

(05-007) - Characterization of the driving pattern of Users with Electric Vehicles

Sánchez Pérez, Marc ¹; Etxandi-Santolaya, Maite ²; Canals Casals, Lluç ³

¹ UPC-ETSEIB, ² UPC-IREC, ³ UPC

This study focuses on the application of data science for the analysis of Electric Vehicles (EVs). In the midst of the growing prominence of electric vehicles, the need to efficiently manage the vast amount of information generated by batteries is emphasized. Data science emerges as an essential tool for examining patterns and trends related to driving and charging, providing valuable insights into the efficiency, range, and durability of batteries.

The study data is derived from tests conducted at the institute (IREC), as part of the project "H2020 ALBATROSS project grant number: 963580." These include cycles designed to simulate various driver behaviors, supplemented with monthly laboratory performance tests to assess the health of the batteries.

The study focuses on analyzing this data, identifying six different types of battery degradation that represent distinct profiles of electric vehicle users. This detailed approach offers an understanding of how various driving styles and charging patterns impact the health and performance of batteries

Keywords: Data Science ; Bateries ; Energy.

Caracterización del patrón de conducción de Usuarios con Vehículos Eléctricos

Este estudio se enfoca en la aplicación de la ciencia de datos para el análisis de vehículos eléctricos (EVs). En medio del creciente protagonismo de los vehículos eléctricos, se subraya la necesidad de gestionar de manera eficiente la gran cantidad de información generada por las baterías. La ciencia de datos se revela como una herramienta esencial para examinar patrones y tendencias relacionadas con la conducción y la carga, ofreciendo un conocimiento valioso sobre la eficiencia, autonomía y durabilidad de las baterías.

Los datos de estudio provienen de pruebas realizadas en el insituto (IREC), como parte del proyecto "H2020 ALBATROSS project grant number: 963580". Estos incluyen ciclos diseñados para simular distintos comportamientos de conductores, complementados con pruebas mensuales de rendimiento en laboratorio para evaluar la salud de las baterías.

El estudio se centra en analizar estos datos, identificando seis tipos de degradación de baterías diferentes, que representan diferentes perfiles de usuarios de vehículos eléctricos. Este enfoque detallado ofrece una comprensión de cómo diversos estilos de conducción y patrones de carga afectan la salud y rendimiento de las baterías.

Palabras clave: Ciencia de datos ; Baterías ; Energía.

Correspondencia:

Agradecimientos: Este estudio es un resultado del proyecto Albatross. Este proyecto ha recibido financiamiento del programa de investigación e innovación Horizon 2020



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

de la Unión Europea bajo el acuerdo de subvención No. 963580. Este financiamiento incluye fondos para apoyar trabajos de investigación y publicaciones de acceso abierto.

Lluc Canals Casals es un Investigador Serra Hunter.

Este trabajo también está respaldado por la Agencia Catalana AGAUR bajo su programa de apoyo a grupos de investigación, subvención al grupo de investigación ENMA No. 2021 SGR 00226.

This study is a result from the Albatross project. This project has received funding from the European Union's Horizon 2020 research and innovation program under grant agreement No. 963580. This funding includes funds to support research work and openaccess publications.

Lluc Canals Casals is a Serra Hunter Fellow.

This work is also supported by the Catalan Agency AGAUR under their research group support program grant to the ENMA research group No. 2021 SGR 00226.

1. Introducción

Durante décadas, el avance tecnológico se ha centrado en facilitar la vida de las personas, aplicando las últimas novedades científicas para satisfacer necesidades humanas (Grau, 1995). La teoría de Maslow, ubicando la necesidad humana de conexiones sociales en su tercer escalafón (Trivedi, 2019), destaca la importancia fundamental de mantenernos enlazados como seres sociales. El automóvil se posiciona como un elemento fundamental en el transporte, al otorgar al ser humano la capacidad de recorrer distancias significativas en lapsos de tiempo considerablemente reducidos. El creciente acceso de la población a este medio ha generado el aumento de su demanda y a su vez, una necesidad imperante en la sociedad contemporánea (Whitelegg, 2017). El transporte, vital para la interconexión, evolucionó desde carruajes a vapor hasta vehículos eléctricos en el siglo XIX. Sin embargo, las limitaciones de las baterías de la época afectaron la autonomía de estos primeros vehículos eléctricos.

En la década de 1880, Karl Benz introdujo el automóvil moderno de combustión interna, marcando el inicio de la era de los vehículos de gasolina. A partir de 1980, los automóviles de combustión se consolidaron como el medio de transporte predominante en España (Miteco, 2018) y pronto se constituyen como uno de los principales agentes contribuyentes al efecto invernadero debido a sus emisiones de CO₂. En el año 2014, estas emisiones representaban el 25% del total en España (Idae, 2019). En vista de este panorama, se hace evidente la imperativa necesidad de abandonar prácticas que contribuyan a la degradación ambiental de nuestro planeta. La creación de un ecosistema más sostenible se presenta como un objetivo prioritario, exigiendo la colaboración de todos para limitar las emisiones de CO₂ y otros contaminantes.

Ante la urgente necesidad de abordar el cambio climático y mejorar la sostenibilidad, los vehículos eléctricos emergen como una alternativa esperanzadora (Soto Crespo, 2021). Su piedra angular es la batería, siendo la energía eléctrica de la batería el análogo al combustible fósil del vehículo de combustión. Este factor es clave, ya que la información que podemos registrar de la batería y, por lo tanto, de nuestro vehículo eléctrico, a través de la centralita y "Battery Management System", es muy amplia. Esta información viene dada en forma de datos y puede representar parámetros como el voltaje e intensidad de la batería, entre otros.

