







ESTUDIO COMPARATIVO APLICADO DE MÉTODOS EXISTENTES PARA ESTIMACIÓN DEL ESTADO DE CARGA EN BATERÍAS DE IONES DE LITIO

APPLIED COMPARATIVE STUDY OF EXISTING METHODS FOR STATE-OF-CHARGE ESTIMATION IN LITHIUM-ION BATTERIES

Edwin Paccha-Herrera^{1,2,*} , Ángel Recalde^{1,3} ,
Francisco Jaramillo-Montoya⁴ , Darwin Tapia-Peralta² 

Recibido: 16-11-2025, Recibido tras revisión: 23-03-2026, Aceptado: 28-04-2026, Publicado: 01-07-2026

Resumen

Estimar el estado de carga (SOC) de las baterías de iones de litio es crucial para la operación de diversos dispositivos y equipos eléctricos y electrónicos. Este trabajo presenta la implementación de modelos basados en un enfoque bayesiano mediante el filtro de Kalman linealizado y el filtro de partículas (PF) para estimar el SOC en baterías de iones de litio. La ecuación de estado de los modelos bayesianos incorpora la resistencia de la batería como un parámetro de evolución artificial. De igual manera, se implementan dos modelos basados en algoritmos de aprendizaje automático: random forest y KNN, mediante el ajuste de parámetros de un circuito eléctrico equivalente a las curvas de mediciones de espectroscopía de impedancia electroquímica. Se utilizó una batería cilíndrica LCO tipo 26650. Los resultados muestran un alto desempeño en la estimación del SOC para los filtros bayesianos, entre los cuales el PF presenta las mejores métricas, con un coeficiente de determinación R^2 de 0.9968.


Palabras clave: aprendizaje de máquinas, EIS, filtro bayesiano, SOC


Abstract


Estimating the state of charge (SOC) of lithium-ion batteries is crucial for the operation of various electrical and electronic devices and equipment. This work presents the implementation of models based on a Bayesian approach using linearized Kalman filtering and particle filtering (PF) to estimate the SOC in lithium-ion batteries. state equation of the Bayesian models incorporates battery resistance as an artificial evolution parameter. Two models based on machine learning algorithms, random forest and K-nearest neighbors (KNN), are also implemented by fitting the parameters of an equivalent electric circuit model to electrochemical impedance spectroscopy measurements. A cylindrical LCO 26650 cell was employed in this study. The results show high performance in SOC estimation for the Bayesian filters, with PF exhibiting the best metrics, including an R^2 adjustment factor of 0.9968.

Keywords: Bayesian filtering, EIS, machine learning, SOC

^{1,*}Facultad de Sistemas y Telecomunicaciones, Universidad Estatal Península de Santa Elena, Ecuador. 

²Facultad de Energía, Universidad Nacional de Loja, Ecuador. 

³Facultad de Ingeniería Eléctrica e Informática, Escuela Superior Politécnica del Litoral, Ecuador. 

⁴Departamento de Ingeniería Eléctrica, Universidad de Chile, Chile. 

Autor para correspondencia ✉: edwin.paccha@unl.edu.ec.

Forma sugerida de citación: E. Paccha-Herrera, A. Recalde, F. Jaramillo-Montoya y D. Tapia-Peralta, “Estudio comparativo aplicado de métodos existentes para estimación del estado de carga en baterías de iones de litio,” *Ingenius, Revista de Ciencia y Tecnología*, N.º 36, pp. 125-136, 2026. DOI: <https://doi.org/10.17163/ings.n36.2026.10>.

1. Introducción

Las baterías de iones de litio son componentes críticos en una amplia gama de sistemas eléctricos y electrónicos, incluidos electrodomésticos, dispositivos médicos, computadoras portátiles, vehículos eléctricos y sistemas de almacenamiento de energía [1]. Debido a su alta densidad energética, larga vida útil, excelente eficiencia y funcionamiento respetuoso con el medioambiente, las baterías de iones de litio se han convertido en la tecnología de almacenamiento de energía más competitiva y prometedora [2]. El estado de carga (SOC) es un parámetro clave que proporciona una medida indirecta de la capacidad utilizable restante de la batería. Para garantizar una operación segura y eficiente, las baterías de iones de litio dependen de sistemas de gestión de baterías (BMS), los cuales monitorean continuamente variables esenciales como el voltaje, la corriente, la temperatura y la capacidad para estimar tanto el SOC como el estado de salud (SOH) [3]. El monitoreo de estas variables permite al BMS proteger la batería contra condiciones adversas como la sobrecarga, la sobredescarga, las temperaturas extremas y las sobrecorrientes, las cuales pueden provocar degradación física y reducir significativamente la vida útil de la batería [4].

