarrollar modelos capaces de aprender a partir de datos históricos y operativos para identificar patrones de comportamiento, detectar anomalías y anticipar posibles fallos antes de que estos se produzcan. Este cambio de enfoque ha impulsado la transición desde modelos reactivos y preventivos hacia estrategias de mantenimiento predictivo basadas en la condición real de los activos (Bouyahrouzi et al., 2025; Jasiulewicz-Kaczmarek, 2024; Mallioris et al., 2024).

Dentro de este contexto, el Machine Learning constituye una de las herramientas más utilizadas en mantenimiento predictivo debido a su capacidad para analizar grandes volúmenes de datos y extraer relaciones complejas entre variables operativas. Estos algoritmos permiten desarrollar modelos capaces de detectar desviaciones respecto al comportamiento normal de los sistemas, estimar tendencias de degradación y predecir la aparición de fallos con suficiente antelación para planificar actuaciones de mantenimiento de forma eficiente (Carvalho et al., 2019; Mahale et al., 2025; Rosati et al., 2023).

Por su parte, las técnicas de Deep Learning han ampliado las capacidades de análisis al permitir el tratamiento de conjuntos de datos más complejos y de carácter temporal. Estas metodologías son especialmente útiles cuando se trabaja con señales procedentes de sensores, ya que permiten identificar patrones difíciles de detectar mediante técnicas convencionales. En este ámbito destacan las arquitecturas basadas en redes neuronales recurrentes y modelos LSTM, ampliamente utilizadas para tareas de detección de anomalías, diagnóstico de fallos y monitorización del estado de los activos (Mahale et al., 2025; Pashami et al., 2022).

Como se puede observar en la Figura 3, se muestra de forma esquemática el proceso general de aplicación de técnicas de Inteligencia Artificial y minería de datos al mantenimiento predictivo. El proceso comienza con la comprensión del problema y la definición de los objetivos del análisis, seguido de la recopilación e integración de información procedente de distintas fuentes. Posteriormente, los datos son sometidos a procesos de limpieza, selección, preprocesamiento y transformación con el objetivo de garantizar su calidad y adecuación para el análisis. A continuación, se aplican técnicas de minería de datos y aprendizaje automático para extraer patrones relevantes y generar modelos predictivos. Finalmente, los resultados obtenidos son evaluados e interpretados para generar conocimiento útil que apoye la toma de decisiones relacionadas con la gestión y el mantenimiento de los activos (Carvalho et al., 2019; Nagy et al., 2025; Rosati et al., 2023).



Figura 3: Proceso general de aplicación de técnicas de Inteligencia Artificial y minería de datos en mantenimiento predictivo.

Un ejemplo de aplicación práctica de estas técnicas puede encontrarse en el trabajo desarrollado por (Pashami et al., 2022), quienes propusieron un sistema de detección de fallos basado en un modelo LSTM Autoencoder utilizando datos operativos reales de una

flota de autobuses Volvo. Los resultados obtenidos demostraron la capacidad de este tipo de algoritmos para identificar comportamientos anómalos en etapas tempranas y facilitar la detección de posibles incidencias antes de que se produzcan fallos críticos, contribuyendo así a mejorar la planificación de las actividades de mantenimiento.

La literatura reciente también destaca el creciente interés por la aplicación de la IA en la gestión de flotas de transporte. En este sentido, (Carvalho et al., 2019) desarrollaron una metodología reproducible basada en técnicas de Machine Learning para el aprovechamiento de datos operativos procedentes de flotas urbanas de autobuses. Los autores concluyen que incluso en entornos con una disponibilidad limitada de datos históricos es posible obtener modelos predictivos útiles para apoyar la toma de decisiones de mantenimiento, siempre que se disponga de procedimientos adecuados de tratamiento y actualización de la información (Agredano et al., 2023; Ibrahim et al., 2025).

En el ámbito de los vehículos eléctricos, la Inteligencia Artificial adquiere una relevancia especial debido a la importancia de las baterías dentro del sistema de propulsión. (Cavus et al., 2025) destacan que los algoritmos de Machine Learning, Deep Learning y Reinforcement Learning están permitiendo mejorar significativamente la gestión de baterías mediante la estimación de parámetros fundamentales como el State of Charge (SOC), el State of Health (SOH) y la Remaining Useful Life (RUL). Estas variables permiten evaluar el estado de degradación de las baterías y constituyen indicadores clave para el desarrollo de estrategias de mantenimiento predictivo orientadas a prolongar su vida útil y mejorar la fiabilidad operativa de los vehículos eléctricos (Ibrahim et al., 2025; Mahale et al., 2025).

Asimismo, la integración de tecnologías IoT, plataformas de monitorización y herramientas de análisis avanzado facilita la supervisión continua de las condiciones de funcionamiento de las baterías y otros componentes críticos. Esta capacidad de monitorización en tiempo real permite detectar procesos de degradación de forma temprana y optimizar las estrategias de mantenimiento tanto a nivel individual como en la gestión conjunta de flotas completas de vehículos eléctricos (Agredano et al., 2023; Ibrahim et al., 2025; Rosati et al., 2023).

Por otra parte, la combinación de Inteligencia Artificial, análisis de datos, sistemas digitales avanzados y tecnologías de la Industria 4.0 constituye uno de los pilares fundamentales para el desarrollo de modelos inteligentes de gestión de activos. La

aplicación de estas tecnologías no solo aporta beneficios operativos en términos de reducción de averías y mejora de la disponibilidad de los equipos, sino que también contribuye a incrementar la eficiencia energética y la sostenibilidad de los sistemas productivos (Bouyahrouzi et al., 2025; Jasiulewicz-Kaczmarek, 2024; Mouhib et al., 2025).

En este contexto, la aplicación de técnicas de Inteligencia Artificial al análisis de datos procedentes de flotas de autobuses eléctricos representa una de las líneas de investigación con mayor potencial dentro del mantenimiento predictivo. La disponibilidad de información operativa generada por los sistemas embarcados permite desarrollar modelos capaces de identificar patrones de degradación, estimar el estado de salud de las baterías y apoyar la toma de decisiones orientadas a maximizar la disponibilidad de la flota y prolongar la vida útil de sus componentes críticos. Estos principios constituyen la base metodológica sobre la que se desarrolla el presente trabajo (Agredano et al., 2023; Ibrahim et al., 2025; Mahale et al., 2025).

2.4 Electrificación del sector automovilístico

2.4.1 Contexto e impacto de la contaminación

La creciente preocupación por los efectos del cambio climático, la degradación de la calidad del aire y la dependencia de los combustibles fósiles ha impulsado la búsqueda de alternativas más sostenibles para el transporte. La electrificación del sector automovilístico se ha consolidado como una de las principales estrategias para avanzar hacia una movilidad más sostenible, contribuyendo a la reducción de las emisiones contaminantes y al desarrollo de sistemas de transporte más eficientes (Lane et al., 2018; Lipman, 2025).

Según (M. G. Folgado et al., 2025), el transporte por carretera representa aproximadamente el 60 % de las emisiones urbanas de gases de efecto invernadero en la ciudad de Valencia. Además, los autores señalan que la contaminación atmosférica continúa siendo una de las principales causas ambientales de mortalidad prematura en Europa, estando relacionada con enfermedades respiratorias y cardiovasculares. El estudio destaca especialmente la influencia de los óxidos de nitrógeno (NOx), contaminantes estrechamente vinculados al tráfico rodado y emitidos principalmente por los motores de combustión interna.

El crecimiento de la contaminación en las ciudades durante las últimas décadas ha

provocado un aumento significativo de las emisiones de gases de efecto invernadero y de contaminantes atmosféricos, afectando tanto al medio ambiente como a la salud de la población (Borge et al., 2012; M. G. Folgado et al., 2025).

Con el objetivo de analizar la relación existente entre el tráfico y la calidad del aire, (M. G. Folgado et al., 2025) estudiaron los datos procedentes de estaciones de monitorización y sensores de tráfico distribuidos por la ciudad de Valencia. La Figura 4 muestra una de las zonas analizadas en el estudio, situada en el entorno de la avenida Peris y Valero y la calle Filipinas. En la parte superior se representa la localización de la estación de medida de calidad del aire y del tramo de tráfico estudiado. Por su parte, la gráfica inferior muestra la relación entre la intensidad del tráfico y las concentraciones de NO_x registradas en la zona.




Figura 4: Zona de estudio y relación entre la intensidad del tráfico y las concentraciones de NO_x en Valencia.
Adaptado de (M. G. Folgado et al., 2025).

Los resultados obtenidos muestran una correlación positiva significativa entre la intensidad del tráfico y las concentraciones de NO_x registradas por la estación de

monitorización. Los NO_x (óxidos de nitrógeno), formados principalmente por monóxido de nitrógeno (NO) y dióxido de nitrógeno (NO₂), constituyen algunos de los contaminantes atmosféricos más estrechamente relacionados con las emisiones procedentes del transporte por carretera. Los resultados indican que los incrementos en la intensidad del tráfico se reflejan casi de forma inmediata en un aumento de las concentraciones de NO_x registradas en la zona estudiada, lo que pone de manifiesto la estrecha relación entre la circulación de vehículos y la contaminación atmosférica. Estos resultados confirman la fuerte influencia que tiene el flujo de vehículos sobre la calidad del aire urbano y ponen de manifiesto el potencial de las técnicas de análisis de datos para identificar relaciones entre variables procedentes de diferentes fuentes de información (M. G. Folgado et al., 2025).

Aunque el estudio de (M. G. Folgado et al., 2025) se centra en el análisis de la relación entre tráfico y contaminación, los resultados obtenidos ponen de manifiesto la necesidad de desarrollar estrategias orientadas a reducir las emisiones asociadas al transporte urbano. Entre estas medidas, la sustitución progresiva de vehículos de combustión por vehículos eléctricos constituye una de las alternativas más prometedoras, especialmente en flotas de transporte público, donde la reducción de emisiones puede tener un impacto significativo sobre la calidad del aire (M. G. Folgado et al., 2025; Lipman, 2025).

En este contexto, las administraciones públicas y los operadores de transporte están impulsando estrategias orientadas a la descarbonización de la movilidad urbana, siendo la electrificación de los vehículos una de las alternativas con mayor potencial para alcanzar este objetivo (Lane et al., 2018; Lipman, 2025).

2.4.2 Electrificación como solución tecnológica

La electrificación del transporte se presenta como una de las principales herramientas para reducir las emisiones asociadas a la movilidad urbana. Frente a los vehículos convencionales impulsados exclusivamente mediante motores de combustión interna, los vehículos electrificados permiten disminuir el consumo de combustibles fósiles y reducir las emisiones generadas durante la circulación (Lane et al., 2018; Lipman, 2025)

La transición hacia la movilidad eléctrica no se está produciendo de manera inmediata, sino mediante diferentes niveles de electrificación que permiten una adaptación progresiva de usuarios, fabricantes e infraestructuras. Actualmente pueden distinguirse tres tecnologías principales: los vehículos híbridos (HEV), los vehículos híbridos

enchufables (PHEV) y los vehículos eléctricos puros (BEV) (Lane et al., 2018; Lipman, 2025).

Los vehículos híbridos combinan un motor térmico y uno eléctrico, utilizando la energía recuperada durante la frenada o generada por el propio motor de combustión para alimentar la batería. Por su parte, los vehículos híbridos enchufables incorporan baterías de mayor capacidad que pueden recargarse mediante conexión a la red eléctrica, permitiendo realizar parte de los desplazamientos utilizando únicamente energía eléctrica. Finalmente, los vehículos eléctricos puros eliminan completamente el motor térmico y utilizan exclusivamente la energía almacenada en baterías para alimentar el sistema de propulsión (Lane et al., 2018; Lipman, 2025).

(Lane et al., 2018) destacan que los vehículos eléctricos de batería (BEV) y los híbridos enchufables (PHEV) presentan características diferenciadas tanto desde el punto de vista tecnológico como desde la perspectiva de los usuarios. Mientras que los BEV dependen exclusivamente de la energía almacenada en las baterías, los PHEV incorporan un motor de combustión de respaldo que elimina las limitaciones asociadas a la autonomía. El estudio identifica la denominada *range anxiety* o ansiedad por autonomía como uno de los principales factores que condicionan la adopción de vehículos eléctricos, especialmente en aquellos usuarios que realizan desplazamientos de larga distancia.

Además de sus beneficios medioambientales, la electrificación permite mejorar la eficiencia energética de los sistemas de propulsión, ya que los motores eléctricos presentan rendimientos significativamente superiores a los motores de combustión interna tradicionales (Lane et al., 2018; Lipman, 2025).

2.4.3 Sistemas de almacenamiento energético

Uno de los elementos más importantes de cualquier vehículo eléctrico es el sistema de almacenamiento energético. Actualmente, las baterías de ion-litio constituyen la tecnología predominante en el sector debido a su elevada densidad energética, su capacidad de recarga y su reducido efecto memoria (Das & Kumar, 2023; Kulkarni et al., 2026).

Sin embargo, la batería continúa siendo uno de los componentes más críticos del vehículo eléctrico debido a su elevado coste y a las exigentes condiciones de funcionamiento a las que está sometida. Factores como las vibraciones, los impactos mecánicos, las variaciones de temperatura y los ciclos continuos de carga y descarga pueden acelerar su degradación

y reducir su vida útil, afectando tanto a la autonomía del vehículo como a su rendimiento operativo (Berecibar et al., 2016; Das & Kumar, 2023)

En este sentido, (Jimenez-Martinez et al., 2024) destacan la importancia del diseño estructural de los alojamientos de baterías, cuya función es proteger los módulos frente a solicitaciones mecánicas y térmicas, garantizando al mismo tiempo la seguridad y la durabilidad del sistema. Los autores señalan que la correcta integración estructural de las baterías constituye uno de los principales desafíos de diseño en los vehículos eléctricos actuales.

2.4.4 Gestión energética y digitalización del vehículo

La electrificación del transporte ha ido acompañada de un importante proceso de digitalización de los vehículos. Los sistemas electrónicos actuales permiten monitorizar en tiempo real el estado de funcionamiento de los diferentes componentes, optimizar el consumo energético y mejorar la eficiencia operativa (Ibrahim et al., 2025; Mahale et al., 2025).

