



HERRAMIENTAS DE MODELIZACIÓN Y ANÁLISIS PARA LA MOVILIDAD ELÉCTRICA

CASOS DE USO A NIVEL URBANO

BABAK RAVANBACH¹, JOHN ERIK ANDERSON¹

¹ German Aerospace Center, Germany

PALABRAS CLAVE	RESUMEN
<i>Transporte</i>	<i>La integración de los sectores del transporte y la electricidad representa tanto un reto como una oportunidad para el sistema energético europeo. Por un lado, se necesitan grandes cantidades de electricidad para alimentar los vehículos eléctricos, lo que exige una predicción más precisa de la demanda, tanto a corto plazo como a futuro. Por otro lado, el uso de la tecnología Vehicle-to-Grid puede proporcionar servicios a la red. El diseño, la gestión y la planificación de la infraestructura requieren sofisticadas herramientas basadas en datos. Este documento destaca una selección de las herramientas existentes del DLR (Centro Aeroespacial Alemán) desarrolladas para el modelado y el análisis del sector de la movilidad eléctrica integrada.</i>
<i>Vehículos eléctricos</i>	
<i>Movilidad eléctrica</i>	
<i>Flexibilidad</i>	
<i>Datos</i>	
<i>Vehículo a red</i>	
<i>Modelos</i>	
<i>Herramientas digitales</i>	
<i>DLR-MobilityLab</i>	

RECIBIDO: 04 / 09 / 2025

ACEPTADO: 01 / 10 / 2025

1. Introducción

La integración de los sectores del transporte y la electricidad supone tanto un reto como una oportunidad para el sistema energético. Por un lado, se necesitan grandes cantidades de electricidad para recargar los vehículos eléctricos, lo que requiere una predicción más precisa de la demanda de recarga a corto plazo y el refuerzo de la infraestructura eléctrica existente a largo plazo. Según la Asociación Europea de Fabricantes de Automóviles (ACEA), en 2023 se instalaron 150 000 puntos de recarga públicos adicionales, lo que elevó el total en Europa a más de 630 000 para los tres millones de vehículos eléctricos de batería (BEV). Para alcanzar la reducción del 55 % de las emisiones de gases de efecto invernadero de la Unión Europea para 2030, se necesitarán un total de 3,5 millones de puntos de recarga (ACEA, 2024). Para alcanzar este objetivo, sería necesario triplicar, en promedio, la tasa de instalación registrada en 2023 durante los años restantes. Por otra parte, la energía almacenada en los vehículos eléctricos puede devolverse a la red mediante la tecnología *Vehicle-to-Grid* (V2G), para ofrecer servicios como el aplanamiento de picos y la estabilización de las redes locales. Teniendo en cuenta el crecimiento del mercado de los vehículos eléctricos en Europa (CE, 2019; CE, 2021; CE, 2023), así como los retos y oportunidades asociados, el diseño, la gestión y la planificación de la infraestructura eléctrica de apoyo para las aplicaciones de carga y descarga requieren herramientas sofisticadas basadas en datos. Predecir los futuros escenarios de movilidad eléctrica, tanto en términos energéticos como de movilidad en el contexto urbano, puede ser crucial para adoptar las decisiones y medidas adecuadas que permitan alcanzar los objetivos de neutralidad en carbono de la UE. En el caso de la gestión energética local, la previsión energética precisa y la cuantificación de la flexibilidad de los vehículos eléctricos son fundamentales para el funcionamiento y la planificación de una red eléctrica estable en el futuro (González et al., 2019).

La innovación tecnológica en el campo de la inteligencia artificial y, en particular, los métodos de aprendizaje automático que se ocupan de la gestión y la planificación energéticas están revolucionando la forma en que los gestores y planificadores de ciudades inteligentes abordan algunos de sus retos cotidianos, así como la aplicación de estrategias para la planificación de infraestructuras a largo plazo. Según Yaghoubi et al., las técnicas de aprendizaje automático (y, en particular, los modelos de aprendizaje profundo, un subconjunto del aprendizaje automático) están surgiendo como técnicas viables en el ámbito del análisis predictivo de los vehículos eléctricos (Yaghoubi, 2024). La planificación de infraestructuras en este contexto implica cinco dimensiones de modelización y cálculo: la predicción de la demanda de recarga, la optimización de la ubicación de las estaciones de recarga, el factor de utilización de dichas estaciones, la programación de la recarga y la fijación de precios (Deb, 2021).

Además, las investigaciones realizadas hasta la fecha han demostrado que la integración de los vehículos eléctricos en el sistema energético es fundamental para avanzar hacia sistemas de transporte y de energía más sostenibles. Rana et al. llevaron a cabo una revisión sobre el impacto de los vehículos eléctricos en las redes eléctricas (Rana, 2025). Los autores descubrieron que los vehículos eléctricos pueden ayudar a equilibrar las oscilaciones de la red eléctrica debido a la imprevisibilidad de la red eléctrica. En otro artículo, Yang et al. exploran los efectos de mitigación de los vehículos eléctricos en la red eléctrica debido a fenómenos meteorológicos extremos (Yang, 2025). Su trabajo propone una evaluación para analizar las vulnerabilidades de la red. Sayed et al. (2022), Garwa y Niazi (2019) y Khalid et al. (2024) han realizado trabajos similares sobre el impacto de los vehículos eléctricos en las redes eléctricas, lo que ilustra la importancia central de este tema.

1.1. Marco teórico (la pregunta de investigación y la revisión de la literatura)

Como se ha señalado anteriormente, los vehículos eléctricos son fundamentales para la transición de los sectores del transporte y la energía, así como para la consecución de los objetivos de sostenibilidad. Si bien las fuentes mencionadas ilustran la amplitud de la investigación realizada sobre este tema, su aplicación en el mundo real sigue siendo difícil de alcanzar (Clarke et al., 2022). Por tanto, aunque se publican numerosas investigaciones, persiste una desconexión entre la teoría y su aplicación. Este es especialmente el caso del sector del transporte (Kervall y Pålsson, 2022;

Khurshid et al., 2023; Kirjavainen y Suopajarvi, 2025). En consecuencia, es necesario trasladar los resultados de la investigación académica a la práctica de manera oportuna y eficiente. Para ello, los autores examinan un nuevo marco para presentar la investigación a los responsables de la toma de decisiones en forma de laboratorio de movilidad, que permite la interacción con modelos, datos y diversas herramientas. Estas herramientas y el propio laboratorio de movilidad se presentan más adelante en el artículo.

Un requisito importante para desarrollar estos modelos basados en datos y herramientas de simulación es la disponibilidad de una gran cantidad de datos sobre el terreno. En el caso de la monitorización en tiempo real del sistema, es evidente que no solo deben utilizarse datos históricos, sino también datos dinámicos de los dispositivos inteligentes del IoT como entrada para estos modelos tan complejos. La disponibilidad de datos de las API (interfaces de programación de aplicaciones) permite una integración y transmisión fluidas de datos dinámicos del sistema para una simulación y un análisis más actualizados y precisos del sistema de movilidad eléctrica en funcionamiento.

1.2. DATAMOST y MoDa: herramientas de investigación para los responsables de la toma de decisiones

Garantizar la transición exitosa hacia un sistema de transporte y energía sostenible requiere no solo nuevas tecnologías, sino también la aceptación de los usuarios y la comprensión de las ventajas e inconvenientes. Por lo tanto, la investigación desempeña un papel clave en la exploración de diferentes resultados mediante el análisis de diversos escenarios. Para ello, se pueden utilizar grandes cantidades de datos y modelos de última generación para determinar diferentes escenarios y cursos de acción. En el DLR (Centro Aeroespacial Alemán), dos proyectos de este tipo destacan el papel de la investigación para facilitar la participación de las partes interesadas en la planificación y la toma de decisiones. Estos proyectos son «Soluciones basadas en datos y modelos para la transformación de la movilidad» (DATAMOST) y «Modelos y datos para la movilidad del futuro_Servicios de apoyo» (MoDa) (DLR, 2022; DLR, 2025).

Estos proyectos se basan en los amplios recursos de datos y modelos del DLR para desarrollar nuevos servicios que ayuden a acelerar el cambio hacia una movilidad más sostenible. Para impulsar eficazmente la transición hacia la movilidad, estos servicios deben ser prácticos, fáciles de usar y adaptados a las necesidades específicas de las empresas y las instituciones públicas. Un elemento clave para desarrollar métodos y herramientas científicamente sólidos es aprovechar la experiencia interinstitucional del DLR.

Los servicios MoDa desarrollarán herramientas científicas relevantes y, lo que es más importante, precisas, para proporcionar información a clientes clave, como los gobiernos locales, el gobierno nacional, las empresas y el público en general. Abarcarán una amplia gama de cuestiones relacionadas con el transporte y colaborarán estrechamente con las posibles partes interesadas (DLR, 2025).

Este documento destaca una selección de las herramientas científicas existentes del DLR que se han desarrollado específicamente para la modelización, simulación y análisis de los sistemas integrados de movilidad eléctrica en el contexto urbano. Estas herramientas de última generación permiten a las partes interesadas en la energía y la movilidad de las ciudades europeas —incluidas empresas de suministro energético, operadores de puntos de recarga, urbanistas y gestores, entre otros— tomar decisiones basadas en datos a corto y largo plazo. Esto se logra mediante una plataforma que permite crear gemelos digitales de los sistemas de movilidad eléctrica, construir diferentes escenarios y generar análisis y soluciones.

1.2.1. Acerca del DLR

El DLR es el Centro Aeroespacial Alemán (en alemán: *Deutsches Zentrum für Luft- und Raumfahrt*). Se trata de una organización de investigación que trabaja en cinco áreas: espacio, vuelo, seguridad, transporte y energía. El DLR actúa como centro espacial nacional de Alemania (DLR, 2025b).

