

Desarrollo de un algoritmo de estimación del estado de salud (SoH) de baterías de ion de litio mediante un modelo de red neuronal artificial

Autor

Karen Dahiana Marcelo Palacios

Universidad de Cundinamarca

Facultad de Ingeniería

Ingeniería Electrónica

Fusagasugá, Colombia

2025

Desarrollo de un algoritmo de estimación del estado de salud (SoH) de baterías de ion de litio mediante un modelo de red neuronal artificial

Trabajo de grado presentado como requisito parcial para optar por el título de ingeniero electrónico

Autor

Karen Dahiana Marcelo Palacios

Director

Andrés Felipe Guerrero Guerrero

Codirector

Edgar Hernando Criollo Velásquez

Línea de investigación:

Aprendizaje, conocimiento, tecnologías, comunicación y digitalización

Universidad de Cundinamarca

Facultad de Ingeniería

Ingeniería Electrónica

Fusagasugá, Colombia

2025

Dedicatoria

Dedico este trabajo de grado a las personas que han sido mi guía, mi apoyo y mi mayor inspiración. A mis padres, por su amor incondicional, sacrificio y enseñanzas. Gracias por enseñarme con su ejemplo que el valor del esfuerzo, la perseverancia y la dedicación son las claves para alcanzar cualquier objetivo.

Al director de este trabajo de grado, el doctor Andrés Felipe Guerrero, y al codirector, el ingeniero Edgar Hernando Criollo Velásquez por su guía y apoyo.

A la persona más sublime, mi abuela materna que me formó como persona y además estuvo presente durante toda mi vida con su valentía, tenacidad y amor inconmensurable. Le dedico este trabajo con todo mi amor y gratitud.

Agradecimientos

Quiero expresar mi más sincera gratitud a todas las personas que han sido parte fundamental durante este proceso académico y personal, cuyo apoyo ha sido invaluable para la culminación de este proyecto y de mi formación profesional.

A mi familia, especialmente a mis padres, quienes han sido mi pilar y la mayor fuente de inspiración en cada etapa de mi vida. A mis hermanos, por ser una valiosa compañía y tener complicidad. A mis tíos y abuelos por su cariño y aliento constante, por estar presentes en los momentos importantes. Gracias por sus consejos y por sus sacrificios.

Agradezco a E. Santiago Rodríguez Jiménez, por estar a mi lado a lo largo de este camino, brindándome su amor, paciencia y apoyo incondicional.

A Cristian Moreno García, María Alejandra Vargas González y Juanita Quiroz Olivella, junto con mis compañeros de carrera y amigos, quienes llenaron mis días de alegría, inspiración y aprendizajes durante el proceso de formación como ingenieros. Confío en que, en el futuro, continuaremos creciendo y alcanzando nuestros metas juntos.

A mi alma mater, la Universidad de Cundinamarca y a la comunidad universitaria, por brindarme un espacio de aprendizaje y crecimiento, donde no solo adquirí conocimientos, sino también valores y experiencias que han marcado mi desarrollo profesional y personal.

A mis directivos y docentes, otorgando un agradecimiento especial a mi director de este trabajo de grado, el doctor Andrés Felipe Guerrero, por los conocimientos brindados, por su dedicación y guía en este proceso de aprendizaje.

A todos aquellos que, de una u otra manera, contribuyeron a la realización de este proyecto, ya sea con su apoyo, consejos o enseñanzas. A quienes creyeron en mí, me motivaron y acompañaron en este proceso, mi más profundo agradecimiento.

Resumen

El presente proyecto presenta un algoritmo basado en redes neuronales artificiales (ANN) para estimar el Estado de Salud (SoH) de baterías de iones de litio (LIBs), con el objetivo de predecir su vida útil restante (RUL) y optimizar su gestión en sistemas de almacenamiento de energía en baterías (BESS), particularmente en microrredes. El modelo implementado, diseñado en MATLAB®, combina técnicas de aprendizaje automático supervisado con filtrado de señales, utilizando datos experimentales del Centro de Excelencia de Pronósticos de la NASA (PCoE), que incluyen variables clave como voltaje, corriente, temperatura e impedancia.

El algoritmo propuesto mostró un desempeño superior frente a otros métodos evaluados como LSTM, GRU, ML, NN, DL y CNN, siendo el único modelo que logró un coeficiente de determinación (R^2) ideal de 1.0 junto con los errores más bajos registrados, (MAE: 0.1004 %, MAPE:0.5231 %, MSE:0.294 % y RMSE: 0.1714 %), con un tiempo de operación de 9 segundos. Validando la precisión, exactitud en contextos comparativos, sensibilidad a errores grandes y calidad del ajuste del modelo propuesto superando los estándares comúnmente reportados en la literatura (MAE < 5 %, RMSE < 2 %, R^2 > 0.98).

Además, el modelo mostró adaptabilidad ante distintos ciclos completos de vida útil en la degradación de la batería y logró un equilibrio entre rendimiento y eficiencia durante el proceso de optimización de hiperparámetros. Los resultados obtenidos evidencian la viabilidad del modelo, gracias a su alta precisión, eficiencia y adaptabilidad frente a diversos perfiles de carga y descarga.

Abstract

This project presents an artificial neural network (ANN)-based algorithm for estimating the State of Health (SoH) of lithium-ion batteries (LIBs), with the goal of predicting their remaining useful life (RUL) and optimizing their management in battery energy storage systems (BESS), particularly in microgrids. The implemented model, designed in MATLAB®, combines supervised machine learning techniques with signal filtering, using experimental data from the NASA Prognostics Center of Excellence (PCoE), which includes key variables such as voltage, current, temperature, and impedance.

The proposed algorithm showed superior performance compared to other evaluated methods such as LSTM, GRU, ML, NN, DL, and CNN. It was the only model to achieve an ideal coefficient of determination (R^2) of 1.0 along with the lowest errors recorded (MAE: 0.1004%, MAPE: 0.5231 %, MSE: 0.294 %, and RMSE: 0.1714 %), with a runtime of 9 seconds. This validated the precision, accuracy in comparative contexts, sensitivity to large errors, and quality of fit of the proposed model, surpassing common standards reported in the literature (MAE < 5 %, RMSE < 2 %, $R^2 > 0.98$).

Furthermore, the model demonstrated adaptability to various full lifecycles of battery degradation and achieved a balance between performance and efficiency during the hyperparameter optimization process. The results obtained demonstrate the viability of the model, thanks to its high accuracy, efficiency, and adaptability to diverse charge and discharge profiles.

Contenido

Resumen	5
Abstract.....	6
INTRODUCCIÓN	11
PLANTEAMIENTO DEL PROBLEMA	13
OBJETIVOS DEL ESTUDIO	15
Objetivo general	15
Objetivos específicos	15
JUSTIFICACIÓN	16
Alcances	18
Limitaciones	18
1. MARCO REFERENCIAL	20
1.1. ESTADO DEL ARTE	20
1.2. FUNDAMENTOS TEÓRICOS	31
1.2.1. Sistema de Gestión de Baterías (BMS)	31
1.2.2. Batería de ion de litio	32
1.2.3. Celdas de baterías de iones de litio	32
1.2.4. Estado de Salud (SoH).....	34
1.2.5. Métricas de rendimiento de un modelo	34
2. DISEÑO METODOLÓGICO	37
2.1. METODOLOGÍA	37
3. DESARROLLO DEL ALGORITMO DE ESTIMACIÓN DEL ESTADO DE SALUD (SOH) DE BATERÍAS DE ION DE LITIO	39
3.1. ANÁLISIS	39
3.2. DISEÑO	41
3.2.1. Herramienta de simulación	42
3.2.2. Selección de variables.....	42
3.2.3. Hiperparámetros de una red neuronal	42
3.2.4. Selección de modelo.....	44
3.2.5. Criterios de suavizado	46
3.3. IMPLEMENTACIÓN	50

3.3.1.	Arquitectura del modelo predictivo	50
3.4.	PRUEBAS DE FUNCIONAMIENTO Y DESEMPEÑO	58
3.4.1.	Evaluación del desempeño del modelo en distintos estados de degradación de la batería	58
3.4.2.	Prueba de ajuste de hiperparámetros	62
4.	ANÁLISIS DE RESULTADOS Y DISCUSIÓN	65
4.1.	ANÁLISIS DEL MATERIAL BIBLIOGRÁFICO	65
4.2.	ESTRATEGIAS DE SELECCIÓN	65
4.3.	VALIDACIÓN EXPERIMENTAL	67
4.3.1.	Análisis del desempeño del modelo en distintos estados de degradación de la batería	67
4.3.2.	Análisis de la prueba de ajuste de hiperparámetros.....	68
5.	CONCLUSIONES Y TRABAJOS FUTUROS	71
5.1.	CONCLUSIONES	71
5.2.	PERSPECTIVAS DE TRABAJO FUTURO	72

Índice de figuras

Figura 1. Relación entre SoH y RUL [1].	12
Figura 2. Métodos de última generación para la estimación del estado de salud (SoH). Tomado de: [23].	22
Figura 3. Diagrama de precisión de diferentes algoritmos para encontrar el SoH. Tomado de: [3].	25
Figura 4. Resumen de la estimación de SoH y error de una celda bajo diferentes métodos de estimación [27].	27
Figura 5. Comparación de los resultados de la distribución de la capacidad relativa de ELM (e) y BPN (f) Tomado de: [32].	30
Figura 6. Diagrama general del BMS. Tomado de: [6].	32
Figura 7. Ilustración esquemática y funcionamiento de una LIB, tomado de: [39].	33
Figura 8. Fases de la metodología.	37
Figura 9. Marco del modelo.	41
Figura 10. Gráfica comparativa del MAE por modelo, utilizando los métodos de suavizado exponencial y Kalman.	50
Figura 11. Diagrama de flujo del modelo.	51
Figura 12. Diagrama de la red neuronal feedforward [75].	55
Figura 13. Resultados de entrenamiento de la red neuronal.	56
Figura 14. Gráfica de la evolución de la impedancia de la batería.	57
Figura 15. Gráfica de SoH real vs predicho.	58
Figura 16. Comparación de SoH real vs predicho del primer escenario de prueba.	59
Figura 17. Comparación de SoH real vs predicho del segundo escenario de prueba.	61
Figura 18. Comparación de SoH real vs predicho del tercer escenario de prueba.	62
Figura 19. Comparación del desempeño del modelo en diferentes etapas del ciclo de vida de tres baterías distintas.	67
Figura 20. Comparación de errores de SoH de los 3 escenarios con distintos hiperparámetros.	69

Índice de tablas

Tabla 1. Comparación de los métodos de estimación de SoH [20].	20
Tabla 2. Resultados del rendimiento de predicción de cinco modelos distintos entrenados en la plataforma FELL para pronosticar el SoH de las baterías de vehículos eléctricos durante 120 días [26].	26
Tabla 3. Estimación de SoH de una celda bajo diferentes métodos de estimación [28].	27
Tabla 4. Resultados de prueba de los modelos de estimación de SoH.	45
Tabla 5. Resultados de prueba de los modelos de estimación de SoH con distintos métodos de suavizado.	49
Tabla 6. Resultados de evaluación del desempeño del modelo de distintos ciclos completos de vida útil.	59
Tabla 7. Resultados de la prueba de ajuste de hiperparámetros.	63

INTRODUCCIÓN

El cambio climático y la creciente demanda energética mundial están impulsando una transición hacia fuentes de energía más sostenibles y eficientes. En este contexto, las baterías de ion de litio (o LIBs por sus siglas en inglés: Lithium Ion Batteries), han emergido como un componente esencial para transformar el modelo del consumo energético y facilitar la transición de fuentes de energía tradicionales a fuentes renovables. Las LIBs se destacan por sus ventajas, que incluyen una alta densidad de energía, alta eficiencia de carga, amplio rango de temperatura de funcionamiento y ciclo de vida prolongado, lo que ha llevado a su amplia adopción en centrales eléctricas de almacenamiento de energía, electrónica de consumo y vehículos eléctricos [1]. En el ámbito del almacenamiento de energía a gran escala, las baterías de ion de litio permiten almacenar la energía generada por fuentes renovables, garantizando así un suministro continuo y estable, incluso en condiciones de baja generación. Esta capacidad de almacenamiento es clave para mitigar la intermitencia existente en los sistemas renovables y avanzar hacia un sistema energético más resiliente y sustentable [2].

Sin embargo, a pesar de sus múltiples beneficios, uno de los desafíos más significativos en la utilización de las LIBs radica en la estimación precisa de su comportamiento de degradación durante la operación. La evaluación exacta del estado de la batería en uso se complica debido a los complejos mecanismos de degradación que experimentan estos dispositivos. En este sentido, el sistema de gestión de batería (o BMS, por sus siglas en inglés: Battery Management System), desempeña un rol fundamental al indicar el estado de la batería y optimizar su comportamiento, lo que asegura el funcionamiento normal diario de las centrales eléctricas de almacenamiento de energía [3].

Un componente crítico del BMS es el modelo algorítmico que analiza los datos sobre la vida útil de las baterías. En particular, la estimación precisa del estado de carga (SoC) y el estado de salud (SoH) permite establecer una consistencia del paquete de baterías durante los procesos de carga y descarga. El SoH, específicamente, es un indicador de la degradación de la batería y su capacidad remanente en comparación con su estado inicial.

La estimación adecuada de SoH y la predicción de la vida útil restante (o RUL por sus siglas en inglés: Remaining Useful Life), son elementos esenciales para el BMS. La Figura 1. muestra la relación entre el SoH y el RUL de la batería. A través de la estimación del SoH y la predicción del RUL, se puede comprender el rendimiento de cada batería y se puede obtener información de la vida útil de la batería con anticipación, a fin de garantizar el buen funcionamiento del sistema de energía. La precisión de los métodos de predicción del RUL afectará directamente el rendimiento general del BMS [1].

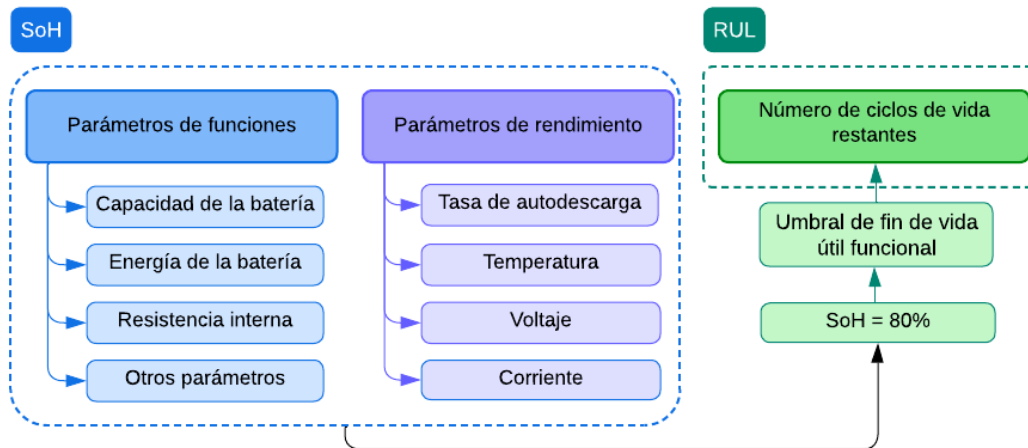


Figura 1. Relación entre SoH y RUL [1].

El desarrollo de métodos avanzados de pronóstico y diagnóstico para baterías de iones de litio se ha convertido en un área de investigación activa. Los enfoques tradicionales, como los modelos electroquímicos y de circuito equivalente, han demostrado ser eficaces, pero presentan limitaciones en cuanto a la precisión y la capacidad de adaptación a diferentes condiciones operativas. Para superar estas limitaciones, se han propuesto métodos basados en aprendizaje profundo y algoritmos de filtrado, los cuales ofrecen una mayor flexibilidad y precisión al incorporar datos en tiempo real y patrones complejos en las estimaciones de SoH y RUL, adicionalmente los métodos basados en datos externos han ganado popularidad debido a su capacidad para abordar la complejidad y comportamientos no lineales propios de los sistemas de baterías [4].

En este contexto, el presente trabajo se enfoca en el desarrollo de un algoritmo de estimación del estado de salud (SoH) de baterías de ion de litio, con el objetivo de establecer una aproximación confiable de su RUL. Para ello, se utiliza un modelo de red neuronal artificial (o ANN por sus siglas en inglés: Artificial Neural Network) inspirado en desarrollos recientes en el campo de los vehículos eléctricos y redes neuronales.

PLANTEAMIENTO DEL PROBLEMA

La transición hacia fuentes de energía más sostenibles y eficientes es una necesidad urgente en el contexto actual de cambio climático y creciente demanda energética. Las LIBs han emergido en esta transformación, siendo utilizadas en una variedad de aplicaciones que van desde vehículos eléctricos hasta sistemas de almacenamiento de energía renovable [5]. Sin embargo, la gestión del SoH de estas baterías presenta desafíos significativos debido a que está altamente correlacionado con condiciones de carga complejas, temperaturas ambientales y escenarios de aplicación que deben ser abordados para maximizar su rendimiento y sostenibilidad.

Las LIBs experimentan una degradación del rendimiento eléctrico en ciclos repetidos de carga y descarga. Por lo tanto, el monitoreo y la estimación del SoH son vitales para las aplicaciones de las LIBs, y una definición ampliamente aceptada de SoH es la relación entre la capacidad máxima recargable y la capacidad nominal, es decir, la capacidad original de la batería [6], [7].

El SoH representa la condición de una batería, considerando factores como el envejecimiento, los patrones de uso y las condiciones ambientales a las que ha sido sometida. Complementariamente, la RUL estima la cantidad de ciclos de carga y descarga restantes antes de que la batería se degrade [7], [8]. Asimismo, se ha demostrado que el almacenamiento a temperaturas elevadas acelera las reacciones secundarias y la pérdida de litio ciclable, lo que conduce a una disminución progresiva de la capacidad [9], [10]. Además, las temperaturas de almacenamiento muy bajas reducen la velocidad de difusión, provocando fenómenos como el recubrimiento de litio metálico en el ánodo, también asociados con pérdidas de capacidad. La temperatura influye directamente en la tasa de autodescarga de la batería la cual oscila entre un 1 % y 3 % mensual a unos 20 °C, afectando negativamente el rendimiento y la estabilidad del sistema energético [10] [11]. Estos procesos de degradación involucran complejas reacciones fisicoquímicas y comportamientos no lineales en parámetros clave como voltaje, temperatura y resistencia interna. La falta de una monitorización adecuada puede llevar a consecuencias severas, como fallos térmicos, incendios o explosiones, especialmente en aplicaciones críticas como los vehículos eléctricos [8].

La incapacidad para evaluar adecuadamente el SoH de estas baterías puede resultar en una gestión ineficiente, lo que no solo reduce su vida útil, sino que también aumenta el riesgo de fallos. Estos fallos no solo comprometen la confiabilidad del suministro eléctrico, sino que también pueden tener consecuencias económicas y ambientales significativas, incluyendo el aumento de residuos electrónicos y la contaminación asociada con la eliminación inadecuada de baterías [12].

Además, la creciente preocupación por la contaminación y la gestión de residuos de baterías plantea la necesidad de soluciones para su reutilización y reciclaje ya que el desecho de las baterías de ion de litio contiene sustancias químicas tóxicas que pueden dispersarse en el suelo y el agua, causando daños a la fauna silvestre y a los seres humanos [12].

A pesar de los avances recientes, los métodos actuales de estimación del SoH presentan limitaciones importantes. En particular, los enfoques basados en el aprendizaje profundo enfrentan problemas como la baja capacidad de generalización, el elevado peso computacional, presenta una alta complejidad del modelo, requiere largos tiempos de entrenamiento y la dependencia de grandes volúmenes de datos etiquetados [13], [14]. Estas características dificultan la implementación de soluciones eficientes en entornos reales donde los datos son ruidosos, escasos o no uniformemente distribuidos.

Por su parte, los métodos tradicionales que incluyen los métodos tradicionales basados en ingeniería de características como los modelos físicos, matemáticos o electroquímicos ofrecen precisión, pero requieren gran cantidad de datos experimentales y un elevado costo computacional, lo que dificulta su implementación práctica. Esto indica que el modelado de sistemas es otro desafío, ya que implica desarrollar representaciones matemáticas o computacionales del comportamiento de la batería. Además, estos métodos demandan un procesamiento intensivo y suelen no considerar la degradación progresiva entre ciclos, reduciendo su capacidad de generalización y adaptarse a escenarios [15].

Finalmente, los enfoques híbridos como los modelos de inteligencia física (o PIML por sus siglas en inglés: Physics-Informed Machine Learning), también enfrentan dificultades asociadas a la personalización de funciones de pérdida, ajuste de hiperparámetros y riesgo de sobreajuste, además de requerir grandes recursos computacionales [8].

Ante este panorama, surge la necesidad de desarrollar nuevas estrategias que aborden las limitaciones mencionadas y permitan estimar de manera eficiente el SoH de las baterías. En consecuencia, ¿Cómo estimar el estado de salud (SoH) de baterías de iones de litio (LIBs), mediante datos operacionales con el fin de establecer una aproximación de su vida útil restante (RUL)?

OBJETIVOS DEL ESTUDIO

Objetivo general

Desarrollar un algoritmo de estimación del estado de salud (SoH) de la batería de ion de litio (LIB) con el fin de establecer una aproximación de su vida útil restante (RUL).