En este punto se introduce el elemento central de estudio, el análisis y uso de la ciencia de datos para la gestión de grandes cantidades de datos, también popularmente conocido como "Big Data". Es esencial destacar el papel fundamental que desempeña la ciencia de datos como herramienta clave en la gestión de la creciente cantidad de información disponible (Li, 2017). La capacidad intrínseca del análisis y ciencia de datos para identificar patrones y tendencias emerge como un recurso invaluable para mejorar diversos aspectos relacionados con los vehículos eléctricos, tales como su eficiencia, autonomía y durabilidad. Entre las contribuciones significativas de estas herramientas, destacan la determinación del nivel de carga óptimo, las predicciones precisas del consumo de la batería y el monitoreo continuo del estado del vehículo (Li, 2017). Esta capacidad predictiva y analítica del Big Data no solo optimiza el rendimiento de las baterías, sino que también contribuye de manera significativa a la evolución y mejora continua de la tecnología de vehículos eléctricos.

Este análisis de datos, forma parte del proyecto "ALBATROSS", respaldado por la Comisión Europea (Cordis, 2022), liderado por un consorcio de 21 empresas y organizaciones de 10 países europeos. El proyecto se centra en el desarrollo de baterías de iones de litio. Su objetivo es abordar preocupaciones relacionadas con autonomía, costes, fiabilidad, reutilización y tiempo de carga.

2. Objetivos

Este estudio pretende ser un primer paso para la determinación del estado de salud y estimación de la degradación de las baterías. Para ello, primero se desarrolla un algoritmo para facilitar la manipulación de los datos recogidos por los sistemas electrónicos que gestionan las baterías en los sistemas de testeo de baterías para optimizar la accesibilidad y obtención de resultados durante la elaboración de estudios científicos. La clasificación de datos en diferentes familias y limpieza de información defectuosa, permite un análisis selectivo y eliminar redundancias o datos defectuosos.

Este proceso permite, posteriormente, caracterizar el ciclado o uso de las baterías identificando los Amperios-hora intercambiados, así como la determinación de las potencias mínimas y máximas. Este algoritmo permite extrapolar los resultados para distintos tipos de conducción y comprender las necesidades del conductor en relación con el uso de la batería.

Esta caracterización, a su vez, permite analizar los principales factores de estrés de una batería (intensidad, voltaje, temperatura...) en función del tipo de uso (o conducción) para identificar la degradación de la batería y prever su fin de vida útil.

Estudiando los factores de estrés, es posible identificar seis tipos de degradación de baterías diferentes, que representan distintos perfiles de usuarios de vehículos eléctricos. Este enfoque ofrece una comprensión de cómo diversos estilos de conducción y patrones de carga afectan la salud y rendimiento de las baterías.

Finalmente, como objetivo complementario, se busca entender cómo realizar una gestión eficiente de las baterías en vehículos eléctricos, para alargar su vida útil en base a los resultados obtenidos en el estudio.

3. Metodología

Los datos analizados en el curso de este estudio fueron proporcionados por el laboratorio del Instituto de Investigación en Energía de Cataluña (IREC).

El foco principal de la investigación se centra en la batería ion-litio utilizada en el proyecto ALBATROSS, compuesta por celdas de la marca "LG" modelo "INR21700-M50LT". La obtención de datos no se llevó a cabo mediante pruebas en vehículos en condiciones reales, sino a través de experimentación en un entorno de laboratorio. Este banco de ensayos reproduce condiciones realistas de conducción mediante perfiles sintéticos, generados a partir de datos reales (Etxandi-Santolaya, 2023), de los que se seleccionan dos tipos para la conducción, "Semi Urban" (SU) para simular entornos generalmente urbanos, o "Semi Highway" (SH) para representar el caso de autovías o autopistas.

La introducción de este perfil sintético en la batería se lleva a cabo mediante un ciclador, modelo "XCTS Mk II" de "BaSyTec". Es un dispositivo especializado en la ejecución de ciclos de carga y descarga de baterías. Los ensayos se realizan dentro de una cámara climática, modelo "MZTC" marca "Arbin", para realizar los experimentos a una temperatura determinada.

Se abordan seis escenarios (Tabla 1), uno por celda testada, todos basados en el mismo modelo, pero sometidos a diferentes condiciones de conducción. Estas variaciones en las condiciones pretenden simular diferentes patrones de conducción de vehículos eléctricos. Las condiciones ajustadas durante los ciclos experimentales se detallan en la Tabla 2.

Tabla 1. Condiciones de cada celda y test.

Celda	Carretera	Población cubierta [%]	Media del tiempo entre cargas [min]	Capacidad
Superior	SH	50	44	30
Inferior	SH	50	44	65
Izquierdo	SH	90	109	65
Derecho	SU	50	52	30
Encabezado	SU	50	52	65
Pie de página	SU	90	126	65

Tabla 2. Condiciones modificadas en las celdas.

Condición	Descripción
Carretera	Condición introducida en el modelo, que describe si la conducción se realiza en una carretera Semi Urban (SU), es decir, por un entorno más urbano, como podría ser la ciudad de Barcelona, o una carretera Semi Highway (SH), es decir, entorno de autopistas y autovías.
Población cubierta	En porcentaje, población que conduce al menos el tiempo definido para la conducción. Por ejemplo, los perfiles que conducen un 50% representan conductores medios de "SU" o "SH", sin embargo, los que conducen un 90%, representan casos externos, donde el 10% de la población conduce más tiempo del introducido para generar los ciclos.
Media del tiempo entre cargas	Tiempo medio que existe entre dos cargas. Un ejemplo puede ser, el tiempo existente entre dos conducciones consecutivas, otro ejemplo, no tan típico, podría ser, el tiempo que transcurre desde que una persona desenchufa el cargador del vehículo, conduce hasta su puesto de trabajo, realiza su jornada laboral, conduce hasta su hogar y vuelve a cargar el vehículo.
Capacidad	Capacidad nominal de la celda.