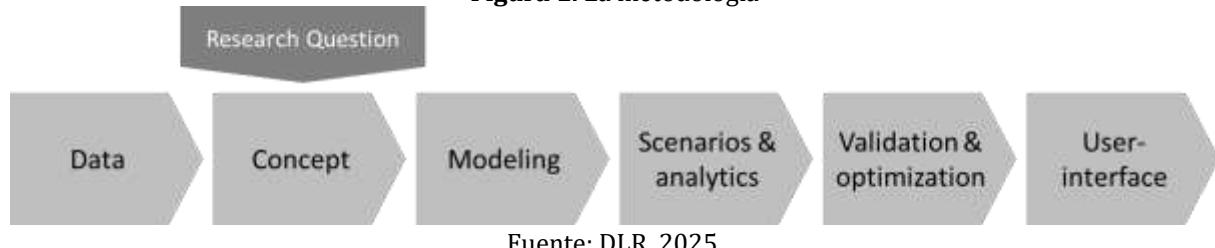
De los 54 institutos del DLR, dos de ellos, el Instituto de Investigación del Transporte del DLR (DLR VF) y el Instituto de Sistemas Energéticos en Red (DLR VE), contribuyen a este documento.

El Instituto de Investigación del Transporte se centra en todos los aspectos del transporte terrestre, con especial atención al transporte sostenible, desde las cuestiones sociales hasta las medioambientales. El personal científico tiene diversos antecedentes (desde ingeniería hasta psicología) para comprender todos los aspectos complejos del transporte y la movilidad en el siglo XXI (DLR, 2025c). En el DLR VE, la atención se centra en la transición hacia un sistema energético sostenible. Para ello, el equipo desarrolla modelos energéticos, de redes eléctricas y de demanda energética a partir de diversas fuentes, incluyendo el transporte. Los expertos del DLR VE también trabajan en la creación de escenarios de uso y utilización de la energía en el futuro (DLR, 2025d).

2. Metodología

Los servicios MoDa, tal y como se describen en la sección introductoria, tienen su origen en las actividades de modelización y análisis científicos del DLR. La modelización y el análisis científicos en su forma estándar comienzan con la formulación de las preguntas de investigación adecuadas relacionadas con el panorama de la movilidad, a lo que sigue la creación de modelos computacionales que representan el complejo sistema objeto de estudio y la formulación de escenarios sólidos para el análisis detallado y los objetivos previstos. En el caso particular de los servicios MoDa, el enfoque estándar de modelización y análisis científicos se amplía mediante la creación de herramientas para los usuarios, con el fin de ofrecer a un espectro más amplio de partes interesadas —más allá de la comunidad científica convencional— la posibilidad de acceder y utilizar los conocimientos generados. La metodología aplicada para crear los servicios MoDa y las herramientas de ampliación consta de seis pasos principales, que se ilustran en el siguiente diagrama.

Figura 1. La metodología



Fuente: DLR, 2025.

2.1.1. Paso 1: Recopilación y preprocesamiento de datos

Las fuentes de datos brutos proceden de datos de código abierto disponibles públicamente o de datos obtenidos internamente mediante mediciones o síntesis de datos. En función de la calidad y la complejidad de los datos, se aplican diversas técnicas de procesamiento de datos para mejorar la regulación y la usabilidad de los mismos.

2.1.2. Paso 2: Conceptualización

Este paso está fuertemente determinado por la formulación de la pregunta de investigación para cada herramienta y por su aplicación específica. El paso de conceptualización consiste en elaborar un plan para abordar los problemas abstractos y complejos de cada aspecto del sector de la movilidad, considerando especialmente los escenarios futuros. A continuación, se examina y se enmarca la relación de estos problemas con los temas de la transición energética. Los conceptos abarcan una amplia variedad de cuestiones del sector del transporte y se desarrollan en estrecha colaboración con los usuarios potenciales, incluyendo autoridades públicas, la industria y el ámbito de la investigación y el desarrollo.

2.1.3. Paso 3: Modelización

El núcleo del enfoque de modelización se basa en métodos computacionales para simular, analizar y comprender los complejos sistemas de movilidad y movilidad eléctrica. Se utilizan lenguajes de programación de última generación, como Python, y sus bibliotecas personalizadas para crear

modelos representativos de los conceptos que se investigan. El aprovechamiento de técnicas modernas de inteligencia artificial, como el aprendizaje automático y las redes neuronales profundas, permite procesar grandes cantidades de datos para realizar predicciones y producir análisis útiles. Estas tecnologías ofrecen la ventaja de integrar datos y principios teóricos.

2.1.4. Paso 4: Generación de escenarios, simulación y análisis

Con el objetivo de proporcionar información a las principales partes interesadas, incluidos los organismos gubernamentales, las empresas y el público en general, es fundamental generar escenarios significativos para cada uno de los servicios MoDa. Este paso ofrece escenarios orientados al cliente que son relevantes y precisos, lo que permite que los servicios MoDa reflejen las necesidades de las distintas partes interesadas a las que se dirigen. Los modelos de simulación proporcionan análisis científicamente probados que ayudan a las partes interesadas en la movilidad y la energía a planificar de forma más eficiente, colaborativa, precisa y rentable.

2.1.5. Paso 5: Validación de los resultados y optimización del modelo y los escenarios

Todos los modelos del MobilityLab y de los servicios MoDa se desarrollaron internamente en el DLR. Para validar los modelos y los resultados, seguimos el proceso típico de revisión por pares, publicando los resultados en conferencias y revistas especializadas. Hasta la fecha se han publicado 17 publicaciones con el proyecto MoDa (desde enero de 2024) (Bergfeld et al., 2024; Bosch et al., 2025; Grunewald et al., 2025; Hasselwander et al., 2025; Herwartz-Polster et al., 2024; Möring-Martínez et al., 2024; Möring-Martínez et al., 2025).

2.1.6. Paso 6: Diseño e implementación de la interfaz de usuario

Una vez desarrollados el modelo y los conjuntos de datos, fue necesario crear la interfaz de usuario. Esto dio lugar a la creación del MobilityLab (véase más abajo). Este fue creado por expertos en visualización, así como por las partes interesadas, con el fin de incorporar sus deseos y necesidades para cada módulo y servicio. Teniendo en cuenta estos factores, el equipo de diseño interno del DLR creó el MobilityLab, que se actualiza constantemente con nuevos resultados y escenarios, así como con los comentarios de los usuarios y las partes interesadas.

En la siguiente sección se describe con más detalle la implementación de la interfaz de usuario de los servicios y herramientas de MoDa.

2.2. El MobilityLab del DLR: un MobilityLab para todos

Como se ha descrito en la sección anterior, los servicios MoDa del DLR proporcionan la base de conocimientos científicos que sustenta las herramientas del DLR. Una vez desarrollados los servicios que son de utilidad para diversas partes interesadas, surge la pregunta de cómo pueden interactuar con ellos. El proyecto de investigación DATAMOST fusionó la experiencia del DLR y los resultados de investigaciones innovadoras en un laboratorio de movilidad interactivo para la visualización y la presentación, denominado MobilityLab.

A partir de los extensos datos del DLR sobre el sector del transporte, se utilizan diversos modelos de simulación en el MobilityLab. Estos modelos tienen en cuenta cómo pueden cambiar resultados como las emisiones relacionadas con el tráfico, el ruido, la demanda de energía, la demanda de transporte y la accesibilidad como consecuencia de diversas medidas de planificación del transporte. También se pueden modelar nuevos tipos de transporte, como los minibuses autónomos, lo que permite investigar mejor sus implicaciones prácticas.

Con el MobilityLab, el DLR puede modelar, visualizar y evaluar medidas de transporte, incluso antes de que se implementen. Esto permite a los responsables de la toma de decisiones de la política, las autoridades locales y la industria planificar de forma más eficiente, colaborativa, precisa y rentable. Este laboratorio crea un espacio físico que permite a las empresas y a la sociedad experimentar y comprender los resultados de la investigación del DLR de forma interactiva. Promueve la exploración y evaluación colectiva y abierta de soluciones de movilidad pioneras por parte del DLR y sus socios prácticos.

DATAMOST desarrolló las interfaces necesarias entre los resultados de la investigación interdisciplinaria del DLR para dar forma a soluciones para las transformaciones de la movilidad. Esto se logra vinculando los modelos existentes, utilizando datos de última generación y empleando métodos analíticos innovadores, como el aprendizaje automático y la inteligencia artificial. De este modo, el DLR amplía la investigación sobre el transporte mediante conexiones sistémicas y visualizaciones intuitivas. El laboratorio de movilidad mejora la comprensibilidad y la visibilidad de los logros de la investigación para la sociedad, la economía, la política y el público.

3. Resultados

En este documento se presentan tres resultados principales: el MobilityLab, los servicios MoDa y la herramienta EPIOT (Electric mobility Prediction Interactive Open-source Tool, herramienta interactiva de código abierto para la predicción de la movilidad eléctrica). El laboratorio de movilidad consta de seis módulos: Atmosphere/Climate, VMo4Orte, TAPAS/SUMO, CAST, MECO(n) y PowerForecastMapper. Entramos en detalle sobre el PowerForecastMapper. A continuación, presentamos los siete servicios MoDa y, por último, presentamos la herramienta EPIOT en detalle.