Dentro de este ámbito, los sistemas de gestión energética desempeñan un papel fundamental en la coordinación entre los diferentes elementos que intervienen en la propulsión del vehículo. Estos sistemas son responsables de determinar la distribución óptima de energía con el objetivo de minimizar el consumo y maximizar la eficiencia. La toma de decisiones en tiempo real se apoya cada vez más en técnicas avanzadas de análisis de datos y algoritmos inteligentes capaces de adaptarse a las condiciones de operación del vehículo (Shi et al., 2024).

En este contexto, (Shi et al., 2024) desarrollan una estrategia de gestión energética basada en aprendizaje por refuerzo profundo aplicada a vehículos híbridos enchufables. Los resultados obtenidos muestran que el empleo de algoritmos inteligentes permite optimizar la utilización de las diferentes fuentes energéticas disponibles, reduciendo el consumo energético y mejorando el rendimiento global del vehículo.

Además, la incorporación de sensores, sistemas de comunicación y herramientas de análisis de datos facilita el desarrollo de estrategias de mantenimiento predictivo capaces de detectar anomalías antes de que se produzcan averías. Estas tecnologías permiten supervisar continuamente el estado de componentes críticos, mejorar la planificación de las intervenciones de mantenimiento y aumentar la fiabilidad y disponibilidad de los vehículos (Hector & Panjanathan, 2024; Ibrahim et al., 2025; Pashami et al., 2022).

2.4.5 Infraestructura de recarga y aplicación al transporte urbano

El desarrollo de la movilidad eléctrica requiere una infraestructura de recarga adecuada que garantice la disponibilidad energética de los vehículos. La expansión de las redes de carga constituye uno de los factores más importantes para favorecer la implantación de vehículos eléctricos tanto en el ámbito privado como en el transporte público (Deb et al., 2018; Muelas et al., 2026).

(Muelas et al., 2026) destacan la importancia de dimensionar correctamente las instalaciones de recarga para garantizar un funcionamiento eficiente de la infraestructura eléctrica. Los autores analizan el caso de la Universitat Politècnica de València, demostrando que una planificación adecuada permite optimizar la potencia instalada y mejorar la gestión energética de los puntos de recarga.

La literatura reciente también propone modelos avanzados para optimizar simultáneamente la localización de estaciones de recarga, la planificación de las operaciones y la gestión energética de las flotas de autobuses eléctricos, contribuyendo a reducir costes operativos y mejorar la disponibilidad de los vehículos (McCabe & Ban, 2023; Wang et al., 2017; Zhang et al., 2021; Zhou et al., 2022).

En el ámbito del transporte público, la electrificación de las flotas urbanas constituye una de las estrategias más efectivas para reducir las emisiones generadas por la movilidad diaria. En la ciudad de Valencia, ha iniciado un proceso progresivo de incorporación de autobuses eléctricos con el objetivo de disminuir el impacto ambiental del servicio y avanzar hacia un modelo de movilidad más sostenible (Agredano et al., 2023; Lipman, 2025).

La implantación de estos vehículos requiere no solo la adquisición de nuevas unidades, sino también el desarrollo de infraestructuras específicas de recarga, sistemas de monitorización energética y herramientas de gestión capaces de garantizar la disponibilidad operativa de la flota. Por ello, la electrificación del transporte público representa un reto tecnológico que integra aspectos relacionados con la energía, la digitalización, la planificación de infraestructuras y la sostenibilidad ambiental (Agredano et al., 2023; Ibrahim et al., 2025; Zhang et al., 2021).

2.5 Mantenimiento vehicular de flota de autobuses eléctricos utilizando IA

El mantenimiento de las flotas de autobuses eléctricos está experimentando una transformación significativa gracias a la incorporación de tecnologías digitales y herramientas de inteligencia artificial. A diferencia de los enfoques tradicionales basados en mantenimientos preventivos programados, las nuevas estrategias se apoyan en la monitorización continua de los sistemas mediante sensores y sistemas de adquisición de datos. Esta evolución permite conocer en tiempo real el estado de los componentes críticos del vehículo, especialmente de las baterías, facilitando la detección temprana de fallos y la optimización de las operaciones de mantenimiento (Cavus et al., 2025; Ibrahim et al., 2025; Mahale et al., 2025).

Las baterías de ion-litio representan uno de los elementos más importantes de los vehículos eléctricos debido a su influencia directa sobre la autonomía, el rendimiento y los costes de operación. Por este motivo, una parte importante de la investigación reciente se ha centrado en el desarrollo de técnicas capaces de estimar el estado de salud de las baterías (SOH) y predecir su vida útil remanente (*Remaining Useful Life*, RUL). Según (Nazim et al., 2025), los sistemas de *Prognostics and Health Management* (PHM) constituyen una de las principales herramientas para alcanzar estos objetivos, integrando procesos de adquisición de datos, monitorización, diagnóstico, predicción de fallos y toma de decisiones de mantenimiento (Das & Kumar, 2023; Nazim et al., 2025).

La disponibilidad de datos procedentes de los sistemas de gestión de baterías ha impulsado inicialmente la aplicación de técnicas tradicionales de Machine Learning para la estimación del estado de salud de las baterías. Entre los algoritmos más utilizados destacan las máquinas de vectores de soporte (Support Vector Machines, SVM), los bosques aleatorios (Random Forest, RF), los árboles de decisión y los métodos basados en vecinos más cercanos. Estas técnicas permiten identificar relaciones entre variables operativas como la tensión, la corriente, la temperatura o los ciclos de carga y descarga, proporcionando estimaciones precisas del estado de degradación de las baterías (Das & Kumar, 2023; Nazim et al., 2025).

En este contexto, (Das & Kumar, 2023) realizaron una revisión de diferentes algoritmos de aprendizaje automático empleados para la estimación del estado de salud de baterías de vehículos eléctricos. Los autores destacan que modelos como Support Vector Machines (SVM) y Random Forest (RF) proporcionan una elevada precisión predictiva

cuando se dispone de datos adecuados, constituyendo una alternativa eficaz para el desarrollo de estrategias de mantenimiento predictivo. Esta revisión también pone de manifiesto que el rendimiento de los modelos depende en gran medida de la calidad y cantidad de los datos disponibles (Das & Kumar, 2023; Nazim et al., 2025).

La disponibilidad de grandes volúmenes de datos procedentes de los sistemas de gestión de baterías (Battery Management System, BMS) ha favorecido la aplicación de técnicas de inteligencia artificial para la estimación del estado de salud de las baterías y la detección de procesos de degradación. Inicialmente, diversos estudios emplearon algoritmos tradicionales de Machine Learning, capaces de identificar relaciones entre variables operativas como la tensión, la corriente, la temperatura o los ciclos de carga y descarga. Más recientemente, el aumento de la capacidad de procesamiento y la disponibilidad de datos ha impulsado el uso de técnicas de Deep Learning, que permiten modelar relaciones complejas y no lineales con una mayor precisión (Ding et al., 2025; Nazim et al., 2025).

En este contexto, (Nazim et al., 2025) destacan el empleo de arquitecturas como las redes neuronales convolucionales (Convolutional Neural Networks, CNN), las redes neuronales recurrentes de memoria a largo plazo (Long Short-Term Memory, LSTM) y los modelos basados en Transformers para la estimación del estado de salud de las baterías (State of Health, SOH). Según los autores, estas arquitecturas presentan una elevada capacidad para modelar el comportamiento no lineal de las baterías y mejorar la precisión de las estimaciones, contribuyendo al desarrollo de estrategias de mantenimiento predictivo más eficientes (Ding et al., 2025; Nazim et al., 2025).

Con el objetivo de evaluar la capacidad de diferentes arquitecturas de Deep Learning para estimar el estado de salud de baterías de ion-litio, Ding et al. (2025) compararon varios modelos utilizando el conjunto de datos UDDS (Urban Dynamometer Driving Schedule), un ciclo de conducción estandarizado que reproduce condiciones típicas de circulación urbana. El estudio analiza el comportamiento de los modelos bajo distintos estilos de conducción, incluyendo escenarios de conducción urbana estándar y conducción agresiva (Ding et al., 2025; Nazim et al., 2025).

La Figura 5 muestra los resultados obtenidos para los modelos LSTM (Long Short-Term Memory) y BiLSTM (Bidirectional Long Short-Term Memory). La precisión de las predicciones se evalúa mediante el indicador MAPE (Mean Absolute Percentage Error),

una métrica ampliamente utilizada para cuantificar el error porcentual medio de un modelo predictivo. Cuanto menor es el valor de MAPE, mayor es la precisión de las estimaciones realizadas.




Figura 5: Resultados de la predicción del estado de salud (SOH) para el conjunto de datos UDDS. Extraído de Ding et al. (2025).

(Ding et al., 2025) muestran que el modelo BiLSTM obtiene valores de MAPE inferiores a los del modelo LSTM tanto en condiciones de conducción urbana estándar como en conducción agresiva. Estos resultados indican que la arquitectura bidireccional proporciona estimaciones más precisas del estado de salud de la batería, especialmente en escenarios de operación más exigentes.

Además de evaluar el rendimiento de los modelos predictivos, Ding et al. (2025) analizaron la influencia de las condiciones de operación sobre la degradación de las baterías de ion-litio. Para ello, compararon la evolución del estado de salud de la batería (State of Health, SOH) en dos escenarios de funcionamiento: uno representativo de condiciones moderadas (25 °C y una tasa de carga-descarga de 1C) y otro correspondiente a condiciones más exigentes (40 °C y 2C), cuyos resultados se presentan en la Figura 6.

La Figura 6 muestra que el estado de salud de la batería disminuye progresivamente a medida que aumenta el número de ciclos de operación. Sin embargo, la pérdida de capacidad es más acusada en el escenario de 40 °C y 2C, lo que evidencia la influencia de la temperatura y de la intensidad de los ciclos de carga y descarga en el proceso de degradación. Estos resultados ponen de manifiesto que ambas variables constituyen factores determinantes en el envejecimiento de las baterías de ion-litio, reforzando la importancia de monitorizar sus condiciones de operación para optimizar las estrategias de mantenimiento y prolongar la vida útil de los sistemas de almacenamiento energético (Berecibar et al., 2016; Ding et al., 2025).




Figura 6: Variación del estado de salud (SOH) bajo diferentes condiciones de temperatura y carga-descarga. Extraído de Ding et al. (2025).

La electrificación del transporte ha incrementado la importancia de componentes como las baterías de ion-litio, mientras que la digitalización ha facilitado la generación y recopilación de grandes cantidades de datos operativos. Paralelamente, el desarrollo de tecnologías asociadas a la Industria 4.0, como el Internet de las Cosas (IoT), la computación en la nube, los sistemas BMS avanzados y los gemelos digitales (*Digital Twins*), ha permitido transformar estos datos en información útil para la toma de decisiones relacionadas con el mantenimiento (Nagy et al., 2025; Rosati et al., 2023; Li et al., 2021).

La combinación de estas tecnologías está haciendo posible la implantación de estrategias

de mantenimiento predictivo capaces de estimar el estado de salud de las baterías, predecir su vida útil remanente y detectar procesos de degradación antes de que se produzcan fallos que afecten al servicio. De esta forma, el mantenimiento deja de basarse exclusivamente en revisiones periódicas para apoyarse en información procedente de la operación real de los vehículos, permitiendo optimizar recursos, reducir tiempos de inactividad y mejorar la fiabilidad de las flotas (Agredano et al., 2023; Ibrahim et al., 2025; Mahale et al., 2025).

Sin embargo, la literatura también identifica diversas limitaciones que todavía dificultan la implantación generalizada de estas tecnologías. Entre ellas destacan la necesidad de disponer de grandes volúmenes de datos de calidad, la dificultad para generalizar los modelos entre diferentes tipos de baterías y condiciones de operación, así como los costes asociados a la implementación de infraestructuras digitales avanzadas. Además, la ausencia de bases de datos estandarizadas continúa siendo uno de los principales retos identificados por la comunidad científica (Hector & Panjanathan, 2024; Nazim et al., 2025).

A pesar de estas limitaciones, la tendencia observada en la investigación reciente indica que la integración entre electrificación, digitalización e inteligencia artificial constituye una de las principales líneas de desarrollo para mejorar la fiabilidad, eficiencia y sostenibilidad de las futuras flotas de autobuses eléctricos. En este contexto, los gemelos digitales permiten simular el comportamiento de los sistemas en tiempo real, optimizar las decisiones de mantenimiento y mejorar la gestión de los activos durante todo su ciclo de vida, convirtiéndose en una de las tecnologías más prometedoras para el transporte inteligente del futuro (Li et al., 2021; Nagy et al., 2025; Rosati et al., 2023).

3 Objetivos de Desarrollo Sostenible

La Agenda 2030 de las Naciones Unidas establece 17 Objetivos de Desarrollo Sostenible (ODS) orientados a promover un desarrollo económico, social y ambiental sostenible. El presente Trabajo Fin de Máster se relaciona principalmente con los ODS 9, 11, 12 y 13, al abordar el análisis de datos de una flota de autobuses eléctricos con el fin de mejorar el conocimiento sobre el comportamiento energético de las baterías y apoyar una gestión más eficiente de estos vehículos.

3.1 ODS 9. Industria, innovación e infraestructura

Este trabajo contribuye al ODS 9 mediante el desarrollo de una metodología basada en el análisis de datos para estudiar el comportamiento energético de una flota de autobuses

eléctricos. La integración y el tratamiento de datos operativos permiten obtener información de apoyo para la gestión de la flota, en línea con los principios de la Industria 4.0 y el Mantenimiento 4.0.

3.2 ODS 11. Ciudades y comunidades sostenibles

El estudio se desarrolla sobre una flota de autobuses eléctricos destinada al transporte público urbano, elemento fundamental para avanzar hacia una movilidad más sostenible. Los resultados obtenidos pueden servir de apoyo para optimizar la gestión de la flota y mejorar la eficiencia de los sistemas de transporte público.