Objetivos específicos

- Realizar una revisión bibliográfica que permita clasificar las estrategias e identificar parámetros de diferentes algoritmos de estimación del SoH de la LIB.
- Diseñar un algoritmo de estimación del SoH, a partir de desarrollos experimentales que permitan establecer la RUL de la LIB.
- Evaluar experimentalmente el desempeño del algoritmo diseñado mediante escenarios de prueba de baterías con diferente nivel de degradación para determinar la variación de la vida útil.

JUSTIFICACIÓN

En un contexto global marcado por la creciente demanda de energía, la transición hacia fuentes renovables y la necesidad de mitigar los impactos ambientales, el desarrollo de sistemas de almacenamiento de energía se presenta como una prioridad para garantizar la estabilidad y eficiencia del suministro eléctrico. En este sentido, las microrredes emergen como una solución prometedora para comunidades remotas y áreas con acceso limitado a la red eléctrica convencional, teniendo en cuenta que según datos recopilados por el Centro Nacional de Monitoreo (CNM), las Zonas No Interconectadas (ZNI) en Colombia representan no menos del 52 % del territorio nacional [16], [17].

Estas microrredes, alimentadas por fuentes de energía renovable y respaldadas por sistemas de almacenamiento, pueden ofrecer autonomía energética y mejorar la resiliencia frente a interrupciones del servicio.

La implementación eficiente de microrredes requiere sistemas de almacenamiento de energía eficientes y confiables que puedan adaptarse a las fluctuaciones en la generación de energía renovable y satisfacer la demanda energética de manera continua y estable [18]. En este contexto, las baterías de ion de litio se han establecido como una alternativa destacada debido a su alta densidad de energética. Sin embargo, estas baterías están sujetas a procesos de degradación acelerada por factores como la temperatura, los ciclos de carga/descarga y el envejecimiento químico. Por lo tanto, un algoritmo adecuado para estimar el estado de salud de las baterías de ion de litio es esencial para garantizar su rendimiento y prolongar su vida útil, lo que contribuirá a la estabilidad y eficiencia de las microrredes.

El propósito fundamental de este proyecto es desarrollar un sistema de estimación del SoH para LIBs que puedan integrarse de manera efectiva en sistemas de almacenamiento de energía (o ESS por sus siglas en inglés: Energy Storage System) diseñados para microrredes. Estos sistemas de estimación permitirán monitorear continuamente el SoH de las baterías, identificar posibles fallos o degradaciones y optimizar la gestión de la energía almacenada. Además, se busca mejorar la precisión, la gestión del almacenamiento energético en contextos reales con datos no ideales y la confiabilidad de los modelos de predicción de vida útil de las baterías, lo que facilitará la planificación y mantenimiento de los sistemas de almacenamiento en microrredes.

La implementación de un algoritmo de estimación de SoH para LIBs para microrredes y ESS tendrá un impacto significativo en varios aspectos. En primer lugar, mejorará la eficiencia operativa y la confiabilidad del suministro eléctrico al garantizar un uso óptimo de las baterías y evitar fallos inesperados [19]. Esto resultará en una reducción de los costos de mantenimiento y reemplazo de equipos. Por otra parte, contribuirá a la

integración efectiva de fuentes de energía renovable en las microrredes, al proporcionar una capacidad de almacenamiento flexible y adaptable a las variaciones en la generación de energía. En última instancia, este modelo promoverá el desarrollo sostenible y la resiliencia energética en comunidades marginadas y áreas remotas, reduciendo su dependencia de fuentes de energía convencionales y mitigando los impactos ambientales. En este sentido, el desarrollo de un algoritmo de estimación de SoH para baterías ofrecerá soluciones para la reutilización de baterías, prolongando así su vida útil y mejorando su valor económico y ambiental al facilitar su reutilización en aplicaciones secundarias o incluso primarias después de alcanzar su vida útil en las microrredes.

ALCANCES Y LIMITACIONES

Este apartado describe los alcances y limitaciones del presente proyecto donde se especifican las condiciones de operación bajo las cuales se implementa la solución propuesta, así como los factores que restringen su aplicabilidad.

Alcances

El proyecto se enfoca en el diseño, desarrollo e implementación de un algoritmo de estimación del SoH de LIBs mediante redes neuronales, desarrollado en el entorno de programación MATLAB®. El algoritmo utiliza las funciones propias del software facilitando el manejo de datos. Este desarrollo está orientado a baterías de ion de litio comunes buscando optimizar el procesamiento de datos y mejorar la precisión en la estimación de parámetros críticos relacionados con el SoH de las baterías.

Para evaluar su funcionamiento, se lleva a cabo un proceso de entrenamiento y validación con datos experimentales adquiridos de terceros, que incluyen variables como tiempo de carga y descarga, voltaje, corriente, temperatura, impedancia, y parámetros del sistema como la capacidad nominal (2 Ah), la capacidad al final de la vida útil (1.4 Ah). Como datos de salida se obtienen el SoH estimado, el SoH suavizado mediante un filtro exponencial, las características extraídas, los conjuntos de entrenamiento y prueba, y las predicciones generadas por la red neuronal.

El desempeño del algoritmo se evalúa mediante métricas como el Error Absoluto Medio (MAE), el Error Porcentual Absoluto Medio (MAPE), el Error Cuadrático Medio (MSE) y la Raíz del Error Cuadrático Medio (RMSE) y el coeficiente de determinación (R^2). Estas métricas permiten comprobar la capacidad del algoritmo para generar estimaciones consistentes del estado de salud de las baterías bajo condiciones representativas.

Limitaciones

El algoritmo desarrollado está diseñado para estimar el SoH de baterías de ion de litio, razón por la cual no se puede aplicar a otros tipos de tecnologías de almacenamiento energético u otros tipos de baterías. El entrenamiento y validación del algoritmo se realiza a partir de bases de datos experimentales que contienen registros de variables eléctricas y térmicas obtenidas en condiciones específicas de operación de la batería como el tiempo de carga y descarga, la corriente de salida, el voltaje del terminal, la temperatura de operación, la corriente de detección del sistema, la corriente suministrada, así como la impedancia interna de la celda, lo que implica que su desempeño puede verse comprometido si se usan conjuntos de datos que no contengan estos parámetros. Además, este proyecto se limita al desarrollo y validación del algoritmo utilizando MATLAB® y no se aborda la optimización avanzada del modelo, como el ajuste

automático de hiperparámetros o el uso de técnicas de regularización para mejorar la generalización. Por tanto, su aplicación en escenarios productivos requiere etapas posteriores de validación, adaptación e implementación.

1. MARCO REFERENCIAL

En esta sección se abordan investigaciones que permitieron establecer un contexto sobre la estimación del estado de salud en baterías de ion de litio, se identificaron diversos estudios que muestran la evolución de los métodos utilizados, adicionalmente se agregan conceptos teóricos clave para el desarrollo del trabajo.

1.1. ESTADO DEL ARTE

La literatura científica revela una clasificación de los enfoques tradicionales basados en voltaje y en otras señales de estimación de SoH, como se puede observar en la Tabla 1, la cual presenta dicha información específicamente para LIBs, indicando las ventajas y limitaciones que deben considerarse en función de los requisitos específicos de la aplicación y las condiciones de operación. Cabe destacar que los ejemplos de los métodos mostrados en la Tabla 1, pueden adaptarse a distintos tipos de entradas, por lo que su enfoque puede variar según el caso de estudio.

Tabla 1. Comparación de los métodos de estimación de SoH [20].

Categoría	Método	Descripción	Ventajas	Desventajas
Métodos de estimación de SoH basados en voltaje	Métodos basados en OCV. Ejemplo: Modelo de Thévenin.	Utiliza el voltaje de circuito abierto (OCV) de una batería, medido en estado de reposo, para identificar características relacionadas con el envejecimiento.	No requiere equipos adicionales, ya que utiliza el OCV medido con sensores del BMS. Las curvas OCV varían de forma monótona con el SoH.	Sensible a cambios de temperatura y al estado de carga (SoC).
	Métodos basados en impedancia. Ejemplo: DELM, SVR, SVM, FO-AEKF y/o ELM.	Mide la impedancia de la batería mediante técnicas como EIS (Espectroscopía de Impedancia Electroquímica) y utiliza la variación de la impedancia de la batería para reflejar el SoH.	Sensible a cambios en la estructura interna de la batería. Permite identificar mecanismos de degradación.	Los resultados pueden verse afectados por factores externos como la temperatura o el estado de carga.

	<p>Métodos basados en parámetros electroquímicos. Ejemplo: EKF, DEKF, FO-AEKF, CDM y/o CCDM.</p>	<p>Emplea modelos matemáticos (como P2D o SPM) que simulan procesos internos reales de la batería que dependen de la relación entre el OCV y el SoC para capturar el envejecimiento de la batería.</p>	<p>Puede proporcionar estimaciones precisas del SoH. Estos modelos pueden estimar el estado de salud con una precisión relativa de hasta el 2 % en comparación con métodos que usan datos experimentales [20], [21].</p>	<p>Requiere conocimiento detallado del modelo electroquímico.</p>
	<p>Métodos basados en datos. Ejemplo: GRU, LSTM, MLP, CNN, BP NN, Elman NN, FNN, RNN y/o RBF.</p>	<p>Usa técnicas de aprendizaje automático para estimar el SoH basándose en las curvas de voltaje/corriente de carga sin considerar los principios electroquímicos.</p>	<p>Puede ser más generalizable y escalable. Se adapta a distintos tipos de batería y perfiles permitiendo capturar relaciones complejas y no lineales entre variables [22].</p>	<p>Su precisión depende de la calidad y representatividad de los datos de entrenamiento.</p>
<p>Métodos de estimación de SoH basados en otras señales</p>	<p>Métodos basados en la temperatura. Ejemplo: GRU y/o DELM.</p>	<p>Se basa en la interpretación de perfiles térmicos como indicadores del estado de la batería.</p>	<p>Puede proporcionar una indicación rápida del estado de salud de la batería.</p>	<p>La temperatura puede variar por múltiples factores ajenos al envejecimiento, lo que limita su utilidad como indicador específico de SoH.</p>
	<p>Métodos basados en ultrasonido.</p>	<p>Utiliza la caracterización por ultrasonido para analizar cambios estructurales internos de las celdas de iones de litio.</p>	<p>Puede detectar defectos internos.</p>	<p>Requiere equipo especializado y acceso a la batería.</p>

	Métodos basados en la fuerza.	Mide la expansión y contracción de las baterías debido a cambios en el estado de carga y la degradación de la salud.	Permiten detectar cambios físicos estructurales en la batería	Requiere hardware específico y condiciones de medición controladas.
--	-------------------------------	--	---	---

Se muestran técnicas empleadas, desde los modelos electroquímicos tradicionales de estimación de SoH hasta los recientes enfoques basados en aprendizaje profundo y algoritmos adaptativos donde cada método tiene enfoques distintos con ventajas y limitaciones específicas, lo que sugiere que no existe una única solución óptima; en cambio, la combinación de varios métodos podría ofrecer estimaciones más precisas y para aplicaciones reales [23].

En la Tabla 1 se han descrito varios métodos para monitorear o estimar el SoH de la batería. A partir de esta información, es posible agrupar los métodos de estimación del SoH en dos categorías principales: los métodos experimentales, que se basan en mediciones directas o modelos basados en mediciones reales, y los métodos adaptativos, que intentan simular o estimar la salud de la batería a partir del comportamiento de esta y de datos de medición mínimos [24]. Estos métodos se presentan en la Figura 2.

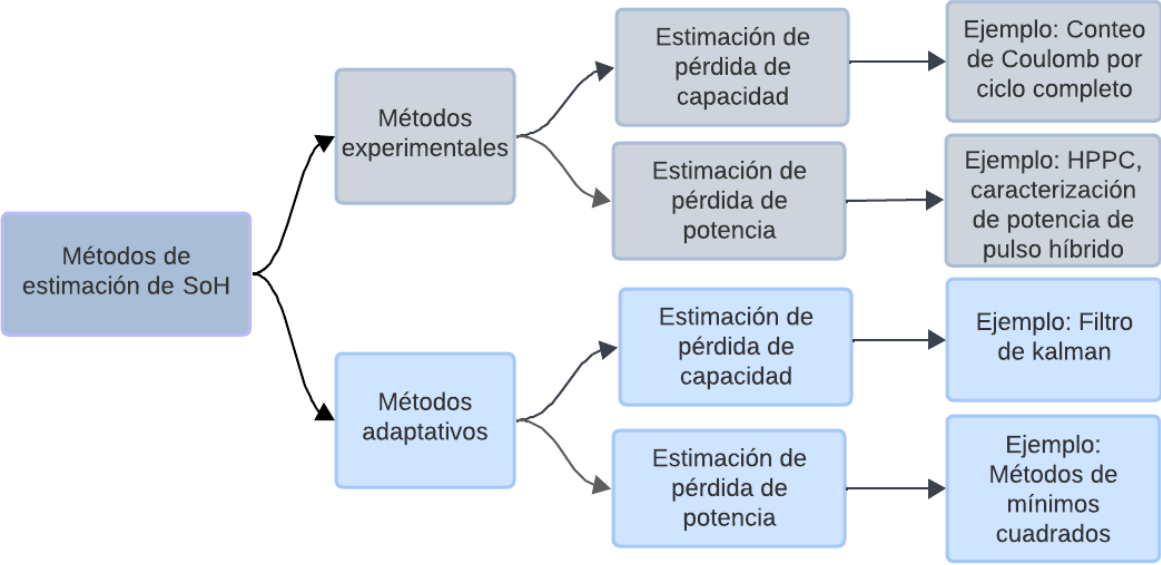


Figura 2. Métodos de última generación para la estimación del estado de salud (SoH). Tomado de: [24].

Los métodos experimentales se basan en los resultados de investigaciones experimentales realizadas antes de la aplicación práctica en condiciones reales de la celda de la batería, y estos resultados sirven como base para la estimación del SoH. A partir de estos métodos, es posible clasificarlos en dos grandes categorías: métodos de estimación de pérdida de capacidad y métodos de estimación de pérdida de potencia.

Los métodos de estimación de pérdida de capacidad, como el conteo de Coulomb, consisten en medir la capacidad real de la batería. Para ello, con la carga desconectada, la batería se somete a un ciclo completo de carga y descarga, integrando la corriente durante este proceso. El principal inconveniente de este método es que la medición durante un ciclo completo, incluido un proceso completo de carga y descarga, requiere mucho tiempo e implica un alto consumo de energía. No obstante, es el estándar para determinar la capacidad de la batería.

Por otro lado, los métodos experimentales de estimación de pérdida de potencia se basan principalmente en la caracterización de la impedancia de la batería. Una técnica común es la prueba de potencia de pulso híbrido (o HPPC por sus siglas en inglés: Hybrid Pulse Power Characterization), en la cual se aplica un pulso de corriente que provoca una caída o un aumento repentino en el voltaje, dependiendo de la dirección del flujo de corriente [24]

Un ejemplo de lo anterior aplica en [24], con un método basado en la espectroscopía de impedancia, que presenta la relación entre la resistencia de la interfaz de electrolito sólido (o SEI por sus siglas en inglés: Solid Electrolyte Interphase) y la resistencia total, utilizando un modelo de circuito de Randles modificado. Este modelo muestra ventajas como una mayor estabilidad y menor sensibilidad al ruido de medición, permitiendo evaluaciones tanto “in-situ” como “ex-situ”, es decir, tanto directa como indirectamente en la celda de la batería, sin necesidad de extrapolar los resultados a escenarios de envejecimiento o fin de vida de la celda.

Los principios de operación se centran en la eficiencia de transferencia de carga, que disminuye linealmente con el SoH a una tasa de 0.02 % por ciclo durante 400 ciclos. Las condiciones de operación incluyen el uso de un método de Corriente Constante, Voltaje Constante (o CCCV por sus siglas en inglés: Constant Current, Constant Voltage) para ciclar las celdas, con mediciones de impedancia realizadas cada 50 ciclos en un rango de frecuencia de 10 mHz a 1 kHz. Los resultados muestran un aumento global de la impedancia con el ciclo, y patrones distintivos en los espectros de impedancia que indican diversos procesos electroquímicos.

Por otro lado, se han investigado métodos adaptativos, como el filtro de Kalman extendido (o EKF por sus siglas en inglés: Extended Kalman Filter), que ofrecen una alta

precisión en diagnósticos al estimar el SoH en función de la variabilidad de voltaje de celdas en diferentes estados de salud.

Uno de los artículos iniciales que se destacó con el uso del EKF fue [25], por su simplicidad y capacidad para manejar sistemas no lineales, lo que lo convirtió en una herramienta popular para el diagnóstico y pronóstico de SoH. Este artículo propuso un nuevo método que implementa un EKF con un nuevo indicador de salud (o HI por sus siglas en inglés: Health Indicator) externo para diagnosticar y pronosticar el SoH de las LIBs, realizando un análisis completo de la reacción electroquímica de las baterías viejas y su proceso de carga real. Este tuvo un buen desempeño en términos de diagnóstico y pronóstico de SoH. El error absoluto promedio (o AAE por sus siglas en inglés: Absolute Average Error) de la estimación IH fue inferior a 0,03 y la desviación de la predicción RUL entre el valor real fue de sólo dos ciclos.

En [3] también se usó un Filtro de Kalman Doble Extendido (o DEKF o por sus siglas en inglés: Dual Extended Kalman Filter) en una investigación y análisis de la reacción electroquímica de las baterías viejas y su proceso de carga real. Se utilizó un conjunto de datos de baterías reales que consta de 12 celdas de baterías conectadas en serie para verificar el algoritmo. Se extrae un nuevo HI que tiene una alta relación con el SoH de las baterías del cual se logra acceder fácilmente y se implementa posteriormente con el algoritmo EKF para el diagnóstico y pronósticos del SoH, llevando a cabo la estimación del SoC y el SoH de las celdas en paquetes de baterías, basado en la inconsistencia de voltaje mediante un modelo de diferencia de referencia y EKF.

Como complemento a los métodos basados en Kalman, la investigación también exploró enfoques alternativos para la estimación del estado de salud de las baterías. Se desarrollaron tres algoritmos de estimación de SoH: empleando el Modelo de Diferencia de Celda (o CDM por sus siglas en inglés: Cell Difference Model), el Modelo de Diferencia de Capacidad de Celda (o CCDM por sus siglas en inglés: Cell Capacity Difference Model) y el modelo de Thévenin para describir esta inconsistencia y establecer una relación entre el SoH y las variaciones de voltaje. El modelo CCDM demostró una precisión superior con un MAE de solo 0.50 %, significativamente mejor que el 1.26 % del modelo CDM y el 3.55 % del modelo Thévenin. Esta precisión permite identificar con exactitud las diferencias de estado entre celdas en un mismo paquete de baterías [3].

Se seleccionó una batería para el análisis comparativo, permitiendo evaluar el rendimiento de los diferentes modelos bajo condiciones controladas. Los resultados de la estimación de capacidad para diferentes modelos utilizando el algoritmo DEKF se muestran en la Figura 3.

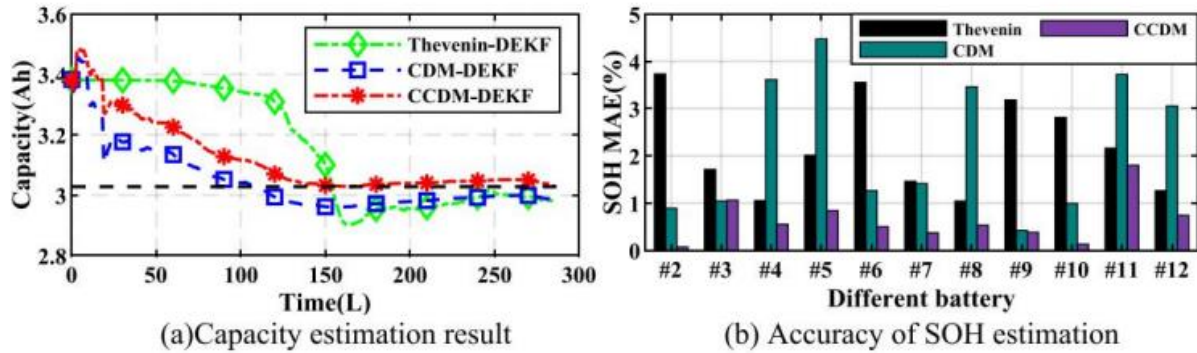


Figura 3. Diagrama de precisión de diferentes algoritmos para encontrar el SoH.
Tomado de: [3].

El algoritmo de DKF inicia con matrices de ganancia y variación de ruido grande, provocando fluctuaciones significativas en las predicciones. A medida que avanzan las iteraciones, estas matrices disminuyen, estabilizando las estimaciones dentro de un rango reducido. El DKF converge más rápido (140 escalas de tiempo) y con menor error (MAE de hasta 0,50 %) en comparación con Thevenin, que usando converge en 180 escalas. El CCDM destaca por requerir menos parámetros, ser más preciso y rápido (13,92 % más eficiente) y evitar errores físicos y divergencias. Con baja carga computacional, es ideal para aplicaciones [3].

De igual manera en la Universidad Ming Chuan, en Taiwán [26], se desarrolló un EFK integrado en una plataforma de aprendizaje profundo para predecir el estado de las baterías de vehículos eléctricos, formando un prototipo de sistema conocido como FELL, que combina EKF y modelos de aprendizaje profundo. El modelo del EKF se basa en un modelo de medición que relaciona las observaciones con el estado interno de la batería, ajustando la incertidumbre en las predicciones.