3.1. *El panel de control del usuario de MobilityLab: un marco modular para mostrar modelos y resultados de investigación*

Un aspecto central de DATAMOST es la expansión metódica del laboratorio de movilidad para evaluar soluciones de movilidad. Esto incluye evaluar la eficacia de las soluciones de movilidad y tráfico previstas. Cabe destacar la integración innovadora de diversas fuentes de datos y métodos para desarrollar gemelos digitales de soluciones de movilidad y obtener resultados de investigación en el DLR. Los métodos cuantitativos y cualitativos para recopilar información y desarrollar soluciones creativas para los retos del sistema de transporte se complementan entre sí.

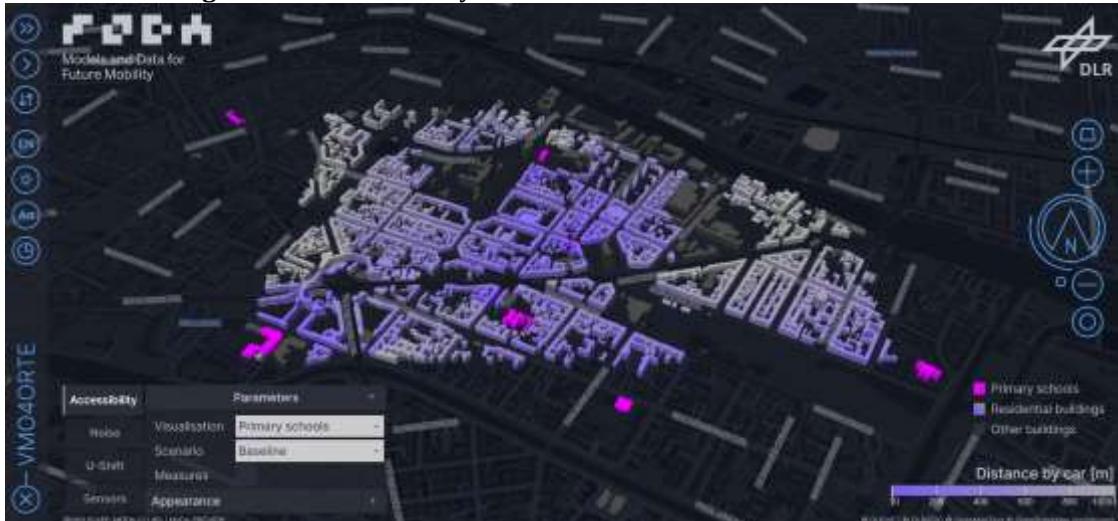
Gracias a su integración, el laboratorio de movilidad aporta un valor añadido a la evaluación y, al mismo tiempo, actúa como proveedor de datos. Genera retroalimentación de datos y conocimientos resultantes que perfeccionan los modelos utilizados. Además, al garantizar la transferibilidad a campos de aplicación del mundo real, se asegura la relevancia comercial del laboratorio de movilidad mediante resultados específicos y sólidos. El DLR MobilityLab se presenta en las siguientes figuras.

Figura 2. Página de inicio del DLR-MobilityLab con diferentes módulos en el lado izquierdo.



Fuente: DLR, 2025.

Figura 3. El DLR-MobilityLab mostrando la herramienta VMo4Orte.



Fuente: DLR, 2025.

3.1.1. Módulos actuales del MobilityLab

Actualmente hay seis módulos en MobilityLab, tal y como se resume en la siguiente tabla.

Tabla 1. Lista actual de módulos del DLR MobilityLab

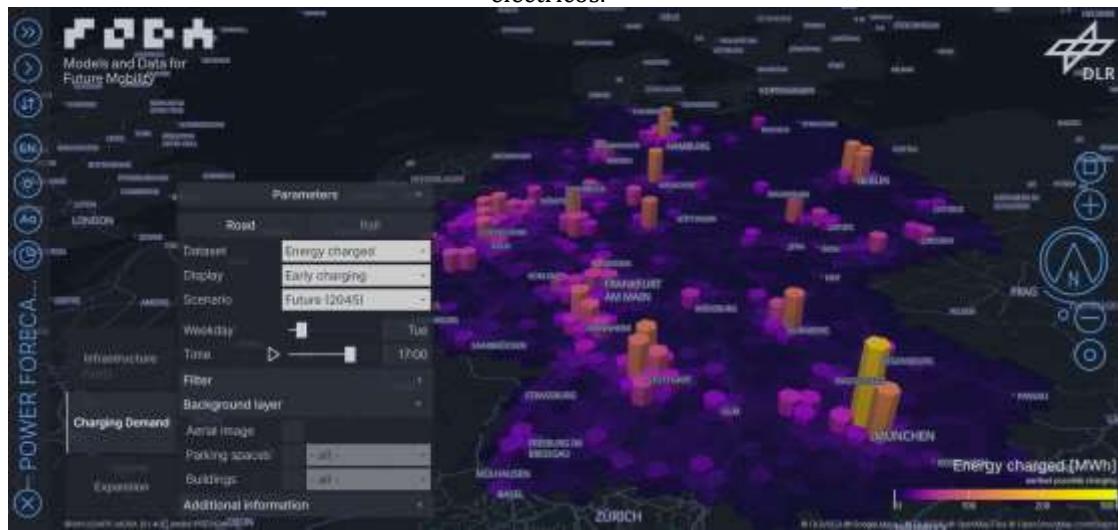
Módulo	Tema y contenido
Atmósfera/Clima	Este módulo presenta los resultados del análisis climático del DLR, que ofrece datos sobre emisiones, cargas contaminantes y forzamiento climático. Se calculan escenarios hasta 2050 para el transporte terrestre, el transporte marítimo internacional y la aviación.
VMo4Orte	Este módulo ilustra posibles soluciones de movilidad dentro de un barrio local de Berlín. Entre ellas se incluyen lanzaderas autónomas para pasajeros y paquetes, así como medidas para reducir el tráfico (limitar el acceso a las calles). Se muestran los resultados en cuanto a contaminación acústica y accesibilidad.
TAPAS / SUMO	Este módulo muestra los resultados de TAPAS (Travel-Activity-Pattern Simulation) y SUMO (Simulation of Urban Mobility) para el estudio de caso de Berlín (Heinrichs 2011, DLR 2025a).
CAST	Este módulo muestra los resultados de CAST (Car Stock Mode) para Alemania, diferenciados por estado federal. Aquí se incluyen los nuevos vehículos y tecnologías (con especial atención a los vehículos eléctricos).
MECO(n)	Este módulo muestra las emisiones y las cargas contaminantes, centrándose en Europa, para los hidrocarburos no metánicos y los NOx del transporte terrestre y el transporte marítimo internacional.
PowerForecastMapper (PFM)	Apoya la expansión de la infraestructura de recarga para vehículos eléctricos de batería. Véase más abajo para obtener información más detallada.

Fuente: DLR, 2025.

3.1.2. PowerForecastMapper (PFM)

La expansión de la movilidad eléctrica requiere una infraestructura de recarga eficiente y ampliamente disponible. Esto incluye no solo la ubicación de las estaciones de recarga, sino también la modificación de la red eléctrica. Sin embargo, esto está sujeto a un alto grado de incertidumbre, ya que la demanda de recarga aumentará de forma diferente en el espacio y el tiempo y las capacidades de la red tendrán que adaptarse en consecuencia. Junto con estos retos, la conexión entre los sistemas de transporte y energía también ofrece oportunidades, como una mayor flexibilidad gracias a la recarga diferida y la devolución de energía a la red.

Figura 4. El servicio DLR: PowerForecastMapper muestra la demanda de recarga de los vehículos eléctricos.



Fuente: DLR, 2025.

El servicio *PowerForecastMapper* (*PFM*) analiza la demanda de recarga de los vehículos de pasajeros y de mercancías por carretera, así como del transporte ferroviario local de pasajeros, con una alta resolución espacial y temporal en diversos escenarios. Basándose en la utilización de la infraestructura existente, se identifican las posibles ubicaciones y configuraciones de puntos de recarga adicionales. Al examinar las interacciones con el sistema energético, se puede estimar el potencial de reducción de la carga máxima y el acoplamiento V2G. Este servicio se ha desarrollado para operadores de infraestructuras de recarga públicas y privadas, propietarios de inmuebles, operadores de redes, operadores de centrales eléctricas, autoridades públicas y responsables políticos.

Dentro del proyecto de investigación MoDa del DLR, estamos desarrollando servicios adicionales para ayudar a las partes interesadas a tomar decisiones sobre el transporte sostenible. Estos servicios adicionales se resumen en la siguiente tabla junto con la nueva herramienta EPIOT.

Tabla 2. Lista actual de los servicios MoDa y EPIOT

Módulo	Tema y contenido
ApplicationSuiteEmissions (ASE)	<i>Transformación sostenible de la movilidad: evaluación de las medidas de protección climática en el sector del transporte.</i>
Previsión de emisiones marítimas (MEF)	<i>Transformación sostenible de la movilidad: identificación y evaluación de estrategias de descarbonización para el sector marítimo.</i>
AirQualityLive (AQL)	<i>Datos en tiempo real sobre partículas en suspensión en el tráfico para promover la calidad del aire y la movilidad sostenibles.</i>
TravelExperienceAPI (TEA)	<i>Desarrollo de métricas centradas en el viajero para evaluar y adaptar los servicios de movilidad.</i>
SmartTransitFleetplanner (STF)	<i>Simulación basada en datos y análisis de escenarios para la integración de flotas autónomas bajo demanda en el transporte público.</i>
TrafficEventFlowcast (TEF)	<i>Predicción del tráfico en eventos mediante la integración de datos en tiempo real procedentes de diversas fuentes.</i>
NewMobilityIndex (NMI)	<i>Índice compuesto de calidad del transporte público y los servicios de movilidad compartida.</i>
Herramienta interactiva de código abierto para la predicción de la movilidad eléctrica (EPIOT)	<i>Herramienta de predicción de la flexibilidad de la movilidad eléctrica. Véase más abajo para obtener información más detallada.</i>

Fuente: DLR, 2025.