3.3 ODS 12. Producción y consumo responsables

El análisis del comportamiento de las baterías permite identificar patrones de utilización que pueden favorecer una gestión más eficiente de estos sistemas de almacenamiento energético. Asimismo, la metodología desarrollada constituye una base para futuras investigaciones orientadas a optimizar el uso de los recursos y prolongar la vida útil de las baterías.

3.4 ODS 13. Acción por el clima

La investigación se relaciona de forma indirecta con el ODS 13, ya que se centra en una tecnología que contribuye a la descarbonización del transporte urbano. Aunque el trabajo no cuantifica la reducción de emisiones, aporta una metodología que puede favorecer una gestión más eficiente de las flotas de autobuses eléctricos y apoyar la transición hacia una movilidad con menor impacto ambiental.

4 Metodología

4.1 Problemática de estudio y descripción de la flota

En este contexto, el presente trabajo se centra en el análisis de datos operativos procedentes de una flota de autobuses eléctricos, con el objetivo de estudiar el comportamiento de las baterías en condiciones reales de operación. Para ello se emplea información relacionada con el estado de carga de las baterías (State of Charge, SOC), la energía suministrada durante los procesos de recarga, el consumo energético registrado durante la operación de los vehículos y otras variables asociadas a su explotación diaria. A partir de esta información se pretende caracterizar el comportamiento energético de la flota, identificar diferencias entre vehículos y líneas de servicio, y analizar patrones de utilización que puedan estar relacionados con la degradación de las baterías.

La Figura 7 muestra de forma esquemática la metodología general seguida durante el desarrollo del estudio. En ella se resumen las principales etapas desarrolladas, desde la obtención de los datos operativos hasta el análisis del comportamiento energético de la flota y la evaluación de la influencia de las condiciones de explotación sobre las baterías.




Figura 7: Esquema general de la metodología empleada para la integración y análisis de los datos procedentes de las múltiples plataformas utilizadas.

La problemática abordada en este trabajo no consiste en la estimación directa del estado de salud de la batería (State of Health, SOH) ni de su vida útil remanente (Remaining Useful Life, RUL), ya que dichos parámetros no se encuentran disponibles en las bases de datos analizadas. En su lugar, el estudio se basa en el análisis de datos operativos reales con el propósito de identificar comportamientos que permitan comprender cómo las condiciones de operación pueden influir en la utilización de las baterías y, potencialmente, en sus procesos de degradación. Este enfoque resulta de especial interés para el desarrollo futuro de estrategias de mantenimiento basadas en datos y para una

gestión más eficiente de las flotas de autobuses eléctricos (Mahale et al., 2025).

Desde esta perspectiva, variables como el estado de carga (SOC), el consumo energético, la energía suministrada durante las recargas, la energía recuperada mediante frenado regenerativo o las características de las líneas de operación constituyen indicadores indirectos que permiten analizar el comportamiento de las baterías en condiciones reales de servicio. Aunque estas variables no permiten determinar de forma directa el grado de degradación de cada batería, sí proporcionan una base de conocimiento útil para identificar diferencias operativas entre vehículos y establecer relaciones entre las condiciones de explotación y la utilización de las baterías (Das & Kumar, 2023; Nazim et al., 2025).

La población objeto de estudio está formada por una flota de 20 autobuses eléctricos que prestan servicio regularmente en la red de transporte urbano de la ciudad de Valencia. Todos los vehículos generan de forma continua información operativa durante su funcionamiento, permitiendo registrar variables relacionadas con los procesos de carga y descarga de las baterías, el consumo energético y las condiciones de operación.

El período analizado comprende desde el 23 de noviembre de 2023 hasta el 31 de mayo de 2026. Con el fin de garantizar la calidad y consistencia de la información empleada, se excluyeron los registros correspondientes al intervalo comprendido entre el 10 y el 31 de enero de 2025, debido a la ausencia de datos fiables durante dicho periodo. La amplitud temporal del conjunto de datos permite estudiar el comportamiento de la flota durante aproximadamente treinta meses de operación real, proporcionando una muestra suficientemente representativa para analizar diferencias entre vehículos y líneas de servicio.

La Tabla 1 resume las principales características de la flota analizada y del período considerado en el estudio.

Parámetro	Valor
Fabricante	MAN
Tipo de propulsión	Eléctrica
Número de autobuses eléctricos	20
Capacidad nominal de la batería	480 kWh
Tecnología de la batería	Iones de litio (NMC)
Número de módulos de batería	6
Potencia nominal del motor	160 kW
Potencia máxima del motor	240 kW

Parámetro	Valor
Longitud del vehículo	12,185 m
Zona de operación	Ciudad de Valencia
Fecha de inicio del estudio	23/11/2023
Fecha de finalización del estudio	31/05/2026
Intervalo excluido	10/01/2025 – 31/01/2025

Tabla 1: Características generales de la flota objeto de estudio.

Una vez definida la problemática de estudio y descritas las características generales de la flota analizada, el siguiente apartado presenta las fuentes de información disponibles y las variables empleadas para desarrollar el análisis del comportamiento energético y de la utilización de las baterías.

4.2 Recopilación de datos e infraestructura disponible

4.2.1 Fuentes de datos

Con el objetivo de analizar el comportamiento energético de la flota de autobuses eléctricos, se emplearon dos fuentes principales de información, ambas complementarias entre sí. La primera fuente corresponde al sistema de monitorización embarcado en los vehículos, encargado de registrar información operativa generada durante su funcionamiento diario. La segunda fuente procede del sistema de gestión de la infraestructura de recarga, donde se almacenan los registros asociados a los procesos de carga realizados por los autobuses.

La primera fuente recoge información generada durante la operación diaria de los vehículos, incluyendo variables temporales, energéticas y operativas relacionadas con la circulación de los autobuses y el comportamiento de las baterías durante los procesos de descarga. La segunda fuente registra los eventos de recarga realizados en la infraestructura eléctrica, incorporando información relativa al inicio y final de cada carga, la energía suministrada, la duración del proceso y el estado de carga de la batería.

La utilización conjunta de ambas fuentes permitió disponer de información complementaria sobre el ciclo de funcionamiento de las baterías, integrando tanto los procesos de descarga desarrollados durante la operación de los vehículos como los procesos de recarga realizados al finalizar el servicio. Esta combinación constituye la base sobre la que se desarrollan los análisis presentados en los apartados siguientes.

4.2.1.1 Datos procedentes de la operación de los vehículos

La información registrada durante la operación de los autobuses permite caracterizar las condiciones reales de explotación de la flota. Cada registro corresponde a un servicio realizado por un vehículo e incorpora información temporal, energética y operativa obtenida automáticamente por los sistemas embarcados.

Entre las variables disponibles se incluyen la identificación del vehículo, las horas de inicio y finalización del servicio, la duración del recorrido, la distancia recorrida, la línea de operación, las velocidades registradas, así como diferentes indicadores relacionados con el comportamiento energético de la batería. Entre estos últimos destacan el estado de carga (SOC), el consumo energético total, el consumo específico por kilómetro recorrido, la energía recuperada mediante frenado regenerativo y el consumo asociado a los sistemas auxiliares del vehículo.

La disponibilidad simultánea de estas variables permite estudiar el comportamiento energético de la flota bajo condiciones reales de funcionamiento, así como analizar la influencia que ejercen las características de cada servicio sobre la utilización de las baterías.

No obstante, esta fuente de información presenta una limitación importante para el objetivo del trabajo, ya que no proporciona indicadores directos del estado de salud de la batería (SOH) ni de la vida útil remanente (RUL). Como consecuencia, la degradación debe analizarse mediante indicadores indirectos obtenidos a partir de la evolución temporal de las variables operativas registradas.

4.2.1.2 Datos procedentes de la infraestructura de recarga

La segunda fuente de información está formada por los registros generados durante los procesos de recarga de los autobuses eléctricos. Cada evento de carga incorpora información cronológica y energética que permite caracterizar el comportamiento de las baterías durante las operaciones de recarga.

Los registros incluyen la identificación del vehículo, las horas de conexión y desconexión del cargador, la duración de la recarga, la energía suministrada a la batería y el estado de carga de la batería al inicio y al final de cada proceso.

Esta información resulta esencial para reconstruir la evolución energética de las

baterías entre servicios consecutivos y constituye el complemento necesario de los datos obtenidos durante la circulación de los vehículos.

De forma aislada, esta fuente únicamente describe los procesos de recarga, por lo que no permite analizar el comportamiento completo de las baterías durante su funcionamiento. Por este motivo, fue necesario combinar ambos conjuntos de datos para reconstruir ciclos completos de descarga y recarga antes de realizar el análisis energético.

4.2.1.3 Comparación de las fuentes de datos

Las dos fuentes de información empleadas presentan un carácter complementario. Mientras los registros operativos permiten analizar el comportamiento energético de los vehículos durante la prestación del servicio, los registros procedentes de la infraestructura de recarga describen las condiciones bajo las que las baterías recuperan la energía consumida.

La Tabla 2 resume las principales variables disponibles en cada una de las fuentes de información empleadas.

Variable	Datos operativos	Datos de recarga
Identificación del vehículo	✓	✓
Información temporal	✓	✓
Estado de carga (SOC)	✓	✓
Energía transferida	✓	✓
Distancia recorrida	✓	X
Velocidad de circulación	✓	X
Línea de servicio	✓	X
Consumo energético	✓	X
Energía recuperada	✓	X
Duración de la recarga	X	✓
Energía suministrada durante la carga	X	✓

Tabla 2: Variables más empleadas para calcular los resultados de degradación y próximos estudios.

La integración de ambas fuentes permitió construir una base de datos unificada que combina la información registrada durante la operación de los vehículos con la obtenida durante los procesos de recarga. Esta base de datos constituye el punto de partida para el proceso de integración, validación y análisis desarrollado en las secciones siguientes.

4.3 Integración y validación de datos

Como se ha descrito en el apartado anterior, la información empleada en este estudio procede de dos conjuntos de datos complementarios. El primero recoge la información generada durante la operación diaria de los vehículos, mientras que el segundo contiene los registros asociados a los procesos de recarga realizados en la infraestructura de carga. De forma independiente, ninguno de ellos permite reconstruir el ciclo completo de funcionamiento de la batería, ya que ambos describen fases diferentes de la operación del vehículo.

Con el fin de disponer de una base de datos unificada para el análisis energético y la evaluación del comportamiento de las baterías, fue necesario desarrollar un procedimiento de integración que permitiera asociar los eventos de descarga con el proceso de carga inmediatamente posterior correspondiente al mismo vehículo. Debido a que ambas fuentes de información no comparten un identificador único para relacionar directamente ambos eventos, la integración se realizó mediante criterios de identificación del vehículo, proximidad temporal y coherencia energética.

La metodología desarrollada se estructuró en tres etapas principales: (i) preparación y homogeneización de los datos, (ii) emparejamiento entre eventos de descarga y carga y (iii) validación de las asociaciones obtenidas. El resultado de este procedimiento fue la construcción de una base de datos integrada que constituye el punto de partida para todos los análisis presentados en los apartados posteriores.

4.3.1 Preparación y homogeneización de los datos

La primera etapa del proceso consistió en verificar la compatibilidad entre ambas fuentes de información e identificar las variables que podían emplearse como criterios de asociación entre registros. Para ello se seleccionaron aquellas variables comunes relacionadas con la identificación de los vehículos, la información temporal y el estado de carga de las baterías, ya que constituyen los elementos fundamentales para reconstruir

correctamente la secuencia operativa de cada autobús.

La Tabla 3 resume las principales variables utilizadas durante el proceso de integración.

Fuente de datos	Identificación	Variables temporales	Variables energéticas
BIAPOWER	vehicle	connection_time, disconnection_time, duration_s	initial_soc_%, final_soc_%
RIOBOX	Nombre del vehículo	Hora de inicio, Hora de finalización, Duración [hh:mm]	Iniciar SoC, Fin del SoC

Tabla 3: Variables utilizadas durante el proceso de integración.

La identificación del vehículo constituyó el primer criterio de asociación entre registros, ya que cada ciclo energético debía reconstruirse exclusivamente utilizando información correspondiente al mismo autobús. Sin embargo, este criterio resultaba insuficiente debido a que cada vehículo acumuló varios centenares de eventos de carga y descarga durante el periodo de estudio. Por este motivo, fue necesario incorporar también variables temporales y energéticas que permitieran determinar la correspondencia más probable entre ambos conjuntos de registros.

Con el objetivo de garantizar la comparabilidad entre ambas fuentes de información, se llevó a cabo un proceso previo de homogeneización. En primer lugar, todas las variables temporales fueron convertidas a un formato común que permitiera realizar comparaciones cronológicas entre registros. Posteriormente, se normalizaron los identificadores de los vehículos para eliminar diferencias derivadas del formato de exportación de los datos y asegurar una identificación unívoca de cada autobús durante todo el procedimiento de integración.

Asimismo, se verificó la consistencia de las variables energéticas asociadas al estado de carga de la batería (SOC), comprobando que los valores registrados presentaban un comportamiento coherente y que ambas fuentes utilizaban la misma escala de representación. Esta comprobación resultó especialmente importante, ya que el estado de carga constituye el principal criterio utilizado posteriormente para validar las asociaciones entre eventos de descarga y carga.

Finalizado el proceso de homogeneización, los registros fueron ordenados cronológicamente para cada vehículo utilizando como referencia el instante de

finalización de los servicios y el inicio de las recargas. Esta ordenación permitió reconstruir la secuencia temporal de funcionamiento de cada autobús y estableció la base necesaria para desarrollar posteriormente el proceso de integración.

Antes de aplicar dicho procedimiento, se realizó un análisis exploratorio destinado a verificar la calidad y representatividad del conjunto de datos empleado. En esta fase se revisaron posibles inconsistencias temporales, valores anómalos y la distribución de las principales variables energéticas utilizadas durante el proceso de integración.

Las Figuras 8 y 9 muestran la distribución del estado de carga registrado al inicio y al final de los procesos de carga y descarga. La comparación de ambas distribuciones permitió comprobar que los valores registrados presentan un comportamiento consistente y que el estado de carga constituye una variable suficientemente robusta para utilizarse como criterio de validación durante el proceso de integración.