Existen varios métodos directos de medición del SOC, incluidos el método de conteo de Coulomb, el voltaje de circuito abierto (OCV), la espectroscopía de impedancia electroquímica (EIS) y los métodos de resistencia interna. Además, existen métodos indirectos de estimación, que implican predecir el valor del SOC de la batería utilizando modelos matemáticos y algoritmos. En general, estos métodos pueden alcanzar una mayor precisión en comparación con los métodos basados en mediciones directas. Los métodos de análisis indirecto pueden clasificarse en cinco subgrupos: basados en modelos, basados en filtros adaptativos, basados en inteligencia artificial adaptativa, algoritmos avanzados y otros métodos. Los métodos basados en modelos se fundamentan en algoritmos que crean una representación matemática del comportamiento eléctrico y de las características de la batería. Dentro de este enfoque se incluyen el modelo de circuito eléctrico (ECM) y el modelo electroquímico (EChM), los cuales son ampliamente utilizados para la estimación del SOC y sirven como base para otras técnicas de modelado de baterías [5].

En [6], el autor propone un modelo que emplea un ajuste basado en un algoritmo polinomial. Este enfoque no requiere un modelo térmico, lo que proporciona una forma de corregir los errores inducidos por la temperatura. Además, en [7] se afirma que los modelos fraccionarios pueden alcanzar una mayor precisión en comparación con sus contrapartes de orden entero, aunque presentan como desventaja una mayor complejidad. Asimismo, los parámetros físicos podrían

considerarse en la estimación del SOC. Por ejemplo, la dependencia de la resistencia interna de la batería respecto del SOC puede aprovecharse para obtener resultados más precisos [8]. Además, el efecto de la temperatura también puede causar inconsistencias en la estimación del SOC de un paquete de baterías [9].

La espectroscopía de impedancia electroquímica (EIS) es una técnica poderosa para la caracterización de baterías. El experimento de EIS se basa en la aplicación de una señal alterna en un rango de frecuencias. Los datos resultantes de corriente y voltaje se correlacionan para identificar la impedancia, la cual proporciona información sobre los procesos electroquímicos en la batería, tales como la cinética de transferencia de carga, la difusión de iones y las reacciones interfaciales [10]. El enfoque basado en EIS podría emplearse para mejorar la estimación del SOC y del SOH [11]. Una desventaja de la EIS es que requiere equipos específicos de ensayo y control de la temperatura ambiental para obtener mejores resultados.

Por otro lado, existen modelos basados en datos que se fundamentan en información de la batería, incluyendo mediciones de temperatura, voltaje y corriente. Estos pueden utilizar modelos más simples o incluso operar sin un modelo explícito; sin embargo, su precisión disminuye cuando los datos de entrada son ruidosos o incompletos. Aun así, estos modelos son más flexibles porque no requieren un modelo específico de batería y demandan menos recursos. El proceso de estimación del SOC basado en datos comprende tres etapas clave: recopilación de datos, entrenamiento del modelo y estimación del SOC. Algunas de las técnicas ampliamente utilizadas son las redes neuronales artificiales (ANNs), la regresión por vectores de soporte (SVR), las máquinas de vectores de soporte (SVMs) y la lógica difusa [2].

Este artículo explora y compara diferentes métodos de estimación del SOC. También se analiza de manera particular la influencia de la resistencia interna en el SOC. La comprensión e implementación de modelos lineales, no lineales y enfoques basados en inteligencia artificial proporcionan una nueva perspectiva para explorar las limitaciones de los métodos actuales y mejorar su robustez y adaptabilidad bajo diversas condiciones de operación. Se presentan modelos directos e indirectos.

El enfoque directo se basa en mediciones de EIS, a partir de las cuales el SOC se predice mediante los algoritmos RF y KNN. Los enfoques indirectos propuestos son el filtro de Kalman linealizado y el filtro de partículas, en los cuales se emplea un perfil de corriente de ciclo de conducción para estimar el SOC de la batería. Al comparar diferentes métodos de estimación del SOC, es posible identificar el modelo más adecuado y robusto para cada condición de operación, lo que mejora las decisiones del BMS. Este estudio abre el camino para optimizar el rendimiento y extender

la vida útil de las baterías de ion-litio, beneficiando a múltiples industrias y contribuyendo al desarrollo de tecnologías más sostenibles y eficientes.

Este artículo está estructurado de la siguiente manera: la introducción presenta una visión general de la estimación del SOC. La sección de materiales y métodos describe las técnicas empleadas para estimar el SOC de la batería de iones de litio propuesta para el estudio. La sección de resultados y discusión expone los principales hallazgos y comparaciones de las métricas calculadas para cada enfoque de estimación del SOC. Finalmente, la sección de conclusiones presenta las principales contribuciones y formula recomendaciones para trabajos futuros.