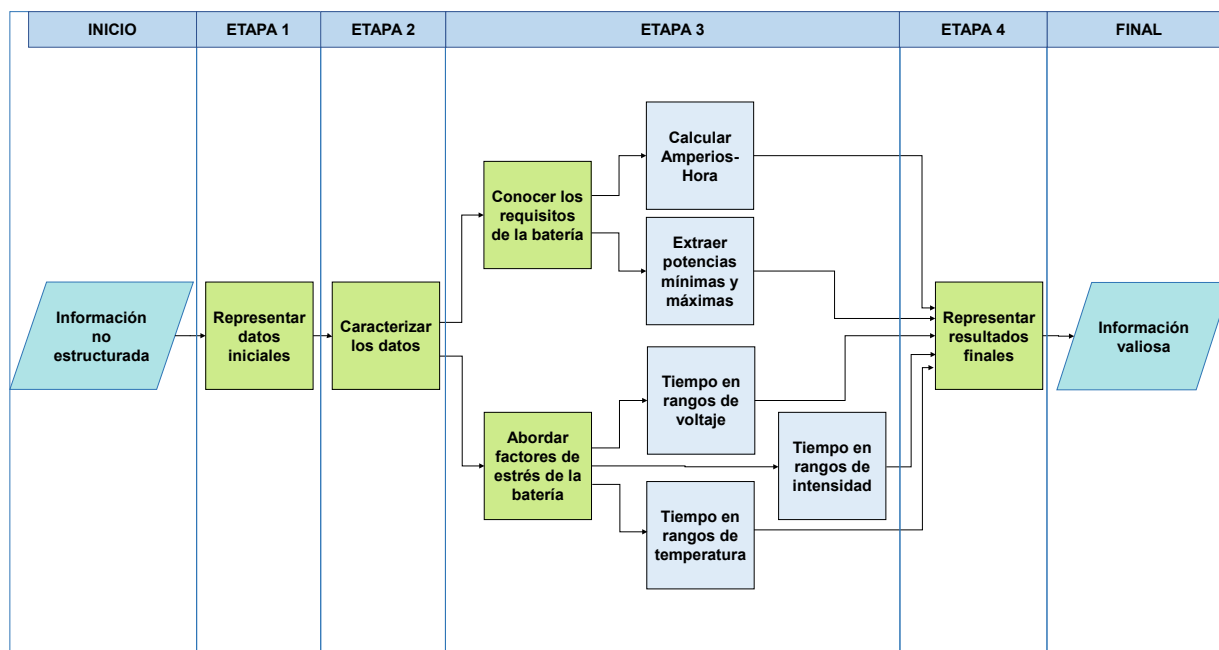
Durante los ensayos, en el ciclador se almacenaron los siguientes parámetros:

- "DateTime": "Fecha registrada en la que ocurre el experimento.
- "Line": Variable que define una línea de código en la que se programa una función.
- "U[V]": Variable que define el voltaje en Voltios.
- "I[A]": Parámetro que define la intensidad en Amperios.
- "T1[°C]": Temperatura a la que está la celda en el experimento, en grados centígrados.
- "batpar_soh": Variable que determina el estado de salud de la batería.
- "soc": Variable que determina el estado de carga de la batería ("SoC").
- "P[W]": Parámetro que define la potencia expresada en Vatios.
- "Ah-Charge": Registra los Amperios-hora de la carga en una variable.
- "Ah-Discharge": Registra los Amperios-hora de la descarga en una variable.
- "batpar_soc": Al igual que la variable "soc", determina el estado de carga de la batería.

El presente estudio se fundamenta en el uso de la programación como herramienta principal para el análisis de datos provenientes de baterías, centrándose en el contexto de baterías ion-litio. La implementación se lleva a cabo mediante el lenguaje de programación "Python", respaldado por las bibliotecas especializadas "Pandas", "Seaborn", "Numpy" y "Pyplot". Estas bibliotecas se utilizan para optimizar la manipulación de datos, principalmente almacenados en "Dataframes" y representarlos gráficamente. Los "Dataframes" son elementos tabulares, que organizan la información de manera estructurada en filas y columnas, almacenando aspectos esenciales de las baterías, tales como la intensidad o el voltaje. Además, también se utiliza el diccionario como herramienta clave, un objeto del lenguaje de programación "Python", es una estructura de datos que permite almacenar pares clave-valor de manera eficiente. Cada elemento del diccionario tiene una clave única asociada a un valor correspondiente. En este estudio, será utilizado para almacenar "Dataframes"

La metodología propuesta para este estudio sigue un enfoque estructurado en diversas etapas que abordan las problemáticas inherentes al análisis de datos provenientes de baterías ion-litio. Cada etapa implica el desarrollo de código de programación específico para resolver los desafíos planteados. Las etapas están representadas en los rectángulos de color verde de la Figura 1.

Figura 1. Diagrama de flujo de la metodología de estudio.



La primera etapa se centra en una primera exploración, transformación y visualización de los datos, basándose en el método EDA (Pramanik, 2019). La abundancia de datos inicialmente recopilados presenta limitaciones en su interpretabilidad y valor. El objetivo principal es convertir estos datos en información visual comprensible. Se crea un algoritmo, que transforma la información ordenada en "Dataframes" en información visual mediante las librerías "Pyplot" y "Seaborn" de "Python". Además, al igual que en los próximos algoritmos, existe una variable que permite seleccionar la celda de estudio deseada (los datos de las celdas están almacenados en archivos distintos). Se emplearán representaciones gráficas para proporcionar una base sólida que sirva como punto de partida para abordar desafíos adicionales.