El sistema FELL permite a los usuarios ingresar parámetros como días de uso y estado de carga, procesando estos datos a través de un módulo de predicción que muestra resultados relevantes sobre el rendimiento de las baterías. Se comparan varios modelos de redes neuronales, incluyendo memoria a corto plazo y largo plazo (o LSTM por sus siglas en inglés: Long Short-Term Memory), Red neuronal recurrente cerrada (o GRU por sus siglas en inglés: Gated Recurrent Unit), perceptrón multicapa (o MLP por sus siglas en inglés: Multi-Layer Perceptron), red neuronal convolucional (o CNN por sus siglas en inglés: Convolutional Neural Network) y transformadores de atención de múltiples cabezales, encontrando que el modelo LSTM ofrece la mayor precisión en la estimación del SoH. Además, se destaca la importancia de factores ambientales en la degradación de las baterías y predecir el SoH utilizando mediciones de voltaje, corriente y

temperatura, y está diseñado para ser escalable y eficiente en el manejo de datos, contribuyendo a la sostenibilidad del transporte eléctrico.

La Tabla 2 presenta los resultados del rendimiento de cinco modelos entrenados en la plataforma FELL para predecir el SoH de las baterías de vehículos eléctricos durante 120 días. El modelo LSTM sobresalió con los índices de error más bajos, demostrando una capacidad predictiva superior y precisión en la estimación del SoH a lo largo del período de pronóstico. En contraste, el modelo MLP mostró los valores más altos en todas las métricas, indicando el menor rendimiento predictivo.

Tabla 2. Resultados del rendimiento de predicción de cinco modelos distintos entrenados en la plataforma FELL para pronosticar el SoH de las baterías de vehículos eléctricos durante 120 días [26].

Modelos	Pasos de previsión = 120 días				
	MSE (%)	RMSE (%)	MAE (%)	MAPE (%)	SMAPE (%)
MLP	22.33	4.73	4.01	5.27	5.43
CNN	21.82	4.67	3.98	6.31	6.11
LSTM	2.91	1.70	1.50	2.29	2.26
GRU	4.23	2.06	1.41	2.18	2.24
Transformador de atención de múltiples cabezales	13.33	3.65	3.11	4.62	4.58

A partir de esto han surgido distintos modelos del uso del KF, como lo es un filtro Kalman extendido adaptativo de orden fraccional (o FO – AEKF por sus siglas en inglés: First-Order Adaptive Extended Kalman Filter) [27] para estimar el SoH, que mostró ventajas como una mayor precisión en la estimación y la capacidad de manejar grandes volúmenes de datos, mejorando así la fiabilidad de los BMS en vehículos eléctricos. Sin embargo, este modelo también presentó desventajas, como la necesidad de grandes conjuntos de datos para entrenar los modelos y la complejidad en la interpretación de los resultados.

Otro uso de este método se desarrolló en [28] con un diagnóstico y pronóstico de SoH basado en datos externos, en China (Zheng Chen y colaboradores). Este estudio propone un método para estimar el estado de salud (SoH) de LIBs utilizando un modelo de predicción de temperatura y GRU. El equipo utiliza diferencias finitas para calcular variaciones de temperatura y luego suaviza estos datos con un KF, obteniendo así características multidimensionales que describen la degradación de la batería. Se seleccionaron seis características clave mediante el coeficiente de correlación de Pearson, y se empleó una GRU para predecir el SoH. Con un RMSE de 0,58 superando

a los demás métodos con el que fue comparado y logrando un R^2 de 0.99 como se observa en la Tabla 3. El modelo supera a las redes neuronales de memoria a corto plazo, mostrando además su eficacia en condiciones de carga incompletas, lo que lo hace adecuado para el monitoreo de SoH en tiempo real.

Tabla 3. Estimación de SoH de una celda bajo diferentes métodos de estimación [28].

Modelos	RMSE (%)	MAE (%)	MAX (%)	R^2
SVM	0.69	0.56	1.86	0.9854
BP	0.75	0.60	1.90	0.9828
Elman	0.79	0.63	2.01	0.9809
LSTM	1.13	1.04	2.03	0.9625
GRU	0.58	0.47	1.32	0.9932

En este caso LSTM tuvo un RMSE mayor (1.13), caso contrario de la tabla anterior, sin embargo, este porcentaje de error es menor en comparación al caso anterior de la Tabla 2, lo que indica una mejora en la estimación de SoH en todos los modelos, en la Figura 4 se puede observar el resumen de la estimación de SoH y error de una celda bajo diferentes métodos de estimación.




Figura 4. Resumen de la estimación de SoH y error de una celda bajo diferentes métodos de estimación [28].

En Hamilton, Canadá, se llevó a cabo un estado del arte sobre el aprendizaje automático aplicado a los vehículos eléctricos con el objetivo de estimar el SoC y el SoH de las LIBs [29], incluyendo técnicas como Red Neuronal de Propagación Directa (o FNN por sus siglas en inglés: Feedforward Neural Network), Red Neuronal Recurrente (o RNN por sus siglas en inglés: Recurrent Neural Network), Máquina de Vectores de Soporte (o SVM por sus siglas en inglés: Support Vector Machine, Función de Base Radial (o RBF por sus siglas en inglés: Radial Basis Function), redes de Hamming y modelos LSTM, destacando la capacidad de estos últimos para capturar dependencias temporales y

mejorar la precisión en diversas temperaturas. También se abordan modelos como GRU, y desafíos como el sobreajuste, la complejidad de los modelos, y la importancia de la preparación de datos, así como el uso de técnicas como el aprendizaje por transferencia y la optimización de hiperparámetros. La mayoría de los métodos logran estimar capacidad o resistencia con un RMSE ≤ 1 , destacando el FNN con k-means y los modelos RNN (LSTM), con errores mínimos de 0,66 % y 0,96 % a 25 °C. Se analiza además la Máquina de Aprendizaje Extremo (o ELM por sus siglas en inglés: Extreme Learning Machine), que ofrece buena eficiencia en la estimación del SoC frente a RBF.

Las ventajas de estos modelos incluyen una mayor precisión en la estimación del SoH y la capacidad de manejar grandes volúmenes de datos, lo que mejora la confiabilidad de los BMS en vehículos eléctricos. Sin embargo, también presentan desventajas, como la necesidad de grandes conjuntos de datos para entrenar los modelos y la complejidad en la interpretación de los resultados. Los modelos de aprendizaje automático (o ML por sus siglas en inglés: Machine Learning) son algoritmos basados en datos y, por lo tanto, la calidad de los datos utilizados para entrenar y validar es un aspecto importante para considerar.

Continuando con la investigación se encontró que, en 2022, Alberto Barragán Moreno y colaboradores [30] propusieron un nuevo método que combina aprendizaje automático y espectroscopia de impedancia electroquímica (o EIS por sus siglas en inglés: Electrochemical Impedance Spectroscopy) para estimar el SoH de las baterías, utilizando un número limitado de mediciones de impedancia a frecuencias fijas, lo que permite una mayor flexibilidad y eficiencia en el análisis. Este modelo se basa en la relación entre la capacidad máxima disponible y la capacidad nominal de la batería. Este método permite realizar estimaciones precisas con un conjunto reducido de datos, lo que facilita su implementación en condiciones reales de operación. El algoritmo alcanzó un MAE de hasta 0.9 % y un RMSE de 1.5 %, demostrando alta precisión. Sin embargo, la efectividad del algoritmo depende de la calidad de las mediciones de impedancia y de las condiciones específicas de envejecimiento de las celdas de ion litio utilizadas al igual que la necesidad de que la batería esté en un nivel específico de SoC para realizar las mediciones, lo que limita la aplicabilidad en situaciones de uso cotidiano. En el mismo año, Lewis Driscoll y otros investigadores de la Universidad de Málaga, España [31] propusieron un modelo de estimación del SoH basado en la extracción de características observadas a partir de patrones en los perfiles de voltaje, corriente y temperatura durante el proceso de carga. Este modelo mostró resultados con coeficientes de determinación entre 0,896 y 0,992, y utilizó significativamente menos datos de entrada que otros trabajos previos. En este trabajo se presenta un modelo para estimar el SoH de baterías mediante redes neuronales artificiales (o ANN por sus siglas en inglés: Artificial Neural Network), aprovechando patrones de voltaje, corriente y temperatura durante el proceso de carga para realizar estimaciones por ciclo. Usando datos de PCoE NASA Ames, el

modelo fue probado en dos grupos de baterías, logrando un MAE de 1.39 % y un R^2 de 0,946 para el conjunto de prueba. Este modelo simplifica la configuración de las redes neuronales al usar modelos con pocas capas, permitiendo así predicciones precisas en varias condiciones de descarga y reduciendo la cantidad de datos de entrada necesarios, lo que mejora su adaptabilidad.

Se ha observado que el uso de múltiples entradas mejora la precisión de la regresión y predicción del SoH, aunque los errores de medición en los sensores del BMS pueden afectar la precisión de la estimación. Además, se ha destacado la complejidad no lineal de la degradación de las baterías y la influencia de factores como la temperatura y la corriente de carga/descarga en el SoH [31].

En [32], (Universidad Sun Yat-sen, China) en 2020 desarrollaron un modelo basado en la resistencia interna equivalente (EIR por sus siglas en inglés: equivalent internal resistance) y regresión de soporte vectorial (o SVR por sus siglas en inglés: Support Vector Regression) para la estimación del SoH en tiempo real. El estudio emplea Gridsearch y validación cruzada K-fold para optimizar la precisión del modelo, logrando una predicción bajo ciclos de carga y descarga a 40 °C en baterías de fosfato de hierro y litio. Los resultados demostraron que al utilizar tres valores de EIR correspondientes a niveles de SoC del 60 %, 70 % y 80 %, el modelo SVR logró una estimación precisa del SoH, alcanzando un MAE de 0.0118 y un RMSE de 0.0169. Sin embargo, se encontró que errores en la medición de sensores dentro del BMS podían impactar la precisión del modelo, recomendando ajustes que aborden estas variaciones para mejorar la eficacia.

Este modelo orientado al ML aborda tanto las ventajas como las limitaciones de los métodos actuales: permite una predicción precisa del SoH mediante el uso de grandes conjuntos de datos, aunque requiere optimización continua en función de las condiciones de operación, como temperatura y ciclos de carga. Las técnicas que emplean ML y modelos adaptativos han demostrado ser eficaces para optimizar la gestión del SoH de la batería en aplicaciones de almacenamiento de energía, en particular en vehículos eléctricos, donde las condiciones cambiantes y la necesidad de predicciones rápidas y precisas son constantes.

Haihong Pan y colaboradores (China) en [33] desarrollaron un método de estimación en línea del SoH mediante el uso de una ELM y múltiples HIs. El modelo se centra en la resistencia interna y la degradación de la capacidad en celdas de litio níquel manganeso cobalto (LiNMC), logrando una correlación efectiva entre los HIs y el SoH. El ELM mostró una mejora notable en velocidad y precisión frente a redes neuronales tradicionales de retropropagación (o BPN por sus siglas en inglés: Backpropagation Neural Network), logrando un error máximo de estimación menor al 2.5 % como se observa en la Figura 5. Este estudio subraya la capacidad del ELM para realizar estimaciones rápidas y

precisas en entornos de operación reales, como vehículos eléctricos, donde la degradación de capacidad se monitorea en tiempo real.

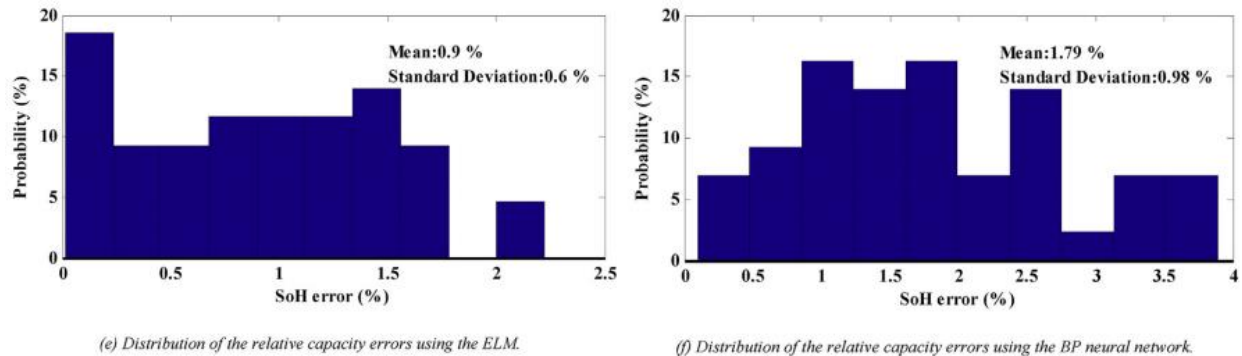


Figura 5. Comparación de los resultados de la distribución de la capacidad relativa de ELM (e) y BPN (f) Tomado de: [33].

El estado del arte sobre SoH de LIBs ha evolucionado significativamente en los últimos años, destacando diversas metodologías y enfoques. En 2023, un estudio realizado por Shukai Sun y colaboradores en China [6] propone un método de estimación del SoH que combina optimización de características basada en modelos y aprendizaje automático extremo profundo (o DELM por sus siglas en inglés: Deep Extreme Learning Machine). Este enfoque busca abordar los desafíos de la estimación en línea, que se complican por comportamientos aleatorios de carga/descarga y condiciones ambientales variables. Se integra el algoritmo de aprendizaje automático adaptativo con un nuevo método de extracción de características basado en modelos. Los datos experimentales de pruebas de ciclo a largo plazo en celdas óxido de cobalto de litio/ óxido de cobalto-níquel (LCO/NCO), óxido de cobalto-níquel-aluminio (NCA) y fosfato de hierro y litio (LFP) se utilizan para la validación. El voltaje de carga se puede reconstruir con precisión mediante el método propuesto con un MAE por debajo del 1 %. Para este atributo, el efecto del ruido se suaviza adecuadamente, lo que facilita la extracción de información y su uso posterior para la estimación de SoH en línea.

Se logra extraer un conjunto de características de frecuencia informativas y de múltiples atributos tanto del modelo empírico como de la ventana de voltaje de carga óptima (o CVW por sus siglas en inglés: Optimal Charging Voltage Window), que son altamente robustos al ruido, la alta tasa de carga y los escenarios de carga incompleta. Aprovechando la reconstrucción de voltaje y la selección óptima de los resultados de la estimación de SoH para tres tipos de baterías se mantuvieron dentro del 2,2 % de RMSE, incluso bajo corrupción de ruido y fluctuaciones de temperatura ambiente. El enfoque basado en datos permite capturar relaciones no lineales complejas entre el SoH y las mediciones, sin requerir un conocimiento profundo de las propiedades químicas internas

de las baterías. Sin embargo, una desventaja es que la precisión de la estimación depende en gran medida de la calidad de los datos y de la extracción de características.

Los principios de operación del método propuesto incluyen la reconstrucción de la curva de voltaje mediante modelos empíricos y la determinación de una CVW para extraer características de salud asociadas, en este caso el SoH está correlacionado con parámetros como la temperatura de la superficie, el voltaje y tiempo de carga y descarga.

A pesar de los avances significativos en la estimación del SoH, persisten desafíos importantes, como la calidad de los datos de entrada y la capacidad de manejar variaciones en las condiciones de operación, como fluctuaciones de temperatura y ciclos de carga/descarga incompletos. Los modelos basados en ML y adaptativos requieren conjuntos de datos grandes y bien etiquetados para entrenar, lo que puede ser un obstáculo en aplicaciones reales. Además, la precisión de las estimaciones sigue siendo sensible a los errores de medición en los sensores y a la capacidad de adaptación del algoritmo a condiciones no ideales.

1.2. FUNDAMENTOS TEÓRICOS

Este apartado presenta los conceptos esenciales que sustentan el desarrollo del proyecto, relacionados con el Sistema de Gestión de Baterías (BMS), con el propósito de contextualizar de manera efectiva su funcionamiento.

1.2.1. Sistema de Gestión de Baterías (BMS)

Un Sistema de Gestión de Baterías (BMS) es un componente esencial en dispositivos portátiles y sistemas de almacenamiento de energía que utilizan baterías recargables, como las de ion de litio. Su función principal es optimizar el uso de la energía almacenada y prevenir daños en la batería, lo que contribuye a extender su vida útil y mejorar su seguridad operativa. Además de sus funciones de monitorización y control, las cuales permiten medir variables críticas como voltaje, corriente y temperatura. Con base en estas mediciones, el sistema regula el flujo de energía para maximizar el rendimiento de la batería y prevenir condiciones peligrosas, como sobrecarga o sobrecalentamiento [7], [34]. Entre las funcionalidades más comunes de un BMS se incluyen la estimación del estado de carga (SoC) y del estado de salud de la batería (SoH), la gestión térmica, el balanceo de celdas, la detección y diagnóstico de fallas, y la protección contra condiciones adversas. Para lograr esto, el BMS integra sensores, actuadores y controladores que permiten la regulación de la batería y notifican a los usuarios sobre posibles anomalías. En caso de detectar irregularidades, como niveles anormales de voltaje o temperatura, el BMS puede desconectar la batería de la carga o el cargador, o incluso apagarla de manera segura, evitando así riesgos de seguridad y posibles daños en el sistema. El BMS se estructura en diferentes módulos que trabajan en conjunto para

supervisar y controlar el proceso de carga y descarga. La Figura 6 ilustra la descripción general del BMS [7].

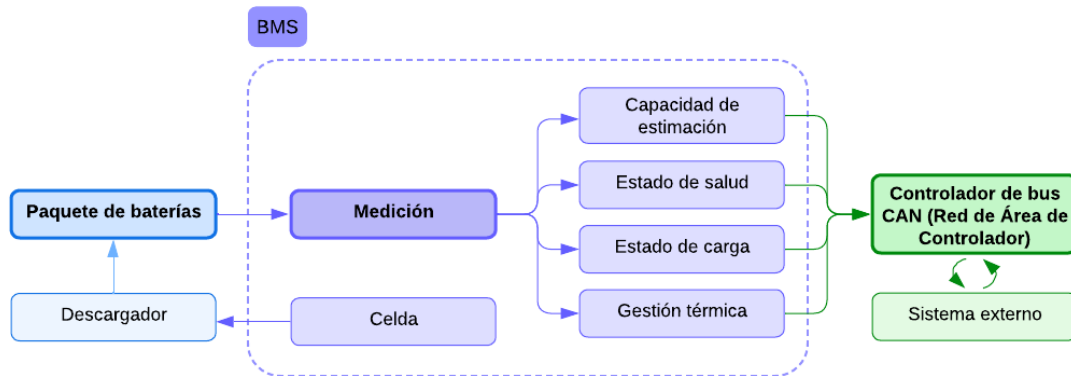


Figura 6. Diagrama general del BMS. Tomado de: [7].

Una batería es un dispositivo que convierte energía química en energía eléctrica mediante procesos de oxidorreducción a partir de un conjunto de celdas electroquímicas conectadas en serie y/o en paralelo para proporcionar el voltaje y la corriente necesarios para una aplicación específica. Las celdas constan de un electrolito en medio de dos electrodos (positivo y negativo), de modo que la energía eléctrica se genera a partir del movimiento de iones entre los electrodos. Existen dos tipos principales de baterías: primarias, que son de un solo uso y no recargables, y secundarias, que son recargables y permiten revertir las reacciones electroquímicas mediante el paso de corriente en dirección inversa. Además, se clasifican según el tipo de electrolito que se emplea, como acuoso, orgánico, polímero, cerámico o sal fundida[35], [36].

1.2.2. Batería de ion de litio

Las baterías de ion de litio (LIBs) son dispositivos electroquímicos que almacenan y liberan energía a través de reacciones de oxidación y reducción. Se caracterizan por su alta densidad de energía, eficiencia de carga y larga vida útil, lo que las convierte en una opción preferida para aplicaciones que van desde dispositivos móviles hasta sistemas de almacenamiento de energía en microrredes [16].

1.2.3. Celdas de baterías de iones de litio

Las celdas de las LIB están compuestas por cuatro partes principales: ánodo (electrodo negativo, generalmente de metal o aleación), cátodo (electrodo positivo, comúnmente de óxido de litio y otros materiales como níquel, manganeso y cobalto en las celdas NMC), electrolito (conductor iónico que permite el flujo de iones entre los electrodos) y separador

(membrana porosa que aísla eléctricamente el ánodo y el cátodo, permitiendo el paso de iones Li^+).

El ciclo de carga y descarga implica procesos electroquímicos donde los iones Li^+ migran entre el ánodo y el cátodo, mientras que los electrones circulan a través del circuito externo. Con el tiempo, estos procesos generan degradación en la celda, afectando su capacidad, resistencia interna y eficiencia energética, lo que impacta directamente en su estado de salud (SoH).

El estado de salud de una batería se ve influenciado por la degradación del cátodo y el ánodo, la formación de una capa de interfase de electrolito sólido (SEI), la pérdida de litio activo y el aumento de la resistencia interna. Estos factores son fundamentales en la estimación del SoH, ya que permiten identificar el envejecimiento de la batería y predecir su rendimiento futuro. El diseño de un algoritmo para estimar el SoH requiere comprender estos fenómenos, modelar su evolución y desarrollar métodos de análisis que permitan evaluar con precisión la capacidad restante y la eficiencia de la batería [22], [30], [37], [38]. En la Figura 7 se presenta el funcionamiento interno de una celda de LIB.




Figura 7. Ilustración esquemática y funcionamiento de una LIB, tomado de: [39].

1.2.4. Estado de Salud (SoH)

El estado de Salud (SoH) de una batería se refiere a su capacidad actual en comparación con su capacidad nominal al inicio de su vida útil. Este parámetro permite evaluar el rendimiento y la RUL de la batería. Sin embargo, el SoH no tiene una definición universalmente aceptada, ya que puede evaluarse desde distintos parámetros como la capacidad de almacenamiento de energía, la resistencia interna, el voltaje y la autodescarga [31], [37], [40], [41], [42].