1.1. Trabajos relacionados

Los enfoques más comunes aplicados a la estimación del SOC son el método de conteo de Coulomb o integración amperio-hora, el método de OCV, el enfoque basado en datos y los métodos basados en modelos [12]. El método de conteo de Coulomb ha sido empleado para estimar la generación de calor en una celda individual de iones de litio [13]. Los autores de [14] afirman que un modelo de red neuronal de memoria a corto y largo plazo (LSTM) muestra una alta precisión para estimar el SOC de un grupo de baterías en comparación con otros modelos de redes neuronales. El algoritmo basado en LSTM podría mejorarse mediante la integración de técnicas de agrupamiento basadas en K-means y fuzzy C-means [15]. Además, un modelo basado en LSTM puede considerar distintas temperaturas y condiciones de envejecimiento para estimar el SOC de manera más precisa [16].

Para enfrentar el error acumulativo del método de conteo de Coulomb, en [17] se formuló un filtro de Kalman extendido basado en la definición amperio-hora del SOC y en un modelo de Thévenin. Este modelo puede mejorarse mediante el uso de una formulación no lineal dada por el filtro de partículas (PF). Por ejemplo, en [18] se empleó un PF mejorado mediante un filtro H_∞ para estimar el SOC en un vehículo eléctrico. Se utilizaron ciclos de conducción estándar.

Además, los modelos de circuitos equivalentes (ECM) se utilizan comúnmente con mediciones de EIS, mediante la combinación de componentes eléctricos y el ajuste de sus parámetros para minimizar la discrepancia entre los datos recopilados y los espectros de impedancia modelados [19]. Por ejemplo, en [20] se realizó la estimación del SOC de la batería utilizando un ECM basado en mediciones de EIS combinado con algoritmos de aprendizaje automático. Se emplearon siete parámetros, incluidos elementos de orden fraccionario. Este enfoque reduce el tiempo de entrenamiento y es adecuado para la estimación en línea del SOC.

2. Materiales y métodos

2.1. Definición del estado de carga (SOC)

El SOC de una batería representa la relación entre la capacidad residual Q_t y la capacidad nominal Q_n , y puede formularse de la siguiente manera:

$$SOC(t) = \frac{Q_t}{Q_n} \times 100 \quad (1)$$

Además, el SOC puede expresarse como [21]:

$$SOC(t) = SOC_0 - \frac{\eta \int_{t_0}^t i(\tau) d\tau}{Q_n} \quad (2)$$

Donde SOC_0 es el valor inicial del estado de carga, $i(t)$ es la corriente en tiempo real, con $I(t) < 0$ durante la carga e $I(t) > 0$ para la descarga, y η es la eficiencia de Coulomb, que representa la relación entre la carga total extraída de la batería y la carga total suministrada a ella durante un ciclo completo.

Este trabajo tiene como objetivo comparar métodos directos e indirectos para estimar el SOC en baterías de iones de litio. El método directo se estableció con base en experimentos de EIS. Los métodos indirectos se basaron en algoritmos bayesianos (filtro de Kalman linealizado y filtro de partículas). Se empleó una batería 26650 de óxido de litio-cobalto (LCO) con una capacidad de 4 Ah.

2.2. SOC estimado mediante espectroscopía de impedancia electroquímica (EIS)

Los resultados de los experimentos de EIS se presentan comúnmente mediante un diagrama de Nyquist, como se muestra en la Figura 1. A partir de los espectros de EIS, puede formularse un ECM. La resistencia óhmica pura R_e corresponde al valor en la intersección de la curva con el eje horizontal [22]; la inductancia L modela los fenómenos electromagnéticos en la batería. La zona de frecuencia media representa la región de transferencia de carga, incluidas la resistencia de transferencia de carga R_{ct} y la capacitancia de doble capa C_{dl} . La R_{ct} refleja la resistencia del movimiento de los iones de litio entre el electrodo y el electrolito [23]. Finalmente, la zona de baja frecuencia representa el proceso de difusión de los iones de litio modelado por el elemento de fase constante Q_{dl} , cuyo exponente n_{dl} varía entre 0, correspondiente a un resistor, y 1, correspondiente a un capacitor. El ECM de la Figura 1 se caracteriza por la impedancia dada por [24]:

$$Z(\omega) = R_e + \frac{1}{j\omega C_{dl}} + \left[\frac{1}{Q_{dl}(j\omega)^{-n}} + R_{ct} \right]^{-1} + j\omega L \quad (3)$$




Figura 1. Diagrama de Nyquist basado en la prueba de EIS de una batería y su modelo de circuito equivalente. Adaptado de [24].