Figura 8: Distribución del SOC inicial registrado como comprobación preliminar de compatibilidad entre plataformas.




Figura 9: Distribución del SOC final registrado como comprobación preliminar de compatibilidad entre plataformas.

Puede observarse en la próxima Figura 10 una elevada concentración de registros próximos al estado de carga máximo, especialmente al finalizar los procesos de recarga y al inicio de los servicios realizados por los vehículos. En la mayoría de los vehículos, el estado de carga final medio se sitúa en torno al 95 %, lo que indica que los procesos de recarga finalizan habitualmente con la batería prácticamente completa. No obstante, los vehículos 2215 y 2217 presentan un estado de carga final medio significativamente inferior al del resto de la flota, lo que podría estar relacionado con diferencias en su operación.




Figura 10: SOC medio inicial y final por autobús.

La comparación entre ambas fuentes de datos constituye una validación adicional del proceso de integración, ya que el estado de carga registrado por los sistemas embarcados

del vehículo presenta un comportamiento coherente con el obtenido a partir de los registros de recarga. Esta concordancia aporta confianza en la calidad de la base de datos integrada empleada en los análisis posteriores.

Desde el punto de vista metodológico, este aspecto resulta especialmente relevante, ya que disponer de condiciones iniciales de carga muy similares reduce la variabilidad asociada a los distintos ciclos de utilización y proporciona un punto de partida homogéneo para comparar el comportamiento energético de los vehículos. En consecuencia, los registros empleados pueden considerarse plenamente representativos de la operación habitual de la flota y adecuados para el estudio de la evolución energética de las baterías.

La Figura 11 muestra el número de registros disponibles para cada uno de los vehículos analizados. Se observa que todos los autobuses presentan un volumen considerable de información, aunque existen ligeras diferencias derivadas de la intensidad de utilización de cada unidad durante el periodo de estudio. En cualquier caso, la cobertura disponible resulta suficiente para reconstruir los ciclos energéticos de todos los vehículos y desarrollar posteriormente los análisis planteados en este trabajo.




Figura 11: Número de registros disponibles por vehículo en datos operativos.

Esta comprobación permitió verificar que la cobertura de datos era válida para todos los vehículos de la flota y que existía un volumen adecuado de registros para llevar a cabo el proceso de reconstrucción de ciclos energéticos. Además, confirmó que las diferencias observadas entre ambas plataformas eran compatibles con la naturaleza de los eventos registrados, ya que los procesos de descarga no disponían de información complementaria de velocidad o línea de servicio. La elevada cobertura temporal, la homogeneidad de los estados iniciales de carga y el volumen de registros disponible para todos los vehículos

proporcionan una base sólida para abordar el proceso de integración descrito en el apartado siguiente y garantizan la fiabilidad de los análisis desarrollados posteriormente.

4.3.2 Algoritmo de emparejamiento entre descargas y cargas

Una vez completada la fase de preparación y homogeneización de los datos, se desarrolló un algoritmo específico de emparejamiento destinado a asociar cada evento de descarga con el evento de carga más probable. El objetivo de este procedimiento fue reconstruir los ciclos energéticos completos de la batería mediante la integración de la información procedente de las diferentes fuentes de datos disponibles.

La principal dificultad de este proceso radicó en la ausencia de un identificador común que permitiera relacionar de forma directa cada descarga con su correspondiente proceso de carga. Por este motivo, fue necesario desarrollar una estrategia de asociación basada en criterios temporales y energéticos.

El procedimiento se aplicó de forma dependiente para cada uno de los 20 vehículos analizados. Para ello, los registros de descarga y carga fueron previamente ordenados cronológicamente utilizando, respectivamente, la hora de finalización de la descarga y la hora de inicio de la carga.

El primer criterio de emparejamiento consistió en restringir la búsqueda únicamente a registros pertenecientes al mismo vehículo. De esta forma, cada descarga solo podía asociarse con eventos de carga correspondientes a ese mismo vehículo.

Posteriormente, para cada descarga se definió una ventana temporal de búsqueda de ± 5 horas respecto a la hora de finalización registrada. Únicamente las cargas cuya hora de inicio se encontraba dentro de este intervalo fueron consideradas candidatas para la asociación.

Una vez identificadas las posibles cargas candidatas, se calculó la diferencia absoluta entre el estado de carga final registrado durante la descarga y el estado de carga inicial registrado al comienzo de la carga. Este parámetro se almacenó en la variable DIF_SOC_DESC_CARGA, utilizada como indicador de coherencia energética entre ambos eventos. Cuanto menor era este valor, mayor era la probabilidad de que ambos registros pertenecieran al mismo ciclo operativo.

De forma simultánea, se calculó la diferencia temporal entre la hora de finalización de la descarga y la hora de inicio de la carga. Esta diferencia se almacenó en la variable

DIF_HORAS, expresada en horas. Este indicador permitió cuantificar la proximidad temporal entre ambos eventos y se utilizó como criterio complementario para resolver posibles ambigüedades entre varias cargas candidatas.

Una vez calculados ambos indicadores, las cargas candidatas fueron ordenadas priorizando, en primer lugar, el menor valor de DIF_SOC_DESC_CARGA y, en segundo lugar, el menor valor de DIF_HORAS. La primera carga resultante tras esta ordenación fue seleccionada como la asociación más probable para la descarga analizada.

Con el fin de evitar asociaciones múltiples y garantizar la unicidad de los ciclos reconstruidos, cada carga seleccionada fue marcada como utilizada y eliminada del conjunto de candidatos disponibles para las siguientes iteraciones. De este modo, cada evento de carga únicamente podía asociarse a un único evento de descarga.

Este procedimiento permitió reconstruir secuencias coherentes de descarga–carga para cada vehículo, combinando simultáneamente criterios energéticos y temporales. Frente a una simple asociación cronológica, la incorporación del estado de carga como criterio principal permitió incrementar la fiabilidad de las asociaciones obtenidas y reducir el riesgo de emparejamientos incorrectos.

La Figura 12 muestra un ejemplo ilustrativo del proceso de selección de la carga asociada a un evento de descarga, mientras que la Figura 13 presenta el diagrama de flujo del algoritmo de emparejamiento desarrollado.




Figura 12: Ejemplo ilustrativo del proceso de selección de la carga asociada a un evento de descarga.

La primera etapa consistió en verificar la calidad y coherencia de los registros obtenidos tras el proceso de integración de datos.

Para ello se utilizaron las variables de validación generadas durante el emparejamiento,

incluyendo las diferencias entre estados de carga registrados en ambas plataformas (DIF_SOC_DESC_CARGA y DIF_SOC_CARGA_PROX_DESC), las diferencias temporales entre eventos consecutivos (DIF_HORAS), así como los indicadores ESTADO_MATCH y ESTADO_PROXIMO_MATCH.

Los registros clasificados como NO MATCH o aquellos que presentaban incoherencias energéticas significativas fueron identificados y revisados antes de incorporarse al análisis final.



Figura 13: Diagrama de flujo del algoritmo de emparejamiento desarrollado.

Esta etapa permitió garantizar que los ciclos de carga y descarga utilizados representaban secuencias operativas coherentes y que las conclusiones obtenidas posteriormente estuvieran basadas en información consistente.

4.4 Caracterizar comportamiento energético de la flota

Una vez completado el proceso de integración entre las plataformas, se obtuvo una base de datos unificada que combina información operativa de descarga con información asociada a los procesos de recarga de las baterías. Este conjunto de datos constituye la base principal para el análisis desarrollado en el presente trabajo.

La metodología aplicada se diseñó con el objetivo de estudiar el comportamiento energético de las baterías en condiciones reales de operación e identificar posibles indicios de degradación a partir de variables operativas registradas durante el servicio de los vehículos.

Debido a la ausencia de indicadores directos de degradación, como el estado de salud de la batería (*State of Health*, SOH), el estudio se fundamenta en el análisis de indicadores indirectos obtenidos a partir de los ciclos de carga y descarga reconstruidos.

Con el objetivo de obtener una visión general del comportamiento energético de la flota de autobuses eléctricos, se analizaron los principales indicadores asociados al consumo

de energía y al uso de la batería durante los servicios realizados. En particular, se estudió la distribución del consumo total, el consumo específico y la variación del estado de carga de las baterías (ΔSOC), permitiendo caracterizar las condiciones medias de explotación y evaluar la homogeneidad de la operación.

4.4.1 Consumo energético total

El consumo energético total representa la cantidad de energía demandada por el vehículo durante la realización de un servicio completo. Su análisis permite conocer el rango habitual de consumos de la flota, identificar servicios especialmente exigentes desde el punto de vista energético y evaluar la homogeneidad del funcionamiento de los vehículos.

La Figura 14 muestra la distribución del consumo energético total registrado en los distintos servicios analizados.




Figura 14: Distribución del consumo total de la flota.

La distribución presenta una forma aproximadamente normal, con una ligera asimetría hacia valores elevados de consumo. El valor medio obtenido es de 161,2 kWh por servicio, mientras que la mayor concentración de observaciones se sitúa entre aproximadamente 130 y 190 kWh.

La presencia de algunos servicios con consumos superiores a 220 kWh indica la existencia de recorridos con una demanda energética considerablemente mayor que la del resto de la flota. Estas diferencias pueden estar asociadas a múltiples factores operativos,

como una mayor distancia recorrida, un mayor número de paradas, condiciones de tráfico desfavorables, perfiles de conducción más exigentes o un uso intensivo de sistemas auxiliares como la climatización.

En conjunto, la distribución refleja un comportamiento relativamente homogéneo de la flota, ya que la mayor parte de los servicios presentan consumos similares y únicamente un reducido número de observaciones se aleja significativamente del comportamiento medio.

4.4.2 Consumo específico

Aunque el consumo energético total proporciona una visión general de la energía requerida por cada servicio, este indicador depende directamente de la distancia recorrida. Por este motivo, resulta conveniente analizar también el consumo específico, definido como la energía consumida por unidad de distancia recorrida (kWh/km). Este parámetro permite comparar la eficiencia energética de distintos servicios independientemente de la longitud del recorrido.

Como puede observarse en la Figura 15, la mayor parte de los servicios presentan consumos específicos comprendidos entre 0,9 y 1,2 kWh/km, con una concentración máxima alrededor de 1,0 kWh/km.




Figura 15: Distribución del consumo específico de la flota.

No obstante, la distribución presenta una dispersión apreciable, con valores que oscilan

aproximadamente entre 0,8 y 1,6 kWh/km. Esta variabilidad indica que servicios con distancias similares pueden requerir cantidades de energía significativamente diferentes, lo que pone de manifiesto la influencia de otros factores además de la longitud del recorrido.

Entre estos factores destacan las características propias de cada línea, el perfil longitudinal del recorrido, el número de detenciones, la densidad del tráfico, las condiciones meteorológicas y el uso de sistemas auxiliares. En consecuencia, el consumo específico constituye un indicador adecuado para comparar la eficiencia energética de diferentes servicios e identificar aquellos escenarios operativos que implican una mayor demanda de energía.

4.4.3 Variación del estado de carga de la batería

La variación del estado de carga de la batería (Δ SOC) permite cuantificar el porcentaje de energía utilizado durante cada servicio. Este indicador resulta especialmente útil para evaluar el aprovechamiento de la capacidad disponible de las baterías y determinar si la autonomía de los vehículos es adecuada para las condiciones de operación de la red.

La Figura 16 muestra la distribución de los valores de Δ SOC registrados durante los servicios analizados. Como puede observarse, la distribución presenta un valor medio de 42 % de descarga, lo que indica que, en promedio, los autobuses consumen alrededor del 40 % de la capacidad disponible de la batería durante la realización de un servicio.




Figura 16: Distribución del Delta de SOC.

La mayor parte de las observaciones se sitúa entre el 31,7 % y 48 %, lo que evidencia una utilización relativamente homogénea de la capacidad energética de los vehículos. Asimismo, la ausencia de valores extremadamente elevados sugiere que la capacidad instalada en las baterías resulta, en términos generales, suficiente para cubrir las necesidades de operación de los servicios analizados.

La distribución observada muestra además una ligera asimetría hacia valores elevados de descarga. Las descargas profundas implican un mayor estrés electroquímico sobre las celdas, favoreciendo procesos de degradación como la pérdida progresiva de capacidad y el incremento de la resistencia interna (Berecibar et al., 2016; Ding et al., 2025). Como consecuencia, aquellos vehículos que realizan de forma habitual servicios con elevados valores de Δ SOC pueden experimentar un envejecimiento más acelerado de sus baterías. Por este motivo, el análisis de este indicador resulta especialmente relevante para identificar condiciones de operación que puedan contribuir a reducir la vida útil del sistema de almacenamiento energético.

4.4.4 Influencia de la distancia recorrida

Una vez caracterizado el comportamiento energético general de la flota, resulta necesario analizar los factores operativos que pueden influir sobre el consumo de energía de los vehículos. Aunque los autobuses pertenecen a una misma flota y utilizan la misma tecnología de propulsión, las condiciones reales de operación pueden variar

significativamente entre servicios.

La distancia recorrida constituye uno de los factores que mayor influencia ejerce sobre el consumo energético de un vehículo eléctrico. En condiciones normales de operación, un incremento de la distancia recorrida implica una mayor demanda de energía y, en consecuencia, una utilización más intensa de la batería. No obstante, esta relación puede verse modificada por otros factores asociados a las condiciones específicas de explotación de cada servicio pueden afectar de forma directa al consumo energético y al nivel de utilización de las baterías. Por este motivo, se estudió la relación existente entre dichas variables y los principales indicadores energéticos obtenidos durante el análisis.

3.4.4.1 Relación entre distancia recorrida y consumo energético

Con el objetivo de evaluar la influencia de la distancia sobre el consumo energético, se analizó la relación existente entre ambas variables para el conjunto de servicios considerados.

La Figura 17 muestra la relación existente entre la distancia recorrida y el consumo energético total registrado durante cada servicio.