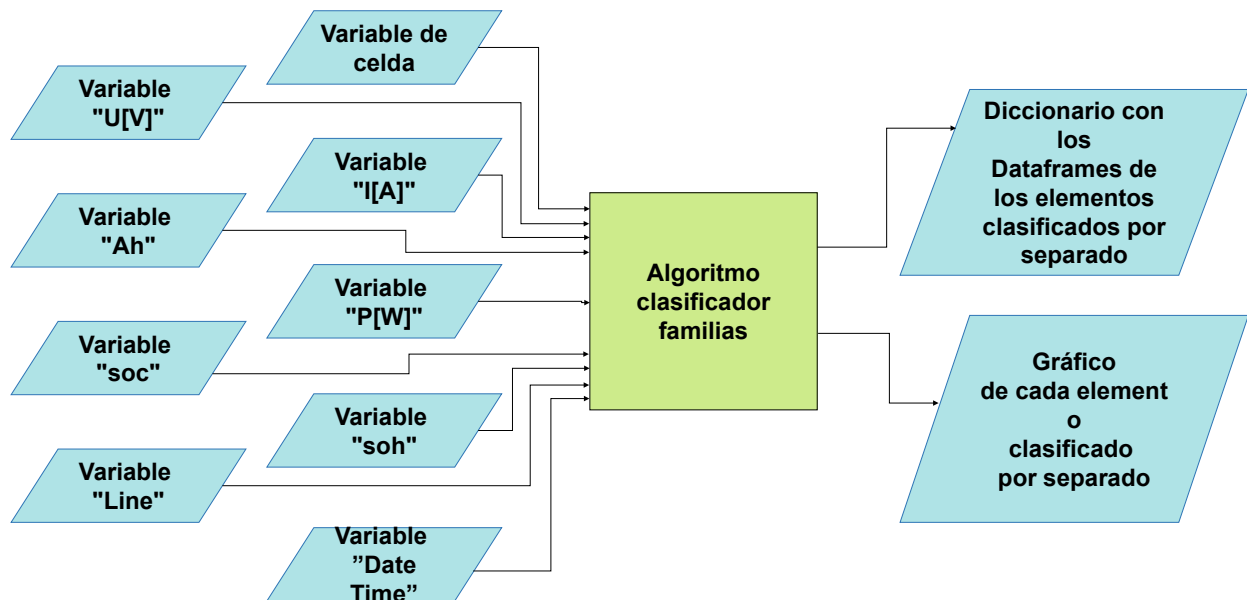
La segunda etapa busca la optimización del tiempo computacional. El manejo de grandes conjuntos de datos implica un alto costo computacional, generando demoras y un consumo energético considerable. En esta etapa, se centra la atención en reducir eficientemente el

tiempo computacional, no mediante la disminución del tamaño de los datos, sino a través de su caracterización y clasificación. Gracias a que los datos de los elementos clasificados presentan distinciones entre ellos, es posible realizar esta caracterización identificando diferentes etapas de los test (Knap, 2018) y utilizar una metodología de clasificación basada en descubrimiento de patrones (Hassini, 2023). La clasificación seguida para separar los datos se divide en los siguientes cuatro grupos:

- **Descarga:** Proceso que implica la pérdida de almacenamiento de energía en la batería al suministrar energía a elementos externos.
- **Carga:** Proceso que implica un incremento del almacenamiento de energía en la batería al recibir energía de elementos externos.
- **Ciclo:** Patrón repetido en el tiempo creado por simulaciones de conducciones alternadas con cargas largas. Las conducciones comprenden períodos de descarga durante la conducción y pequeñas cargas durante la recuperación de energía en las frenadas. Los períodos largos de cargas simulan la recarga de la batería.
- **“Reference Performance Test” (RPT):** Evaluación periódica de la degradación de la batería. Se realiza con dos cargas y descargas consecutivas, seguidas de una conducción.

Para realizar la clasificación, se crean diferentes funciones, una para cada tipo de familia. Cada familia presenta patrones de comportamiento diferentes a lo largo del tiempo para las variables tensión, intensidad, potencia, energía, “SoH”, “SoC” y temperatura, por lo que, aplicando filtros a estas condiciones, es posible separar todos y cada uno de los elementos clasificados. Además, la variable temporal y variable “Line”, han sido utilizadas para separar cada uno de los componentes de estas familias, debido a que, por ejemplo, además de ser necesario analizar todas las cargas conjuntamente, también es útil identificar individualmente las cargas y el resto de familias, ver Figura 2.

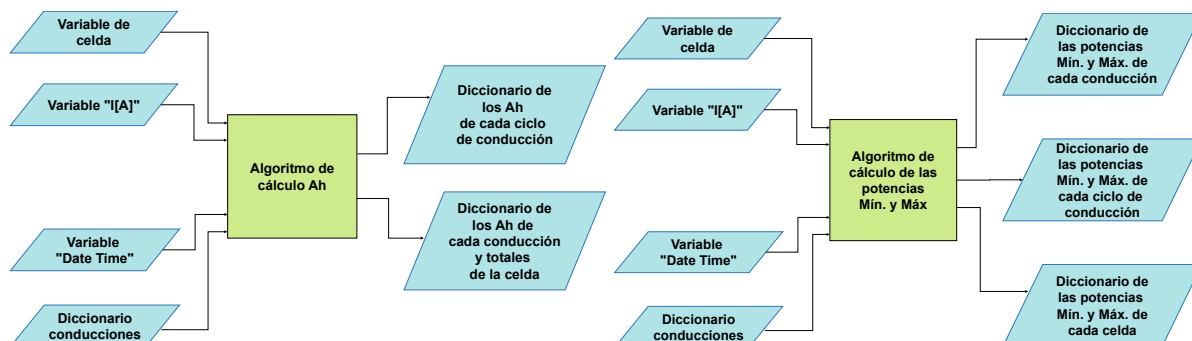
Figura 2. Diagrama representativo del algoritmo de representación gráfica inicial.



La tercera etapa se centra en la creación de dos algoritmos encargados de hacer el “tracking” e identificar el funcionamiento de los distintos tipos de celda. Para ello, utilizando las familias clasificadas en la etapa anterior, se estudian los amperios-hora descargados por la batería, pues es una forma de saber cuánta distancia recorre un usuario con el tipo de conducción de la celda estudiada. Además, también se analizan las potencias máximas y mínimas de cada

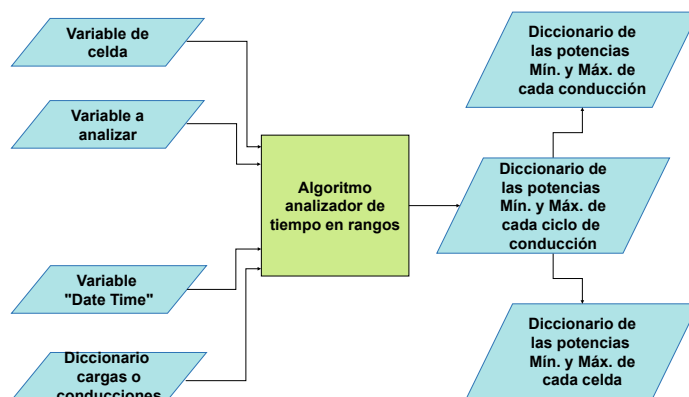
celda, de esta forma, es posible saber que potencia necesitará el usuario en función de su tipo de conducción, Figura 3.