En este trabajo, la predicción del SOC basada en mediciones de EIS se llevó a cabo mediante un equipo de prueba PGSTAT302N. La EIS se realizó en un intervalo de SOC comprendido entre el 5 % y el 100 %, utilizando una celda de iones de litio LCO 26650 de 4 Ah. Se aplicó a la batería una señal de corriente sinusoidal con una amplitud de 0,05 A. Algunos perfiles de EIS se muestran en la Figura 2.




Figura 2. Diagrama de Nyquist obtenido a partir de la prueba de EIS de la batería LCO 26650 a diferentes valores de SOC.

La estimación del SOC basada en mediciones de EIS se aplicó mediante el ajuste de los parámetros del ECM a partir de la curva de EIS (véase un ejemplo en la Tabla 1) y del voltaje terminal de la batería. Posteriormente, estos parámetros se utilizaron para entrenar algoritmos RF y KNN con el fin de predecir

el SOC de la batería. El SOC de la batería se predice para cada medición de EIS. Por lo tanto, también se requiere ajustar los parámetros del ECM para cada medición de SOC.

Tabla 1. Parámetros ajustados para el ECM con un SOC de 0.6

Parámetro	Valor
C_{dl} (F)	0.1
L (H)	5.191×10^{-7}
n_{dl}	0.5
Q_{dl} ($\Omega^{-1} s^{n_{dl}}$)	1×10^{-5}
R_{ct} (Ω)	0.01
R_e (Ω)	0.06662

RF se implementó con 100 estimadores (árboles). Por otro lado, KNN se desarrolló con un valor de $k = 2$ para el número de vecinos más cercanos. Además, en ambos casos se empleó validación K-fold, con cinco particiones y un estado aleatorio igual a 42.

2.3. Estimación del SOC basada en el filtro de kalman Linealizado

2.3.1. Filtro de Kalman linealizado

El filtro de Kalman linealizado (LKF) es un método de estimación utilizado para sistemas no lineales cuyas dinámicas pueden aproximarse adecuadamente mediante una expansión de primer orden alrededor de una trayectoria de referencia conocida. Este enfoque se presenta ampliamente en la literatura clásica de filtrado [25, 26].

Considere el siguiente sistema no lineal:

$$x_{k+1} = f(x_k, u_k) + w_k, \quad (4)$$

$$z_k = h(x_k) + v_k, \quad (5)$$

donde x es el vector de estado, u denota la entrada, z es el vector de medición, k es el instante de tiempo, y w_k y v_k son ruidos de media cero con covarianzas Q y R , respectivamente. El LKF asume la existencia de una trayectoria nominal \bar{x}_k que satisface:

$$\bar{x}_{k+1} = f(\bar{x}_k, u_k), \quad (6)$$

y representa la evolución esperada en ausencia de perturbaciones.

Las variables de error se definen como:

$$\delta x_k = x_k - \bar{x}_k, \quad \delta z_k = z_k - h(\bar{x}_k), \quad (7)$$

y el sistema se linealiza alrededor de \bar{x}_k utilizando los jacobianos:

$$F_k = \left. \frac{\partial f(x, u_k)}{\partial x} \right|_{x=\bar{x}_k}, \quad (8)$$

$$H_k = \left. \frac{\partial h(x)}{\partial x} \right|_{x=\bar{x}_k}. \quad (9)$$

Esto produce el siguiente modelo lineal de estado de error:

$$\delta x_{k+1} = F_k \delta x_k + w_k, \quad (10)$$

$$\delta z_k = H_k \delta x_k + v_k, \quad (11)$$

que define un sistema lineal variante en el tiempo (LTV) adecuado para el filtrado de Kalman.

La principal característica del filtro de Kalman (KF) es que permite la estimación recursiva de los estados internos no medibles de un sistema, que, en el caso de la batería, corresponden al SOC. Esto se logra mediante conocimiento previo, predicciones basadas en modelos y mediciones ruidosas. Los pasos de predicción y actualización se describen a continuación [26]:

Predicción:

$$\delta \hat{x}_{k|k-1} = F_{k-1} \delta \hat{x}_{k-1|k-1}, \quad (12)$$

$$P_{k|k-1} = F_{k-1} P_{k-1|k-1} F_{k-1}^T + Q_{k-1}. \quad (13)$$

Actualización:

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1}, \quad (14)$$

$$\delta \hat{x}_{k|k} = \delta \hat{x}_{k|k-1} + K_k (\delta z_k - H_k \delta \hat{x}_{k|k-1}), \quad (15)$$

$$P_{k|k} = (I - K_k H_k) P_{k|k-1}, \quad (16)$$

donde K_k es la matriz de ganancia de Kalman, P_k es la covarianza del error e I es la matriz identidad. Entonces, la estimación del estado real se reconstruye como:

$$\hat{x}_{k|k} = \bar{x}_k + \delta \hat{x}_{k|k}. \quad (17)$$

En comparación con el filtro de Kalman extendido (EKF), el LKF linealiza únicamente alrededor de una trayectoria nominal predefinida, por lo que resulta adecuado cuando dicha trayectoria es conocida a priori y las desviaciones permanecen pequeñas [27].