3.1.3. Futuros módulos en MobilityLab

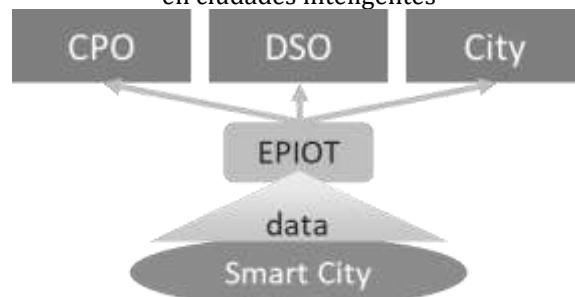
Actualmente se está desarrollando un nuevo módulo, denominado EPIOT (Electric Mobility Prediction Interactive Open-source Tool), que se integrará en el conjunto de herramientas interactivas de MobilityLab. EPIOT está diseñado principalmente para cuantificar la flexibilidad V2G y optimizar la ubicación de las estaciones de recarga en una zona urbana europea genérica. En la siguiente sección se presentan algunos aspectos destacados del módulo EPIOT, incluyendo la conceptualización y modelización subyacentes de la flexibilidad, la arquitectura del modelo y los métodos computacionales, la obtención y el preprocesamiento de datos y, por último, algunos resultados seleccionados.

3.2. Una herramienta para la gestión y planificación de la infraestructura de movilidad eléctrica

Teniendo en cuenta los objetivos de la UE de promover el despliegue masivo de la movilidad eléctrica en toda Europa y la implementación de V2G en el proceso, en los últimos años ha cobrado importancia una cuestión de investigación importante entre los científicos del sector energético. La primera pregunta es cuánta flexibilidad pueden ofrecer los vehículos eléctricos en una determinada zona urbana y, en segundo lugar, cuánta de esta flexibilidad se puede aprovechar en beneficio de la red mediante la aplicación V2G. Cabe preguntarse además cómo debemos proceder para ampliar la infraestructura y optimizarla con el fin de satisfacer las necesidades futuras.

Dentro del proyecto de la UE del DLR titulado DriVe2X, se ha diseñado y desarrollado una herramienta basada en datos denominada EPIOT (Electric mobility Prediction Interactive Open-source Tool) con el objetivo de ayudar a los operadores de puntos de recarga (CPO), así como a los operadores de sistemas de distribución (DSO) y a los planificadores de ciudades inteligentes, entre otros, a planificar el funcionamiento eficiente de su sistema y a planificar de forma inteligente la ampliación de la infraestructura para dar cabida al rápido crecimiento del número de dispositivos de movilidad eléctrica en el futuro europeo. El objetivo de este trabajo es utilizar modelos computacionales de última generación para construir un modelo que pueda predecir el comportamiento de la movilidad eléctrica y ofrecer recomendaciones para un plan optimizado de la infraestructura de estaciones de recarga que aproveche la flexibilidad de V2G.

Figura 5. EPIOT: una herramienta basada en datos para la gestión y planificación de la movilidad eléctrica en ciudades inteligentes



Fuente: Elaboración propia, 2025.

EPIOT es una potente herramienta interactiva de predicción energética desarrollada para predecir los perfiles energéticos (incluida la carga y la descarga) de las estaciones públicas. EPIOT cuenta con métodos para predecir la flexibilidad de carga y descarga de los vehículos eléctricos en una sola estación de carga y métodos adicionales para agregar a nivel de ciudad. Una de las características importantes de esta herramienta es determinar la flexibilidad V2G a nivel de estación de carga y utilizarla como base para la optimización de la ubicación de las estaciones de carga en una zona urbana (ciudad). EPIOT lo consigue aprovechando las técnicas de aprendizaje automático, utilizando una combinación de datos dinámicos de código abierto recopilados y preprocesados del entorno cercano a las estaciones de carga.

EPIOT recopila y utiliza datos de fuentes de acceso público, como OpenStreetMap (OSM 2025), lo que le permite funcionar como una herramienta genérica, adaptable a cualquier ciudad de la UE con los datos básicos disponibles. Tiene la capacidad de aprender de los datos dinámicos que fluyen desde las API de las ciudades inteligentes, por ejemplo, los datos de recarga de las API de los operadores de puntos de recarga, para predecir los patrones de recarga del día siguiente. Está equipada con una interfaz interactiva y fácil de usar con funciones que permiten ajustar diversos escenarios e indicadores clave de rendimiento (KPI) para satisfacer las necesidades de las distintas partes interesadas en la gestión y planificación de las aplicaciones e infraestructuras de movilidad eléctrica.

3.2.1. Indicadores clave de rendimiento

Es fundamental establecer KPI (indicadores clave de rendimiento) y métricas para las distintas partes interesadas en el ámbito de los vehículos eléctricos (VE) por varias razones. En primer lugar, estos KPI y métricas sirven como herramientas valiosas para evaluar y cuantificar el rendimiento y el impacto de las actividades relacionadas con los VE. Permiten a las partes interesadas ir más allá de los datos brutos y obtener información significativa, que es esencial para tomar decisiones informadas en materia de funcionamiento y planificación. Además, los KPI y las métricas proporcionan un lenguaje y un marco comunes para la comunicación entre las diferentes partes interesadas del ecosistema de los VE. Ayudan a salvar la brecha entre los datos técnicos y la toma de decisiones prácticas, traduciendo información compleja en conocimientos claros y aplicables. Esto facilita la colaboración y el entendimiento entre diversos grupos, como operadores, planificadores, organismos gubernamentales y empresas, todos ellos con un interés particular en el éxito de las iniciativas relacionadas con los VE.

Sin embargo, diferentes KPI pueden resultar interesantes para diferentes partes interesadas. Por ejemplo, es más probable que un operador de red esté interesado en el nivel de carga de los transformadores locales debido a la recarga, mientras que un comité medioambiental del municipio esté interesado en minimizar las emisiones de CO₂. Al adaptar los estudios de casos y utilizar KPI de alta calidad, los operadores y planificadores pueden tomar decisiones más eficaces y eficientes. Estos KPI les guían a la hora de abordar retos y oportunidades específicos dentro de sus áreas de responsabilidad, garantizando que los recursos se asignen de forma óptima y que la infraestructura de vehículos eléctricos se desarrolle de manera que se maximicen sus beneficios para la comunidad y el medio ambiente.

Habrá cinco categorías iniciales de KPI que se calcularán y seguirán, cada una de ellas centrada en diferentes áreas, como la red, la movilidad eléctrica, el medio ambiente, la ciudad y el usuario. Estos KPI pueden configurarse tanto en términos de restricciones espaciales como temporales. Como característica adicional, también es posible definir e integrar algunos escenarios de usuario o KPI agregados para investigar la influencia de los parámetros cambiantes de la ciudad y la movilidad eléctrica en las estaciones de recarga y la red.

3.2.1.1. KPI de la red

A partir de los perfiles de carga agregados de numerosos cargadores de vehículos eléctricos y aprovechando la topología de la red, los usuarios pueden supervisar la carga de los transformadores individuales resultante de la recarga de vehículos eléctricos. Este proceso se facilita mediante la utilización de una topología de red del Sistema de Información Geográfica (SIG) de código abierto. En esencia, se ha desarrollado un algoritmo para reconstruir la red de baja tensión (BT), lo que permite el seguimiento de las líneas eléctricas desde las estaciones de carga hasta los transformadores. Este enfoque proporciona una visión global de los efectos de la carga de vehículos eléctricos en diferentes zonas de una ciudad.

Cuando los usuarios seleccionan centrarse en un transformador específico, los modelos analíticos, en colaboración con la salida de ML y la calculadora de KPI, ofrecen una representación visual del perfil de carga agregado a nivel del transformador. Este KPI es una herramienta valiosa, especialmente para los operadores de la red, ya que les permite cuantificar el impacto de la recarga de vehículos eléctricos y comprender mejor el potencial de flexibilidad inherente, lo que contribuye a una gestión de la red y una toma de decisiones más informadas.

3.2.1.2. KPI de la ciudad

Un KPI útil para las zonas urbanas es el índice de ocupación de los cargadores de vehículos eléctricos dentro de una zona determinada. Este KPI es un recurso valioso para los urbanistas, normalmente asociados a los organismos municipales, y para los operadores de redes a la hora de tomar decisiones informadas sobre la instalación de cargadores. Una zona con cargadores ocupados de forma constante puede indicar una escasez de puntos de recarga disponibles, lo que pone de relieve una posible limitación a medida que la población de vehículos eléctricos sigue aumentando en los próximos años. En la práctica, nuestro modelo aprovecha los resultados del modelo de aprendizaje automático, en particular los detalles de las transacciones de recarga en un día, para visualizar la tasa de ocupación dentro de las áreas de interés. Por ejemplo, los operadores de sistemas de distribución (DSO) podrían estar interesados en evaluar el total de cargadores conectados a un transformador, mientras que las autoridades municipales podrían centrarse en el total de cargadores dentro de una calle residencial. Este enfoque permite tanto a los urbanistas como a los operadores de redes abordar de manera eficaz la creciente demanda de infraestructura de recarga de vehículos eléctricos, garantizando una cobertura y accesibilidad adecuadas para los usuarios de vehículos eléctricos.