Figura 3. Representación gráfica de los algoritmos de “tracking” de funcionamiento.



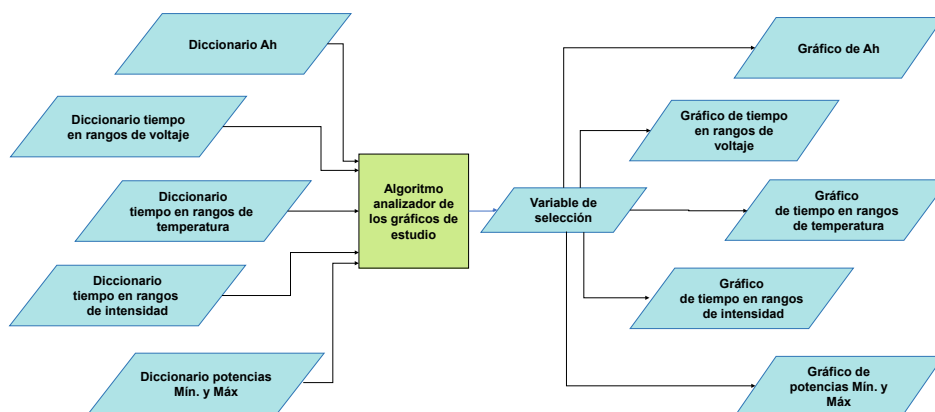
Algunos de los factores que envejecen la vida de la batería son el voltaje, intensidad y temperatura (Etxandi-Santolaya, 2023) y (Gao, 2022) , por lo que, en esta etapa se estudiará cuanto tiempo pasan las celdas en los diferentes rangos de trabajo a través de la función definida en la Figura 4.

Figura 4. Diagrama de funcionamiento de los algoritmos del cálculo del tiempo entre rangos.



Finalmente, se reconoce que la interpretación de resultados puede ser un desafío en algunos casos. Por lo tanto, se aborda este problema mediante la creación de gráficos y tablas que facilitan la representación y comprensión de la información extraída, el diagrama de funcionamiento se muestra en la Figura 5.

Figura 5. Diagrama del algoritmo de representación de resultados finales.



4. Resultados

Esta sección presenta los resultados que contribuyen a la comprensión del comportamiento individual de cada celda, además, también muestra aquellos que inciden en la optimización del uso de la información recopilada. Este enfoque integral permite no solo desentrañar los matices de cada celda, sino también discernir patrones y estrategias para maximizar la utilidad de los datos obtenidos en el marco de esta investigación.

4.1 Número de elementos caracterizados en cada celda

La caracterización de datos se centra en posibilitar estudios detallados de cada elemento del sistema, permitiendo extraer conclusiones basadas en sus características específicas.

La Tabla 3 presenta una revisión del número de elementos encontrados en la caracterización.

Tabla 3. Elementos caracterizados encontrados.

	RPT	Ciclos	Cargas	Conducciones
Albatross_1	8	28	433	433
Albatross_2	11	44	335	335
Albatross_3	10	22	398	398
Albatross_4	9	33	524	524
Albatross_5	12	56	917	917
Albatross_6	9	27	386	386
Total	59	187	2993	2993

Se destaca que el número de RPT es similar en todos los casos, ya que generalmente se elaboraba un RPT en la misma fecha para cada celda. En cuanto a los ciclos, "Albatross_1", "Albatross_3", "Albatross_4", y "Albatross_6" hicieron alrededor de 30 ciclos, mientras que "Albatross_2" supera los 40 ciclos y "Albatross_5" supera los 50, siendo la de mayor número de ciclos. Analizando los ciclos y RPT, se observa qué ocurre con todas las conducciones y cargas contenidas en estos ciclos. "Albatross_2" presenta el menor número, alrededor de 300 cargas y conducciones, mientras que la celda que más ciclos presenta es, "Albatross_5", triplicando, aproximadamente, la cantidad ciclos del resto de celdas.

En términos generales, se observa que muchos ciclos implican conducciones de duración más corta, mientras que pocos ciclos están asociados a conducciones más prolongadas.

Además, siguiendo el proceso descrito en la sección 3 Metodología, esta ordenación de datos, permite separar los elementos en familias, simplificando los estudios futuros y ayudando a extraer conclusiones basadas en grupos. También implica que, a la hora de realizar cálculos, se escojan datos segmentados de menor tamaño y, por lo tanto, este proceso ayuda a reducir los tiempos computacionales, destacando su importancia no solo por el costo temporal, sino también por el consumo energético generado por el ordenador. En la Tabla 4 se presenta una comparativa del tamaño inicial y final de los datos, medido en kilobytes y referenciado al tamaño comprimido en un archivo "ZIP".

Tabla 4. Tamaño de los datos de partida y los segmentados.

Archivo	Tamaño de archivos de partida [KB]	Tamaño de archivos de cargas [KB]	Tamaño de archivos de conducciones [KB]	Tamaño de archivos de RPT [KB]
Albatross_1	564.995	309.053	338.753	115.452
Albatross_2	654.913	89.446	204.607	170.490
Albatross_3	853.919	316.143	805.343	150.028
Albatross_4	625.207	282.374	489.662	147.486
Albatross_5	1.073.648	317.354	1.253.768	251.726
Albatross_6	835.840	214.758	918.874	134.077
Total	4.608.522 KB	1.529.128 KB	4.011.007 KB	969.259 KB

Se puede observar, como en el 88,89% de los casos (16/18), el tamaño de los archivos finales es inferior al de partida.