2.3.2. Implementación de la estimación del SOC basada en LKF

En este contexto, el vector de estado se escribe como:

$$x_k = \begin{bmatrix} x_{1,k} \\ x_{2,k} \end{bmatrix}, \quad (18)$$

donde $x_{1,k}$ es el componente asociado a la resistencia interna de la celda y $x_{2,k}$ es el SOC en el instante k .

El enfoque bayesiano requiere una ecuación de medición. En el presente estudio, esta ecuación es el voltaje de la batería v_0 , linealizado alrededor del punto $x_0 = [x_{1,0} \ x_{2,0}]^T$ e i_0 [28]:

$$v_0 = v_L + (v_{OC} - v_L) e^{\gamma(x_{2,0}-1)} + \alpha v_L + (x_{2,0} - 1) + (1 - \alpha) v_L (e^{-\beta} - e^{-\beta\sqrt{x_{2,0}}}) - i_0 x_{1,0} \quad (19)$$

La corriente de descarga i es el parámetro de entrada del modelo, y v_{OC} es el voltaje de circuito abierto al 100 % de SOC. Los parámetros v_L , α , β y γ se estiman fuera de línea y fueron tomados de [28].

Las matrices para resolver el algoritmo LKF se formulan como:

$$F_k = \begin{bmatrix} 1 & 0 \\ -\frac{\Delta t}{E_{crit}} i_0 \frac{\partial v_0}{\partial x_1} & 1 - \frac{\Delta t}{E_{crit}} i_0 \frac{\partial v_0}{\partial x_2} \end{bmatrix}, \quad (20)$$

$$H_k = \begin{bmatrix} \frac{\partial v_0}{\partial x_1} & \frac{\partial v_0}{\partial x_2} \end{bmatrix}, \quad (21)$$

donde E_{crit} es la energía crítica, que corresponde a la energía total esperada suministrada por la batería.

2.4. Estimación del SOC basada en el filtro de partículas

2.4.1. Filtro de partículas (PF)

El filtro de partículas (PF), al igual que el LKF, estima recursivamente la función de densidad de probabilidad posterior (PDF) del vector de estado desconocido x_k , dadas las mediciones $z_{(1:k)}$ donde $k \in \mathbb{N}$ representa el instante de tiempo [29]. El PF tiene como objetivo representar la PDF posterior $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ en el instante k mediante el uso de partículas, es decir, un conjunto de N_p muestras aleatorias con sus respectivos pesos, descritos en la ecuación (22) [30].

$$\{\mathbf{x}_k^{(i)}, w_k^{(i)}\}_{i=1}^{N_p}, \quad \sum_{i=1}^{N_p} w_k^{(i)} = 1 \quad (22)$$

Para formular la PDF posterior en cada instante de tiempo, el PF muestrea secuencialmente las N_p partículas a partir de una PDF alternativa $q(\cdot)$, denominada densidad de importancia [31]. Por lo tanto, $p(\mathbf{x}_k | \mathbf{z}_{1:k})$ puede modelarse como [29]:

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) \approx \sum_{i=1}^{N_p} \mathbf{w}_k^{(i)} \delta(\mathbf{x}_k - \mathbf{x}_k^{(i)}), \quad (23)$$

donde el peso de cada partícula puede actualizarse mediante:

$$\mathbf{w}_k^{(i)} = \mathbf{w}_{k-1}^{(i)} \frac{p(\mathbf{z}_k | \mathbf{x}_k^{(i)}) p(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k^{(i)} | \mathbf{x}_{0:k-1}^{(i)}, \mathbf{z}_{1:k})}. \quad (24)$$