3.2.1.3. KPI medioambiental

La medición de los gramos de CO₂ ahorrados constituye un KPI medioambiental que aborda una de las preocupaciones más apremiantes de los paisajes urbanos actuales. En concreto, el cálculo de este KPI es relativamente sencillo y se correlaciona directamente con la cantidad de KWh de energía cargada dentro de un área definida por el usuario durante un periodo de tiempo específico. A medida que avanzamos hacia una mayor dependencia de los vehículos eléctricos, esto no solo permite un uso más eficiente de los recursos de energía renovable, sino que también sirve para reducir la presencia de los coches con motores de combustión convencionales en nuestras carreteras. Algunos países han impuesto regulaciones estrictas que rigen las emisiones de dióxido de carbono en los centros urbanos. Por lo tanto, cuantificar el impacto de los procesos de recarga es un paso significativo en el esfuerzo colectivo por salvaguardar nuestro planeta y fomentar mejores condiciones de vida en nuestras ciudades. Al reducir las emisiones de CO₂ y

promover alternativas de transporte más limpias, contribuimos a la mejora de los entornos urbanos, haciéndolos más habitables y sostenibles para las generaciones presentes y futuras.

3.2.1.4. KPI de usuario

Los KPI de usuario sirven como herramienta para realizar un seguimiento del número de sesiones de recarga dentro de un área definida por el usuario durante un periodo de tiempo especificado por él. Permiten comprender de forma exhaustiva el comportamiento de los usuarios en relación con la recarga de vehículos eléctricos. Estos valiosos datos permiten a las distintas partes interesadas en los vehículos eléctricos, incluidos los CPO, evaluar la rentabilidad potencial de establecer una infraestructura de recarga en áreas con características similares. En esencia, este KPI contribuye a un proceso de toma de decisiones más informado y ayuda a maximizar la eficiencia y la eficacia de los servicios de recarga de vehículos eléctricos en respuesta a las demandas y preferencias de los usuarios.

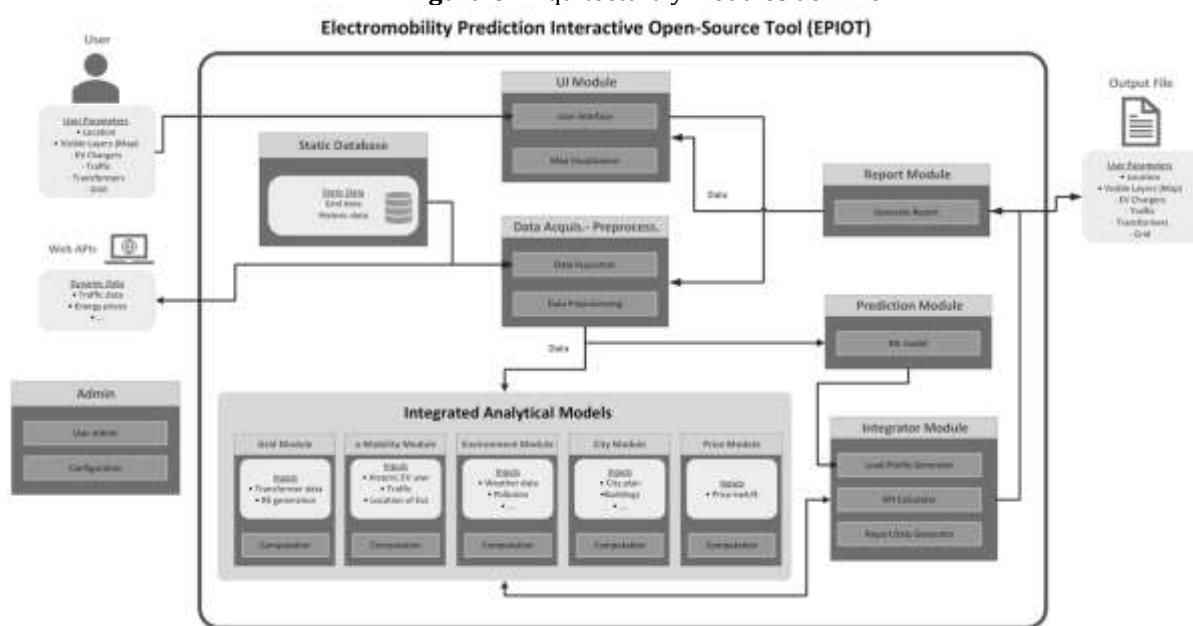
3.2.1.5. KPI de movilidad eléctrica

Por último, presentamos la métrica de los kilómetros que se pueden recorrer gracias a la recarga. Este KPI de movilidad eléctrica se alinea con los objetivos de los KPI que supervisan el consumo total de energía y el número total de sesiones de recarga. Estas métricas ofrecen colectivamente información valiosa que puede guiar a los CPO y a las autoridades municipales a la hora de cuantificar el potencial de flexibilidad de las soluciones inteligentes de recarga de vehículos eléctricos. Al examinar estos KPI, las partes interesadas obtienen una imagen más clara de cómo la recarga de vehículos eléctricos puede mejorar la movilidad eléctrica y, al mismo tiempo, optimizar la utilización de la infraestructura de recarga actual.

3.3. Arquitectura y módulos

En la siguiente figura se muestra una versión de la arquitectura prototipo de EPIOT y sus módulos.

Figura 6. Arquitectura y módulos de EPIOT



Fuente: Ravanbach et al., 2024.

Partiendo del «módulo UI», este módulo sirve como capa principal de interacción entre el usuario y los datos. Todas las funcionalidades interactivas de EPIOT pueden activarse y visualizarse en esta capa. La interfaz principal cuenta con un mapa interactivo en el que el usuario puede hacer clic, navegar e interactuar para seleccionar el tipo de información que se mostrará en el mapa y en las ventanas sucesivas. Esta interfaz de visualización dinámica mejora la capacidad

del usuario para analizar los datos, ofreciendo una visión completa de la infraestructura de movilidad eléctrica y los parámetros de la ciudad en segundo plano. Los elementos de la ciudad se pueden activar y desactivar (estaciones de carga o transformadores, etc.), y se pueden integrar adicionalmente en el mapa más capas, incluyendo datos dinámicos de varias API de ciudades inteligentes.

El «módulo de adquisición de datos» se encarga de obtener los datos de una base de datos estática o una API web y preprocesarlos en el formato correcto, de modo que puedan ser utilizados por otros módulos. Su función principal consiste en obtener y preprocesar los datos solicitados por el usuario a través de la interfaz de usuario (mapa), el modelo predictivo de aprendizaje automático o los modelos analíticos integrados. Toda la información estática de EPIOT se almacena en una base de datos de código abierto, escalable y fiable. El «módulo de predicción» es donde se llevará a cabo la funcionalidad principal del módulo de ML, como se ha presentado anteriormente.

Los «módulos analíticos integrados» se utilizarán para el posprocesamiento de los resultados del ML con el fin de ayudar en el cálculo de los KPI predefinidos. Por último, el «módulo integrador» consta de tres submódulos: el generador de perfiles de carga, el generador de KPI y el agregador de datos. Estos submódulos combinan los resultados de los modelos analíticos y del módulo ML para crear un resultado final útil para el usuario. A continuación, el usuario tendrá la opción de seleccionar varios parámetros en este proceso, como los KPI que se van a calcular y sus detalles, la resolución temporal y el tipo de agregación de datos.

3.3.1. Modelización

3.3.1.1. Definición de flexibilidad

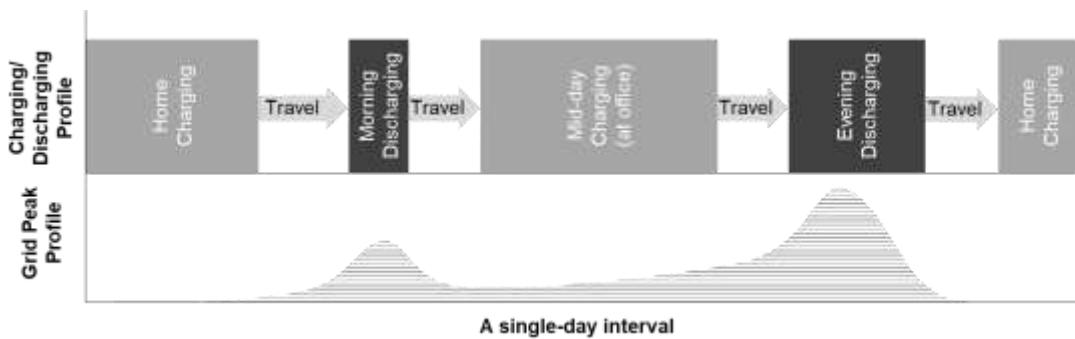
El objetivo de este trabajo es desarrollar un modelo computacional que se utilice para cuantificar la flexibilidad V2G en una zona urbana europea genérica en una primera fase y, en una segunda fase, optimizar la ubicación de las estaciones de recarga existentes con el objetivo de maximizar el intercambio de flexibilidad con la red.

En este trabajo, la flexibilidad se define como la energía disponible del vehículo eléctrico (almacenada en la batería a bordo) que se intercambia con la red (en el momento de la recarga o la descarga) manteniendo los requisitos de la red (restricciones de tensión, sobrecarga). Aprovechar esta flexibilidad puede contribuir a respaldar la red, por ejemplo, mediante la reducción de picos de demanda, la minimización de las actualizaciones de infraestructura y la absorción de energía procedente de fuentes renovables.

El modelado de la flexibilidad de los vehículos eléctricos se lleva a cabo mediante el desarrollo de dos enfoques complementarios. Uno de ellos se basa en el modelado de aprendizaje automático, que se centra en la predicción del perfil de carga en una sola estación de carga utilizando métodos de aprendizaje automático tanto temporales como espaciales, y el segundo método se basa en un modelo basado en reglas que investiga el patrón de descarga de los vehículos eléctricos en la misma estación de carga.