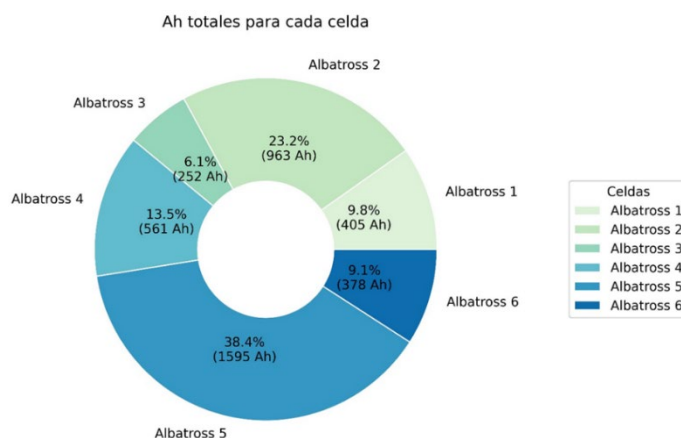
4.2 Requerimientos de la celda

Identificar con precisión el final de la vida útil de las baterías es crucial, estimándose en aproximadamente 8 años para vehículos eléctricos, además, una vez finalizada la primera vida de la batería, puede llegar a alargar su vida hasta los 20 años realizando otras aplicaciones, ya que su "SoH" todavía es elevado (Canals Casals, 2022). Detectar tempranamente la degradación severa de la batería permite optimizar su tiempo máximo de operación tanto en su primera como segunda vida (Etxandi-Santolaya, 2023).

La determinación del fin de la primera vida útil de una batería se vincula a la distancia recorrida. Al igual que los vehículos convencionales, la distancia es un indicador clave; sin embargo, en el caso de las baterías, se emplean amperios-hora como medida universal, prescindiendo del sistema métrico convencional. Este estudio utiliza indistintamente amperios-hora o kilómetros para referirse a la distancia recorrida por la celda, permitiendo una evaluación precisa del estado de la batería.

La celda "Albatross_5" destaca como la de mayor distancia recorrida, marcando una significativa diferencia con las demás, según la Figura 6. Por otro lado, "Albatross_3" se posiciona como la celda con menor distancia recorrida.

Figura 6. Representación gráfica de los Amperios-Hora totales de las celdas en valor absoluto.



Existe un punto crucial en el ciclo de vida de las baterías que revela su posible agotamiento: cuando la batería no puede proporcionar la potencia demandada (en valor absoluto) por el

conductor (Cui, 2017). Un ejemplo ilustrativo sería un conductor de vehículo eléctrico que intenta adelantar en una carretera, pero al presionar el acelerador no logra alcanzar la velocidad necesaria para superar a otro vehículo. Este escenario evidencia una degradación considerable de la batería, incapaz de ofrecer la potencia requerida, marcando un indicio determinante del final de su vida útil. Analizando la Tabla 5, se puede observar como la celda que tiene una potencia máxima (valor absoluto) mayor que el resto de celdas es "Albatross_1", concretamente sucede en el ciclo 9, mientras que la celda con una potencia máxima (valor absoluto) menor que el resto de celdas es "Albatross_6", concretamente en el ciclo 4. Por lo tanto, el tipo de conductor de la celda "Albatross_1" demandará más potencia en sus trayectos, lo cual, hará que su degradación sea más prematura, todo lo contrario, a la celda "Albatross_6".

Tabla 5. Potencias mínimas y máximas en ciclos.

Celda	Potencia mínima ciclo [W]	Ciclo Potencia mínima	Potencia máxima ciclo [W]	Ciclo Potencia máxima
Albatross_1	-73,01	9	33,56	18
Albatross_2	-36,70	7	24,90	22
Albatross_3	-37,72	5	23,02	5
Albatross_4	-70,46	7	34,99	7
Albatross_5	-33,44	13	16,39	32
Albatross_6	-33,35	4	16,45	15

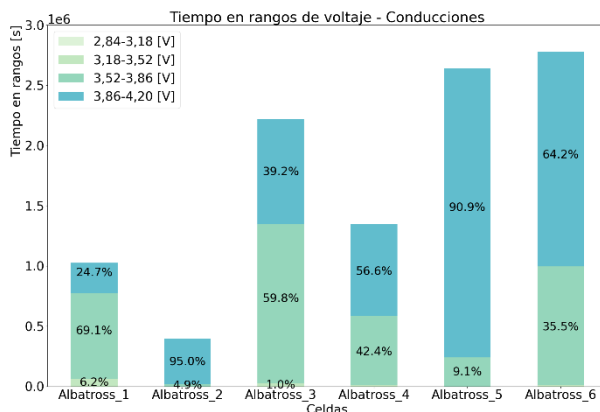
4.3 Factores de estrés de la celda

Este subapartado se centra en la identificación y análisis de los factores de estrés que inciden significativamente en la reducción del primer ciclo de vida de una batería de vehículo eléctrico. Analizando en que rangos de voltaje, intensidad o temperatura, en los que la celda pasa más tiempo, podemos saber el estrés a la que está sometida. La utilización de la batería fuera de sus rangos de funcionamiento ideales conlleva riesgos, entre otros, la pérdida de eficiencia. Por lo tanto, resulta imperativo operar la batería dentro de sus rangos de funcionamiento nominales. Este análisis se basa en la determinación de los intervalos en los que cada parámetro se encuentra más tiempo activo.

- **Voltaje:**

Las celdas operan exclusivamente en el rango comprendido entre 2,84 V y 4,20 V durante sus conducciones, que se dividen en 4 intervalos. Las celdas "Albatross_1" y "Albatross_3" predominan en el intervalo de 3,52 V a 3,86 V, mientras que las demás lo hacen en el intervalo de 3,86 V a 4,2 V (ver Figura 7). Notablemente, "Albatross_5" es la celda que pasa más tiempo conduciendo en el intervalo más demandante, 3,86 a 4,20 [V], lo cual generará un factor de estrés elevado, mientras que "Albatross_1", presenta su mayor tiempo de conducción en un intervalo menos demandante, 3,52 a 3,86 [V], por lo que, el estrés generado por el voltaje no será muy elevado para esta celda.