Una de las formas más comunes de definir el SoH siendo la manera utilizada en el desarrollo del algoritmo propuesto es a partir de la capacidad de la batería, se calcula como la relación entre la capacidad actual y su capacidad nominal o inicial. Se considera que una batería ha alcanzado el fin de su vida útil (o EOL por sus siglas en inglés: End Of Life) cuando su capacidad cae entre 70-80 % de su capacidad inicial, lo que se expresa como:

$$CEOL = C_{\text{inicial}} * \eta \quad (1)$$

Donde η es un valor entre 70 y 80 %.

Si se toma el SoH en condiciones ideales como 100% y en su EOL como 0 %, se puede definir de la siguiente manera:

$$SoH = \frac{C_{\text{current}} - CEOL}{C_{\text{nominal}} - CEOL} * 100 \% \quad (2)$$

Otra forma de definir el SoH es a partir de la resistencia interna (o IR por sus siglas en inglés: Internal Resistance), se evalúa el aumento de la resistencia con el uso. Se considera que una batería ha llegado a su EOL cuando su IR alcanza el 160 % de su valor inicial. El SoH basado en la IR se define como:

$$SoH = \frac{REOL - R_{\text{current}}}{REOL - R_{\text{new}}} * 100 \% \quad (3)$$

También puede expresarse en función de la relación entre la diferencia de IR actual e inicial, como [29]:

$$SoH = \frac{R_{\text{current}} - R_{\text{inicial}}}{R_{\text{inicial}}} * 100 \% \quad (4)$$

1.2.5. Métricas de rendimiento de un modelo

Para evaluar el rendimiento de un modelo de estimación del SoH de las baterías de ion de litio, se emplean diversas métricas de error y ajuste que permiten analizar la precisión de las predicciones. Entre las métricas más utilizadas en la literatura se encuentran el

error absoluto medio (o MAE por sus siglas en inglés: Mean Absolute Error), el error cuadrático medio (o MSE por sus siglas en inglés: Mean Squared Error), la raíz del error cuadrático medio (o RMSE por sus siglas en inglés: Root Mean Squared Error), el error porcentual absoluto medio (o MAPE por sus siglas en inglés: Mean Absolute Percentage Error) y el coeficiente de determinación (R^2). Las ecuaciones correspondientes a estas métricas se presentan en las ecuaciones (5), (6), (7), (8) y (9), donde \hat{y}_i y y_i representan los valores estimados y reales de la i -ésima muestra, respectivamente, y N es el número total de muestras [30], [31], [43].

1.2.6. Error Absoluto Medio (MAE)

El MAE mide la diferencia absoluta promedio entre los valores predichos y los valores reales, un menor MAE indica una mejor precisión del modelo. Se expresa como [30]:

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (5)$$

1.2.6.1. Error Porcentual Absoluto Medio (MAPE)

El MAPE expresa el error en términos porcentuales, facilitando la comparación entre diferentes modelos.

Un valor más bajo de MAPE indica una mejor precisión del modelo, aunque esta métrica puede verse afectada por valores reales cercanos a cero [43], [44]:

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

1.2.6.2. Error Cuadrático Medio (MSE) y Raíz del Error Cuadrático Medio (RMSE)

El MSE evalúa el error promedio al elevar al cuadrado la diferencia entre los valores predichos y los reales [31]:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (7)$$

Mientras que la Raíz del Error Cuadrático Medio (RMSE) se obtiene al calcular la raíz cuadrada del MSE [30], [45]:

$$\text{RMSE} = \sqrt{\text{MSE}} \quad (8)$$

El RMSE proporciona una medida más interpretativa del error, ya que mantiene las mismas unidades que las variables originales.

1.2.6.3. Coeficiente de Determinación (R^2)

El R^2 cuantifica la proporción de la varianza total de la variable dependiente que es explicada por el modelo. Refleja el grado de ajuste entre los valores observados y los valores estimados. Un valor cercano a 1 indica una alta capacidad explicativa del modelo, mientras que valores cercanos a 0 o negativos evidencian un ajuste deficiente. Este se define como [45]:

$$R^2 = 1 - \frac{\sum(y_i - \hat{y}_i)^2}{\sum(y_i - \bar{y})^2} \quad (9)$$

2. DISEÑO METODOLÓGICO

2.1. METODOLOGÍA

La presente investigación adopta un enfoque cuantitativo, aplicado y tecnológico, ya que busca desarrollar una solución concreta mediante el diseño y validación de un algoritmo para la estimación del SoH de LIBs. Se emplea un método experimental, basado en pruebas con conjuntos de datos reales, para analizar el comportamiento del algoritmo en diferentes condiciones operativas.

La metodología se divide en tres etapas consecutivas las cuales permiten el cumplimiento de los objetivos planteados en el proyecto, se describe en la Figura 8.



Figura 8. Fases de la metodología.

Fase 1. Se llevó a cabo una revisión de algoritmos de estimación de SoH de baterías de iones de litio previamente implementadas. Este análisis se basó en la consulta de fuentes especializadas, tales como revistas científicas, normativas relevantes y artículos que brinden información primordial del SoH, para el diagnóstico de los niveles de degradación de la batería prediciendo la vida útil restante de la batería (RUL). Como resultado de esta fase se obtuvo un documento con la revisión del estado del arte y un cuadro comparativo de los diferentes algoritmos de estimación.

Fase 2. De acuerdo con el análisis previo de los diferentes métodos existentes de estimación de baterías de ion de litio se identificaron los factores más relevantes y se diseñó de un algoritmo de estimación que permite establecer la vida útil restante (RUL) usando un modelo de red neuronal artificial (ANN). Posteriormente, se ejecutaron las

pruebas de funcionamiento utilizando distintos modelos de estimación, con el fin de contrastar resultados simulados y realizar ajustes en el algoritmo para optimizar su funcionamiento.

Fase 3. Se realizaron pruebas de simulación en baterías de ion de litio (LIBs), utilizando el algoritmo desarrollado en la fase anterior con el fin de supervisar los parámetros de referencia del SoH y capacidad de las baterías. Para ello, se emplearon conjuntos de datos baterías con diferentes ciclos completos de vida útil y se ajustaron los hiperparámetros de la red neuronal. Como producto de esta fase, se identificaron comportamientos asociados a la degradación de las baterías, lo que permitió una evaluación y una predicción precisa de la vida útil restante (RUL).

3. DESARROLLO DEL ALGORITMO DE ESTIMACIÓN DEL ESTADO DE SALUD (SOH) DE BATERÍAS DE ION DE LITIO

En este capítulo, se presenta un análisis del diseño del algoritmo propuesto abordando las problemáticas y necesidades asociadas a su desarrollo. A partir de esto, se establecen los requisitos fundamentales del modelo. Se detalla cada una de las etapas que componen el diseño. Además, se incluye la selección del modelo final y la evaluación de su desempeño mediante métricas de rendimiento del modelo. Finalmente, se presentan las pruebas de funcionamiento del algoritmo, así como un análisis de los resultados obtenidos, con el fin de verificar su precisión y aplicabilidad en diferentes escenarios de degradación y con distintos ajustes de hiperparámetros.

3.1. ANÁLISIS

La creciente demanda energética de sistemas de almacenamiento y la transición hacia energías limpias han impulsado el desarrollo de tecnologías para la gestión de LIBs [1], [5]. Estas baterías son ampliamente utilizadas en aplicaciones como vehículos eléctricos, almacenamiento de energía y dispositivos electrónicos portátiles debido a su alta densidad de energía y larga vida útil. No obstante, el envejecimiento y la degradación de estas baterías plantean desafíos significativos en términos de seguridad operativa, eficiencia y durabilidad [28]. La degradación de las LIBs ocurre progresivamente a lo largo de los ciclos de carga y descarga, siendo influenciada por múltiples factores, entre ellos la temperatura de operación, el SoC, la velocidad de carga/descarga (C-rate), la profundidad de descarga (o DoD por sus siglas en inglés: Depth of Discharge) y las condiciones ambientales [47], [46].

Los métodos de estimación de SoH basados en datos enfrentan limitaciones importantes, especialmente en la forma en que se extraen y utilizan los indicadores de salud (o HF por sus siglas en inglés: Health Features). En varios estudios, se emplean únicamente una o muy pocas variables como HF, lo que dificulta capturar de forma precisa la compleja dinámica de degradación de las baterías. Asimismo, los modelos predictivos pueden presentar bajo rendimiento de generalización si sus parámetros e hiperparámetros (como el número de neuronas en capas ocultas y cantidad de épocas) no se ajustan adecuadamente a los datos disponibles [47].

En los estudios de estimación del SoH, comúnmente se emplean variables como la corriente, el voltaje, la temperatura y la impedancia, registradas durante los ciclos de

carga y descarga. Estos parámetros permiten capturar el comportamiento dinámico de la batería [48], [49].

En este trabajo se utilizan datos experimentales obtenidos del Centro de Excelencia de Pronósticos de la NASA (PCoE), los cuales contienen perfiles completos de carga y descarga, así como mediciones de impedancia de celdas de ion de litio operadas bajo diversas condiciones. Estos datos permiten identificar patrones específicos de degradación a lo largo del tiempo según los perfiles de uso propios de una microrred y establecer correlaciones significativas entre las condiciones operativas y los cambios en la capacidad de la batería [50].

En este contexto, se requiere desarrollar un algoritmo que estime el SoH de las baterías, permitiendo anticipar fallos, optimizar el mantenimiento y extender la vida útil del sistema. El entorno de operación final previsto para este algoritmo es una microrred eléctrica, por lo que el diseño debe considerar condiciones operativas reales y variables propias de este tipo de sistema. En esta línea, se definen las siguientes necesidades que el algoritmo debe satisfacer:

- **Adaptabilidad operativa:** El algoritmo debe funcionar en diversos regímenes de carga/descarga, temperaturas fluctuantes y diferentes estados de carga, como los que se presentan en una microrred con fuentes renovables y cargas variables.
- **Entrada de datos del modelo:** Se deben utilizar registros multivariados y temporales que reflejen el comportamiento de las baterías en entornos dinámicos, considerando variables críticas como voltaje, corriente, impedancia y tiempo de carga y descarga, además de tener en cuenta la temperatura de operación.
- **Salida del modelo:** El algoritmo debe proporcionar como resultado una estimación del SoH con un MAE menor a 5 % garantizando así la precisión del modelo. Las salidas del modelo pueden estar expresadas en ciclos o tiempo restante de vida útil o en porcentaje de capacidad remanente (SoH).
- **Compatibilidad con herramientas de simulación y análisis:** La implementación del algoritmo se realiza en MATLAB®, aprovechando su compatibilidad para el desarrollo de redes neuronales, así como su entorno integrado que facilita el procesamiento de datos, entrenamiento supervisado, visualización de resultados y validación del modelo. Esto garantiza flexibilidad, reproducibilidad y facilidad de integración con futuros desarrollos.

- **Precisión:** Se requiere que el modelo alcance un nivel de error dentro de un margen aceptable, idealmente con métricas como el MAE o el MSE inferiores al 5 % en condiciones de prueba.

En distintas aplicaciones de baterías se considera un margen de error de 5 % como máximo tolerable y/o como criterio de convergencia durante el entrenamiento de modelos [51], [52], [53]. Un RMSE de aproximadamente 1 o menos se considera excelente para estimación de SoH, y alrededor de 2-5 % se considera una estimación eficaz para baterías [53], [54], [55].

- **Capacidad de generalización:** El modelo debe evitar el sobreajuste y demostrar un rendimiento adecuado frente a datos no vistos durante la fase de entrenamiento.

3.2. DISEÑO

El desarrollo del modelo de aprendizaje general para la estimación de SoH consta de tres módulos funcionales: preparación de datos, proceso de entrenamiento, estimación y evaluación. Esta división permite organizar el desarrollo del modelo de forma sistemática. La Figura 9 ilustra el marco general del modelo propuesto, en el cual se resumen las etapas clave para la implementación del algoritmo.

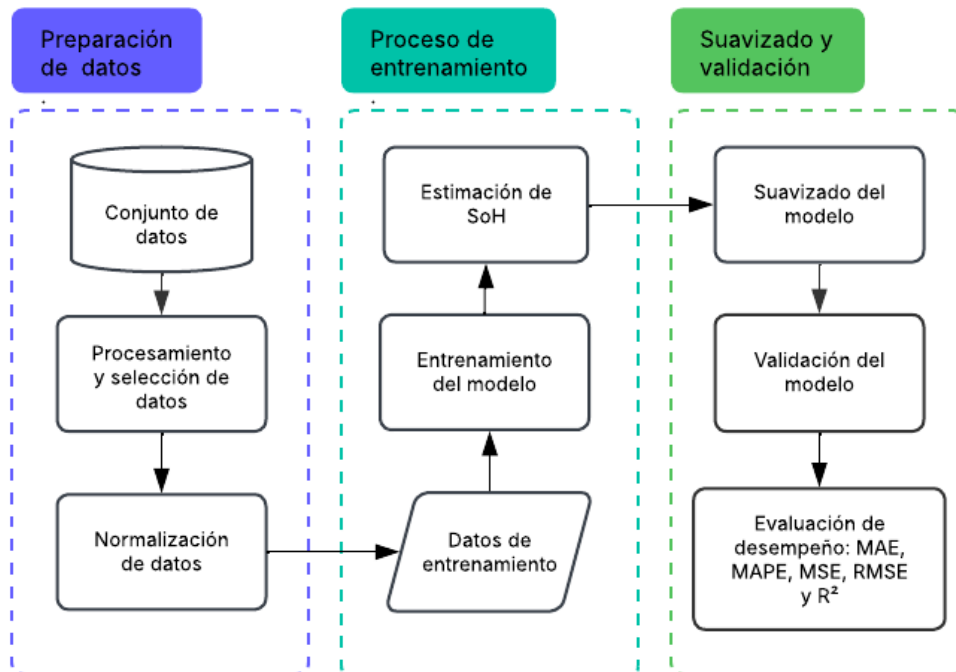


Figura 9. Marco del modelo.

A partir del análisis presentado en la sección 3.1, se establece un diseño cuyo objetivo principal es estimar el SoH de baterías de ion de litio utilizando un modelo basado en datos. Los procesos específicos del modelo son los siguientes:

3.2.1. Herramienta de simulación

Para el desarrollo del trabajo se utilizó MATLAB®, un entorno de programación numérica ampliamente empleado en ingeniería por su capacidad para el procesamiento de datos, modelado de sistemas, entrenamiento de redes neuronales y visualización de resultados. En particular, se hizo uso de la herramienta Deep Learning Toolbox™, la cual permite implementar modelos de aprendizaje supervisado, ideales para modelar y controlar sistemas dinámicos, clasificar datos con ruido y predecir eventos futuros [56].

Este toolbox incluye soporte para distintos tipos de redes neuronales supervisadas, como las redes feedforward, de base radial, dinámicas y de cuantificación vectorial de aprendizaje. En este trabajo se emplearon las redes feedforward, que se caracterizan por su arquitectura directa entre capas y su eficacia en tareas de regresión y clasificación.

MATLAB® también facilitó el uso de funciones integradas para la gestión de datos experimentales, incluyendo su normalización, limpieza y análisis estadístico para el desarrollo del modelo. Además, su uso es respaldado por la Universidad de Cundinamarca, la cual cuenta con una licencia tipo Campus-Wide o Licencia de Campus, lo que garantiza el acceso completo a sus funcionalidades.

3.2.2. Selección de variables

Para alimentar el modelo, se seleccionaron variables clave que forman parte del monitoreo estándar de un BMS. Estas variables incluyen el tiempo correspondiente al ciclo de operación o tiempo de carga y descarga, el voltaje del terminal medido de la batería, la corriente de salida medida de la batería, la corriente suministrada por la batería, la corriente de detección del sistema, la temperatura de operación de la batería, así como la impedancia interna de la celda.

La elección de estas variables se fundamenta en su alta correlación con los fenómenos de deterioro electroquímico propios de las LIBs, así como en su disponibilidad en la mayoría de los sistemas comerciales de almacenamiento energético [49]. Este criterio permite identificar el comportamiento interno de las celdas y garantizar la compatibilidad del algoritmo con implementaciones reales.

3.2.3. Hiperparámetros de una red neuronal

Los hiperparámetros son configuraciones clave que determinan el comportamiento del modelo de red neuronal durante su entrenamiento y afectan directamente su capacidad

de aprendizaje, generalización y rendimiento [57]. A diferencia de los pesos sinápticos, que son ajustados automáticamente por el modelo durante el entrenamiento, los hiperparámetros deben ser establecidos manualmente o mediante métodos de búsqueda como validación cruzada, búsqueda aleatoria o algoritmos de optimización bayesiana [58].

Los hiperparámetros se dividen comúnmente en dos categorías principales: hiperparámetros de arquitectura y de entrenamiento.

3.2.3.1. Hiperparámetros de arquitectura

Los hiperparámetros de arquitectura determinan la forma y complejidad estructural de la red neuronal, lo cual influye directamente en su capacidad de modelado y en los recursos computacionales requeridos para su entrenamiento.

3.2.3.1.1. Número de capas ocultas

La cantidad de capas ocultas en una red neuronal determina su profundidad y capacidad para modelar relaciones complejas en los datos. Una mayor cantidad de capas permite representar funciones más complejas, pero también incrementa el riesgo de sobreajuste y los requerimientos computacionales [59].

3.2.3.1.2. Número de neuronas en la capa oculta

El número de neuronas en las capas ocultas influye directamente en la capacidad de la red para aprender patrones a partir de los datos. Un número insuficiente de neuronas puede limitar la capacidad de aprendizaje del modelo (sub-ajuste). Por otro lado, un número excesivo puede llevar al sobreajuste, donde el modelo se adapta demasiado a los datos de entrenamiento y pierde capacidad de generalización. Además, un mayor número de neuronas incrementa la complejidad computacional del modelo [60].

3.2.3.1.3. Función de activación

La función de activación introduce no linealidades en el modelo, lo cual permite que la red neuronal aprenda relaciones complejas entre las variables de entrada y salida. Funciones comunes incluyen la unidad lineal rectificadora (o ReLU por sus siglas en inglés: Rectified Linear Unit), sigmoide y tangente hiperbólica (tanh) [61].

La elección de la función de activación afecta significativamente la capacidad expresiva del modelo, es decir, su habilidad del modelo para aprender y representar relaciones no lineales. Además, influye en la velocidad de convergencia durante el entrenamiento y en el rendimiento de generalización del modelo. Comprender las propiedades de distintas

funciones de activación permite diseñar arquitecturas efectivas y adaptadas a los requerimientos de cada problema [62].

3.2.3.2. Hiperparámetros de entrenamiento

Estos hiperparámetros definen cómo se entrena la red neuronal, estos incluyen:

3.2.3.2.1. Número de épocas

El número de epochs o épocas corresponde a una iteración completa sobre el conjunto de datos de entrenamiento, y su cantidad influye directamente en el tiempo necesario para entrenar el modelo. Un mayor número de épocas permite que el modelo ajuste los pesos de las redes neuronales de manera más precisa, reduciendo el error en las predicciones y mejorando la capacidad de generalización. Sin embargo, un número excesivo de épocas también aumenta el costo computacional y puede llevar al sobreajuste, un problema donde el modelo se ajusta demasiado a los datos de entrenamiento y pierde capacidad para generalizar a datos nuevos [63].

En contraste, un número insuficiente de épocas resulta en un modelo subentrenado, con una capacidad limitada para aprender patrones relevantes en los datos, afectando negativamente su rendimiento [64].

3.2.3.2.2. Algoritmo de entrenamiento

El algoritmo de entrenamiento es el método mediante el cual se ajustan los pesos sinápticos de la red neuronal durante el proceso de aprendizaje, con el objetivo de minimizar una función de error que mide la diferencia entre las salidas predichas por el modelo y las salidas reales. La elección del algoritmo de entrenamiento determina la eficiencia del proceso de optimización, la velocidad de convergencia y la capacidad del modelo para alcanzar una solución adecuada. Entre los algoritmos de entrenamiento más utilizados se encuentran el gradiente descendente, Levenberg-Marquardt, y Adam [65].

3.2.4. Selección de modelo

La Figura 2 muestra una clasificación general de los métodos de estimación de SoH existentes, agrupándolos en dos grandes categorías: métodos experimentales y métodos adaptativos. Cada uno de estos se subdivide según el tipo de pérdida que evalúan (capacidad o potencia) y los métodos específicos que emplean.

Complementariamente, la Tabla 1 sintetiza diversas metodologías utilizadas para la estimación del SoH, clasificadas en métodos basados en voltaje (OCV impedancia, parámetros electroquímicos y datos) y otras señales empleadas como temperatura,

ultrasonido y fuerza. Se presentan ejemplos concretos, así como sus ventajas y desventajas. Esta tabla resalta las limitaciones de los métodos tradicionales frente a condiciones variables o costosas de medición, y subraya el potencial de los enfoques basados en voltaje.

Para validar lo expuesto anteriormente, se realizó un análisis comparativo de distintos modelos de redes neuronales y algunos modelos basados en aprendizaje automático para la estimación del SoH, utilizando los mismos datos de entrada de baterías y aplicando técnicas de suavizado exponencial. Los modelos evaluados con redes neuronales incluyeron ANN, NN, CNN, LSTM y GRU, así como un modelo tradicional de aprendizaje automático (o ML por sus siglas en inglés: Machine Learning) y un modelo general de aprendizaje profundo (o DL por sus siglas en inglés: Deep Learning). En la Tabla 4 se presentan los resultados de esta comparación.