Figura 17: Relación entre distancia recorrida y consumo energético total.

La principal aportación de la Figura 17 es la dispersión observada en los datos. A igualdad de distancia recorrida, el consumo energético presenta una variabilidad considerable. En

torno a los 150 km se registran consumos que oscilan aproximadamente entre 120 y 250 kWh, evidenciando que servicios con un kilometraje similar pueden requerir cantidades de energía muy diferentes. Este comportamiento indica que el consumo energético también está condicionado por otros factores operativos no representados en el eje horizontal.

3.4.4.2 Relación entre distancia recorrida y utilización de la batería

Además del consumo energético, resulta de interés analizar la influencia de la distancia recorrida sobre el porcentaje de batería utilizado durante cada servicio, representado mediante la variación del estado de carga (Δ SOC).

La Figura 18 muestra la relación entre la distancia recorrida y la variación del estado de carga de la batería.




Figura 18: Relación entre distancia recorrida y variación del estado de carga de la batería.

La Figura 18 muestra una relación positiva entre la distancia recorrida y la variación del estado de carga de la batería (Δ SOC); sin embargo, la elevada dispersión de los datos indica que la distancia, aunque influye en el consumo de energía, no resulta suficiente para explicar por sí sola el comportamiento observado. Para recorridos de longitud similar se registran diferencias apreciables en los valores de Δ SOC, lo que pone de manifiesto la influencia de otros factores operativos sobre la energía demandada durante el servicio.

4.4.5 Influencia de la velocidad media sobre el consumo energético

La velocidad media constituye otro de los parámetros operativos que pueden influir sobre el comportamiento energético de un vehículo eléctrico. En entornos urbanos, este indicador está condicionado por numerosos factores externos, como la intensidad del tráfico, la regulación semafórica, la frecuencia de las paradas o las condiciones de circulación.

Con el fin de evaluar su influencia, se analizó la relación entre la velocidad media registrada durante cada servicio y el consumo energético total.

La Figura 19 muestra la relación entre ambas variables.




Figura 19: Relación entre velocidad media y consumo energético total.

A diferencia de la distancia recorrida, la velocidad media no presenta una relación claramente definida con el consumo energético. Aunque pueden apreciarse determinadas tendencias, la elevada dispersión de las observaciones indica que este parámetro, considerado de forma aislada, no permite explicar las diferencias de consumo observadas entre los distintos servicios.

Este resultado es coherente con la naturaleza del transporte urbano, donde velocidades medias similares pueden corresponder a condiciones de circulación muy diferentes. Un mismo valor de velocidad puede obtenerse tanto en recorridos fluidos como en trayectos con frecuentes aceleraciones y frenadas, situaciones que presentan demandas energéticas

significativamente distintas.

Por ello, la velocidad media debe interpretarse como un indicador complementario cuya influencia resulta más representativa cuando se analiza conjuntamente con otras variables operativas.

4.4.6 Influencia de la climatización sobre el consumo energético

Los sistemas de climatización constituyen uno de los principales consumos auxiliares presentes en los autobuses eléctricos. A diferencia de la energía destinada a la propulsión, la empleada para calefacción o refrigeración depende principalmente de las condiciones ambientales, por lo que su contribución al consumo energético puede variar entre servicios. Con el fin de cuantificar su impacto, se calculó el porcentaje que representa el consumo energético de climatización respecto al consumo energético total de cada servicio. La distribución de estos valores se muestra en la Figura 20.




Figura 20: Distribución del porcentaje de consumo de climatización respecto al consumo energético total.

La Figura 20 muestra que el consumo asociado a la climatización representa habitualmente una fracción moderada del consumo energético total. La distribución se concentra principalmente entre el 5 % y el 40 %, con un valor medio del 20,1 % y una mediana del 18,5 %, lo que indica que, en la mayoría de los servicios, aproximadamente una quinta parte de la energía consumida se destina a los sistemas de climatización. Aunque la propulsión continúa siendo el principal consumidor de energía, estos resultados

ponen de manifiesto que la climatización constituye un consumo auxiliar relevante que debe considerarse en el análisis energético y en la planificación operativa de flotas de autobuses eléctricos.

4.5 Análisis de la degradación de las baterías

Una vez caracterizado el comportamiento energético general de la flota mediante el análisis de los consumos, el estado de carga de las baterías y las principales variables operativas, resulta de interés estudiar cómo evoluciona el comportamiento de las baterías a lo largo del periodo analizado. Aunque todos los autobuses pertenecen al mismo modelo y disponen de la misma tecnología de almacenamiento energético, las diferencias en las condiciones reales de explotación pueden dar lugar a distintos niveles de utilización de las baterías y, potencialmente, a diferentes ritmos de envejecimiento.

Como se ha indicado en los apartados anteriores, las bases de datos disponibles no incluyen información relativa al estado de salud de las baterías (State of Health, SOH), por lo que no es posible cuantificar directamente su degradación. En consecuencia, el análisis desarrollado en esta sección se basa en indicadores indirectos obtenidos a partir de los datos procesados correspondientes a los procesos de recarga, previamente integrados y validados según la metodología descrita en las Secciones 3.2 y 3.3.

Para ello, se estudia la relación existente entre la energía suministrada durante las recargas y la variación del estado de carga de la batería (ΔSOC) mediante el ajuste de modelos de regresión lineal. La comparación de las pendientes obtenidas para diferentes instantes temporales permite evaluar la evolución del comportamiento energético de cada vehículo y estimar posibles pérdidas de capacidad útil compatibles con procesos de envejecimiento de las baterías.

Debe señalarse que esta metodología no proporciona una medida directa de la degradación electroquímica de las baterías, sino una estimación relativa basada exclusivamente en el comportamiento observado durante los procesos de carga registrados en condiciones reales de operación. No obstante, este enfoque permite comparar de forma objetiva el comportamiento de los distintos vehículos de la flota e identificar aquellos que presentan una evolución diferenciada, constituyendo una herramienta de apoyo para futuros estudios de mantenimiento predictivo y gestión de activos.

4.5.1 Metodología empleada para la estimación indirecta de la degradación de las baterías

Con el objetivo de ilustrar la aplicación de la metodología propuesta y mostrar distintos niveles de degradación estimada dentro de la flota, se seleccionaron cuatro vehículos representativos. Para cada uno de ellos se comparó la relación entre la energía suministrada durante la carga y la variación del estado de carga (ΔSOC) utilizando los datos correspondientes a diciembre de 2023 y diciembre de 2025. Sobre los datos operativos ya integrados, se ajustó una recta de regresión lineal para cada periodo, cuya pendiente constituye el indicador empleado para estimar la evolución de la capacidad útil de la batería. Asimismo, en todas las representaciones se incluye una línea de referencia correspondiente a una capacidad nominal de 480 kWh, con el objetivo de facilitar la interpretación visual de los resultados.

La Figura 21 corresponde al vehículo 2204, seleccionado por presentar una degradación estimada reducida. Se observa una elevada coincidencia entre las rectas de regresión obtenidas para ambos periodos, reflejando un comportamiento muy similar de la batería durante las recargas analizadas. La nube de puntos mantiene una distribución lineal y una dispersión comparable en ambos años, sin apreciarse desplazamientos significativos respecto a la tendencia principal. Asimismo, ambas rectas permanecen próximas entre sí y por debajo de la línea de referencia, lo que indica que el comportamiento energético apenas ha variado entre diciembre de 2023 y diciembre de 2025.




Figura 21: Comparativa del comportamiento energético durante la recarga para el vehículo 2204 utilizando datos de diciembre de 2023 y diciembre de 2025.

La escasa diferencia entre las pendientes de ambas rectas indica que la relación entre la energía suministrada y el incremento del estado de carga apenas ha variado durante el periodo analizado. En consecuencia, este vehículo representa un caso de degradación reducida, en el que la evolución del comportamiento energético permanece prácticamente estable.

La Figura 22 presenta el análisis correspondiente al vehículo 2214. En este caso continúa observándose una elevada linealidad en la distribución de los datos, aunque comienza a apreciarse una ligera separación entre las rectas de regresión obtenidas para diciembre de 2023 y diciembre de 2025. Dicha diferencia resulta más evidente para valores elevados de ΔSOC , donde la recta correspondiente al periodo más reciente queda ligeramente por debajo de la obtenida dos años antes.




Figura 22: Comparativa del comportamiento energético durante la recarga para el vehículo 2214 utilizando datos de diciembre de 2023 y diciembre de 2025.

La disminución de la pendiente respecto al periodo inicial sugiere una reducción moderada de la capacidad útil estimada de la batería. No obstante, la proximidad entre ambas rectas indica que el comportamiento energético continúa siendo relativamente estable y que las variaciones observadas son todavía limitadas.

La Figura 23 muestra el comportamiento del vehículo 2205. A diferencia de los casos anteriores, la separación entre ambas rectas resulta claramente visible en prácticamente todo el intervalo de valores de ΔSOC . Además, la nube de puntos correspondiente a

diciembre de 2025 se distribuye sistemáticamente por debajo de la obtenida en diciembre de 2023, manteniendo una tendencia lineal similar pero con una pendiente sensiblemente inferior.

Bus 2205 - December: 2023 vs 2025




Figura 23: Comparativa del comportamiento energético durante la recarga para el vehículo 2205 utilizando datos de diciembre de 2023 y diciembre de 2025.

Esta diferencia indica que el indicador empleado para estimar la capacidad presenta una reducción apreciable respecto al periodo inicial. Aunque el comportamiento continúa siendo lineal, la disminución de la pendiente refleja una degradación estimada superior a la observada en los vehículos analizados previamente, constituyendo un ejemplo representativo de una degradación elevada. No obstante, este resultado debe interpretarse conjuntamente con otros factores de explotación, como la ocupación del vehículo, las líneas en las que ha prestado servicio, la intensidad de uso, el número de ciclos de recarga o las condiciones operativas a las que ha estado sometido durante el periodo analizado.

Finalmente, la Figura 24 presenta el caso del vehículo 2213, seleccionado por mostrar el mayor nivel de degradación entre los cuatro ejemplos analizados. Visualmente se aprecia una separación mucho más acusada entre ambas rectas de regresión, especialmente conforme aumenta el valor de Δ SOC. La nube de puntos correspondiente a diciembre de 2025 se sitúa de forma consistente por debajo de la obtenida en diciembre de 2023, confirmando la diferencia existente entre ambos periodos.

Bus 2213 - December: 2023 vs 2025




Figura 24: Comparativa del comportamiento energético durante la recarga para el vehículo 2213 utilizando datos de diciembre de 2023 y diciembre de 2025.

La diferencia entre pendientes es considerablemente superior a la observada en los tres casos anteriores, lo que pone de manifiesto una disminución más importante del indicador empleado para estimar la evolución de la capacidad útil de la batería. Este ejemplo representa el caso con mayor degradación estimada entre los cuatro vehículos seleccionados y permite apreciar cómo la metodología propuesta es capaz de diferenciar distintos niveles de evolución del comportamiento energético a partir de datos reales de recarga.

Con el fin de resumir los resultados obtenidos para los cuatro vehículos representativos, la Tabla 4 recoge las pendientes de las rectas de regresión y el porcentaje de degradación estimado para cada uno de ellos. Aunque las Figuras 21 a 24 muestran únicamente la comparación correspondiente a diciembre de 2023 y diciembre de 2025, los resultados presentados en la tabla se obtuvieron considerando un conjunto más amplio de datos operativos. Para cada vehículo se realizaron tres comparativas entre meses equivalentes de distintos años: diciembre de 2023 frente a diciembre de 2025, enero de 2024 frente a enero de 2026 y agosto de 2024 frente a agosto de 2025. Este procedimiento permitió incrementar el número de eventos de recarga analizados y reducir la influencia de posibles variaciones puntuales asociadas a un único periodo temporal.

Vehículo	Pendiente diciembre 2023	Pendiente diciembre 2025	Degradación estimada (%)
2204	4.23	4.12	2.59
2214	4.55	4.17	8.42
2205	4.72	4.16	11.93
2213	5.06	4.37	13.69

Tabla 4: Pendientes de las rectas de regresión y porcentaje de degradación estimado para los vehículos estudiados.

Los resultados recogidos en la Tabla 4 corroboran las diferencias observadas en las representaciones gráficas. El vehículo 2204 presenta la menor degradación estimada, mientras que el vehículo 2213 muestra la mayor diferencia entre las pendientes obtenidas para los periodos comparados. Los vehículos 2214 y 2205 representan situaciones intermedias, poniendo de manifiesto que la metodología empleada permite diferenciar distintos niveles de degradación estimada a partir de datos reales de operación.

Asimismo, resulta especialmente relevante la dispersión observada en las pendientes de regresión obtenidas para un mismo periodo temporal. A pesar de tratarse de vehículos de la misma marca y modelo, con características técnicas equivalentes, las diferencias entre pendientes son apreciables, lo que indica que la evolución del comportamiento energético no depende únicamente del diseño del vehículo o de la batería. Este comportamiento sugiere la influencia de otros factores asociados a la explotación, como las líneas asignadas, la ocupación del vehículo, la intensidad de utilización, el perfil de conducción o las condiciones operativas, aspectos que se analizan con mayor detalle en los apartados siguientes.

Una vez calculado el porcentaje de degradación para todos los vehículos de la flota mediante el mismo procedimiento, se elaboró un ranking con el objetivo de comparar la evolución del comportamiento energético de las baterías y analizar la variabilidad existente entre los distintos autobuses. La Figura 25 presenta dicho ranking, ordenando los vehículos según su porcentaje de degradación estimada.




Figura 25: Ranking de degradación estimada de la flota de autobuses eléctricos.

Como puede observarse, la degradación estimada presenta una variabilidad apreciable entre los distintos vehículos de la flota. Mientras algunos autobuses muestran diferencias reducidas entre las pendientes obtenidas en las tres comparativas temporales realizadas, otros presentan una disminución más acusada del indicador empleado para estimar la evolución de la capacidad útil de la batería. Esta dispersión sugiere que la degradación no ha sido uniforme y que factores como las condiciones de explotación, el perfil de servicio, la intensidad de uso o las estrategias de recarga pueden influir en la evolución del comportamiento energético de las baterías.