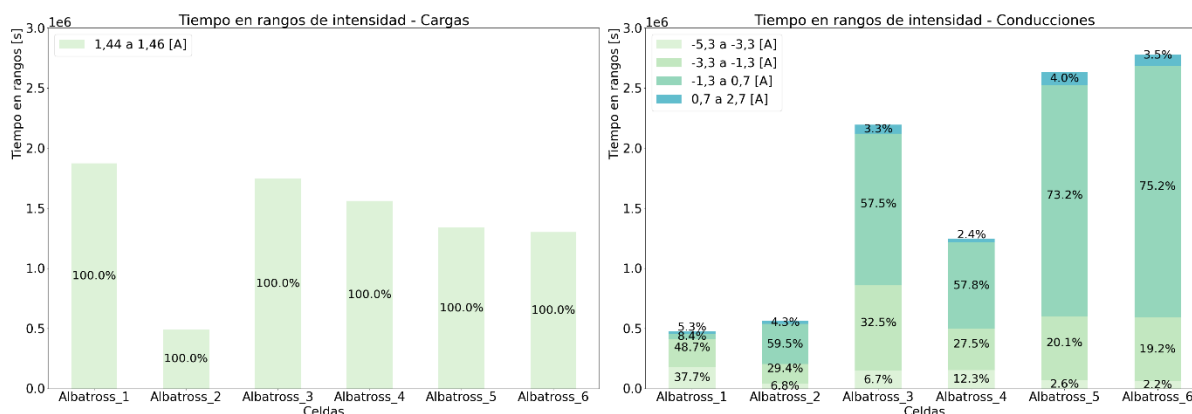
Figura 7. Tiempo, en segundos, en rangos de voltaje para las conducciones de las celdas.



• **Intensidad:**

Durante la carga, las baterías reciben una corriente constante de aproximadamente 1.45 A, (ver Figura 8, izqda). La celda "Albatross_1" es la que experimenta una mayor duración en estado de carga, por lo tanto, pasará más tiempo recargándose, lo que conlleva mayor degradación derivada de la corriente, mientras que "Albatross_2" es la que presenta menor tiempo, menos degradación causada por la corriente. Durante la conducción, la intensidad a través de las celdas varía desde 0.7 A, con valores positivos que reflejan la regeneración por frenado, hasta -5.3 A, que corresponde a la máxima aceleración requerida. A excepción de "Albatross_1", cuyo rango principal de funcionamiento se sitúa entre -3.3 A y -1.3 A, las demás celdas operan mayormente dentro del rango de -1.3 A a 0.7 A, por lo que la intensidad de operación de "Albatross_1" causará una mayor degradación (ver Figura 8, dcha).

Figura 8. Tiempo, en segundos, en rangos de intensidad para las cargas y conducciones, respectivamente, de las celdas.




• **Temperatura:**

Al igual que en las cargas, algunas celdas no registran tiempo en ciertos rangos de temperatura, ya que los experimentos se llevaron a cabo seleccionando temperaturas específicas en lugar de transitar de manera progresiva de un valor a otro, como ocurre en condiciones reales. Durante los periodos de carga (ver Figura 9, izqda), todas las celdas pasan más tiempo en el intervalo de 35 °C a 38 °C, con la excepción de "Albatross_4" y "Albatross_1", que operan mayoritariamente en intervalos de temperatura inferiores, lo que

hace que la degradación causada por la temperatura sea inferior al resto durante las cargas. Se recomienda que las celdas operen en rangos que estén cercanos a 25 °C, a partir de 35 °C el estrés sufrido por la batería a causa de la temperatura aumenta considerablemente y tanto los electrodos como el electrolito se ven afectados significativamente (Leng, 2015). Los sistemas BMS integrados en el vehículo eléctrico actúan, disminuyendo otros parámetros como la corriente cuando la temperatura excede ciertos valores cercanos a 45 °C, con el objetivo de aplacar los daños que se puedan causar (Cheng, 2011). Durante las conducciones (ver Figura 9, dcha), "Albatross_1" y "Albatross_6" pasan más tiempo en el intervalo de 25 °C a 27 °C, mientras que las demás lo hacen en el rango de 23 °C a 25 °C. También en este caso, algunos rangos de temperatura no registran tiempo de operación, siguiendo el mismo principio explicado para las cargas. Aunque las celdas suelen operar mayormente en un rango de temperatura cercano a los 25 °C, durante su funcionamiento en conducciones, es importante destacar que también pasan una parte considerable de tiempo expuestas a temperaturas más elevadas. Esta exposición prolongada a temperaturas superiores genera un estrés significativo en las celdas, similar al que experimentan durante las fases de carga.

Figura 9 Tiempo, en segundos, en rangos de temperatura para las cargas y conducciones, respectivamente, de las celdas.



Una vez vistos los resultados podemos saber cómo afecta el tipo de conducción al envejecimiento de la batería:

- **Albatross_1:** Celda con baja conducción total, pero alta demanda de potencia en algunos ciclos, que se caracterizará por un envejecimiento medio al tener poca actividad, pero de alto estrés generado por la temperatura y potencia de trabajo.
- **Albatross_2:** Posee una conducción total alta, pero demanda de potencia baja, lo que implica una degradación lenta pero sostenida.
- **Albatross_3:** Conducción total mínima, baja demanda de potencia y bajo estrés, lo que la hace la más duradera en su primera, pero seguramente tendrá pocas opciones en segunda vida por haberle alargado la primera.
- **Albatross_4:** Similar a "Albatross_1" pero con ligeras diferencias en kilómetros recorridos y potencia máxima. Su segunda vida útil será longeva debido a distancias moderadas recorridas en su primera vida además del poco estrés generado por temperatura e intensidad.
- **Albatross_5:** Mayor conducción total, baja demanda de potencia, pero estrés moderado en voltaje.
- **Albatross_6:** Conducciones cortas, baja demanda de potencia, pero alto estrés por elevada temperatura y voltaje. Aunque sufra degradación, no será la más afectada, y podría tener una segunda vida útil longeva.

5. Conclusiones

Este estudio presenta una metodología para adaptar la enorme cantidad de datos obtenidos durante el testeo de baterías para poder trabajar con ellos de forma efectiva y eficaz en la caracterización del funcionamiento. Este proceso puede ser extrapolable a un proceso de conducción real.

El algoritmo logró una mayor accesibilidad a través de una clasificación y segmentación en función de su relación con RPT, ciclo, conducción o carga del ciclo. Esta estrategia facilitó el estudio selectivo al almacenar cuatro archivos para cada una de las celdas testeadas, simplificando así su análisis.