Tabla 4. Resultados de prueba de los modelos de estimación de SoH.

Modelo	MAE (%)	MAPE (%)	MSE (%)	RMSE (%)	R ²	Tiempo de operación (s)	Épocas	Capas ocultas
ANN	0.1004	0.5231	0.0294	0.1714	1.0000	9	1000	1 capa oculta con 10 neuronas
LSTM	0.1912	1.1820	0.0784	0.2800	0.9999	84	200	100 capas
GRU	0.3050	1.7782	0.1725	0.4153	0.9998	117	200	100 capas
ML	0.5100	2.0167	0.3543	0.5953	0.9996	3	No aplica	No aplica
NN	0.5299	2.1704	0.5160	0.7183	0.9994	144	200	2 capas ocultas con 64 y 32 neuronas
DL	0.9588	4.9186	1.6499	1.2845	0.9980	85	200	2 capas ocultas con 64 y 32 neuronas
CNN	1.6303	5.2418	5.1592	2.2714	0.9959	72	200	2 capas convolucionales con 16 y 8 filtros y 1 capa densa de 1 neurona

Los resultados descritos en la Tabla 4 muestran que la ANN y LSTM con suavizado exponencial tuvieron los mejores desempeños. En particular, ANN logró un MAE de 0.1004 %, un coeficiente de determinación R² de 1.0 y el menor MSE, además de requerir

un tiempo de operación bajo. Este modelo también se destacó por su simplicidad y eficiencia, utilizando una sola capa oculta de 10 neuronas y 1000 épocas de entrenamiento.

Los modelos LSTM, GRU, ML, DL y CNN, que son más complejos y adecuados para la predicción de series temporales y extracción de características secuenciales, obtuvieron resultados menos favorables. En particular, las CNN mostraron los mayores errores, con un MAE alrededor de 1.63 % y R^2 cercano a 0.9955.

Considerando la naturaleza no lineal y multivariada de los datos y la precisión, el costo computacional, simplicidad y rendimiento del algoritmo, este trabajo adopta como modelo principal la ANN, ya que permite identificar relaciones no lineales entre variables operativas y la degradación de la batería y utilizando los demás modelos como referencia para la comparación del desempeño.

3.2.5. Criterios de suavizado

Para el presente diseño, se adoptaron criterios específicos para la selección y evaluación de los métodos de suavizado aplicados a las señales estimadas, con el fin de mejorar la calidad y estabilidad de la señal final.

En primer lugar, se detectó la presencia de ruido y oscilaciones abruptas en las señales de SoH calculadas, lo cual podía afectar la interpretación del SoH. Por ello, se eligieron métodos de suavizado que pudieran mitigar estas fluctuaciones sin distorsionar el comportamiento real de degradación. Además, se valoró la estabilidad temporal de la señal suavizada, buscando que esta reflejara una evolución progresiva y coherente con la degradación física de la batería, evitando sobreajustes o inconsistencias.

Otro criterio fundamental fue la baja complejidad computacional, dado que la implementación está orientada a sistemas embebidos con recursos limitados, donde se requiere eficiencia para procesar datos en tiempo real sin comprometer la precisión.

Con base en estos criterios, se compararon dos métodos de suavizado ampliamente usados en estimación del SoH:

3.2.5.1. Filtro exponencial simple

El suavizado exponencial simple es útil cuando los datos no presentan tendencias ni estacionalidades significativas. Para series temporales con tendencias o estacionalidades, se recomiendan métodos más avanzados como el suavizado exponencial doble o triple [66].

El método de suavizado exponencial simple se basa en la siguiente fórmula:

$$\hat{y}_{t+1} = \alpha y_t + (1 - \alpha) \hat{y}_t \quad (10)$$

donde:

- \hat{y}_{t+1} es el pronóstico para el tiempo $t + 1$.
- y_t es el valor observado en el tiempo t .
- \hat{y}_t es el pronóstico para el tiempo t .
- α es el parámetro de suavizado, con $0 < \alpha < 1$

Este método aplica un promedio ponderado recursivo, donde el parámetro α controla la suavidad. Presenta ventajas de simplicidad, rapidez y buena capacidad para eliminar ruido, favoreciendo la detección de tendencias claras sin introducir retrasos significativos en la señal [66].

3.2.5.2. Filtro de Kalman de primer orden

Este filtro de Kalman (o KF por sus siglas en inglés: Kalman Filter) permite reducir el ruido mediante la combinación de las mediciones observadas y su estimación previa, utilizando dos parámetros (Q y R): “Q” que representa la varianza del proceso. Un valor más alto de Q asume que el estado real puede cambiar rápidamente. Por otro lado, “R” corresponde a la varianza de la medición y refleja el nivel de ruido o incertidumbre en las observaciones [26]. Estos parámetros se ajustaron empíricamente a los valores $Q=1$ y $R=0.1$, permitiendo obtener una señal de SoH suavizada y representativa del comportamiento real de degradación de la batería.

El proceso de filtrado se implementa mediante las siguientes ecuaciones [68], [69], [67]:

- **Predicción del estado:**

$$\hat{x}_{k|k-1} = \hat{x}_{k-1} \quad (11)$$

Esta ecuación realiza una predicción del estado actual $\hat{x}_{k|k-1}$, que representa una estimación anticipada del SoH (estimada a “priori”) antes de considerar la nueva medición disponible. Esta estimación se basa únicamente en el valor estimado del estado anterior \hat{x}_{k-1} , asumiendo que el sistema evoluciona de forma constante entre un instante y el siguiente.

- **Predicción de la varianza del error:**

$$P_{k|k-1} = P_{k-1} + Q \quad (12)$$

Donde $P_{\bar{k}}$ es la varianza del error en la predicción del estado a “priori”, P_{k-1} es la varianza del error del paso anterior.

- **Cálculo de la ganancia de Kalman:**

$$K_k = \frac{P_{\bar{k}}}{P_{\bar{k}} + R} \quad (13)$$

Donde K_k es la ganancia de Kalman, $P_{\bar{k}}$ es la varianza del error en la predicción del estado.

- **Corrección del estado con la observación:**

$$\hat{x}_k = \hat{x}_{\bar{k}} + K_k(z_k - \hat{x}_{\bar{k}}) \quad (14)$$

Donde \hat{x}_k es la estimación corregida del estado (SoH filtrado), z_k es la observación medida del SoH, $\hat{x}_{\bar{k}}$ es la predicción previa, y K_k es la ganancia de Kalman. Esta ecuación ajusta la predicción según la diferencia entre lo medido y lo predicho, ponderada por la ganancia.

- **Corrección de la varianza del error:**

$$P_k = (1 - K_k)P_{\bar{k}} \quad (15)$$

Donde P_k es la varianza del error corregida para el estado actualizado, K_k es la ganancia de Kalman, y $P_{\bar{k}}$ es la varianza del error previa. Esta ecuación refleja la reducción en la incertidumbre luego de incorporar la medición.

El KF ha sido usado en la estimación del SoH y del SoC de LIBs, debido a su capacidad para ajustar las estimaciones del sistema, incluso cuando las condiciones de operación presentan incertidumbre o interrupciones en los datos. Además, permite combinar predicciones de modelos y observaciones ruidosas de forma óptima estadísticamente. Este filtro permite mejorar significativamente la estabilidad y confiabilidad de la señal estimada, especialmente en condiciones operativas donde las mediciones pueden ser intermitentes o afectadas por ruido [68]. El KF se destaca por su rendimiento del filtrado del ruido y velocidad de convergencia. En comparación con variantes más avanzadas como el filtro de Kalman extendido (EKF), el filtro de Kalman cúbico (CKF) y el filtro de Kalman no lineal (UKF), el KF estándar presenta una menor precisión en ciertos escenarios no lineales; sin embargo, también ofrece una menor complejidad computacional, lo que lo convierte en una alternativa adecuada para aplicaciones embebidas o de tiempo real [69].

Tabla 5. Resultados del desempeño de los modelos de estimación de SoH usando el suavizado con filtro exponencial vs. filtro de Kalman.

Modelo	Método de Suavizado	MAE (%)	MAPE (%)	MSE (%)	RMSE (%)	R ²	Tiempo de operación (s)	Épocas	Capas ocultas
ANN	Exponencial	0.1004	0.5231	0.0294	0.1714	1.0000	9	1000	1 capa oculta con 10 neuronas
	Kalman	0.1690	2.9008	0.0514	0.2266	0.9999	6		
LSTM	Exponencial	0.1912	1.1820	0.0784	0.2800	0.9999	84	200	100 capas
	Kalman	0.2426	3.2794	0.1328	0.3645	0.9998	105		
GRU	Exponencial	0.3050	1.7782	0.1725	0.4153	0.9998	117	200	100 capas
	Kalman	0.2838	5.2659	0.1730	0.4159	0.9998	133		
ML	Exponencial	0.5100	2.0167	0.3543	0.5953	0.9996	3	No aplica	No aplica
	Kalman	0.6274	3.9206	0.6752	0.8217	0.9992	5		
NN	Exponencial	0.5299	2.1704	0.5160	0.7183	0.9994	144	200	2 capas ocultas con 64 y 32 neuronas
	Kalman	0.6329	3.4854	0.6494	0.8058	0.9992	141		
DL	Exponencial	0.9588	4.9186	1.6499	1.2845	0.9980	85	200	2 capas ocultas con 64 y 32 neuronas
	Kalman	0.8059	6.4843	1.1273	1.0617	0.9986	152		
CNN	Exponencial	1.6303	5.2418	5.1592	2.2714	0.9959	72	200	2 capas convolucionales con 16 y 8 filtros y 1 capa densa de 1 neurona
	Kalman	1.6431	5.7154	5.3431	2.3115	0.9955	90		

De acuerdo con los resultados de la Tabla 5, el suavizado exponencial simple mostró un mejor desempeño general en cuanto a métricas de error para la mayoría de los modelos, evidenciando menores valores de MAE, MAPE, MSE y RMSE, así como coeficientes de determinación R² muy cercanos a la unidad. Por ejemplo, la ANN con suavizado exponencial alcanzó un MAE de 0.1004 % y R² de 1.0, mientras que con filtro de Kalman presentó un aumento significativo del MAE a 0.1690 % y una ligera reducción del R² a 0.9999.

En la Figura 10 se presenta una gráfica comparativa del MAE de los distintos modelos evaluados, utilizando los métodos de suavizado exponencial y Kalman.




Figura 10. Gráfica comparativa del MAE por modelo, utilizando los métodos de suavizado exponencial y Kalman.

Se observa que el método de suavizado exponencial presenta un menor MAE en cinco de los siete modelos evaluados (ANN, LSTM, ML, NN y CNN). Esto indica una estimación más precisa del SoH, alineada con los criterios de suavizado planteados. Por su parte, aunque el filtro de Kalman ofrece ventajas teóricas para la combinación de mediciones y predicciones, en este caso presentó mayores errores. Con base en estos resultados, se selecciona el suavizado exponencial como método principal para la estimación del SoH en el presente proyecto.

3.3. IMPLEMENTACIÓN

En esta sección, se presenta el desarrollo e implementación del modelo, desde la adquisición y preprocesamiento de los datos hasta el diseño, entrenamiento y evaluación del algoritmo propuesto.

3.3.1. Arquitectura del modelo predictivo

La arquitectura del modelo predictivo implementado para la estimación del SoH se basa en un flujo de procesamiento secuencial, desde la adquisición de datos hasta la

evaluación del rendimiento. En la Figura 11 se detalla cada etapa del proceso siguiendo el diagrama de flujo presentado.

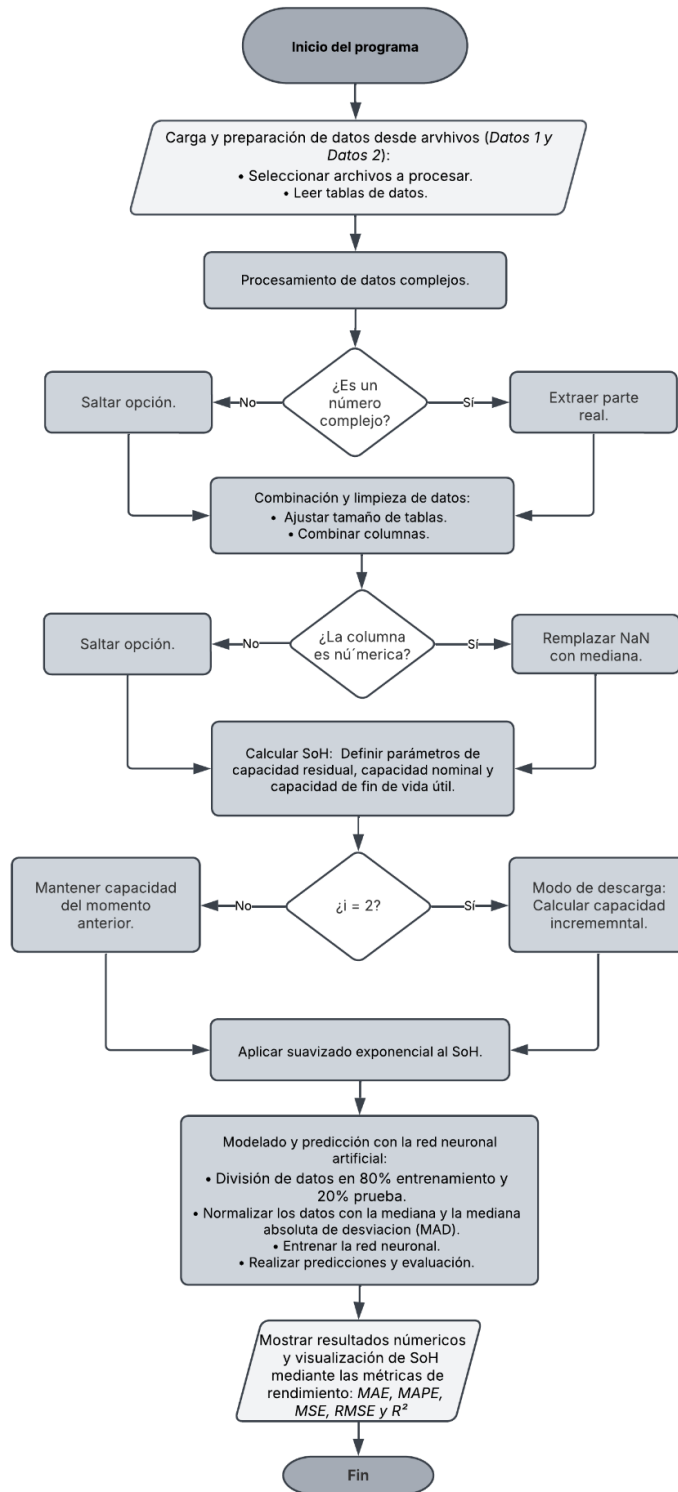


Figura 11. Diagrama de flujo del modelo.

A partir de este diagrama de flujo se establece la metodología secuencial para el desarrollo del algoritmo, la cual se compone de los siguientes pasos:

3.3.1.1. Adquisición y procesamiento de datos

El sistema parte del procesamiento de archivos experimentales proporcionados por el centro (PCoE) de la NASA, los cuales contienen registros de celdas de ion de litio bajo diversas condiciones de operación. En este proyecto, se asume que el entorno de operación final del algoritmo será una microrred eléctrica. Por tanto, todas las decisiones de diseño se orientan a garantizar su correcto funcionamiento para datos obtenidos en este tipo de sistema [70].

Los datos de entrada utilizados para el entrenamiento y prueba del algoritmo contienen información de un conjunto de datos de distintas baterías de ion de litio que fueron sometidas a ciclos de carga, descarga y medición de EIS a temperatura ambiente. Las descargas se llevaron a cabo a diferentes niveles de corriente hasta alcanzar umbrales de voltaje predeterminados, algunos de los cuales se situaron por debajo del nivel recomendado por el fabricante (2,7 V) para inducir artificialmente mecanismos de envejecimiento acelerado, como el daño por descarga profunda. El procedimiento de prueba incluyó ciclos repetidos de carga y descarga hasta que la batería alcanzó su criterio de EOL, definido como una pérdida del 30 % de su capacidad nominal (de 2 Ah a 1,4 Ah) [50].

Para este trabajo, se utilizaron 1.050 archivos en formato CSV de dicho conjunto de datos, los cuales fueron divididos en dos grupos que contienen parámetros como: el primer conjunto de datos (Datos 1) se encuentra la corriente de salida medida de la batería (Current_measured), el voltaje del terminal medido de la batería (Voltage_measured) y la temperatura de operación de la batería (Temperature_measured) que corresponde a la temperatura ambiente durante los ciclos de carga y descarga de la batería y en el segundo conjunto de datos (Datos 2) la corriente de detección del sistema (Sense_current), la corriente suministrada por la batería (Battery_current), así como la impedancia interna de la celda calculada a partir de datos brutos (Battery_impedance), esta información se puede observar en el diagrama de flujo del modelo de la Figura 11 [50].

Estos conjuntos de datos se integran en una única tabla denominada "dataTableCombined". Durante este proceso, los valores faltantes se rellenan utilizando la media de cada variable correspondiente. Esta estrategia de imputación permite mantener la integridad del conjunto de datos sin introducir distorsiones que afecten el desempeño del modelo.

Posteriormente, se seleccionaron las primeras 600 muestras de la tabla combinada para ser utilizadas en el entrenamiento y prueba del modelo. Cabe señalar que este valor

puede modificarse según la cantidad de datos que se desee analizar, lo que otorga flexibilidad al proceso de entrenamiento del algoritmo.

3.3.1.2. Estimación y suavizado de SoH

La estimación del SoH se realiza a partir de la capacidad actual estimada de la batería ($C_{current}$), la cual se obtiene integrando la corriente durante el proceso de carga y descarga, menos la CEOL como umbral de fin de vida útil una capacidad de 1.4 Ah (70 % de la capacidad nominal). Este resultado se compara con la capacidad nominal de la celda (2 Ah) que es representada en la ecuación (2) y (16) como $C_{nominal}$ menos la CEOL nuevamente.

La formulación matemática utilizada es:

$$SoH = \frac{C_{current} - CEOL}{C_{nominal} - CEOL} * 100 \% \quad (16)$$

Este procedimiento genera una señal de SoH con fluctuaciones e irregularidades derivadas del entorno experimental.

Para mejorar la estabilidad y adecuación de esta señal durante el entrenamiento, se aplicó el filtro exponencial simple seleccionado en la sección 3.2.5. Este filtro utiliza un coeficiente de ponderación $\alpha=0.05$, lo que significa que cada nuevo valor suavizado se calcula tomando un porcentaje del 5 % del valor actual y un porcentaje del 95 % del valor anterior, dando más importancia al historial que al nuevo dato, lo que permite atenuar de manera efectiva las oscilaciones abruptas presentes en los datos sin provocar pérdida de la capacidad del sistema. Este método fue aplicado directamente sobre los valores calculados del SoH, generando una serie suavizada que conserva la tendencia general de degradación de la celda y reduce el impacto del ruido inherente a las mediciones.

3.3.1.3. Proceso de entrenamiento

En el entrenamiento del modelo se empleó el algoritmo “trainlm” de Levenberg-Marquardt, apropiado para tareas de regresión con conjuntos de datos de tamaño moderado [71]. Los datos fueron divididos en 80 % para entrenamiento, 20 % para prueba mediante la función `cvpartition` con la opción `HoldOut`. El entrenamiento se detiene automáticamente al alcanzar un número máximo de 1000 épocas. Si después de 1000 épocas la red no ha alcanzado un buen rendimiento, el entrenamiento se detiene automáticamente, o tras seis fallos consecutivos en la validación debido a que es un valor por defecto del algoritmo.

3.3.1.4. Normalización de características

En este caso se implementó una técnica de normalización basada en la mediana y la desviación absoluta mediana (o MAD por sus siglas en inglés: Median Absolute Deviation). Esta técnica permite mitigar la presencia de valores atípicos o ruido en los datos, ya que es menos sensible a estos valores que las técnicas tradicionales basadas en la media y la desviación estándar.

La normalización se realizó según la siguiente expresión [72]:

$$X_{\text{norm}} = \frac{X - \text{mediana}(X_{\text{train}})}{1.4826 * \text{MAD}(X_{\text{train}})} \quad (17)$$

Donde el factor 1.4826 permite escalar la MAD para que sea comparable con la desviación estándar bajo una distribución normal [73].

Este procedimiento se aplicó tanto a los datos de entrenamiento como de prueba, utilizando la mediana y MAD calculadas exclusivamente a partir del conjunto de entrenamiento, con el fin de evitar el sesgo por fuga de datos.

3.3.1.5. Creación y configuración de la red neuronal

La red neuronal utilizada en este proyecto adopta una arquitectura feedforward de tipo supervisado, como se ilustra en la Figura 12, la cual representa gráficamente el flujo de datos desde las variables de entrada hasta la predicción del SoH. Esta red está compuesta por tres capas principales: una capa de entrada (Input Layer), una capa oculta (Hidden Layer) y una capa de salida (Output Layer) [74].