En conjunto, los resultados obtenidos muestran que la metodología propuesta permite comparar de forma objetiva la evolución del comportamiento energético de las baterías utilizando datos reales de operación. Aunque el procedimiento no proporciona una medida directa del estado de salud (SOH), constituye una herramienta útil para identificar diferencias entre vehículos y establecer una base para futuras estrategias de mantenimiento predictivo y gestión de flotas de autobuses eléctricos.

4.6 Influencia energética en las líneas de operación

Tras validar en el apartado anterior la existencia de un proceso de degradación en las baterías de los autobuses analizados mediante el estudio de las pendientes de regresión obtenidas para los distintos vehículos, en esta sección se evalúa si las diferencias observadas pueden estar relacionadas con las características de las líneas de operación en las que estos prestan servicio. Aunque todos los autobuses analizados pertenecen a la misma serie y disponen de configuraciones técnicas equivalentes, las condiciones reales de explotación pueden variar significativamente en función del recorrido, la intensidad del tráfico, el número de paradas o la velocidad comercial, pudiendo influir tanto en la demanda energética como en la utilización de las baterías.

4.6.1 Selección de líneas más representativas

Como primer paso, se evaluó la representatividad de la información disponible para cada línea de operación. Para ello se realizaron tres estudios complementarios para la selección de las líneas estudiadas. En primer lugar, se analizó el número de eventos registrados por línea, con el objetivo de identificar aquellas rutas que disponen de un volumen suficiente de información para realizar un análisis estadísticamente representativo. Los resultados obtenidos se muestran en la Figura 26, donde puede observarse una diferencia notable entre el número de registros disponibles para las distintas líneas de operación.



Figura 26: Número de eventos registrados por línea.

Como puede observarse, existe una diferencia considerable en el número de registros disponibles entre las distintas líneas. Mientras algunas rutas concentran varios miles de eventos, otras únicamente disponen de unas pocas observaciones durante todo el periodo analizado. Esta diferencia pone de manifiesto que no todas las líneas presentan el mismo nivel de representatividad estadística y que, por tanto, resulta conveniente restringir el

análisis detallado a aquellas que cuentan con un volumen suficiente de información.

No obstante, el número de registros por sí solo no garantiza que una línea sea adecuada para el estudio. También es necesario comprobar que dichos registros se distribuyen de forma suficientemente homogénea a lo largo del periodo analizado. Para ello se evaluó la cobertura temporal de la información disponible para cada línea, considerando el número de meses con datos y el porcentaje de cobertura respecto al periodo completo comprendido entre noviembre de 2023 y mayo de 2026.

La Tabla 5 resume el número de eventos registrados, el número de meses con información disponible y el porcentaje de cobertura temporal correspondiente a cada línea. Puede observarse que las líneas 5, 6, 11 y 70 presentan simultáneamente un elevado volumen de información y una cobertura temporal cercana al 80 % del periodo de estudio, mientras que el resto de las líneas muestran una disponibilidad de datos considerablemente menor.

Línea	Eventos	Meses con datos
70	2325	26
11	1951	26
5	1631	26
6	1226	25
10	579	25
27	498	21
9	119	22
14	107	11

Tabla 5: Cobertura temporal de las líneas de operación.

Aunque estos dos criterios permiten identificar las líneas con mayor representatividad, se consideró conveniente evaluar además la robustez estadística de los resultados obtenidos. Para ello se aplicó una técnica de remuestreo Bootstrap, mediante la cual se generaron múltiples muestras aleatorias con reemplazo a partir de los datos originales y se calcularon intervalos de confianza para las principales métricas analizadas.

La Figura 27 representa la relación entre el número de eventos disponibles y la anchura del intervalo de confianza del 95 % obtenida mediante el primer análisis Bootstrap.

Anchura del IC95 de los kWh de carga en función del número de eventos




Figura 27: Relación entre IC95 % (KWh – Energía de Carga) y el número de eventos obtenida mediante Bootstrap.

Como puede observarse, la anchura del intervalo de confianza disminuye conforme aumenta el número de eventos disponibles. Las líneas con un mayor volumen de información presentan estimaciones considerablemente más estables, mientras que aquellas con pocos registros muestran una incertidumbre significativamente mayor. Este comportamiento confirma que el tamaño de la muestra constituye un factor determinante en la precisión de las métricas calculadas.

Con el objetivo de validar estos resultados, se realizó un segundo análisis Bootstrap empleando un criterio de evaluación estadística con la variable de porcentaje de descarga. Los resultados obtenidos se muestran en la Figura 28.




Figura 28: Validación de la representatividad de las líneas mediante el segundo análisis Bootstrap.

Los resultados obtenidos mediante ambos análisis Bootstrap muestran una elevada coherencia entre sí. En ambos casos, las líneas 5, 6, 11 y 70 presentan los menores niveles de incertidumbre y las estimaciones más estables, confirmando que constituyen la muestra más adecuada para desarrollar el análisis energético detallado del resto del capítulo.

Considerando conjuntamente el número de eventos registrados, la cobertura temporal de los datos y los dos análisis Bootstrap realizados, se seleccionaron las líneas 5, 6, 11 y 70 para desarrollar el estudio comparativo. Estas cuatro líneas combinan un elevado volumen de información, una amplia cobertura temporal y una elevada robustez estadística, garantizando la fiabilidad de las comparaciones realizadas en los apartados siguientes.

La Tabla 6 recoge los parámetros operativos medios correspondientes a las cuatro líneas seleccionadas.

COD_LINEA	Eventos	Distancia media [km]	Consumo específico [kWh/km]	Velocidad media [km/h]	Δ SOC medio [%]
70	2325	150.77	1.17	10.37	43.35
11	1951	148.17	1.14	9.69	42.42
5	1631	149.52	1.04	10.2	37.67
6	1226	161.58	1.13	10.94	45.67

Tabla 6: Resumen de parámetros operativos de las principales líneas analizadas.

4.6.2 Caracterización energética de las líneas seleccionadas

Una vez seleccionadas las líneas con mayor representatividad estadística, se procede a analizar su comportamiento energético mediante el estudio de las principales variables

registradas durante la operación de los vehículos. El objetivo de este apartado es identificar las diferencias existentes entre las líneas 5, 6, 11 y 70, evaluando tanto el consumo energético asociado a los diferentes sistemas del vehículo como la utilización de la batería a lo largo de los recorridos. Dado que todos los vehículos analizados pertenecen a una misma serie y presentan características técnicas equivalentes, las diferencias observadas pueden atribuirse principalmente a las condiciones de operación propias de cada línea, tales como el perfil del recorrido, el número de paradas, la velocidad comercial o las condiciones del tráfico.

Como primera aproximación, la Tabla 7 presenta los valores medios de las principales variables energéticas consideradas en el estudio para las cuatro líneas seleccionadas. Entre ellas se incluyen el consumo energético total, el consumo asociado al sistema de tracción, el consumo correspondiente a los sistemas auxiliares, el consumo destinado a climatización, la energía recuperada mediante frenado regenerativo, la energía suministrada durante las recargas y la variación media del estado de carga de la batería (ΔSoC).

Línea	Número de eventos [-]	Consumo total [kWh]	Consumo tren motriz [kWh]	Consumo climatización [kWh]	Regeneración [kWh]	ΔSOC [%]
5	1631	148.38	81.72	33.41	66.58	37.67
6	1226	175.67	102.57	32.99	95.86	45.67
11	1951	159.9	90.12	34.65	81.01	42.42
70	2325	164.85	94.22	35.53	91.34	43.35

Tabla 7: Valores medios de las principales variables energéticas.

A partir de los valores recogidos en la Tabla 6 y la Tabla 7 puede realizarse una primera comparación del comportamiento energético de las líneas analizadas. La línea 6 presenta, de forma general, los mayores valores de consumo energético total, consumo del tren motriz, energía recuperada mediante frenado regenerativo, variación del estado de carga de la batería. En el extremo opuesto se sitúa la línea 5, que registra sistemáticamente los menores niveles de consumo y una menor utilización de la batería durante los recorridos. Las líneas 11 y 70 muestran un comportamiento intermedio, con valores relativamente próximos entre sí. Estas diferencias ponen de manifiesto que, aun operando con vehículos técnicamente equivalentes, las condiciones de explotación propias de cada recorrido ejercen una influencia significativa sobre la demanda energética.

No obstante, el análisis de los valores medios resulta insuficiente para caracterizar completamente el comportamiento de cada línea, ya que no proporciona información

acerca de la dispersión de los datos ni de la variabilidad existente entre recorridos. Por este motivo, el estudio se complementa mediante diagramas de caja, los cuales permiten comparar simultáneamente la mediana, el rango intercuartílico, la dispersión de los datos y la presencia de valores atípicos. En estas representaciones, la línea horizontal situada en el interior de cada caja corresponde a la mediana de la distribución, mientras que la caja engloba el 50 % central de los datos. Los extremos de los bigotes representan el rango de valores comprendidos dentro de 1,5 veces el rango intercuartílico, y los círculos identifican los valores atípicos. Asimismo, el rombo rojo representa el valor medio de la variable, facilitando la comparación entre la media y la mediana y permitiendo identificar posibles asimetrías en la distribución de los datos.

La Figura 29 muestra los diagramas de caja correspondientes al consumo energético total de las cuatro líneas seleccionadas. Esta representación permite comparar de forma simultánea la mediana, el rango intercuartílico, la dispersión de los datos y la presencia de valores atípicos, proporcionando una visión más completa del comportamiento energético de cada línea que la obtenida únicamente a partir de los valores medios.




Figura 29: Diagramas de caja del consumo energético total para las líneas elegidas.

La distribución del consumo energético total confirma las diferencias ya observadas en los valores medios. La línea 6 presenta la mediana y el valor medio más elevados, seguida por las líneas 70 y 11, mientras que la línea 5 registra los menores niveles de consumo. Asimismo, las cuatro distribuciones presentan valores atípicos tanto por encima como por

debajo del comportamiento habitual, reflejando la variabilidad propia de las condiciones reales de explotación. A pesar de esta dispersión, la separación existente entre las medianas permite diferenciar claramente el comportamiento energético de las cuatro líneas.

Con el fin de identificar el origen de estas diferencias, resulta necesario analizar de forma individual las principales variables que intervienen en el balance energético del vehículo.

La Figura 30 representa la distribución del consumo de energía correspondiente al tren motriz, principal responsable de la demanda energética durante la circulación.




Figura 30: Diagramas de caja del consumo de energía del tren motriz para las líneas seleccionadas.

La distribución del consumo del tren motriz reproduce prácticamente el mismo comportamiento observado para el consumo energético total. La línea 6 vuelve a presentar la mayor mediana y el mayor valor medio, seguida por las líneas 70 y 11, mientras que la línea 5 mantiene los menores niveles de consumo. Esta similitud pone de manifiesto que las diferencias observadas en el consumo energético total se encuentran determinadas, principalmente, por la energía necesaria para la propulsión del vehículo. Del mismo modo, la existencia de valores atípicos confirma que determinados recorridos requieren un esfuerzo energético considerablemente superior al habitual como consecuencia de las condiciones específicas de explotación.

La Figura 31 muestra los diagramas de caja correspondientes al consumo de energía asociado a la climatización.

Comparativa líneas - Consumo de climatización




Figura 31: Diagramas de caja del consumo de energía de climatización para las líneas seleccionadas.

A diferencia de lo observado para el tren motriz, las diferencias entre líneas son notablemente menores. Las medianas y los valores medios presentan una gran proximidad entre sí y los rangos intercuartílicos muestran una dispersión muy similar. Únicamente la línea 70 presenta una ligera tendencia hacia consumos superiores, aunque dicha diferencia resulta reducida frente a la variabilidad existente en la muestra. Bajo este análisis, el consumo destinado a climatización no parece constituir un factor determinante para diferenciar el comportamiento energético entre las líneas estudiadas. Asimismo, los posibles factores que pueden influir en esta variable, como la ocupación, las condiciones climáticas u otros aspectos operativos, presentan un comportamiento relativamente estable entre las distintas líneas analizadas.

La influencia de la operación sobre la recuperación de energía puede evaluarse mediante la Figura 32, donde se representa la distribución de la energía recuperada durante las fases de frenado regenerativo.

Comparativa líneas - Energía regenerada




Figura 32: Diagramas de caja de la energía recuperada mediante frenado regenerativo para las líneas seleccionadas.

En este caso vuelven a apreciarse diferencias significativas entre líneas. La línea 6 presenta nuevamente los mayores valores centrales de regeneración, seguida por la línea 70 y la línea 11, mientras que la línea 5 registra la menor recuperación energética. Este comportamiento resulta coherente con el mayor consumo energético observado anteriormente, ya que una mayor demanda durante la circulación suele ir acompañada de un mayor potencial de recuperación en las fases de deceleración y frenado. Sin embargo, aunque estas líneas recuperan una mayor cantidad de energía, dicha recuperación no resulta suficiente para compensar completamente el incremento del consumo energético asociado a su operación.

Finalmente, la Figura 33 recoge la distribución de la variación del estado de carga de la batería (ΔSoC), parámetro que cuantifica el porcentaje de batería utilizado durante cada recorrido.

Comparativa líneas - Variación del estado de carga (ΔSOC)




Figura 33: Diagramas de caja de la variación del estado de carga de la batería (ΔSoC) para las líneas seleccionadas.

La distribución del ΔSoC mantiene la misma tendencia observada en las variables analizadas anteriormente. La línea 6 presenta el mayor porcentaje de descarga de la batería, seguida por las líneas 70 y 11, mientras que la línea 5 vuelve a registrar la menor utilización del sistema de almacenamiento energético. Además, las cuatro distribuciones presentan una dispersión relativamente similar, indicando que, aunque existen recorridos con demandas energéticas muy diferentes, el comportamiento global de cada línea se mantiene estable a lo largo del periodo de estudio.