Para construir el perfil de flexibilidad tal y como se ha definido anteriormente, es necesario determinar tres magnitudes. Para una estación de recarga determinada: 1) ¿cuántos vehículos hay en las proximidades a lo largo del tiempo? 2) ¿cuánta energía ofrecen? y 3) ¿cuánto se contribuye a la reducción de picos de la red en diferentes escenarios?

Considerando la flexibilidad V2G como un servicio para la red, por ejemplo, la reducción de picos de demanda, hemos modelado el sistema de manera que sea posible simular la cantidad de energía que se descarga desde las estaciones de carga hacia la red durante los intervalos pico del día. En este enfoque, el modelo asume que la carga de los vehículos eléctricos solo tiene lugar en dos lugares, en casa y en la oficina, entre los que el vehículo eléctrico se desplaza a diario. La descarga solo puede tener lugar entre estos dos lugares y en una estación de carga pública. El gráfico siguiente muestra la hipótesis en términos de perfiles energéticos. Los recuadros de color gris claro ilustran los intervalos de carga en casa o en la oficina, y los recuadros de color gris oscuro indican los intervalos de descarga en una estación de carga pública, donde se puede apoyar la reducción de picos.

Figura 7. Definición del perfil de flexibilidad (descarga a la red para la reducción de picos)

Fuente: Elaboración propia, 2025.

3.3.1.2. Parametrización del sistema

Se determinan seis elementos clave que interactúan entre sí y que, en conjunto, conforman el sistema de movilidad eléctrica. Los parámetros seleccionados en cada categoría se enumeran en la tabla siguiente (Tabla 3). La parametrización del sistema constituye la base para la recopilación y el preprocesamiento de los datos que se utilizarán en el modelo de predicción basado en el aprendizaje automático impulsado por datos. La selección de la combinación adecuada de parámetros de entrada para cada elemento seleccionado del sistema se lleva a cabo mediante un proceso iterativo denominado «ingeniería de características». En este proceso, las variables brutas se transforman en características listas para su inclusión en un modelo de aprendizaje automático (Smith, 2017).

Tabla 3. Descripción de los elementos del sistema de movilidad eléctrica

Categoría	Parámetro (entrada del modelo)
Ciudad	Coordenadas geográficas de la ciudad Número de puntos de recarga Tipos de edificios (oficinas y residenciales, etc.)
Red	Monitorización energética de los puntos de recarga (tanto actual como prevista) Demanda de carga
Vehículos eléctricos (VE)	Modelo de VE Número de VE Monitorización de la energía de los VE (tanto actual como prevista)
Usuario	Propiedad del VE (propietario frente a usuario) Tipo (entidad profesional frente a privada) Tiempo de carga/descarga por sesión
Entorno	Emisiones de CO ₂
Precio	Precio del mercado eléctrico Mecanismos activos de fijación dinámica de precios

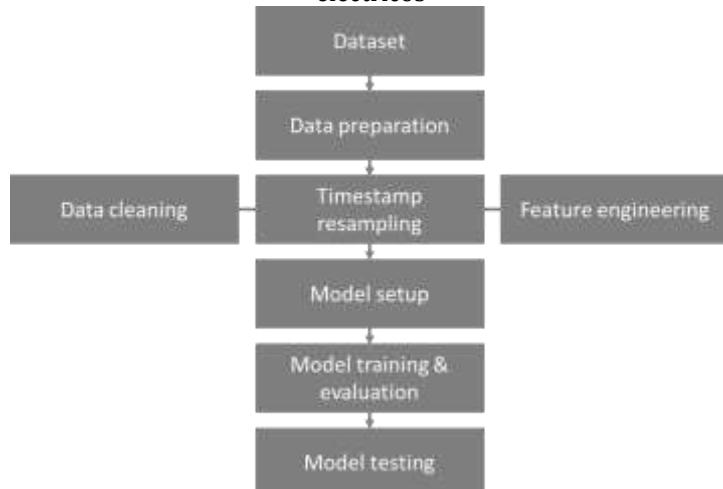
Fuente: Ravanbach et al., 2024.

3.3.1.3. Aplicación de métodos de aprendizaje automático (un modelo integrado de predicción temporal y espacial)

Como se ha mencionado anteriormente, se aplica un enfoque basado en datos para la predicción de la flexibilidad de la infraestructura de recarga de movilidad eléctrica y las cargas de los vehículos eléctricos a nivel urbano. Como componente esencial de este enfoque, se aplica un modelo de aprendizaje automático que, por convención, se basa íntegramente en una gran cantidad de datos estáticos y dinámicos como entrada para el aprendizaje (entrenamiento) y, posteriormente, la predicción de la flexibilidad.

Los resultados del modelo en las estaciones de recarga de vehículos eléctricos muestran su capacidad predictiva, ofreciendo información precisa sobre el estado operativo de las estaciones. El siguiente gráfico presenta un diagrama de flujo de la metodología aplicada en este trabajo.

Figura 8. Diagrama de flujo de la metodología para predecir los perfiles de carga de los vehículos eléctricos



Fuente: Mantri, 2025.

El flujo de trabajo comienza con la recuperación y limpieza de los datos. La limpieza de datos consiste en eliminar los valores que faltan, resolver las inconsistencias y preparar los datos en cuanto a formato y escala para los siguientes pasos del análisis. El siguiente paso consiste en volver a muestrear los datos para obtener un conjunto de datos de resolución consistente ajustado a intervalos de 15 minutos o 1 hora (dependiendo de las preferencias de configuración del usuario). En el siguiente paso se llevará a cabo un método de ingeniería de características, que implica la producción de nuevas entradas temporales y espaciales informativas. Algunas de las características recién creadas, denominadas elementos de descomposición, incluyen tendencias y estacionalidad en el ámbito temporal y la distancia al centro de la ciudad y a algunos tipos de edificios urbanos seleccionados en el ámbito espacial. Tras mejorar las entradas del modelo mediante el ejercicio de ingeniería de características, se procede a la división típica de los datos en subconjuntos de entrenamiento, validación y prueba, como preparación para la ejecución y evaluación del modelo (Mantri, 2025).

La selección del modelo (incluida la configuración) está influenciada por el objetivo de la tarea, la predicción del perfil de carga a nivel de la estación de carga, lo que implica dos dimensiones: temporal y espacial. Por un lado, se considera una manipulación y predicción típicas de datos de series temporales, en este caso, perfiles energéticos. Por otro lado, el procesamiento de los datos espaciales recopilados del entorno de las estaciones de carga requiere la utilización de modelos que puedan manejar no solo la dimensión temporal, sino también el aprendizaje espacial (Mantri, 2025). Las investigaciones existentes en el campo de la predicción de la demanda de vehículos eléctricos se enfocan principalmente en los parámetros temporales de la carga, mientras que los parámetros espaciales que influyen en los patrones de recarga suelen ser ignorados (He et al., 2022). En nuestro enfoque, los parámetros basados en la ubicación que influyen en el patrón de recarga, como la distancia entre las estaciones de recarga o la distancia al aparcamiento más cercano, se incorporan como parte del aprendizaje.

Según Mantri, se seleccionan cuatro modelos adecuados para esta tarea, entre los que se incluyen:

Persistencia: sirvió como punto de referencia directo.

RNN simple: este modelo se eligió para explorar las capacidades de las redes neuronales recurrentes en el manejo de las dependencias temporales

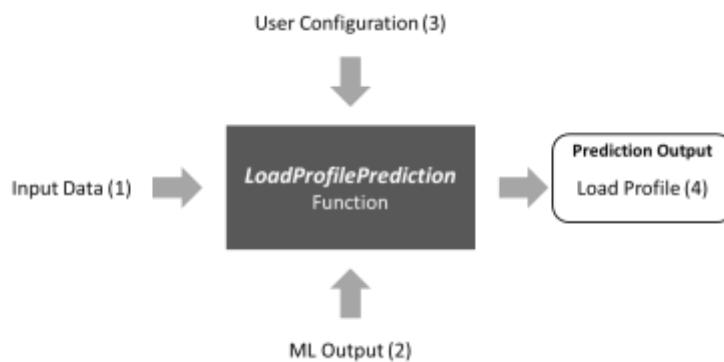
LSTM: conocido por su eficacia con datos secuenciales, este modelo se utilizó para capturar dependencias y variaciones a más largo plazo

GCLSTM: este modelo se seleccionó para incorporar tanto las dependencias temporales como las espaciales, que, como se ha mencionado anteriormente, son fundamentales en esta aplicación debido a los parámetros que influyen en la ubicación geográfica de las estaciones de recarga y a la interrelación entre las estaciones de recarga (la distancia es el parámetro principal) (Mantri, 2025).

3.3.1.4. El perfil de carga resultante

El perfil energético de una sola estación de recarga pública se considera el principal resultado del modelo predictivo previsto. El perfil de carga se genera a partir de tres flujos de datos de entrada que se integrarán mediante una función computacional de posprocesamiento, denominada *LoadProfilePrediction* en la figura siguiente. La descripción de las entradas y la salida se describe en la siguiente tabla.

Figura 9. Entrada y salida de la función LoadProfilePrediction.



Fuente: Ravanbacht et al., 2024.

Tabla 4. Descripción de las entradas y salidas del módulo LoadProfilePrediction

Datos de entrada (Figura 8, 1)	Los parámetros que influyen en el perfil de carga en cada estación de carga provienen de diversas fuentes con diferentes formas y resoluciones, y pueden ser dinámicos o estáticos. Los datos de entrada incluyen los datos adquiridos de los seis elementos clave del sistema de movilidad eléctrica.
Salida de ML (Figura 8, 2)	La salida del modelo ML es un conjunto de datos que predice la conectividad de los vehículos eléctricos en una sola estación de carga con un día de antelación.
Configuración del usuario (Figura 8, 3)	El usuario puede configurar el alcance espacial y la escala temporal de los datos o crear escenarios personalizados.
Perfil de carga (Figura 8, 4)	Como resultado del modelo predictivo, se predice un perfil de carga de serie temporal en una sola estación según la configuración del usuario
Función de predicción del perfil de carga	Este módulo es una función de cálculo determinista que se encarga de generar el perfil de carga objetivo a partir de las entradas explicadas en las filas anteriores.