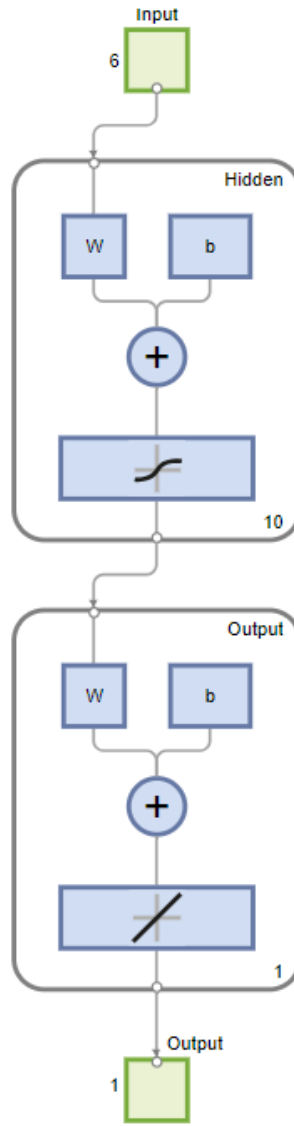


Figura 12. Diagrama de la red neuronal feedforward [74].

La capa de entrada representada en la imagen como “Input” está constituida por seis neuronas, cada una correspondiente a una característica clave extraída del sistema de batería: corriente medida, voltaje de terminal, temperatura, impedancia interna, corriente medida y corriente suministrada.

Estas entradas se conectan a cada una de las neuronas en la capa oculta “Hidden”, que está compuesta por 10 neuronas. Cada conexión entre una neurona de entrada y una de la capa oculta posee un peso sináptico “W”, el cual representa la importancia o influencia de esa entrada específica sobre la neurona receptora. Además, cada neurona de la capa oculta incorpora un sesgo representado como “b”. Este sesgo permite ajustar la activación de la neurona, desplazando la función de activación para mejorar la flexibilidad del modelo y su capacidad de ajuste a relaciones no lineales. El resultado se pasa a

través de una función de activación sigmoide. Esta función es una curva en forma de S que transforma los valores de entrada en un rango entre 0 y 1, lo cual permite introducir no linealidad en la red. La sigmoide también facilita que los valores de salida se mantengan acotados, contribuyendo a la estabilidad del entrenamiento [74].

Posteriormente, las salidas de la capa oculta se transmiten a una única neurona de salida con activación lineal, que entrega el valor estimado del SoH para cada instante de análisis. Este valor representa la salud relativa de la batería en un rango porcentual entre el 100 % (condición nueva) y el 0 % (fin de vida útil).

En la Figura 13 se observa el resultado de entrenamiento de la red neuronal.

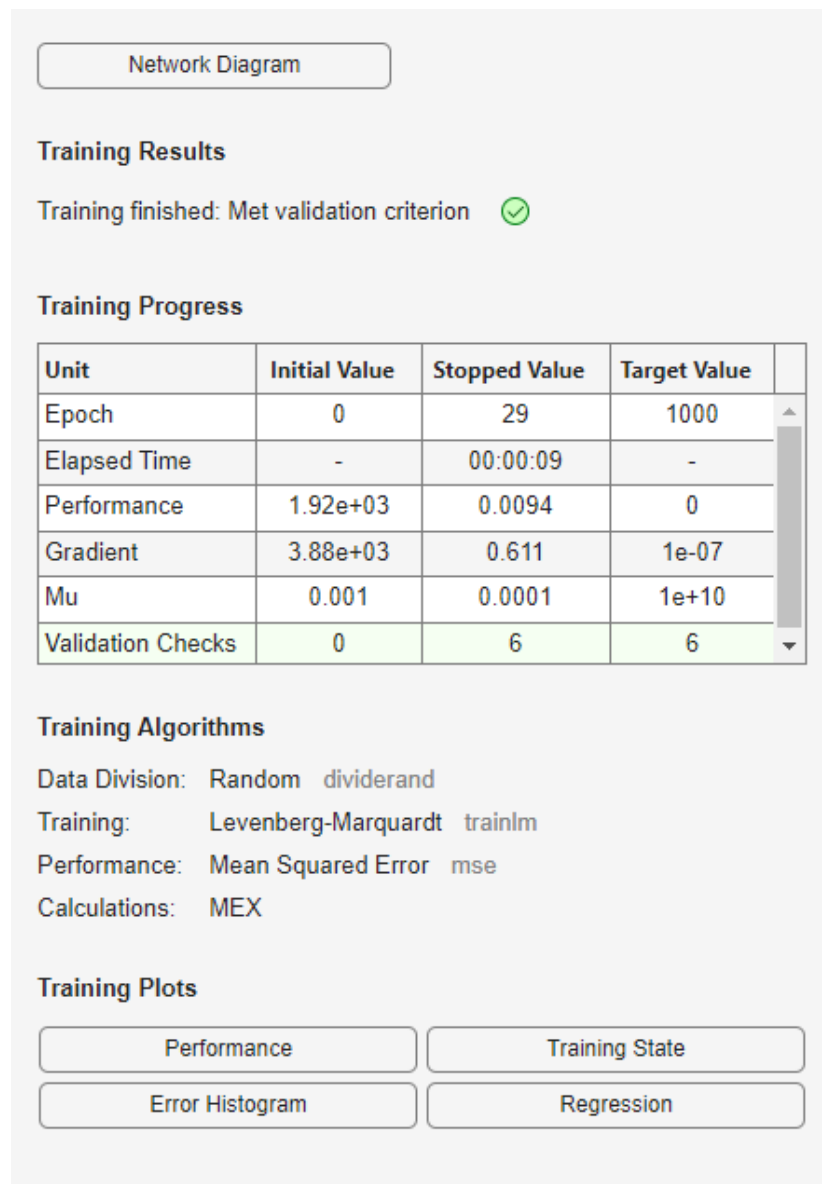


Figura 13. Resultados de entrenamiento de la red neuronal.

El entrenamiento de esta red se realizó utilizando los conjuntos de entrenamiento, configurando el número de épocas en 1000, lo que permite mejorar la precisión del modelo, incluso en escenarios donde se empleen conjuntos de datos con un mayor rango o mayor complejidad. El entrenamiento de la red neuronal finalizó en la época 29 tras cumplir el criterio de validación, evidenciando un bajo costo computacional. Se realizaron 6 validaciones antes de detener el entrenamiento, con un tiempo de operación de 9 segundos. Cabe destacar que este tiempo puede variar dependiendo de las características del equipo utilizado; en este caso, se empleó un portátil con procesador Intel Core i3 de séptima generación, 8 GB de memoria RAM y disco de estado sólido (SSD) de 500 GB.

3.3.1.6. Evaluación del modelo

El modelo fue evaluado mediante métricas como MAE, MSE, RMSE, MAPE y R^2 (estas métricas se pueden observar en las ecuaciones (5), (6), (7), (8) y (9) alcanzando un R^2 superior a 0.99 y errores porcentuales menores al 1 %, lo que evidencia su precisión.

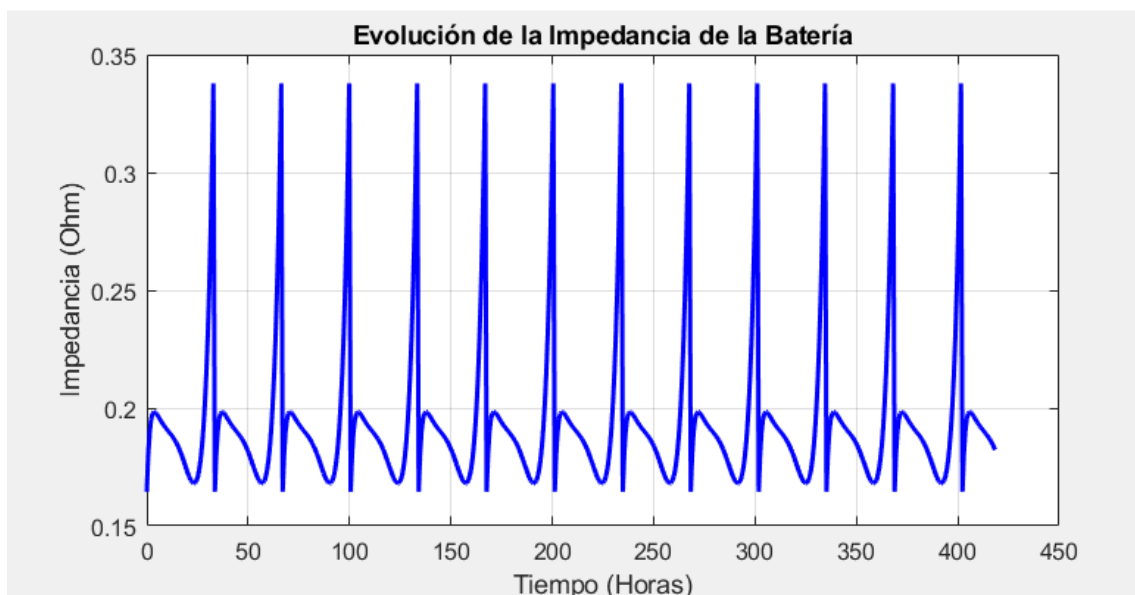


Figura 14. Gráfica de la evolución de la impedancia de la batería.

La Figura 14 se muestra la evolución de la impedancia interna de la batería en función del tiempo, evidenciando un patrón cíclico con picos periódicos que están relacionados con los ciclos de carga y descarga. La tendencia general creciente en los valores mínimos de impedancia indica un deterioro progresivo de la batería y la pérdida de capacidad reflejada en el SoH.




Figura 15. Gráfica de SoH real vs predicho.

En la Figura 15 se observa la evolución del estado de salud (SoH) de la batería a lo largo del tiempo, donde la línea roja representa el valor real del SoH suavizado mediante el filtro exponencial, mientras que la línea azul segmentada corresponde al valor predicho por el modelo basado en red neuronal para visualizar la precisión del modelo.

Ambas curvas presentan un comportamiento decreciente desde un valor inicial cercano al 100 % hasta valores cercanos al 0 %, lo que refleja la degradación progresiva de la batería. La alta coincidencia entre las dos curvas indica un excelente ajuste entre los valores reales y los predichos, validando la precisión del modelo propuesto.

3.4. PRUEBAS DE FUNCIONAMIENTO Y DESEMPEÑO

Para las pruebas de funcionamiento del modelo, se desarrollaron dos tipos de pruebas: una evaluación del desempeño utilizando conjuntos de datos representativos de distintos niveles de envejecimiento de una batería, y una prueba de ajuste de hiperparámetros, en la que se modificaron la cantidad de capas ocultas y las épocas de entrenamiento para analizar su impacto en la precisión del modelo.

3.4.1. Evaluación del desempeño del modelo en distintos escenarios para analizar la degradación de distintas baterías

Para evaluar el desempeño del modelo, se diseñaron tres escenarios de prueba utilizando conjuntos de datos correspondientes a diferentes ciclos y condiciones de operación de la batería. Cada conjunto de datos y/o cada archivo representa un ciclo completo de vida útil de una batería distinta en cada caso y cada uno consta de 600

ciclos de carga/descarga, teniendo en cuenta que en todos los casos se tenía una temperatura fluctuante de 24°C a 28°C o temperatura ambiente. Los archivos fueron analizados en orden secuencial a su proceso de adquisición. Esto permitió observar el comportamiento del modelo a medida que la batería envejecía progresivamente con el uso. En la Tabla 6, se presentan los resultados cuantitativos de las métricas de error y ajuste para cada uno de los tres escenarios:

Tabla 6. Resultados de evaluación del desempeño del modelo de distintos ciclos completos de vida útil.

Datos	Tiempo en que SoH llega a 1 (h)	MAE (%)	MAPE (%)	MSE (%)	RMSE (%)	R ²
Datos 1	463.55	0.0844	0.5348	0.0108	0.1039	1.0000
Datos 2	439.29	0.1190	0.6462	0.0261	0.1614	1.0000
Datos 3	495.95	0.1802	4.6937	0.0642	0.2533	0.9999

3.4.1.1. Primer escenario de prueba

El conjunto de datos inicial presentó un MAE de 0.0844 %, el valor más bajo entre las pruebas, y un tiempo de 463.55 horas hasta alcanzar un SoH cercano a 1. Este tiempo se toma como referencia porque corresponde al punto en el que el SoH comienza a disminuir de forma más lenta, lo que indica una desaceleración natural en el proceso de degradación. El bajo margen de error puede atribuirse a que en este caso la batería conserva un comportamiento más estable y predecible, lo que facilita el aprendizaje del modelo. Además, el coeficiente de determinación $R^2 = 1.0$ confirma que el modelo fue capaz de capturar con precisión la tendencia general del deterioro desde esta fase temprana del ciclo de vida de la batería. La Figura 16 presenta la comparación del SoH real vs predicho del primer escenario de prueba.




Figura 16. Comparación de SoH real vs predicho del primer escenario de prueba.

3.4.1.2. Segundo escenario de prueba

En el segundo escenario de prueba, la precisión del modelo es mejor, reflejándose en un MAE de 0.1190 % ligeramente superior al primer escenario. El modelo mantuvo un R^2 de 1.0, demostrando nuevamente su capacidad de generalización. El tiempo hasta que el SoH fue cercano a 1 fue de 439.29 horas, reflejando una degradación acumulativa intermedia. Este escenario representa una etapa donde comienzan a evidenciarse efectos de envejecimiento más marcados, lo que pone a prueba la eficiencia del algoritmo. A pesar de ello, el comportamiento decreciente del SoH fue adecuadamente replicado. Los resultados de este escenario se pueden observar en la Figura 17.

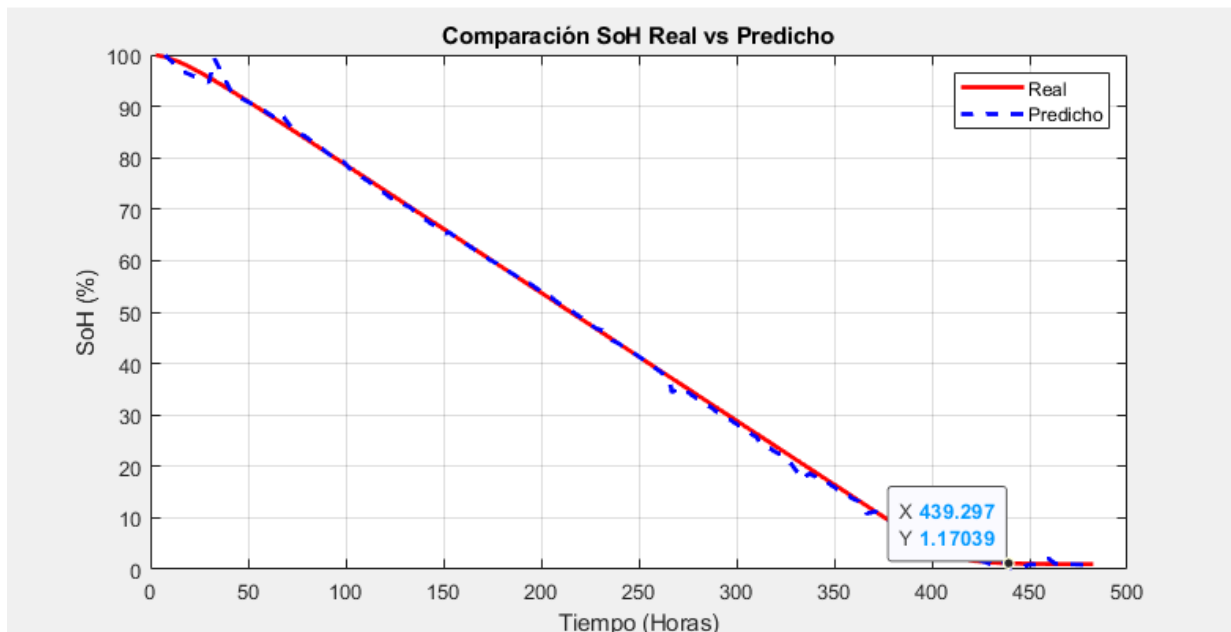


Figura 17. Comparación de SoH real vs predicho del segundo escenario de prueba.

En esta etapa, se observa que, al igual que en el caso anterior, el SoH inicia en el 100 % de su capacidad nominal y desciende progresivamente hasta alcanzar el 1 %. Este comportamiento se debe a que cada archivo analizado representa un ciclo completo de vida útil de la batería (600 ciclos de carga/descarga), desde su estado inicial hasta una condición de deterioro severo. Esta situación sucede en los tres escenarios.

3.4.1.3. Tercer escenario de prueba

El tercer conjunto de datos presentó el MAE más alto (0.1802 %) y el MAPE más elevado (4.6937 %), lo que se debe a que el modelo presentó mayores dificultades para predecir con precisión en los estados finales de carga, especialmente cuando el SoH < 10 %. Sin embargo, el modelo logró mantener un excelente R^2 de 0.9999, lo cual sigue validando su capacidad predictiva. El tiempo estimado para alcanzar SoH = 1 fue el mayor entre los tres escenarios: 495.95 horas, lo que puede deberse a una batería que tuvo un envejecimiento más gradual. Estos resultados se pueden observar en la Figura 18.

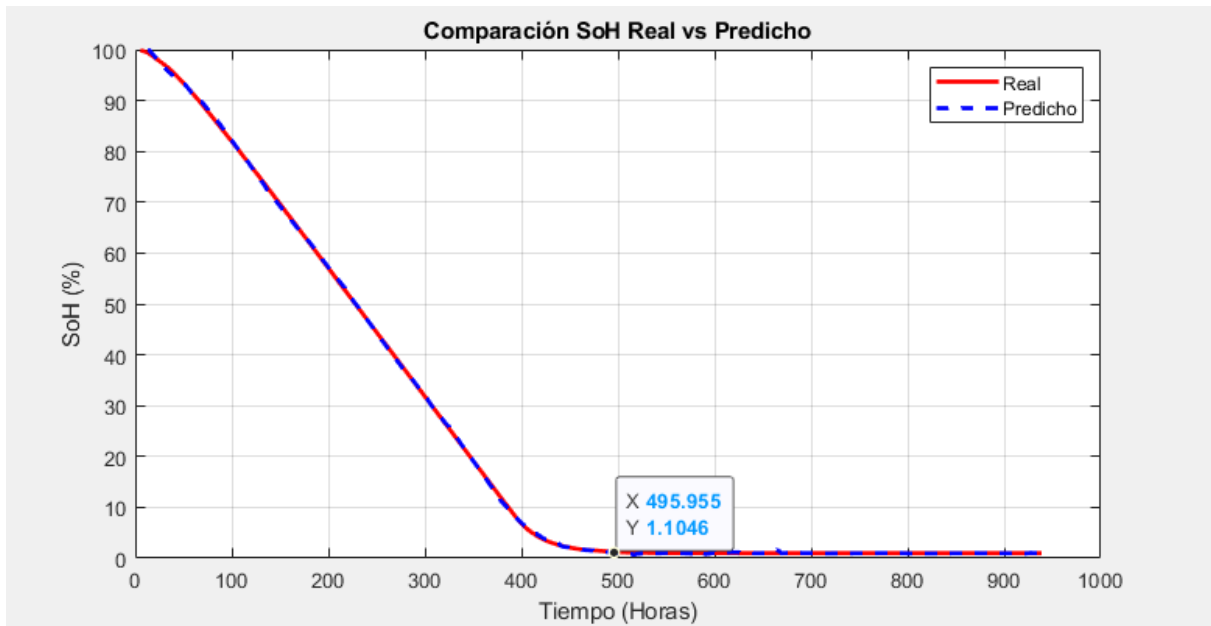


Figura 18. Comparación de SoH real vs predicho del tercer escenario de prueba.

A partir de los tres escenarios evaluados, se evidencia una tendencia consistente: a medida que la batería acumula ciclos de carga y descarga, su capacidad de retención se ve progresivamente afectada, lo que se refleja en una disminución del tiempo necesario para que el SoH alcance un valor cercano a 1. Las gráficas muestran una degradación continua desde valores iniciales cercanos al 100 %, representando un estado óptimo, hasta niveles muy bajos de SoH, donde la degradación tiende a desacelerarse. Esta evolución confirma el carácter acumulativo del deterioro electroquímico, y valida la precisión del modelo propuesto, que obtuvo MAE inferiores al 0.2 % y coeficientes de determinación (R^2) superiores a 0.999 en todos los casos.

3.4.2. Prueba de ajuste de hiperparámetros

En esta prueba se evaluó el impacto de tres configuraciones diferentes de hiperparámetros sobre el desempeño del modelo. Se ajustaron principalmente dos variables manteniendo constantes los demás parámetros: el número de capas ocultas, las cuales se incrementaron progresivamente en complejidad y la cantidad de épocas de entrenamiento, ajustadas en función a la cantidad de capas ocultas.

Se probaron tres escenarios principales: el primer escenario con una red básica con una sola capa oculta de 10 neuronas y 2000 épocas, el segundo con una red intermedia con dos capas ocultas de 15 y 10 neuronas, 3000 épocas y el tercero una red avanzada con tres capas ocultas de 50, 30 y 10 neuronas, 5000 épocas.

A modo de referencia, también se presenta el resultado del modelo base original (épocas = 1000), con la misma arquitectura del escenario 1. La Tabla 7 resume los principales indicadores de rendimiento obtenidos en cada configuración:

Tabla 7. Resultados de la prueba de ajuste de hiperparámetros.

Escenario	MAE (%)	MAPE (%)	MSE (%)	RMSE (%)	R ²	Tiempo de operación (s)	Épocas	Capas ocultas
Base	0.1004	0.5231	0.0294	0.1714	1.0000	9	1000	10
1	0.1004	0.5231	0.0294	0.1714	1.0000	10	2000	10
2	1.5703	6.1506	6.4168	2.5331	0.9923	12	3000	2 capas ocultas con 15 y 10 neuronas
3	0.7440	1.9428	0.7186	0.8477	0.9991	16	5000	3 capas ocultas con 50, 30 y 10 neuronas

El escenario 1 obtuvo exactamente los mismos resultados que el modelo base, a pesar de duplicar el número de épocas (2000 frente a 1000). Esto se explica porque el algoritmo de entrenamiento 'trainlm' utiliza un criterio de convergencia basado en la reducción del gradiente o el error, junto con mecanismos internos de "early stopping" cuando no se detectan mejoras significativas. En este caso, la red alcanza una predicción en muy pocas épocas, por lo que ampliar la cantidad de iteraciones no genera ningún cambio en la calidad del modelo. El criterio de parada basado en validación (6 fallos consecutivos sin mejora) garantiza que el modelo no continúe entrenando innecesariamente una vez encontrado el mínimo óptimo.