Es crucial tener en cuenta dos consideraciones. La primera está relacionada con la aproximación dada por la ecuación (23), la cual converge hacia la verdadera PDF posterior $p(\mathbf{x}_k|\mathbf{z}_{1:k})$ cuando $N_p \rightarrow \infty$. La segunda se refiere al diseño y al desempeño de la implementación del PF, que depende de una elección apropiada de la densidad de importancia $q(\cdot)$. Por ejemplo, en la implementación del PF, frecuentemente se propone la siguiente formulación [32]:

$$q(\mathbf{x}_k|\mathbf{x}_{k-1}^{(i)}, \mathbf{z}_k) = p(\mathbf{x}_k|\mathbf{x}_{k-1}^{(i)}), \quad (25)$$

donde la PDF $q(\cdot)$ es igual a la PDF previa, lo que permite actualizar el vector de pesos $\mathbf{w}_k^{(i)}$ mediante la función de verosimilitud, como se detalla en la ecuación (26):

$$\mathbf{w}_k^{(i)} = \mathbf{w}_{k-1}^{(i)} p(\mathbf{z}_k|\mathbf{x}_k^{(i)}). \quad (26)$$

2.4.2. Evolución artificial para la estimación en línea de parámetros

La evolución artificial es una estrategia para la estimación conjunta de estados y parámetros dentro de un marco de filtrado de partículas [33]. Es particularmente útil cuando algunos parámetros del modelo son desconocidos o varían lentamente en el tiempo [34]. Este enfoque se implementa mediante la ampliación del vector de estado para incluir el vector de parámetros, el cual se trata como una variable de estado adicional cuya evolución se describe mediante un proceso de caminata aleatoria [34]. Bajo esta formulación, el modelo de proceso aumentado puede expresarse de la siguiente manera:

$$\mathbf{x}_k = \mathbf{f}_k(\mathbf{x}_{k-1}, \boldsymbol{\theta}_{k-1}, \mathbf{u}_{k-1}, \boldsymbol{\omega}_{k-1}), \quad (27a)$$

$$\boldsymbol{\theta}_k = \boldsymbol{\theta}_{k-1} + \boldsymbol{\eta}_{k-1}. \quad (27b)$$

Debe señalarse que la varianza del proceso de caminata aleatoria debe seleccionarse cuidadosamente, ya que una elección inapropiada puede afectar significativamente las estimaciones de la PDF posterior [35]. Para abordar este problema, la literatura reporta varias técnicas para ajustar la varianza de la caminata aleatoria

de acuerdo con criterios específicos. Entre los ejemplos se incluyen el suavizado por kernel [33] y los bucles externos de corrección por retroalimentación (OFCL) [36], los cuales han sido adoptados en implementaciones basadas en PF que dependen de la evolución artificial de parámetros.

2.4.3. Implementación de la estimación del SOC basada en PF

Primero, el modelo de transición de estados se define de la siguiente manera [28]:

$$x_1(k+1) = x_1(k) + \omega_1(k) \quad (28)$$

$$x_2(k+1) = x_2(k) - v(k) \cdot i(k) \cdot \Delta t \cdot E_{\text{crit}}^{-1} + \omega_2(k). \quad (29)$$

donde x_1 representa la resistencia interna de la batería, tratada como un parámetro desconocido que debe ser estimado, y x_2 denota el SOC. La implementación del PF considerada en este estudio utiliza el siguiente modelo de medición de voltaje:

$$\begin{aligned} v(k) = & v_L + (v_{OC} - v_L) \cdot e^{\gamma \cdot (x_2(k)-1)} + \\ & \alpha \cdot v_L \cdot (x_2(k) - 1) + \\ & (1 - \alpha) \cdot v_L \cdot \left(e^{-\beta} - e^{-\beta \sqrt{x_2(k)}} \right) - \\ & i(k) \cdot x_1(k) + \eta(k) \end{aligned} \quad (30)$$

El ruido del proceso (ω_1 y ω_2) y el ruido de medición (η) se consideran en la formulación del espacio de estados.

En la implementación del PF, las condiciones iniciales (x_1 y x_2), los términos de ruido del proceso (ω_1 y ω_2) y el ruido de medición (η) se modelan mediante distribuciones gaussianas, es decir, $x_1(0) \sim \mathcal{N}(\mu_1, \sigma_1^2)$, $x_2(0) \sim \mathcal{N}(\mu_2, \sigma_2^2)$, $\omega_1 \sim \mathcal{N}(0, \sigma_{\omega_1}^2)$, $\omega_2 \sim \mathcal{N}(0, \sigma_{\omega_2}^2)$, y $\eta \sim \mathcal{N}(0, \sigma_{\eta}^2)$. Además, se utilizó una población de $N_p = 300$ partículas, y se asignó inicialmente a cada partícula i un peso $W_i = 1/N_p$. La configuración de parámetros del PF se resume en la Tabla 2.