Fuente: Ravanbach et al., 2024.

Los perfiles de carga obtenidos, con una resolución temporal relativamente alta, pueden proporcionar una predicción fiable del balance energético al operador del sistema con un día de antelación. Los perfiles de carga agregados a nivel de ciudad pueden proporcionar una visión general del rendimiento de la infraestructura basándose en los KPI configurados. Los datos de salida pueden ser utilizados por los planificadores de la ciudad o de la red para analizar y optimizar la ubicación de las estaciones de carga y la infraestructura de apoyo a largo plazo.

El cálculo del perfil de carga de cada cargador no se basa únicamente en los resultados del aprendizaje automático, sino que también se ve influido por parámetros definidos por el usuario. La causa principal radica en la incertidumbre generada por la duración variable de las sesiones de carga. Si bien el módulo de aprendizaje automático destaca por predecir la ocupación de las estaciones de carga con un alto grado de precisión, actualmente carece de la capacidad de pronosticar con exactitud el comportamiento de carga de los vehículos eléctricos. Esta limitación se atribuye principalmente a la escasez de datos de entrenamiento específicos para cada estación.

de carga. Para abordar este reto, empleamos estrategias de carga definidas por el usuario para estimar los perfiles de carga de cada estación de carga. Un escenario común consiste en optimizar la carga de los vehículos eléctricos para una recarga lo más rápida posible, independientemente del precio de la electricidad o de las limitaciones de carga de la red. Por otro lado, cuando una sesión de carga se prolonga más allá de la duración necesaria para la carga completa de la batería de un vehículo eléctrico, el comportamiento de carga puede modificarse en el tiempo para optimizar los objetivos relacionados con los costes o la estabilidad de la red. Además, nuestro modelo de perfil de carga se mejora aún más mediante la incorporación de datos estadísticos específicos de cada zona geográfica. Esto incluye la consideración de las características de las estaciones de carga individuales, como su potencia nominal y tipo de conexión, junto con información sobre los modelos de vehículos eléctricos más comunes. Dado que las diversas combinaciones de estaciones de carga y vehículos eléctricos poseen atributos únicos, como la capacidad de la batería y las tasas de carga mínima y máxima, generan perfiles de carga diversos. Por lo tanto, nos basamos en distribuciones estadísticas que reflejan con precisión el panorama de la recarga de vehículos eléctricos en diferentes áreas, lo que garantiza que nuestras estimaciones sean representativas de situaciones reales.

Al ofrecer a los usuarios la flexibilidad de explorar diversas estrategias de recarga y observar su impacto en varios KPI, les permitimos adaptar los casos prácticos a sus necesidades y objetivos de investigación específicos. Esta adaptabilidad permite un examen más completo y personalizado del panorama de la recarga de vehículos eléctricos.

3.4. La interfaz de usuario interactiva y los resultados analíticos de muestra

Los gráficos siguientes muestran capturas de pantalla del prototipo en línea de la herramienta EPIOT, disponible en: <https://drive2x-epiot.ewi.tudelft.nl/>. Las capturas de pantalla muestran algunas de las principales características y ventanas de resultados de la herramienta, entre las que se incluyen:

- Página de inicio: la página de inicio muestra el mapa de una ubicación seleccionada por el usuario con las estaciones de recarga y los transformadores resaltados con iconos visibles. El usuario puede seleccionar un área de análisis que incluya varias estaciones y transformadores.

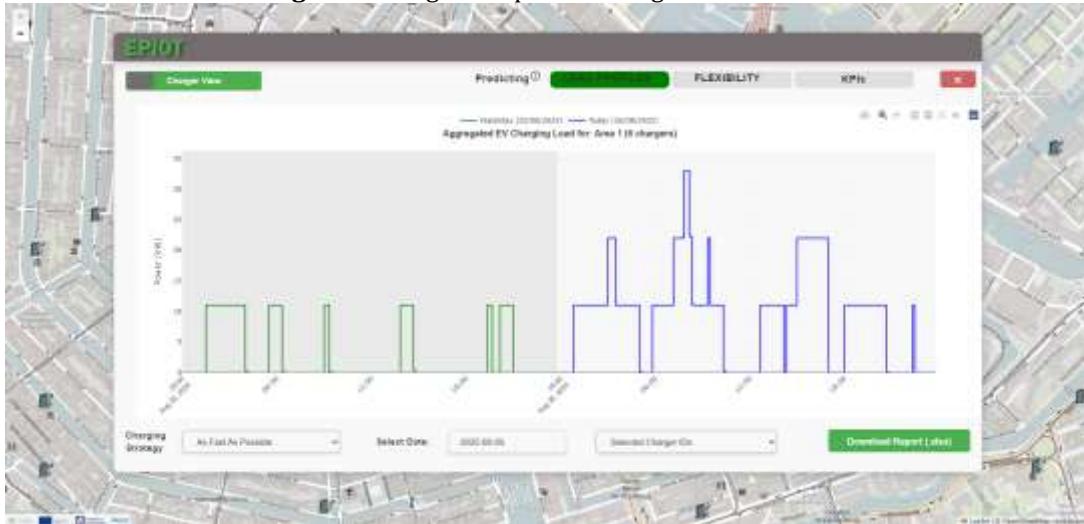
Figura 10. Página de inicio de EPIOT (mapa interactivo de estaciones de recarga)



Fuente: TU Delft, 2025.

- Página de perfil de carga: esta página mostrará el perfil de carga previsto para las estaciones de carga agregadas o individuales seleccionadas por el usuario en la página de inicio anterior. A continuación, el usuario puede seleccionar cómodamente una estrategia de carga concreta en el menú desplegable de la barra inferior para investigar la influencia en la forma del perfil de carga basándose en escenarios de carga preajustados.

Figura 11. Página de perfil de carga de EPIOT



Fuente: TU Delft, 2025.

- Página de flexibilidad: el usuario puede cambiar a la vista de flexibilidad para ver y analizar el patrón de descarga de los vehículos eléctricos en las estaciones de carga seleccionadas (de nuevo, tanto a nivel individual como agregado).

Figura 12. Página de flexibilidad de EPIOT



Fuente: TU Delft, 2025.

- Página de KPI: como última característica, la interfaz permite al usuario navegar por un conjunto predefinido de KPI que se generan en función de la selección de área del usuario. El usuario puede seleccionar una estación concreta o ver los resultados agregados.

Figura 13. Página de KPI de EPIOT



Fuente: TU Delft, 2025.

- Informe: el usuario puede descargar un informe completo del análisis en cualquier momento haciendo clic en el botón verde.

4. Debate y conclusión

La transición exitosa hacia un sistema de transporte sostenible requiere la integración holística de los vehículos eléctricos en el sistema energético. Por ello, proyectos de investigación como DATAMOST y MoDa desempeñan un papel clave en el análisis de datos complejos y la creación de modelos. Estos modelos son más útiles cuando las partes interesadas y los responsables políticos pueden utilizarlos directamente y ver los efectos de las diferentes medidas. Por ello, hemos creado el DLR-MobilityLab para permitir el uso interactivo de numerosos modelos y servicios MoDa. En el ámbito de la movilidad eléctrica, el servicio PowerForecastMapper y el modelo EPIOT proporcionan información fundamental sobre la interacción entre los sectores del transporte y la energía.

No obstante, el estudio previo presenta ciertas limitaciones. En primer lugar, el ámbito de la investigación se limitó a Alemania y, en algunos casos, a Europa. Aunque nuestro objetivo ha sido desarrollar una metodología científicamente sólida y aplicable siempre que existan datos de código abierto, los casos de uso analizados se restringen a estas regiones. En segundo lugar, nos centramos en el transporte de pasajeros y no en el transporte público. Por lo tanto, el trabajo se centra en los vehículos individuales y no en los vehículos de transporte público de mayor tamaño (por ejemplo, autobuses, trenes). Por último, el trabajo se completó utilizando datos de código abierto. Esto limitó el análisis de las redes eléctricas existentes, ya que estos datos no están disponibles públicamente en Alemania. Para futuras investigaciones, nuestro objetivo es ampliar estos modelos a otros países europeos y crear una plataforma de código abierto para el DLR-MobilityLab.

EPIOT es una herramienta prototípica basada en datos que apoya a un gran número de partes interesadas en la movilidad eléctrica, incluidos los operadores de puntos de recarga, los operadores de sistemas de distribución y los planificadores de ciudades inteligentes del futuro, permitiéndoles producir análisis personalizados y evaluar diferentes escenarios basados en KPI calculados. Sus funcionalidades y resultados transferibles pueden proporcionar información valiosa sobre la cuantificación y optimización de la flexibilidad V2G en la infraestructura de recarga existente o futura de cualquier ciudad de Europa. En esencia, estas herramientas basadas en datos son indispensables para impulsar el crecimiento y el éxito de la industria de los vehículos eléctricos, al tiempo que minimizan los posibles inconvenientes (Ravanbach et al., 2024).

5. Agradecimientos

El desarrollo inicial del DLR-MobilityLab se llevó a cabo en el proyecto DATAMOST del DLR («Soluciones basadas en datos y modelos para la transformación de la movilidad», número de proyecto 2846048). El trabajo realizado en el marco del proyecto MoDa («Modelos y datos para la movilidad del futuro_Servicios de apoyo») fue financiado por el Centro Aeroespacial Alemán (DLR) con el número de financiación 2846141. El desarrollo inicial del EPIOT se llevó a cabo en el DLR como parte del proyecto de investigación e innovación de la UE DriVe2X con financiación de la Unión Europea (número de subvención 101056934).