Por otro lado, los escenarios 2 y 3, que incrementaron progresivamente la complejidad estructural de la red mediante el uso de múltiples capas ocultas y neuronas adicionales, no mejoraron los resultados. En particular, el escenario 2 presentó un deterioro significativo en todas las métricas, indicando una posible inestabilidad durante el entrenamiento y sobreajuste o "overfitting" debido a la incorporación de parámetros adicionales como la cantidad de capas ocultas, neuronas y épocas. Aunque el escenario 3 mostró un rendimiento aceptable, su error fue considerablemente mayor que el de la red simple.

Este comportamiento refleja que, en este caso, un modelo más robusto no implica una mejora en la precisión. Por el contrario, el aumento innecesario de la complejidad puede

introducir ruido, dificultar la convergencia y afectar negativamente la capacidad del modelo para generalizar datos.

4. ANÁLISIS DE RESULTADOS Y DISCUSIÓN

Este análisis integra los resultados teóricos, estratégicos y experimentales para validar el algoritmo. A través de una metodología que combina revisión bibliográfica, selección de técnicas y pruebas experimentales, se demuestra cómo el modelo propuesto de una red neuronal artificial de 1 capa oculta y 10 neuronas logra alta precisión (MAE: 0.1004 %, R^2 : 1.0) y un tiempo de operación de 9 segundos, superando estándares de la literatura y adaptándose a distintos ciclos de vida útil de baterías.

4.1. ANÁLISIS DEL MATERIAL BIBLIOGRÁFICO

La literatura confirma la superioridad de los métodos basados en datos para estimar el SoH, particularmente en entornos dinámicos. Mientras los modelos electroquímicos tradicionales requieren parámetros específicos y presentan una alta carga computacional, las redes neuronales, especialmente ANN, LSTM y GRU han demostrado mayor precisión y adaptabilidad con errores inferiores a 2 % en RMSE [28], [33]. Estos resultados coinciden con los obtenidos, que se pueden observar en la Tabla 5 donde la ANN implementada alcanzó un RMSE de 0.1714 %.

Además, se establece la importancia del preprocesamiento de datos mediante técnicas como el suavizado exponencial, que mostró ventajas sobre el filtro de Kalman, siendo más sencillo de implementar y menos sensible a ajustes de parámetros. Las métricas de evaluación empleadas (MAE < 5 %, RMSE < 2 % y R^2 > 0.98) siguen los estándares establecidos en la literatura [6].

Por otro lado, [30], [31] define que las métricas de evaluación mencionadas anteriormente son aceptables para aplicaciones en BMS.

El MAE es útil para evaluar errores en condiciones operativas extremas como SoH bajos, donde otras métricas como el MAPE pueden ser sensibles a valores cercanos a cero [43]. Los resultados obtenidos (MAE: 0.1004 %, RMSE: 0.1714 % y R^2 : 1.0) superan estos estándares, validando la precisión, sensibilidad a errores y calidad del ajuste del modelo propuesto.

4.2. ESTRATEGIAS DE SELECCIÓN

La selección de la arquitectura del modelo y su configuración se basó en un análisis comparativo orientado a maximizar la precisión con el menor costo computacional posible. Tras evaluar múltiples opciones como ANN, LSTM, GRU, ML, NN, DL y CNN se determinó que una red neuronal artificial (ANN) con una arquitectura simple era la alternativa más eficiente. Este diseño logró equilibrar el rendimiento del modelo con la

facilidad de entrenamiento y tiempos de ejecución reducidos. A partir de esto se demostró mediante la optimización de hiperparámetros que una configuración compuesta por una sola capa oculta con 10 neuronas generaba los mejores resultados, mientras que el aumento en la complejidad estructural del modelo (más capas y mayor número de neuronas) condujo a un sobreajuste o a una degradación del desempeño.

En cuanto a la selección de la función de activación, se optó por utilizar la sigmoide logística, que es la opción predeterminada en MATLAB® para las capas ocultas de redes feedforward. Esta selección se basó en su estabilidad numérica, su capacidad para manejar relaciones no lineales y su eficacia en problemas de regresión, como la estimación del SoH de baterías. Esta función produce salidas en el rango $[0, 1]$, lo cual es apropiado cuando se trabaja con estimaciones que representan proporciones o probabilidades, como en este caso, dado que el SoH es una magnitud expresada como una proporción o porcentaje entre 0 % y 100 %. Esta característica permite mantener los valores de activación dentro de un intervalo fijo, facilitando la estabilidad del aprendizaje [75], [76]. Además, su derivada simple permitió una retropropagación eficiente del error durante el ajuste de pesos, contribuyendo a la rápida convergencia del modelo.

Durante las pruebas comparativas también se evaluaron otras funciones de activación, como ReLU y tanh, en diferentes arquitecturas. En el caso de las redes CNN, DL y NN se utilizó ReLU, y en los modelos GRU y LSTM se empleó tanh; sin embargo, estas configuraciones no superaron el desempeño obtenido con la ANN basada en función sigmoide, que alcanzó el mejor resultado con un MAE de 0.1004 % y un R^2 de 1.0. Aunque la función tanh comparte con la sigmoide la no linealidad, su rango de salida $[-1, 1]$ puede provocar que, cuando las entradas son muy grandes o pequeñas, las salidas se acerquen a los extremos del rango descrito y las derivadas tiendan a valores muy bajos. Este fenómeno, conocido como saturación dificulta el ajuste de los pesos durante el entrenamiento o incluso puede detener el aprendizaje. Por su parte, ReLU ofrece buen rendimiento en redes profundas, pero es susceptible al problema de las “neuronas muertas” (o dead ReLUs), cuando las salidas negativas se fijan en cero y la neurona deja de actualizarse [75]. En este contexto, la función sigmoide resultó ser la más adecuada para la ANN empleada, ya que proporcionó estabilidad durante el entrenamiento, capacidad de generalización y una rápida convergencia al trabajar con datos normalizados en el rango predicho, lo cual se alinea con la salida esperada del SoH y favorece la interpretación y el ajuste del modelo. Es importante señalar que la elección óptima de la función de activación depende en gran medida de la arquitectura utilizada y de la naturaleza de los datos de entrada.

Para el entrenamiento del algoritmo, se eligió el método Levenberg-Marquardt “trainlm” debido a su eficacia con conjuntos de datos de tamaño moderado y su rápida capacidad de convergencia, logrando resultados óptimos en un promedio de 29 épocas. Para evitar

el sobreentrenamiento, se implementó un mecanismo de parada temprana “early stopping” el cual monitorea el rendimiento y detiene el proceso automáticamente tras seis iteraciones consecutivas sin mejora significativa, optimizando así tanto el tiempo de cómputo como la calidad de los resultados.

En la etapa de preprocesamiento de datos se aplicó una normalización basada en la mediana y la MAD de la ecuación (16), minimizando el impacto de valores atípicos y ruido experimental. Adicionalmente, se empleó un suavizado exponencial ($\alpha = 0.05$) que redujo las fluctuaciones en la señal de SoH sin introducir retrasos significativos. Esta técnica demostró mayor precisión que el filtro de Kalman, con un MAE de 0.1004 % frente a 0.1690 %.

4.3. VALIDACIÓN EXPERIMENTAL

En esta sección se describen los resultados de cada simulación presentada en la sección 3.4.

4.3.1. Análisis del desempeño del modelo con distintos estados de degradación de la batería

Durante las pruebas realizadas, el modelo mantuvo un desempeño consistente a lo largo de todo el ciclo de vida de tres baterías distintas, aunque con variaciones características en cada fase como se logra observar en la Figura 19, que resume la comparación del error de predicción del SoH real y predicho en los distintos escenarios evaluados.

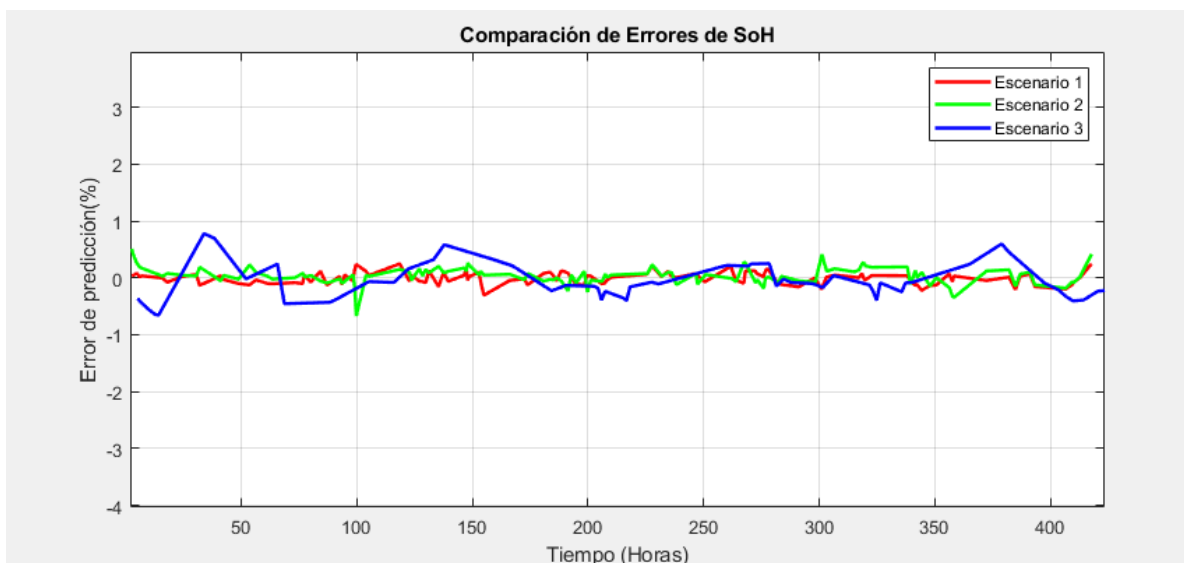


Figura 19. Comparación del desempeño del modelo en diferentes etapas del ciclo de vida de tres baterías distintas.

En el escenario 1 (Datos 1), el modelo presentó el MAE más bajo (0.0844 %) y un R^2 de 1.0, reflejando una alta precisión. En este escenario, la degradación es más lenta y estable, lo que facilita que el modelo aprenda los patrones de comportamiento con mayor exactitud. El tiempo registrado hasta que el SoH alcanzó un valor cercano a 1 fue de 463.55 horas, punto en el que la tasa de degradación comenzó a disminuir, indicando una transición hacia una etapa más avanzada del ciclo de vida.

En el escenario 2 (Datos 2), el modelo mantuvo el rendimiento, con un MAE de 0.1190 %, RMSE de 0.1614 % y un R^2 de 1.0. Aunque el error aumentó ligeramente respecto al primer escenario, el modelo siguió replicando correctamente la tendencia del SoH. El tiempo hasta $\text{SoH} \approx 1$ fue de 439.29 horas, reflejando una degradación acumulativa intermedia. En este caso los efectos del envejecimiento comienzan a ser más notorios, pero aún son predecibles.

En el Escenario 3 (Datos 3), el modelo obtuvo su mayor MAE y MAPE debido a la dificultad de estimación en los estados de SoH muy bajos, especialmente cuando el valor cae por debajo del 10 %. A pesar de esto, el modelo conservó un alto nivel de precisión general con un R^2 de 0.9999, validando su capacidad predictiva. El tiempo hasta $\text{SoH} \approx 1$ fue de 495.95 horas, indicando un proceso de envejecimiento más gradual en comparación con los otros casos.

En conjunto, los resultados obtenidos de la Tabla 6 reflejan una clara correlación entre el estado de degradación de la batería y el desempeño del modelo. A medida que las baterías envejecen, se reduce progresivamente el tiempo requerido para alcanzar un SoH bajo, lo cual es consistente con la pérdida de capacidad asociada a los mecanismos de degradación electroquímica, la pérdida de material activo y las modificaciones estructurales en los electrodos. En todos los casos el RMSE fue inferior en 0.26, demostrando estabilidad frente fluctuaciones de temperatura ambiente, es decir de 24°C a 28°C.

Asimismo, se destaca la estabilidad del modelo, que logra mantener una alta precisión pese a las variaciones en los datos de entrada, con MAE inferiores a 0.19 y coeficientes de determinación (R^2) superiores a 0.999 en todos los casos. Además, el modelo demuestra buen desempeño conforme avanza la degradación, permitiendo un monitoreo adecuado del SoH.

4.3.2. Análisis de la prueba de ajuste de hiperparámetros

A partir de los resultados de la prueba de ajuste de hiperparámetros que se muestra en la Tabla 7, se evidencia que en este caso aumentar la complejidad del modelo no garantiza una mejora en el desempeño. La red simple del escenario 1, con una sola capa oculta de 10 neuronas y 1000 épocas, alcanzó exactamente los mismos resultados que

el modelo base con solo 1000 épocas. Esto confirma que el algoritmo de entrenamiento implementa una convergencia temprana, y que extender las épocas más allá de ese punto no aporta beneficios adicionales.

En contraste, los escenarios con arquitecturas más complejas (2 y 3) mostraron un deterioro en las métricas de error, siendo más pronunciado en el escenario 2, que registró un MAE de 1.5703 % y una pérdida notable en R^2 (0.9923), posiblemente por sobreajuste o dificultades de convergencia. Aunque el escenario 3 mejoró respecto al escenario 2, su desempeño siguió siendo inferior al de la red simple. En la Figura 20 se logra observar los resultados de los 3 escenarios de prueba.

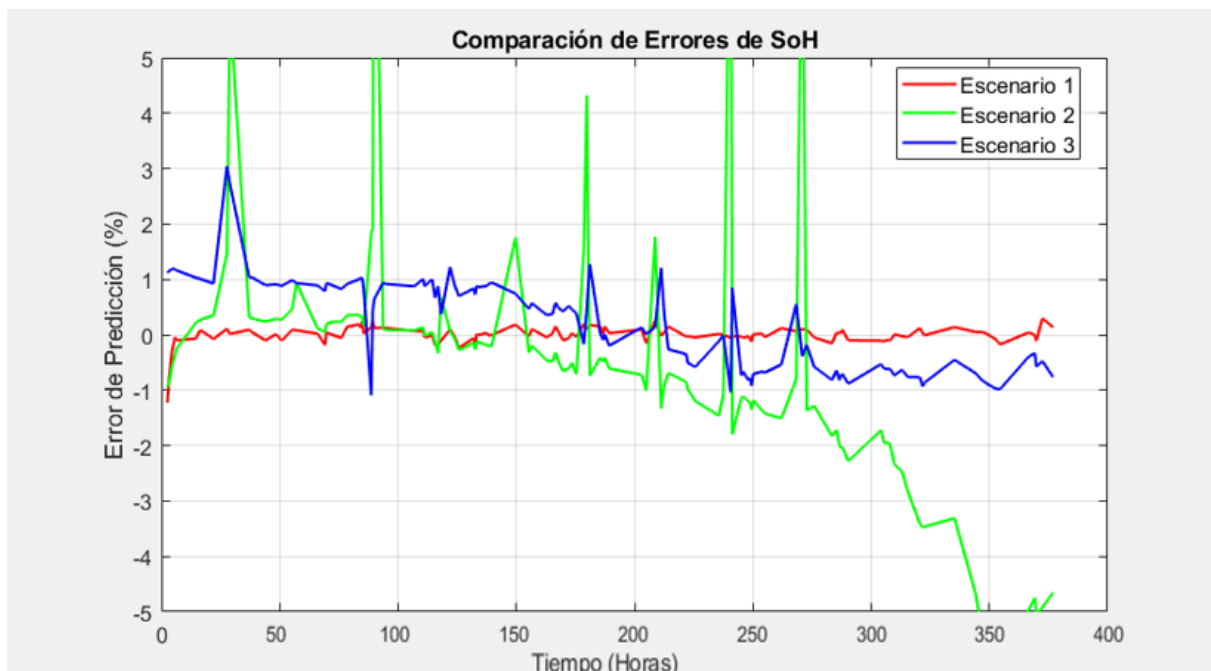


Figura 20. Comparación de errores de SoH de los 3 escenarios con distintos hiperparámetros.

La Figura 20 muestra el error de cada escenario complementando este análisis al mostrar visualmente cómo el error aumenta al introducir mayor complejidad, confirmando la efectividad del diseño propuesto, y que un diseño balanceado entre capacidad y simplicidad favorece la generalización. Esto resalta la importancia de evitar redes innecesariamente profundas en contextos donde los patrones de entrada ya son suficientemente representativos para una red liviana.

Es importante destacar que estos resultados se obtuvieron a partir de un conjunto de datos controlado, caracterizado por patrones bien definidos y relativamente estables. En escenarios donde los datos presenten mayor complejidad, variabilidad o ruido podría ser necesario recurrir a modelos con mayor capacidad para adaptarse a esas condiciones. Por tanto, la selección óptima de los hiperparámetros debe adaptarse a las

características particulares del conjunto de datos y a los requisitos de precisión de cada aplicación específica.

5. CONCLUSIONES Y TRABAJOS FUTUROS

En esta sección, se presentan las conclusiones derivadas del desarrollo del algoritmo de estimación de SoH de LIBs mediante un modelo de red neuronal artificial, resaltando los logros, desafíos y hallazgos significativos que surgieron durante el análisis, desarrollo y validación de este, abordando el rendimiento del modelo en diversas condiciones. Además, se señalan direcciones para investigaciones futuras.

5.1. CONCLUSIONES

Con el objetivo de desarrollar un modelo capaz de estimar con precisión el estado de salud (SoH) de baterías de ion de litio, se realizó una revisión bibliográfica que incluyó literatura científica nacional e internacional, artículos especializados, estudios de caso en vehículos eléctricos, sistemas de almacenamiento y microrredes. Este análisis evidenció que, aunque los métodos físicos y electroquímicos ofrecen alta precisión, presentan importantes limitaciones en entornos reales debido a su complejidad, la necesidad de mediciones intrusivas y su escasa adaptabilidad a diferentes condiciones operativas. En contraste, los modelos basados en aprendizaje automático, en especial las redes neuronales, ofrecen un buen rendimiento cuando se dispone de datos de pronóstico.

A partir de esta base teórica, se fundamentaron distintas estrategias que condujeron al desarrollo de un algoritmo que aprovecha las ventajas de las redes neuronales para modelar relaciones no lineales y dinámicas complejas de degradación de las baterías utilizando una arquitectura de red neuronal artificial (ANN) tipo feedforward. El modelo fue entrenado y validado con datos experimentales de acceso público, provenientes del PCoE de la NASA, empleando como variables de entrada tiempo de carga y descarga, voltaje, corriente, temperatura e impedancia, mientras que el SoH se estableció como la relación entre la capacidad actual de la batería y su capacidad nominal inicial, obtenida a partir del análisis de los ciclos de descarga. La normalización basada en la desviación absoluta mediana (MAD) y el uso de un filtro exponencial para suavizar el ruido en las señales fueron estrategias que mejoraron la estabilidad y convergencia del modelo durante el entrenamiento. Estas técnicas permitieron reducir la influencia de valores atípicos y optimizar el rendimiento sin comprometer la capacidad predictiva.

El algoritmo demostró su desempeño siendo el único modelo, con un coeficiente de determinación (R^2) ideal de 1.0 junto con los errores más bajos registrados, entre ellos un MAE de 0.1004 %. Comparado con otros modelos evaluados como LSTM, GRU, ML NN, DL y CNN estos resultados no solo destacan el rendimiento del modelo ANN, sino que también superan los estándares establecidos en la literatura ($MAE < 5 \%$, $RMSE < 2 \%$ y $R^2 > 0.98$). Además, el modelo mostró adaptabilidad en distintos ciclos completos

de vida útil, manteniendo un MAE inferior a 0.19 % y mostrando una correlación consistente entre el tiempo para alcanzar un alto grado de envejecimiento de la batería. El algoritmo presentó un tiempo de operación aproximado de 9 segundos, el cual podría considerarse aceptable para aplicaciones en microrredes o sistemas con requisitos de latencia moderada.

Por otra parte, la prueba de ajuste de hiperparámetros del modelo de la sección 3.4.2. confirmó que la configuración principal de 1 capa oculta, 10 neuronas a pesar de ser más simple fue la más efectiva en este caso, logrando el mejor equilibrio entre rendimiento y eficiencia. El modelo mostró un deterioro en precisión en el escenario 2 (MAE de 1.5703 %) al usar 2 capas ocultas con 15 y 10 neuronas, y de igual forma en el escenario 3 (MAE de 0.7440 %), que, aunque fue mejor que el escenario 2, no superó al escenario 1. Respecto al entrenamiento, el algoritmo implementa “early stopping” al alcanzar convergencia óptima, razón por la cual aumentar el límite de épocas no cambia los resultados.

5.2. PERSPECTIVAS DE TRABAJO FUTURO

Una proyección inmediata de este trabajo consiste en su implementación en entornos reales. Para ello, será fundamental la recolección de datos propios generados directamente por LIBs operando en condiciones locales y reales. La creación de una base de datos con esta información permitirá adaptar el modelo a patrones reales de carga y descarga, condiciones ambientales específicas, perfiles de uso locales y características operativas propias del entorno de aplicación, considerando patrones reales de carga ajustados a la aplicación particular, temperatura ambiente, tasas de descarga y condiciones operativas.