En relación con la eficiencia computacional se observó que la carga de archivos de menor tamaño resultó en una disminución del tiempo de computación en un 88,89% de los casos. Se sugiere para futuros estudios explorar otras estructuras de clasificación basadas en funciones de la librería "Pandas" en lugar de diccionarios.

El algoritmo permite identificar perfiles de conductores que impactan significativamente en la vida útil de las celdas. Este proceso evidenció como la celda "Albatross_1" tiene un comportamiento que acelera la degradación de la celda, mientras que "Albatross_3" muestra una duración de vida más prolongada. Esto permite ver que, a pesar de conducir en condiciones similares, las diferencias en los tiempos entre cargas y la capacidad de las celdas influyen en el estrés de las baterías.

Estas observaciones resaltan la necesidad de continuar la investigación para comprender con mayor claridad las necesidades del conductor y los factores de estrés de la celda.

6. Referencias

- Canals Casals, L., Etxandi-Santolaya, M., Bibiloni-Mulet, P. A., Corchero, C., & Trilla, L. (2022). Electric Vehicle Battery Health Expected at End of Life in the Upcoming Years Based on UK Data. *Batteries*, 8(10), 15. <https://doi.org/10.3390/batteries8100164>
- Cheng, K. W. E., Divakar, B. P., Wu, H., Ding, K., & Ho, H. F. (2011). Battery-Management System (BMS) and SOC Development for Electrical Vehicles. *IEEE Transactions on Vehicular Technology*, 60(1), 76–88. <https://doi.org/10.1109/TVT.2010.2089647>
- Cordis, E. (2022). *Advanced Light-weight BATteRy systems Optimized for fast charging, Safety, and Second-life applications*. <https://cordis.europa.eu/project/id/963580>
- Cui, Y., Yang, J., Du, C., Zuo, P., Gao, Y., Cheng, X., Ma, Y., & Yin, G. (2017). Prediction Model and Principle of End-of-Life Threshold for Lithium Ion Batteries Based on Open Circuit Voltage Drifts. *Electrochimica Acta*, 255, 83–91. <https://doi.org/10.1016/J.ELECTACTA.2017.09.151>
- Etxandi-Santolaya, M., Canals Casals, L., Amante García, B., & Corchero, C. (2023). Circular Economy-Based Alternatives beyond Second-Life Applications: Maximizing the Electric Vehicle Battery First Life. *World Electric Vehicle Journal*, 14(3), 8–13. <https://doi.org/10.3390/wevj14030066>
- Etxandi-Santolaya, M., Canals Casals, L., & Corchero, C. (2023). Estimation of electric vehicle battery capacity requirements based on synthetic cycles. *Transportation Research Part D: Transport and Environment*, 114. <https://doi.org/10.1016/j.trd.2022.103545>
- Etxandi-Santolaya, M., Casals, L. C., & Corchero, C. (2023). Limitations of the State of Health and Health Indicators for Electric Vehicle Batteries. *2023 IEEE Vehicle Power and Propulsion Conference (VPPC)*, 1–6. <https://api.semanticscholar.org/CorpusID:267337963>

- Gao, K., Xu, J., Li, Z., Cai, Z., Jiang, D., & Zeng, A. (2022). A Novel Remaining Useful Life Prediction Method for Capacity Diving Lithium-Ion Batteries. *ACS Omega*, 7(30), 26701–26714. <https://doi.org/10.1021/acsomega.2c03043>
- Grau, J. E. (1995). *Tecnología y educación*.
- Hassini, M., Redondo-Iglesias, E., & Venet, P. (2023). Lithium–Ion Battery Data: From Production to Prediction. *Batteries*, 9(7). <https://doi.org/10.3390/batteries9070385>
- Idae. (2019). *Consumo de carburante y emisiones*. <https://coches.idae.es/consumo-de-carburante-y-emisiones#:~:text=Espa%C3%B1a%20figura%20en%20la%20el,64%20kg%20de%20CO2>.
- Knap, V., Stroe, D.-I., Purkayastha, R., Walus, S., Auger, D. J., Fotouhi, A., & Propp, K. (2018). Reference Performance Test Methodology for Degradation Assessment of Lithium-Sulfur Batteries. *Journal of The Electrochemical Society*, 165(9), A1601. <https://doi.org/10.1149/2.0121809jes>
- Leng, F., Tan, C., & Pecht, M. (2015). Effect of Temperature on the Aging rate of Li Ion Battery Operating above Room Temperature. *Scientific Reports*, 5, 12967. <https://doi.org/10.1038/srep12967>
- Li, B., Kisacikoglu, M. C., Liu, C., Singh, N., & Erol-Kantarci, M. (2017). Big Data Analytics for Electric Vehicle Integration in Green Smart Cities. *IEEE Communications Magazine*, 55(11). <https://doi.org/10.1109/MCOM.2017.1700133>
- Miteco. (2018). *Ministerio para la Transición Ecológica y el Reto Demográfico*. Principales características del sector. <https://www.miteco.gob.es/es/cambio-climatico/temas/mitigacion-politicas-y-medidas/transporte.aspx#:~:text=El%20transporte%20por%20carretera%20es,movilidad%20total%20a%20nivel%20nacional>.
- Pramanik, J., Samal, A. K., Sahoo, K., & Pani, Dr. S. (2019). Exploratory Data Analysis using Python. *International Journal of Innovative Technology and Exploring Engineering*, 8, 4727–4730.
- Soto Crespo, S. S., & Castañeda Olivera, C. A. (2021). *Análisis bibliométrico del uso de vehículos eléctricos como alternativa de reducción de la huella de carbono*.
- Trivedi, A. J. (2019). *Maslow's Hierarchy of Needs - Theory of Human Motivation* (pp. 2321 – 2853).
- Whitelegg, J., Dr.-Ing. Holzapfel, H., Britton, E., & Tranter, P. (2017). *World Transport Policy and Practice*. 23.1, 30.

**Comunicación alineada con los
Objetivos de Desarrollo Sostenible**