6. Contribuciones

Ravanbach: Concepción y diseño del artículo, todo el trabajo relacionado con EPIOT (concepto y diseño). Anderson: Comentarios sobre el diseño del artículo, todo el trabajo relacionado con DATAMOST, MoDa y MobilityLab en este artículo (todo el equipo del DLR responsable del trabajo detallado en estos proyectos).

Referencias

- ACEA (2024). *Charging ahead: accelerating the roll-out of EU electric vehicle charging infrastructure*.
- Bergfeld, M; Hoyer-Klick, C.; Rottoli, M.; Anderson, J. E., (2024), Bidirectional Charging as a Contribution to the Energy and Mobility Transitions: a Methodology for Modelling. *22nd IEEE Mediterranean Electrotechnical Conference, MELECON 2024. IEEE. 22nd IEEE Mediterranean Electrotechnical Conference.* <https://doi.org/10.1109/MELECON56669.2024.10608601>
- Bosch, E., Luther, A.R. & Ihme, K., (2025) Travel experience in public transport: Experience sampling and cardiac activity data for spatial analysis. *Sci Data* 12, 633 (2025). <https://doi.org/10.1038/s41597-025-04955-4>
- Clarke, L. & Wei, Y.-M. (2022). Energy Systems. In: IPCC, 2022. Climate Change 2022: Mitigation of Climate Change. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. P.R. Shukla et al. (eds.). Cambridge University Press, Cambridge, UK and New York, NY, USA. doi: <https://doi.org/10.1017/9781009157926.008>
- Deb, S. (2021). Machine Learning for Solving Charging Infrastructure Planning Problems: A Comprehensive Review. *Energies*, 14(23), 7833. <https://doi.org/10.3390/en14237833>
- DLR (German Aerospace Center) (2022). *DATAMOST project*. <https://www.dlr.de/de/eoc/forschung-transfer/projekte-und-missionen/datamost>
- DLR (German Aerospace Center) (2025), *MoDa project*. <https://www.dlr.de/de/forschung-und-transfer/projekte-und-missionen/moda>
- DLR (German Aerospace Center) (2025a). *SUMO*, <https://sumo.dlr.de/docs/index.html>
- DLR (German Aerospace Center) (2025b). *DLR, About Us*. <https://www.dlr.de/en/dlr/about-us>
- DLR (German Aerospace Center) (2025c). *DLR VF, About Us*. <https://www.dlr.de/en/vf/about-us/the-institute>
- DLR (German Aerospace Center) (2025d). *DLR VE, About Us*, <https://www.dlr.de/en/ve/about-us/institute-of-networked-energy-systems>
- EC (European Commission) (2019). *Clean Vehicles Directive*. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32019L1161>
- EC (European Commission) (2021). *European Climate Law*. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32021R1119>
- EC (European Commission) (2023). Renewable Energy Directive. <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX%3A32023L2413&qid=1699364355105>
- Garwa, N. and K. R. Niazi, (2019), "Impact of EV on Integration with Grid System – A Review", *8th International Conference on Power Systems (ICPS)*, Jaipur, India, 2019, pp. 1-6, doi: <https://doi.org/10.1109/ICPS48983.2019.9067587>.
- Gonzalez, F., Petit, M., Perez, Y. (2019). Electric Vehicles as Flexibility Providers for Distribution Systems. A Techno-Economic Review. *25th International Conference and Exhibition on Electricity Distribution, Jun 2019, Madrid, Spain*. (hal-02283355)
- Grunewald, Erik und Maertens, Sven und Viergutz, Kathrin Karola und Wegener, Jan und Scheier, Benedikt (2025) SnackTrack: Digitaler Zwilling für Turbo-Umstiege – Imbissbestellung leicht gemacht! In: Proff, H. (eds) *New Players in Mobility*, 1, Seiten 607-621. Springer Gabler, Wiesbaden. 16. Wissenschaftsforum Mobilität, 2024-06-13, Duisburg, Deutschland. https://doi.org/10.1007/978-3-658-46485-1_3
- Hasselwander, Samuel; Rettich, Julian; Schmid, Stephan; Siefkes, Tjark (2025) How will future BEV models develop? Market potential of different battery technologies assessed by a ML-based manufacturer agent. *Journal of Energy Storage*, 131(A). <https://doi.org/10.1016/j.est.2025.117195>
- He, S. Y., Kuo, Y.-H., & Sun, K. K. (2022). The spatial planning of public electric vehicle charging infrastructure in a high-density city using a contextualised location-allocation

- model. *Transportation Research Part A: Policy and Practice*, 160, 21-44. <https://doi.org/10.1016/j.tra.2022.02.012>
- Heinrichs, Matthias (2011) *TAPAS: Travel-Activity-Pattern Simulation - Parallelisiertes Mikroskopisches Verkehrsnachfragermodell*. In: Next GEneration Forum 2011, Seite 74. Deutsches Zentrum für Luft und Raumfahrt e.V.. Next Generation Forum 2011, 2011-09-26 - 2011-09-27, Oberpfaffenhofen, Deutschland., <https://github.com/DLR-VF/TAPAS>
- Herwartz-Polster, S; J. Pagenkopf, J. Kaiser, M. Freienhofer, (2024), "Power Forecast of Overhead Catenary Islands in Battery Electric Train Operation: Case Study of Pfalznetz", in J. Pombo, (Editor), "Proceedings of the Sixth International Conference on Railway Technology: Research, Development and Maintenance", Civil-Comp Press, Edinburgh, UK, Online volume: CCC 7, Paper 12.4, 2024. <https://doi.org/10.4203/ccc.7.12.4>
- Kervall, M. & Pålsson, H., 2022. Barriers to change in urban freight systems: a systematic literature review. *European Transport Research Review*, 14(1), p.29. Available at: <https://doi.org/10.1186/s12544-022-00553-2>.
- Khurshid, A., Khan, K. & Cifuentes-Faura, J., 2023. 2030 Agenda of sustainable transport: Can current progress lead towards carbon neutrality? *Transportation Research Part D: Transport and Environment*, 122, p.103869. Available at: <https://doi.org/10.1016/j.trd.2023.103869>
- Kirjavainen, J. & Suopajarvi, L., 2025. Barriers and risks of socio-technical transition towards sustainable road transport in sparsely populated areas: case of Finnish Lapland. *European Transport Research Review*, 17(1), p.21. <https://doi.org/10.1186/s12544-025-00721-0>
- Mantri, H. (2025). *A data-driven approach to predict the load profile at an electric vehicle charging station*. Master's thesis, University of Bremen.
- Möring-Martínez, Gabriel; Senzeybek, Murat; Jochem, Patrick (2024): Clustering the European Union electric vehicle markets: A scenario analysis until 2035. In *Transportation Research Part D: Transport and Environment* 135, p. 104372. <https://doi.org/10.1016/j.trd.2024.104372>
- Möring-Martínez, Gabriel; Murat Senzeybek; Samuel Hasselwander; Stephan Schmid, (2025), Quantifying the impact of fleet turnover on electric vehicle uptake in Europe, *Transportation Research Part D: Transport and Environment*, 147, 104945. <https://doi.org/10.1016/j.trd.2025.104945>.
- Mutayab Khalid, Jagruti Thakur, Sivapriya Mothilal Bhagavathy, Monika Topel, (2024), "Impact of public and residential smart EV charging on distribution power grid equipped with storage", *Sustainable Cities and Society*, 104, 105272. <https://doi.org/10.1016/j.scs.2024.105272>.
- OSM (OpenStreetMap) (2025) © OpenStreetMap Contributors. Available online: <https://www.openstreetmap.org>.
- Rana, M. Masud et al., (2025) "Comprehensive Review on the Charging Technologies of Electric Vehicles (EV) and Their Impact on Power Grid," *IEEE Access*, 13, 35124-35156. <https://doi.org/10.1109/ACCESS.2025.3538663>
- Ravanbach, B. et al., "A Dynamic Prediction Tool for Vehicle-to-Grid Operation and Planning," *2024 IEEE 22nd Mediterranean Electrotechnical Conference (MELECON)*, Porto, Portugal, 2024, pp. 610-615. <https://doi.org/10.1109/MELECON56669.2024.10608538>
- Smith, M. J., Wedge, R. and Veeramachaneni K., FeatureHub: Towards collaborative data science," in *2017 IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, 2017
- Sayed, Mohammad Ali, Ribal Atallah, Chadi Assi, Mourad Debbabi, (2022), "Electric vehicle attack impact on power grid operation", *International Journal of Electrical Power & Energy Systems*, 137, 107784. <https://doi.org/10.1016/j.ijepes.2021.107784>.
- TU Delft (2025), *EPIOT: Quantifying EV Flexibility*. <https://drive2x-epiot.ewi.tudelft.nl/>
- Yaghoubi, Ela., Yaghoubi, Eln, Khamees, A, Razmi, D., Lu T., (2024), "A systematic review and meta-analysis of machine learning, deep learning, and ensemble learning approaches in predicting EV charging behavior", *Engineering Applications of Artificial Intelligence*, 135, 108789. <https://doi.org/10.1016/j.engappai.2024.108789>.

Yang, Li, Jiashen Teh, Ching-Ming Lai, (2025), "Assessing power grid vulnerability to extreme weather: The impact of electric vehicles and energy storage systems", *Journal of Energy Storage*, 112, 115534. <https://doi.org/10.1016/j.est.2025.115534>.