Tabla 2. Parámetros de configuración del filtro de partículas

Parámetro	Símbolo	Valor
Número de partículas	N_p	300
Media inicial de la resistencia interna	μ_1	0.12 Ω
Media inicial del SOC	μ_2	1.00
Desviación estándar inicial de la resistencia interna	σ_1	0.005
Desviación estándar inicial del SOC	σ_2	0.02
Desviación estándar de ω_1	σ_{ω_1}	0.001 Ω
Desviación estándar de ω_2	σ_{ω_2}	0.0001
Desviación estándar del ruido de medición	σ_{η}	0.001 V

2.5. Caso de estudio

Para estimar el SOC de la batería mediante KF y PF, se empleó un ciclo de conducción HWFET. Se aplicó a la batería de iones de litio 26650 con química LCO un perfil de corriente de descarga escalado para este ciclo (véase la Figura 3). Este perfil fue elegido porque presenta un comportamiento variable, dado que un perfil de corriente constante no es adecuado para caracterizar la dinámica del SOC de la batería.




Figura 3. Perfil de corriente HWFET escalado para una batería LCO de 4 Ah [13].

3. Resultados y discusión

Esta sección presenta los resultados de la implementación de los enfoques propuestos para estimar el SOC de la batería. Las Figuras 4, 5, 6 y 7 presentan la estimación del SOC obtenida mediante el filtro de Kalman, el filtro de partículas, el enfoque random forest y el enfoque KNN, respectivamente. Los dos últimos enfoques presentan una menor calidad de ajuste debido a que requieren un mayor volumen de datos de entrenamiento. Además, los hiperparámetros del modelo podrían optimizarse mediante otras técnicas, como los modelos híbridos.




Figura 4. Estimación del SOC mediante el filtro de Kalman utilizando el perfil de conducción HWFET.

El algoritmo PF presenta un desempeño robusto debido a su capacidad para capturar comportamientos no lineales y realizar la estimación en línea simultáneamente. Asimismo, los algoritmos bayesianos son más complejos de implementar, y su robustez depende de diversos factores, tales como la ecuación del proceso, los ruidos del proceso y la medición, entre otros.




Figura 5. Estimación del SOC mediante el filtro de partículas utilizando el perfil de conducción HWFET.




Figura 6. Estimación del SOC mediante random forest basada en EIS.

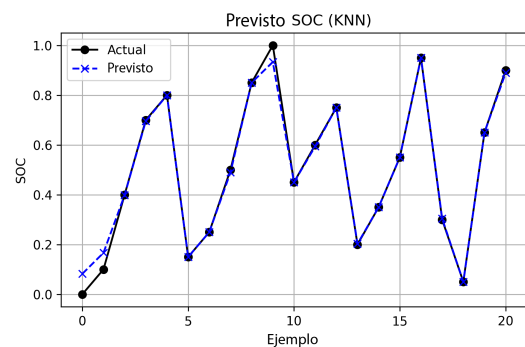


Figura 7. Estimación del SOC mediante KNN basada en EIS.

Además, las Figuras 8 y 9 muestran la estimación del voltaje mediante la aplicación del filtro de Kalman y del filtro de partículas, respectivamente. El PF presenta un mejor ajuste al comparar el voltaje real y el estimado.




Figura 8. Estimación del voltaje mediante el filtro de Kalman utilizando el perfil de conducción HWFET.




Figura 9. Estimación del voltaje mediante el filtro de partículas utilizando el perfil de conducción HWFET.

Una ventaja de utilizar la evolución artificial del parámetro de resistencia de la batería es que el valor inicial se ajusta de manera continua dentro del modelo PF, como se muestra en la Figura 10.




Figura 10. Evolución artificial de la resistencia de la batería (en ohmios).

Se realizó una comparación general de los modelos desarrollados en términos de las métricas RMSE y R^2 , como se muestra en la Tabla 3. En general, los enfoques bayesianos alcanzan un mejor desempeño que los métodos basados en EIS. Debido a la naturaleza discreta de las mediciones de EIS, los modelos RF y KNN predicen el SOC únicamente en los puntos de operación específicos donde se adquirieron los espectros de impedancia, en lugar de proporcionar una estimación continua en el tiempo. El PF presenta las mejores métricas debido a su estructura no lineal, que permite capturar mejor las variaciones del SOC.