Actualmente, el modelo fue entrenado con datos estandarizados provenientes de plataformas internacionales. Si bien estos datos son útiles para validar el enfoque general, no representan completamente las condiciones de operación propias del contexto donde se busca aplicar el algoritmo. Al emplear datos reales obtenidos localmente, será posible mejorar la adaptabilidad, precisión y capacidad de predicción del modelo en escenarios reales.

Por otra parte, se plantea validar el algoritmo en un rango más amplio de tipos de baterías de ion de litio, considerando baterías con distintas composiciones químicas (como LiFePO_4 , NMC, NCA), capacidades y arquitecturas internas. Esta diversidad permitirá fortalecer la capacidad de generalización del modelo ante distintas baterías comerciales.

Asimismo, se propone dotar al algoritmo de mecanismos de autoajuste de parámetros, con el fin de que pueda adaptarse dinámicamente a cambios en el comportamiento de la

batería sin intervención manual. Esto permitirá optimizar continuamente el rendimiento del modelo en función de las condiciones operativas, facilitando su integración en sistemas inteligentes de gestión energética y mejorando su utilidad en aplicaciones reales a largo plazo. Además, de ser útil al momento de utilizar datos provenientes de distintas fuentes o condiciones.

REFERENCIAS

- [1] M. F. Ge, Y. Liu, X. Jiang, and J. Liu, "A review on state of health estimations and remaining useful life prognostics of lithium-ion batteries," *Measurement (Lond)*, vol. 174, Apr. 2021, doi: 10.1016/j.measurement.2021.109057.
- [2] Redway Battery, "¿Qué hace que las baterías de iones de litio de alta capacidad sean adecuadas para el almacenamiento de energía renovable?" [Online]. Available: <https://www.redwaybattery.com/es/what-makes-high-capacity-lithium-ion-batteries-suitable-for-renewable-energy-storage/>
- [3] A. X. Mu, B. J. Zhang, C. G. Li, D. Z. Xiao, E. F. Zeng, and F. J. Liu, "Estimating SOC and SOH of energy storage battery pack based on voltage inconsistency using reference-difference model and dual extended Kalman filter," *J Energy Storage*, vol. 81, Mar. 2024, doi: 10.1016/j.est.2023.110221.
- [4] A. Kara, "A data-driven approach based on deep neural networks for lithium-ion battery prognostics," *Neural Comput Appl*, vol. 33, no. 20, pp. 13525–13538, Oct. 2021, doi: 10.1007/s00521-021-05976-x.
- [5] K. Luo, X. Chen, H. Zheng, and Z. Shi, "A review of deep learning approach to predicting the state of health and state of charge of lithium-ion batteries," 2022. doi: 10.1016/j.jechem.2022.06.049.
- [6] S. Sun, H. Zhang, J. Ge, and L. Che, "State-of-health estimation for lithium-ion battery using model-based feature optimization and deep extreme learning machine," *J Energy Storage*, vol. 72, Nov. 2023, doi: 10.1016/j.est.2023.108732.
- [7] A. K. Ghazali, N. A. Ab. Aziz, and M. K. Hassan, "Advanced Algorithms in Battery Management Systems for Electric Vehicles: A Comprehensive Review," *Symmetry (Basel)*, vol. 17, no. 3, p. 321, Feb. 2025, doi: 10.3390/sym17030321.
- [8] C. Rincón Maya, D. Acosta González, F. Guevara Carazas, F. Hernández Barajas, C. Patino Rodríguez, and O. Usuga Manco, "Predictive Modeling of Electric Bicycle Battery Performance: Integrating Real-Time Sensor Data and Machine Learning Techniques," *Sensors*, vol. 25, Feb. 2025, doi: 10.3390/s25051392.
- [9] A. Barré, B. Deguilhem, S. Grolleau, M. Gérard, F. Suard, and D. Riu, "A review on lithium-ion battery ageing mechanisms and estimations for automotive applications," 2013. doi: 10.1016/j.jpowsour.2013.05.040.
- [10] K. Neigum and Z. Wang, "Technology, economic, and environmental analysis of second-life batteries as stationary energy storage: A review," *J Energy Storage*, vol. 103, p. 114393, Dec. 2024, doi: 10.1016/j.est.2024.114393.

- [11] A. C. Moreira, D. R. Pinto, M. D. F. Rosolem, L. A. Rolim, M. S. Medrano, and E. L. Junior, "A comprehensive second-life review of electric vehicle batteries - A Brazilian study case," in *ISGT Latin America 2021*, Institute of Electrical and Electronics Engineers Inc., Sep. 2021. doi: 10.1109/ISGTLatinAmerica52371.2021.9543057.
- [12] "El impacto ambiental de las baterías de iones de litio.," Emtez. [Online]. Available: <https://www.emtez.es/blog/el-impacto-ambiental-de-las-bater%C3%ADas-de-iones-de-litio#:~:text=Un%20incendio%20de%20iones%20de,de%20destruir%20extensas%20C3%A1reas%20forestales>.
- [13] C. Liu, H. Li, K. Li, Y. Wu, and B. Lv, "Deep Learning for State of Health Estimation of Lithium-Ion Batteries in Electric Vehicles: A Systematic Review," Mar. 01, 2025, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/en18061463.
- [14] G. Sun, Y. Liu, and X. Liu, "A method for estimating lithium-ion battery state of health based on physics-informed machine learning," *J Power Sources*, vol. 627, Jan. 2025, doi: 10.1016/j.jpowsour.2024.235767.
- [15] K. Q. Zhou, Y. Qin, and C. Yuen, "Graph neural network-based lithium-ion battery state of health estimation using partial discharging curve," *J Energy Storage*, vol. 100, Oct. 2024, doi: 10.1016/j.est.2024.113502.
- [16] "Convocatoria de la asignación para la ctei-ambiental del sgr para la conformación de un listado de propuestas de proyecto elegibles de investigación, desarrollo e innovación para el ambiente y el desarrollo sostenible del país," Bogotá, Cundinamarca, 2021.
- [17] H. Deng *et al.*, "Optimization of configurations and scheduling of shared hybrid electric-hydrogen energy storages supporting to multi-microgrid system," *J Energy Storage*, vol. 74, Dec. 2023, doi: 10.1016/j.est.2023.109420.
- [18] A. Esmaeel Nezhad, M. Mobtahej, M. S. Javadi, P. H. J. Nardelli, and S. Sahoo, "Optimal operation of lithium-ion batteries in microgrids using a semidefinite thermal model," *International Journal of Electrical Power and Energy Systems*, vol. 155, Jan. 2024, doi: 10.1016/j.ijepes.2023.109630.
- [19] M. A. Giovanniello and X. Y. Wu, "Hybrid lithium-ion battery and hydrogen energy storage systems for a wind-supplied microgrid," *Appl Energy*, vol. 345, Sep. 2023, doi: 10.1016/j.apenergy.2023.121311.
- [20] J. Tian, R. Xiong, and W. Shen, "A review on state of health estimation for lithium ion batteries in photovoltaic systems," Nov. 01, 2019, *Elsevier B.V.* doi: 10.1016/j.etrans.2019.100028.
- [21] A. Allam, E. Catenaro, and S. Onori, "Pushing the Evelope in Battery Estimation Algorithms," *iScience*, vol. 23, no. 12, Dec. 2020, doi: 10.1016/j.isci.2020.101847.

- [22] Z. Cao, W. Gao, Y. Fu, N. V. Kurdkandi, and C. Mi, "A general framework for lithium-ion battery state of health estimation: From laboratory tests to machine learning with transferability across domains," *Appl Energy*, vol. 381, Mar. 2025, doi: 10.1016/j.apenergy.2024.125086.
- [23] J. Tian, R. Xiong, and W. Shen, "A review on state of health estimation for lithium ion batteries in photovoltaic systems," Nov. 01, 2019, *Elsevier B.V.* doi: 10.1016/j.etsan.2019.100028.
- [24] A. Y. Kallel, V. Petrychenko, and O. Kanoun, "State-of-Health of Li-Ion Battery Estimation Based on the Efficiency of the Charge Transfer Extracted from Impedance Spectra," *Applied Sciences (Switzerland)*, vol. 12, no. 2, Jan. 2022, doi: 10.3390/app12020885.
- [25] E. Liu, G. Niu, X. Wang, and B. Zhang, "SOH Diagnostic and Prognostic Based on External Health Indicator of Lithium-ion Batteries," in *IECON Proceedings (Industrial Electronics Conference)*, IEEE Computer Society, Oct. 2021. doi: 10.1109/IECON48115.2021.9589170.
- [26] D. C. Li, J. R. Felix, Y. L. Chin, L. V. Jusuf, and L. J. Susanto, "Integrated Extended Kalman Filter and Deep Learning Platform for Electric Vehicle Battery Health Prediction," *Applied Sciences (Switzerland)*, vol. 14, no. 11, Jun. 2024, doi: 10.3390/app14114354.
- [27] Q. Zhu, M. Xu, W. Liu, and M. Zheng, "A state of charge estimation method for lithium-ion batteries based on fractional order adaptive extended kalman filter," *Energy*, vol. 187, Nov. 2019, doi: 10.1016/j.energy.2019.115880.
- [28] Z. Chen, H. Zhao, Y. Zhang, S. Shen, J. Shen, and Y. Liu, "State of health estimation for lithium-ion batteries based on temperature prediction and gated recurrent unit neural network," *J Power Sources*, vol. 521, Feb. 2022, doi: 10.1016/j.jpowsour.2021.230892.
- [29] C. Vidal, P. Malysz, P. Kollmeyer, and A. Emadi, "Machine Learning Applied to Electrified Vehicle Battery State of Charge and State of Health Estimation: State-of-the-Art," 2020, *Institute of Electrical and Electronics Engineers Inc.* doi: 10.1109/ACCESS.2020.2980961.
- [30] A. Barragán-Moreno, E. Schaltz, A. Gismero, and D. I. Stroe, "Capacity State-of-Health Estimation of Electric Vehicle Batteries Using Machine Learning and Impedance Measurements," *Electronics (Switzerland)*, vol. 11, no. 9, May 2022, doi: 10.3390/electronics11091414.
- [31] L. Driscoll, S. de la Torre, and J. A. Gomez-Ruiz, "Feature-based lithium-ion battery state of health estimation with artificial neural networks," *J Energy Storage*, vol. 50, Jun. 2022, doi: 10.1016/j.est.2022.104584.
- [32] X. Tan *et al.*, "Real-Time State-of-Health Estimation of Lithium-Ion Batteries Based on the Equivalent Internal Resistance," *IEEE Access*, vol. 8, pp. 56811–56822, 2020, doi: 10.1109/ACCESS.2020.2979570.

- [33] H. Pan, Z. Lü, H. Wang, H. Wei, and L. Chen, "Novel battery state-of-health online estimation method using multiple health indicators and an extreme learning machine," *Energy*, vol. 160, pp. 466–477, Oct. 2018, doi: 10.1016/j.energy.2018.06.220.
- [34] H. J. Bergveld, W. S. Kruijt, and P. H. L. Notten, *Battery Management Systems : Design by Modelling*, 1st ed., vol. 1. Boston: Kluwer Academic Publishers, 2002. doi: doi.org/10.1007/978-94-017-0843-2.
- [35] C. J. Cleveland and C. G. Morris, Eds., *Dictionary of energy*, 2da ed., vol. 2. Elseiver, 2014.
- [36] H. Messel and S. T. Butler, Eds., "Batteries," in *Solar Energy : Pergamon International Library of Science, Technology, Engineering and Social Studies*, 1st ed., Oxford, 1975, ch. 8, pp. 135–150.
- [37] M. U. Pallàs, "Estimació de l'Estat de Salut de la bateria d'un Vehicle Elèctric MEMÒRIA Autor," Catalunya, Jun. 2023.
- [38] J. T. Warner, "The handbook of lithium-ion battery pack design : chemistry, components, types and terminology /," vol. 1, Amsterdam, 2015, ch. 7, pp. 65–89.
- [39] Labster, "Batería de litio." [Online]. Available: <https://theory.labster.com/es/lithium-battery/>
- [40] H. Tian, P. Qin, K. Li, and Z. Zhao, "A review of the state of health for lithium-ion batteries: Research status and suggestions," Jul. 10, 2020, *Elsevier Ltd*. doi: 10.1016/j.jclepro.2020.120813.
- [41] L. Lu, X. Han, J. Li, J. Hua, and M. Ouyang, "A review on the key issues for lithium-ion battery management in electric vehicles," Mar. 15, 2013. doi: 10.1016/j.jpowsour.2012.10.060.
- [42] H. Dai, Z. Sun, and X. Wei, "A New SOH Prediction Concept for the Power Lithium-ion Battery Used on HEVs," *IEEE*, 2009.
- [43] A. B. Moreno, "Machine Learning-based Online State-of-Health Estimation of Electric Vehicle Batteries. Artificial Intelligence Applied to Battery Management Systems," Aalborg Universitet, Aalborg, 2021.
- [44] M. Wei, Q. Wang, M. Ye, and J. Li, "State of charge estimation for lithium-ion battery using dynamic neural networks," in *Proceedings - International Conference on Artificial Intelligence and Electromechanical Automation, AIEA 2020*, Institute of Electrical and Electronics Engineers Inc., Jun. 2020, pp. 23–26. doi: 10.1109/AIEA51086.2020.00012.
- [45] Z. Liu, Y. Sun, Y. Li, Y. Liu, Y. Chen, and Y. Zhang, "Lithium-ion battery health prognosis via electrochemical impedance spectroscopy using CNN-BiLSTM model," *Journal of Materials Informatics*, vol. 4, no. 2, Jun. 2024, doi: 10.20517/jmi.2024.09.

- [46] K. Q. Zhou, Y. Qin, and C. Yuen, "Graph neural network-based lithium-ion battery state of health estimation using partial discharging curve," *J Energy Storage*, vol. 100, Oct. 2024, doi: 10.1016/j.est.2024.113502.
- [47] S. Peng, Y. Sun, D. Liu, Q. Yu, J. Kan, and M. Pecht, "State of health estimation of lithium-ion batteries based on multi-health features extraction and improved long short-term memory neural network," *Energy*, vol. 282, Nov. 2023, doi: 10.1016/j.energy.2023.128956.
- [48] X. Wang, X. Wei, and H. Dai, "Estimation of state of health of lithium-ion batteries based on charge transfer resistance considering different temperature and state of charge," *J Energy Storage*, vol. 21, pp. 618–631, Feb. 2019, doi: 10.1016/j.est.2018.11.020.
- [49] L. Yongtao, L. Chuanpan, L. Yongjie, S. Feiran, Q. Jie, and X. Ting, "Review on degradation mechanism and health state estimation methods of lithium-ion batteries," *Journal of Traffic and Transportation Engineering*, vol. 10, no. 4, pp. 578–610, 2023, [Online]. Available: <https://doaj-org.ucundinamarca.basededatosezproxy.com/article/1036bac570864f4381d7686ea78d0f6f>
- [50] C. Yitia, "Conjunto de datos de baterías de iones de litio de la NASA," IEEE Dataport. [Online]. Available: <https://iee-dataport.org/documents/nasa-lithium-ion-battery-dataset>
- [51] S. Bockrath, V. Lorentz, and M. Pruckner, "State of health estimation of lithium-ion batteries with a temporal convolutional neural network using partial load profiles," *Appl Energy*, vol. 329, Jan. 2023, doi: 10.1016/j.apenergy.2022.120307.
- [52] P. Venugopal and T. Vigneswaran, "State-of-health estimation of Li-ion batteries in electric vehicle using InDRNN under variable load condition," *Energies (Basel)*, vol. 12, no. 22, Nov. 2019, doi: 10.3390/en12224338.
- [53] L. Su, Y. Xu, and Z. Dong, "State-of-health estimation of lithium-ion batteries: A comprehensive literature review from cell to pack levels," *Energy Conversion and Economics*, vol. 5, no. 4, pp. 224–242, Aug. 2024, doi: 10.1049/enc2.12125.
- [54] Z. Deng *et al.*, "Battery health evaluation using a short random segment of constant current charging," *iScience*, vol. 25, no. 5, May 2022, doi: 10.1016/j.isci.2022.104260.
- [55] J. Lu, R. Xiong, J. Tian, C. Wang, and F. Sun, "Deep learning to estimate lithium-ion battery state of health without additional degradation experiments," *Nat Commun*, vol. 14, no. 1, Dec. 2023, doi: 10.1038/s41467-023-38458-w.
- [56] MATLAB, "¿Qué es el aprendizaje no supervisado?," MathWorks. [Online]. Available: <https://la.mathworks.com/discovery/unsupervised-learning.html#2>

- [57] C. Zhang, S. Bengio, M. Hardt, B. Recht, and O. Vinyals, "Understanding deep learning (still) requires rethinking generalization," *Commun ACM*, vol. 64, no. 3, pp. 107–115, Mar. 2021, doi: 10.1145/3446776.
- [58] Grégoire. Montavon, "Practical recommendations for gradient-based training of deep architectures," in *Neural Networks: Tricks of the Trade*, 2nd ed., vol. 7700, G. Montavon, Ed., Berlin: Springer, 2012, ch. 19, pp. 437–478.
- [59] R. Gupta and R. Jindal, "Impact of Too Many Neural Network Layers on Overfitting," *International Journal of Computer Science and Mobile Computing*, vol. 14, no. 5, pp. 1–14, May 2025, doi: 10.47760/ijcsmc.2025.v14i05.001.
- [60] K. G. Sheela and S. N. Deepa, "Review on methods to fix number of hidden neurons in neural networks," *Math Probl Eng*, vol. 2013, 2013, doi: 10.1155/2013/425740.
- [61] K. Attarde and J. Sayyad, "GEPAF: A non-monotonic generalized activation function in neural network for improving prediction with diverse data distributions characteristics," *Neural Networks*, vol. 180, Dec. 2024, doi: 10.1016/j.neunet.2024.106738.
- [62] S. Bouraya and A. Belangour, "A comparative analysis of activation functions in neural networks: unveiling categories," *Bulletin of Electrical Engineering and Informatics*, vol. 13, no. 5, pp. 3301–3308, Oct. 2024, doi: 10.11591/eei.v13i5.7274.
- [63] G. Ian, B. Yoshua, and C. Aaron, *Aprendizaje profundo*, 1st ed. Cambridge, Massachusetts, 2016.
- [64] C. Bishop, "Linear Models for Regression," in *Pattern Recognition and Machine Learning*, 1st ed., New York: Springer, 2012, ch. 4, pp. 132–136.
- [65] D. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," Dec. 2014, [Online]. Available: <http://arxiv.org/abs/1412.6980>
- [66] M. del C. Rodríguez Franco and E. Velasteguí López, "El suavizado exponencial en el pronóstico de series no estacionarias," *Ciencia Digital*, vol. 4, no. 1, pp. 97–110, Jan. 2020, doi: 10.33262/cienciadigital.v4i1.1073.
- [67] F. Feng *et al.*, "Co-estimation of lithium-ion battery state of charge and state of temperature based on a hybrid electrochemical-thermal-neural-network model," *J Power Sources*, vol. 455, Apr. 2020, doi: 10.1016/j.jpowsour.2020.227935.
- [68] X. Li, W. Liu, B. Liang, Q. Li, Y. Zhao, and J. Hu, "Highly robust co-estimation of state of charge and state of health using recursive total least squares and unscented Kalman filter for lithium-ion battery," *IET Renewable Power Generation*, Dec. 2024, doi: 10.1049/rpg2.12965.

- [69] X. Liu, K. Li, J. Wu, Y. He, and X. Liu, "An extended Kalman filter based data-driven method for state of charge estimation of Li-ion batteries," *J Energy Storage*, vol. 40, Aug. 2021, doi: 10.1016/j.est.2021.102655.
- [70] NASA, "Li-ion Battery Aging Datasets." [Online]. Available: <https://data.nasa.gov/dataset/li-ion-battery-aging-datasets>
- [71] MATLAB, "'trainlm' Retropropagación Levenberg-Marquardt," MathWorks. [Online]. Available: <https://la.mathworks.com/help/deeplearning/ref/trainlm.html>
- [72] C. Leys, C. Ley, O. Klein, P. Bernard, and L. Licata, "Estimation of Location and Scale," *J Exp Soc Psychol*, no. 4, pp. 64–766, Jul. 2013, [Online]. Available: doi.org/10.1016/j.jesp.2013.03.013
- [73] P. J. Rousseeuw and C. Croux, "Alternatives to the Median Absolute Deviation," *J Am Stat Assoc*, Dec. 1993, [Online]. Available: <https://www.jstor.org/stable/2291267>
- [74] MATLAB, "'feedforwardnet' Generar una red neuronal prealimentada," MathWorks. [Online]. Available: <https://la.mathworks.com/help/deeplearning/ref/feedforwardnet.html>
- [75] C. Yunji, L. Ling, L. Wei, G. Qi, D. Zidong, and X. Zichen, "Fundamentals of neural networks," in *AI Computing Systems. An Application-Driven Perspective*, 1st ed., Elseiver, 2023, ch. 2, pp. 17–51. doi: 10.1016/B978-0-32-395399-3.00008-1.
- [76] J. Lu, R. Xiong, J. Tian, C. Wang, and F. Sun, "Deep learning to estimate lithium-ion battery state of health without additional degradation experiments," *Nat Commun*, vol. 14, no. 1, Dec. 2023, doi: 10.1038/s41467-023-38458-w.