En conjunto, el análisis de las Figuras 29 a 33 confirma que las diferencias energéticas observadas entre las líneas seleccionadas están determinadas principalmente por el consumo asociado al tren motriz, que constituye la principal contribución al consumo energético total del vehículo. Por el contrario, el consumo destinado a climatización presenta un comportamiento mucho más homogéneo, evidenciando una menor dependencia de las características del recorrido. Asimismo, aunque las líneas con mayor demanda energética recuperan una mayor cantidad de energía mediante frenado regenerativo, esta recuperación no compensa completamente el incremento del consumo, traduciéndose finalmente en una mayor utilización de la batería. En consecuencia, los resultados obtenidos ponen de manifiesto que las condiciones de explotación propias de cada línea influyen de forma significativa en el comportamiento energético de los vehículos y justifican la necesidad de analizar, en el siguiente apartado, cómo estas variables evolucionan a lo largo del año para identificar la influencia de la estacionalidad

sobre el consumo energético.

4.6.3 Variación estacional del comportamiento energético

Una vez caracterizadas las diferencias energéticas existentes entre las líneas seleccionadas, resulta de interés analizar cómo evolucionan dichas variables a lo largo del año. Aunque las características geométricas y operativas de cada recorrido permanecen prácticamente constantes, las condiciones de explotación experimentan variaciones estacionales asociadas principalmente a la temperatura ambiente, la utilización del sistema de climatización y las condiciones generales de circulación. Como consecuencia, la demanda energética del vehículo y la utilización de la batería pueden variar de forma significativa en función de la época del año.

Como primera aproximación, la Tabla 8 resume el intervalo anual comprendido entre el valor medio mensual mínimo y el máximo alcanzado por las principales variables energéticas analizadas para cada una de las líneas de operación.

Variable	Línea 5	Línea 6	Línea 11	Línea 70
Consumo total (kWh)	126,8 – 182,6	152,2 – 229,1	133,8 – 207,9	141,3 – 206,0
Consumo de climatización (kWh)	10,7 – 66,9	11,0 – 104,4	8,8 – 80,1	9,5 – 77,1
ΔSoC (%)	33,5 – 49,2	40,1 – 61,8	35,6 – 57,0	38,1 – 56,8

Tabla 8: Intervalo anual de las principales variables energéticas para las líneas analizadas.

Los resultados muestran que las mayores variaciones estacionales se producen en el consumo energético total y, especialmente, en el consumo asociado a la climatización. En todas las líneas puede observarse un incremento considerable entre los valores mínimos y máximos registrados a lo largo del año, siendo la línea 6 la que presenta el mayor intervalo tanto en consumo energético total como en porcentaje de descarga de la batería. Por el contrario, la línea 5 mantiene los menores valores durante prácticamente todo el periodo analizado. Estas diferencias indican que la influencia de la estacionalidad no es uniforme y que las condiciones propias de cada recorrido condicionan la magnitud del

incremento energético experimentado a lo largo del año.

Con objeto de visualizar esta evolución, la Figura 34 representa la distribución del consumo energético total correspondiente al mes de enero, considerado representativo de las condiciones de operación invernales.




Figura 34: Histograma del consumo energético total durante el mes de enero para las líneas seleccionadas.

Durante el mes de enero las cuatro distribuciones presentan una elevada concentración de registros alrededor de sus respectivos valores medios, indicados mediante líneas verticales discontinuas. Aunque se mantiene el mismo orden relativo identificado en el apartado anterior —la línea 6 presenta el mayor consumo y la línea 5 el menor—, las diferencias entre líneas son moderadas y las distribuciones muestran una elevada superposición. Este comportamiento refleja que, durante el periodo invernal, las necesidades energéticas de los vehículos permanecen relativamente contenidas.

Con el fin de evaluar la influencia de la estacionalidad, la Figura 35 representa la distribución del consumo energético total durante el mes de julio, correspondiente al periodo de mayor demanda energética.

Comparativa líneas - Consumo total (Julio)




Figura 35: Histograma del consumo energético total durante el mes de julio para las líneas seleccionadas.

La comparación entre las Figuras 34 y 35 evidencia un desplazamiento generalizado de todas las distribuciones hacia valores superiores de consumo. Las medias aumentan de forma apreciable en las cuatro líneas y la dispersión de los datos también resulta ligeramente mayor, reflejando una mayor variabilidad en las condiciones de explotación durante los meses de verano. A pesar de este incremento, el comportamiento relativo entre las líneas permanece prácticamente inalterado: la línea 6 continúa registrando los mayores consumos energéticos, seguida por las líneas 70 y 11, mientras que la línea 5 mantiene los menores niveles de demanda energética.

Para identificar el origen de este incremento resulta necesario analizar el comportamiento del consumo asociado a la climatización. La Figura 36 muestra la distribución de esta variable durante el mes de julio.

Comparativa líneas - Consumo de climatización (Julio)




Figura 36: Histograma del consumo energético de climatización durante el mes de julio para las líneas seleccionadas.

En todas las líneas se observa un incremento muy significativo del consumo destinado a climatización respecto a los valores registrados durante el invierno. Las distribuciones presentan un comportamiento muy similar entre sí, con valores medios comprendidos aproximadamente entre 70 y 105 kWh. Este resultado indica que el consumo asociado a la climatización depende principalmente de las condiciones ambientales y explica una parte importante del incremento observado en el consumo energético total durante el periodo estival.

Finalmente, la Figura 37 muestra la distribución de la variación del estado de carga de la batería (ΔSoC) correspondiente al mes de julio.

Comparativa líneas - Variación del estado de carga (ΔSOC) (Julio)




Figura 37: Diagramas de caja de la variación del estado de carga de la batería (ΔSOC) durante el mes de julio para las líneas seleccionadas.

Realizando la comparativa con la Figura 16 que se representó anteriormente en este documento, la distribución del ΔSOC confirma que el incremento de la demanda energética durante el verano se traduce en una mayor utilización de la batería. La línea 6 presenta nuevamente la mayor descarga media, seguida por las líneas 70 y 11, mientras que la línea 5 registra los menores porcentajes de utilización. Además, la dispersión de los datos y la presencia de valores atípicos ponen de manifiesto la variabilidad existente entre recorridos, aunque el comportamiento general permanece estable para cada una de las líneas.

En conjunto, los resultados obtenidos muestran que la estacionalidad influye de forma significativa en el comportamiento energético de los vehículos. Durante los meses de verano se registra un incremento generalizado del consumo energético, asociado principalmente al mayor uso del sistema de climatización. Este aumento de la demanda obliga a la batería a suministrar una mayor cantidad de energía durante la operación, incrementando el esfuerzo al que se encuentra sometida. Además, las elevadas temperaturas ambientales propias del periodo estival pueden favorecer los mecanismos de envejecimiento electroquímico descritos en la literatura, al acelerar las reacciones internas que intervienen en la degradación de las celdas. Aunque la degradación de una batería depende de múltiples factores, los resultados obtenidos ponen de manifiesto que las condiciones de explotación y la estacionalidad constituyen elementos que pueden contribuir a acelerar su deterioro a largo plazo.

4.7 Análisis exploratorio mediante clustering

Se realizó un análisis exploratorio adicional con el objetivo de evaluar si las técnicas de inteligencia artificial podían capturar relaciones más complejas entre las variables operativas. Aunque el análisis estadístico básico permite identificar límites simples en indicadores individuales, no describe completamente el comportamiento de los vehículos. Por este motivo, se incorporó un enfoque de aprendizaje no supervisado como análisis complementario.

Para ello, se seleccionó el algoritmo K-Means, una técnica de clustering sencilla e interpretable. El objetivo no fue clasificar fallos ni predecir la degradación de la batería, sino agrupar eventos operativos similares en función de sus características de uso energético. Adicionalmente, este estudio incluyó nuevas variables creadas con la premisa de capturar mejor las relaciones del fenómeno de estudio, las cuales se presentan en la tabla 9. Las mismas fueron seleccionadas porque representan diferentes aspectos de la operación del vehículo y de la demanda sobre la batería.

Variable utilizada	Descripción	Unidad
Consumo motriz/km	Consumo energético del tren motriz por kilómetro recorrido.	kWh/km
Climatización/km	Consumo energético del sistema de climatización por kilómetro recorrido.	kWh/km
Ratio de recuperación	Relación entre la energía regenerada durante la frenada y la energía total consumida por el vehículo durante el evento operativo.	—
Δ SOC/km	Variación del estado de carga (SOC) de la batería por kilómetro recorrido.	%/km
Distancia	Distancia total recorrida durante el evento operativo.	km

Tabla 9: Variables utilizadas en el análisis exploratorio mediante clustering.

Se seleccionó un modelo de tres clusters como la opción más adecuada para este análisis exploratorio y se utilizaron solo los datos relativos al mes de noviembre, por contener suficiente información y representatividad de autobuses, y, adicionalmente, como forma de asegurar la homogeneidad de los resultados. Aunque las métricas internas de validación mostraron una separación moderada entre los grupos, la solución de tres clusters ofreció un equilibrio razonable entre interpretabilidad, tamaño de los grupos y significado físico.

Una vez aplicado el modelo K-Means, los eventos asociados a cada línea se distribuyeron entre los tres clusters tal como se muestra en la Tabla 10. Esta distribución permite identificar en qué grupos se concentraron principalmente los eventos de cada línea. Los resultados muestran que las líneas 5 y 6 se agruparon mayoritariamente en el Cluster 0, con un 72,17% y un 63,96% de sus eventos, respectivamente. En cambio, la línea 11 presentó una mayor concentración en el Cluster 2, con un 62,57% de sus eventos, mientras que la línea 70 también mostró una presencia relevante en este cluster, con un 48,91%.

COD_LINEA	0	1	2
5	72,17	23,48	4,35
6	63,96	12,61	23,42
11	18,71	18,71	62,57
70	34,24	16,85	48,91

Tabla 10: Distribución porcentual de los eventos de cada línea entre los clusters obtenidos mediante K-Means.

En cuanto a los clusters obtenidos, los resultados muestran la existencia de perfiles operativos diferenciados entre los eventos analizados. En términos generales, el Cluster 1 se distingue de forma clara respecto a los Clusters 0 y 2 por presentar las condiciones energéticas más demandantes para el vehículo. Esta mayor exigencia se observa principalmente en el consumo de SOC por kilómetro, que alcanza los valores más elevados en este grupo (Figura 38).




Figura 38: Distribución del consumo de SOC por kilómetro para los tres clusters identificados mediante el algoritmo K-Means.

En la Figura 38 se muestra la relación entre el consumo de SOC por kilómetro y el consumo del tren motriz por kilómetro. En primer lugar, se observa lo comentado previamente: el Cluster 1 presenta, en general, valores más elevados de SOC por

kilómetro en comparación con los Clusters 0 y 2. Sin embargo, al analizar el consumo del tren motriz, las diferencias entre los clusters no son tan marcadas. El Cluster 0 tiende a presentar valores inferiores de consumo motriz, mientras que los Clusters 1 y 2 muestran rangos más similares entre sí. Esto sugiere que el mayor consumo de SOC observado en el Cluster 1 no se explica únicamente por una mayor demanda del tren motriz.

Para profundizar en esta relación, resulta conveniente analizar simultáneamente el consumo de SoC y el consumo del tren motriz. En la Figura 39 se representa la relación entre ambas variables para los distintos clústeres obtenidos. Se aprecia que el Clúster 1 continúa diferenciándose del resto al presentar valores elevados de consumo de SoC para niveles de consumo del tren motriz similares a los observados en los Clústeres 0 y 2. Esta distribución indica que el incremento del consumo energético total no está asociado exclusivamente al sistema de propulsión, sino que existe una demanda adicional procedente de otros sistemas auxiliares del vehículo. Como consecuencia, los resultados apuntan a que el comportamiento más demandante del Clúster 1 está relacionado con una mayor utilización de los sistemas auxiliares, especialmente del sistema HVAC.




Figura 39: Relación entre el consumo de SoC por kilómetro y el consumo del tren motriz según el clúster.

Con el fin de comprobar esta hipótesis, se analiza la influencia del sistema de climatización sobre el consumo energético del vehículo. Como muestra la Figura 40, existe una clara relación entre el consumo de SoC por kilómetro y el consumo específico

del sistema HVAC. El Clúster 1 concentra los mayores valores de consumo de climatización y presenta una tendencia creciente entre ambas variables. Por el contrario, los Clústeres 0 y 2 permanecen agrupados en zonas de menor consumo HVAC y menor consumo de SoC por kilómetro. Esta separación confirma que la climatización constituye el principal factor responsable del incremento del consumo energético observado en el Clúster 1, explicando la dispersión detectada en las figuras anteriores.




Figura 40: Relación entre el consumo de SoC por kilómetro y el consumo del sistema HVAC según el clúster.

A partir de esta aproximación, se observa que una mejor comprensión del comportamiento del sistema HVAC podría contribuir a optimizar el uso de la batería, ya que los eventos asociados al Cluster 1 presentan una mayor demanda energética y un mayor consumo de SOC por kilómetro. No obstante, muchos de los factores que afectan al funcionamiento del HVAC no son completamente controlables, como la temperatura exterior o la demanda de pasajeros. En este sentido, identificar con mayor precisión las situaciones que favorecen la aparición de eventos en el Cluster 1 permitiría apoyar futuras decisiones operativas, como la asignación de vehículos con mayor margen de batería en días o servicios especialmente demandantes, o la reserva de vehículos con baterías más degradadas para condiciones de menor exigencia. Por tanto, un análisis más detallado de los eventos pertenecientes a este cluster podría aportar criterios útiles tanto para la reorganización de líneas como para la gestión operativa y de mantenimiento de la flota.



Es importante considerar que este clustering constituye una primera aproximación exploratoria. En datos operativos reales de máquinas y vehículos, las fronteras entre grupos no suelen estar claramente separadas, ya que los eventos forman parte de un continuo de condiciones de operación. Por tanto, los clusters no deben entenderse como categorías definitivas, sino como perfiles preliminares que ayudan a identificar patrones de uso energético.

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 9, se describe cada sección.

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	450	30 €	13,500.00 €
2. Recursos materiales					
2.1	MES	Amortización del equipo informático	6	33 €	198.00 €
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					23,338.00 €
Gastos Generales (7%)					1,633.66 €
Beneficios industriales (8%)					1,867.04 €
Total Presupuesto sin I.V.A					26,838.70 €
I.V.A (21%)					5,636.13 €
TOTAL PRESUPUESTO					32,474.83 €

Tabla 11: Presupuesto para ejecución del TFM.

6 Conclusiones

Los resultados obtenidos demuestran que las condiciones de explotación influyen de forma significativa en el comportamiento energético de los autobuses eléctricos y, por tanto, en la utilización de sus baterías. A pesar de que todos los vehículos analizados pertenecen al mismo modelo y presentan características técnicas equivalentes, se han identificado diferencias apreciables en el consumo energético entre las distintas líneas de operación, evidenciando que factores como el recorrido, la velocidad comercial o las condiciones del tráfico condicionan la demanda energética del vehículo.

El análisis realizado muestra que el consumo asociado al tren motriz constituye la principal contribución al consumo energético total y es el factor que mejor explica las diferencias observadas entre las distintas líneas. Por el contrario, el consumo de climatización presenta un comportamiento más homogéneo entre recorridos, aunque su influencia aumenta considerablemente durante los meses de verano.

Asimismo, el estudio pone de manifiesto una clara influencia de la estacionalidad sobre el comportamiento energético de la flota. Durante el periodo estival se produce un incremento del consumo energético total, provocado principalmente por el aumento de la demanda del sistema de climatización. Como consecuencia, las baterías deben suministrar una mayor cantidad de energía durante la operación, viéndose sometidas a un mayor esfuerzo que puede favorecer los procesos de degradación a largo plazo.

Por otra parte, el análisis de los distintos vehículos ha permitido comprobar que existen diferencias en la evolución de los indicadores energéticos entre autobuses que operan bajo condiciones similares, lo que pone de manifiesto la importancia de realizar un seguimiento individualizado de cada vehículo para detectar comportamientos anómalos y optimizar su utilización.

En conjunto, los resultados obtenidos demuestran que el análisis de datos operativos constituye una herramienta eficaz para comprender el comportamiento energético de una flota de autobuses eléctricos e identificar los factores que influyen en la utilización de las baterías. Esta información puede servir como apoyo para optimizar la gestión de la flota, mejorar la planificación del mantenimiento y favorecer estrategias de operación que contribuyan a reducir el esfuerzo al que se encuentran sometidas las baterías y prolongar su vida útil.

7 Trabajos a futuro

Los resultados obtenidos en este trabajo abren diversas líneas de investigación orientadas a profundizar en el estudio de la degradación de las baterías de autobuses eléctricos. Una de las principales consiste en desarrollar metodologías que permitan estimar la degradación de forma más precisa mediante la incorporación de variables adicionales, especialmente el voltaje de las celdas durante los procesos de carga y descarga. El análisis conjunto de la evolución del voltaje, la corriente, la temperatura y el estado de carga permitiría caracterizar con mayor rigor el estado de las baterías y comprender mejor los mecanismos asociados a su envejecimiento.

Asimismo, sería de interés desarrollar modelos predictivos basados en técnicas de inteligencia artificial y aprendizaje automático capaces de anticipar la evolución de la degradación a partir de los datos históricos de operación. Estas herramientas permitirían identificar de forma temprana comportamientos anómalos, optimizar la planificación del mantenimiento y mejorar la disponibilidad de la flota.

Por otra parte, ampliar el periodo de estudio y disponer de un mayor histórico de datos permitiría analizar con mayor precisión la evolución temporal de las baterías y validar las tendencias observadas en este trabajo. Del mismo modo, la incorporación de nuevas variables relacionadas con la operación de los vehículos, como la topografía de las rutas, la ocupación del autobús o las condiciones meteorológicas, contribuiría a explicar con mayor detalle las diferencias energéticas observadas entre las distintas líneas de servicio.

Finalmente, la metodología desarrollada podría extenderse a otras flotas de autobuses eléctricos con el fin de comparar diferentes estrategias de explotación y evaluar su influencia sobre el comportamiento energético y la degradación de las baterías, favoreciendo el desarrollo de criterios de gestión y mantenimiento aplicables a distintos entornos de operación.

8 Bibliografía

Agredano, F., Taha, M., Kenné, J. P., & Yalaoui, F. (2023). Maintenance 4.0 Opportunistic Strategy for Electric Buses. CIGI QUALITA MOSIM 2023.

Berecibar, M., Gandiaga, I., Villarreal, I., Omar, N., Van Mierlo, J., & Van den Bossche, P. (2016). Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews*, 56, 572-587. <https://doi.org/https://doi.org/10.1016/j.rser.2015.11.042>

Borge, R., Miguel, I., Paz, D., Lumbreras, J., Perez, J., & Rodríguez, E. (2012). Comparison of road traffic emission models in Madrid (Spain). *Atmospheric Environment*, 62, 461–471. <https://doi.org/10.1016/j.atmosenv.2012.08.073>

Bouyahrouzi, E. M., Benmimoun, R., El Kihel, Y., & Bajjou, M. S. (2025). Integrating Industry 4.0 and Maintenance 4.0 Technologies for Sustainable Manufacturing: A Systematic Literature Review. *The International Journal of Advanced Manufacturing Technology*, 140(1), 35-61.

Carvalho, T., Soares, F., Vita, R., Francisco, R., Basto, J., & Alcalá, S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>

Cavus, M., Dissanayake, D., & Bell, M. (2025). Next Generation of Electric Vehicles: AI-Driven Approaches for Predictive Maintenance and Battery Management. *Energies*, 18(5). <https://doi.org/10.3390/en18051041>

Das, K., & Kumar, R. (2023). Electric vehicle battery capacity degradation and health estimation using machine-learning techniques: a review. *Clean Energy*, 7, 1268-1281. <https://doi.org/10.1093/ce/zkad054>

Deb, S., Tammi, K., Kalita, K., & Mahanta, P. (2018). Review of recent trends in charging infrastructure planning for electric vehicles. *Wiley Interdisciplinary Reviews: Energy and Environment*, 7. <https://doi.org/10.1002/wene.306>

Ding, T., Xiang, D., Sun, T., Qi, Y., & Zhao, Z. (2025). AI-Driven Prognostics for State of Health Prediction in Li-ion Batteries: A Comprehensive Analysis with Validation. <https://doi.org/10.48550/arXiv.2504.05728>

Elnadi, M., & Abdallah, Y. O. (2024). Industry 4.0: critical investigations and synthesis of key findings. *Management Review Quarterly*, 74(2), 711-744. <https://doi.org/10.1007/s11301-022-00314-4>

Folgado, F. J., Calderón, D., González, I., & Calderón, A. J. (2024). Review of Industry 4.0 from the Perspective of Automation and Supervision Systems: Definitions, Architectures and Recent Trends. *Electronics*, 13(4), 782. <https://doi.org/10.3390/electronics13040782>

Folgado, M. G., Sanz, V., Hirn, J., Lorenzo-Sáez, E., & Urchueguia, J. (2025). Deep learning for urban air quality: a traffic-based prediction and alert system for Valencia. *Neural Computing and Applications*, 37(20), 15837-15854. <https://doi.org/10.1007/s00521-025-11316-0>

Hector, I., & Panjanathan, R. (2024). Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques. *PeerJ Computer Science*, 10, e2016. <https://doi.org/10.7717/peerj-cs.2016>

Ibrahim, H., Ali, A. M., & Attia, T. (2025). Optimizing electric bus performance via predictive maintenance: a combined experimental and modeling approach. *Frontiers in Future Transportation*, Volume 5-2024. <https://www.frontiersin.org/journals/future-transportation/articles/10.3389/ffutr.2024.1506866>

Jasiulewicz-Kaczmarek, M. (2024). Maintenance 4.0 Technologies for Sustainable Manufacturing. *Applied Sciences*, 14(16), 7360.

Jimenez-Martinez, M., Valencia-Sánchez, J. L., Torres-Cedillo, S. G., & Cortés-Pérez, J. (2024). Battery Housing for Electric Vehicles, a Durability Assessment Review. *Designs*, 8(6). <https://doi.org/10.3390/designs8060113>

Kulkarni, S., Duan, K., Pang, G., & Bhatti, A. (2026). Recent advancements and perspectives in lithium-ion battery technology. *Energy Strategy Reviews*, 64. <https://doi.org/10.1016/j.esr.2026.102064>

Lane, B., Dumortier, J., Carley, S., Siddiki, S., Clark-Sutton, K., & Graham, J. (2018). All plug-in electric vehicles are not the same: Predictors of preference for a plug-in hybrid versus a battery-electric vehicle. *Transportation Research Part D*

Transport and Environment, 65, 1-13. <https://doi.org/10.1016/j.trd.2018.07.019>

Lipman, T. E. (2025). Recent Developments and Challenges with Electric Bus Implementation for Transit Fleets. *Current Sustainable/Renewable Energy Reports*, 12(1), 19. <https://doi.org/10.1007/s40518-025-00267-8>

Mahale, Y., Kolhar, S., & More, A. S. (2025). A comprehensive review on artificial intelligence driven predictive maintenance in vehicles: technologies, challenges and future research directions. *Discover Applied Sciences*, 7(4), 243. <https://doi.org/10.1007/s42452-025-06681-3>

Mallioris, P., Aivazidou, E., & Bechtsis, D. (2024). Predictive Maintenance in Industry 4.0: A Systematic Cross-Sector Mapping. *CIRP Journal of Manufacturing Science and Technology*, 50, 80-103.

McCabe, D., & Ban, X. (Jeff). (2023). Optimal locations and sizes of layover charging stations for electric buses. *Transportation Research Part C: Emerging Technologies*, 152, 104157. <https://doi.org/https://doi.org/10.1016/j.trc.2023.104157>

Mouhib, Z., Gallab, M., Merzouk, S., Soulhi, A., & Di Nardo, M. (2025). Total Productive Maintenance and Industry 4.0: A Literature-Based Path Towards a Proposed Standardized Framework. *Applied System Innovation*, 8(4), 98.

Muelas, D., Bastida Molina, P., Berna, C., Álvarez-Piñeiro, L., & Montagud, C. (2026). Statistical energy-based sizing of electric vehicle charging infrastructure for workplace parking facilities: case study of Polytechnic University of Valencia, Spain. *Energy Conversion and Management*: X, 31, 101994. <https://doi.org/10.1016/j.ecmx.2026.101994>

Nagy, M., Figura, M., Valášková, K., & LazaroIU, G. (2025). Predictive Maintenance Algorithms, Artificial Intelligence Digital Twin Technologies, and Internet of Robotic Things in Big Data-Driven Industry 4.0 Manufacturing Systems. *Mathematics*, 13, 981. <https://doi.org/10.3390/math13060981>

Nazim, M., Joha, M., Alam, S. S., Rahman, M. M., Umam, M., & Jang, Y. M. (2025). Artificial intelligence for estimating State of Health and Remaining Useful Life of EV batteries: A systematic review. *ICT Express*, 11.

<https://doi.org/10.1016/j.icte.2025.05.013>

Pashami, S., Veloso, B., Nowaczyk, S., Fan, Y., Pereira, P., Ribeiro, R., & Gama, J. (2022). A Fault Detection Framework Based on LSTM Autoencoder: A Case Study for Volvo Bus Data Set (pp. 39-52). https://doi.org/10.1007/978-3-031-01333-1_4

Rejeb, A., Rejeb, K., Süle, E., Hassoun, A., & Keogh, J. G. (2025). Knowledge flows in industry 4.0 research: a longitudinal and dynamic analysis. *Journal of Data, Information and Management*, 7(2), 123-145. <https://doi.org/10.1007/s42488-025-00146-3>

Rosati, R., Romeo, L., Cecchini, G., Tonetto, F., Viti, P., Mancini, A., & Frontoni, E. (2023). From Knowledge-Based to Big Data Analytics Model: A Novel IoT- and Machine Learning-Based Decision Support System for Predictive Maintenance in Industry 4.0. *Journal of Intelligent Manufacturing*, 34(1), 107-121.

Shi, D., Xu, H., Wang, S., Hu, J., Chen, L., & Yin, C. (2024). Deep reinforcement learning based adaptive energy management for plug-in hybrid electric vehicle with double deep Q-network. *Energy*, 305, 132402. <https://doi.org/https://doi.org/10.1016/j.energy.2024.132402>

Sipho, T., Johan, T., & Sibusiso, P. (2025). Enhancing the Reliability of Mechatronic Devices for Sustainable Industry 4.0 Systems. *Fusion of Multidisciplinary Research, An International Journal*, 6, 812-828. <https://doi.org/10.63995/GCDU2539>

Wang, Y., Huang, Y., Xu, J., & Barclay, N. (2017). Optimal recharging scheduling for urban electric buses: A case study in Davis. *Transportation Research Part E: Logistics and Transportation Review*, 100, 115-132. <https://doi.org/https://doi.org/10.1016/j.tre.2017.01.001>

Yang, F., & Gu, S. (2021). Industry 4.0, a revolution that requires technology and national strategies. *Complex & Intelligent Systems*, 7(3), 1311-1325. <https://doi.org/10.1007/s40747-020-00267-9>

Zhang, L., Wang, S., & Qu, X. (2021). Optimal electric bus fleet scheduling considering battery degradation and non-linear charging profile. *Transportation Research Part E: Logistics and Transportation Review*, 154, 102445. <https://doi.org/https://doi.org/10.1016/j.tre.2021.102445>



Zhou, Y., Meng, Q., & Ong, G. P. (2022). Electric Bus Charging Scheduling for a Single Public Transport Route Considering Nonlinear Charging Profile and Battery Degradation Effect. *Transportation Research Part B: Methodological*, 159, 49-75.

<https://doi.org/https://doi.org/10.1016/j.trb.2022.03.002>

Li, H., Kaleem, M. B., Chiu, I. J., Gao, D., & Peng, J. (2021). *A Digital Twin Model for the Battery Management Systems of Electric Vehicles*.

<https://doi.org/10.1109/HPCC-DSS-SmartCity-DependSys53884.2021.00171>