Tabla 3. RMSE y R^2 para la estimación del SOC

Algoritmo	RMSE	R^2
KF	0.0187	0.9891
PF	0.0164	0.9968
RF	0.0644	0.9548
KNN	0.0276	0.9917

El análisis comparativo de los métodos de estimación del estado de carga (SOC) para baterías de iones de litio ha destacado ventajas y limitaciones clave de cada enfoque. El filtro de Kalman (KF) demostró un desempeño confiable en escenarios de estimación lineal, pero presentó sensibilidad a las inexactitudes del modelo y al ruido, lo que podría conducir a errores durante períodos prolongados de operación. Por el contrario, el filtro de partículas (PF) mostró robustez en el manejo de no linealidades e incertidumbres, lo que lo hace particularmente adecuado para la estimación en tiempo real del SOC en entornos dinámicos. Sin embargo, su complejidad computacional sigue siendo un desafío, por lo que requiere implementaciones optimizadas para su despliegue práctico en sistemas de gestión de baterías (BMS). En el presente enfoque, la formulación del PF, incluidas la ecuación del proceso y la ecuación de medición, así como los parámetros de la batería, fueron adoptados del trabajo de [28]. En dicho estudio, se alcanzó una mayor precisión en la estimación del SOC mediante una estimación fuera de línea de los parámetros de la ecuación del proceso. Otra técnica que podría considerarse para capturar el comportamiento no lineal es el EKF, el cual se utiliza en vehículos eléctricos para ofrecer una estimación del SOC en tiempo real bajo diferentes condiciones operativas, lo que conduce a un mejor desempeño del BMS [37]. Otras condiciones operativas y parámetros que deben explorarse pueden incluir otros ciclos de conducción, la temperatura, los efectos de envejecimiento de la batería, el frenado regenerativo y diferentes ecuaciones de proceso en el modelo.

Por otro lado, los enfoques basados en aprendizaje automático (RF y KNN) son menos prácticos que los enfoques bayesianos. RF y KNN predicen el SOC a partir de mediciones de EIS, pero estos experimentos requieren equipos complejos y no son adecuados para implementaciones en línea. Los resultados están restringidos a los valores de SOC para los cuales existen datos experimentales de EIS. Además, los algoritmos de aprendizaje automático requieren el ajuste de distintos parámetros. Métricas similares a las mostradas en la Tabla 3 para la predicción del SOC mediante RF y KNN fueron reportadas en [24].

Los resultados indican que los enfoques basados en modelos, tales como KF y PF, continúan siendo esenciales debido a su desarrollo y aplicabilidad en tiempo real, mientras que las técnicas basadas en aprendizaje automático poseen potencial para un mayor perfeccionamiento. Los trabajos futuros deberían explorar

metodologías híbridas que puedan aprovechar las capacidades de ambos enfoques, al integrar técnicas de corrección en línea con modelos de aprendizaje profundo para lograr una estimación del SOC robusta y adaptativa.

La Figura 11 muestra el RMSE de la estimación del SOC como una función del factor de escala aplicado individualmente a cada parámetro de ruido. Cada parámetro fue variado individualmente mediante la multiplicación de su valor nominal por factores de escala, mientras que todos los parámetros restantes se mantuvieron en su configuración nominal. El PF muestra baja sensibilidad a σ_{ω_1} y σ_{η} , con un RMSE estable de aproximadamente 0.016–0.019 en todo el rango evaluado. El ruido del proceso del SOC σ_{ω_2} presenta la mayor sensibilidad: valores por debajo de la configuración nominal provocan que el RMSE exceda 0.059, ya que una transición de estado excesivamente restringida impide una adecuada diversidad de partículas. De manera similar, la varianza del núcleo de verosimilitud σ_v^2 degrada la precisión de la estimación en ambos extremos. En general, la configuración nominal, definida por un factor de escala igual a 1.0 con los parámetros seleccionados, produce el menor RMSE para todos los parámetros.

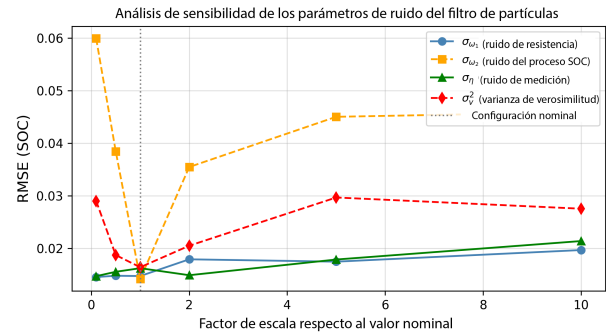


Figura 11. Análisis de sensibilidad de los parámetros de ruido del PF

Considerando que la principal aplicabilidad de este estudio está orientada al BMS de la batería, se discuten algunos aspectos importantes de este sistema. La Tabla 4 presenta el costo computacional y la viabilidad de implementación embebida para los diferentes enfoques de estimación del SOC de la batería. Los estimadores basados en el algoritmo KF destacan debido a su precisión, su consumo de memoria bajo o medio y su alta viabilidad de integración en sistemas embebidos. Por otro lado, los modelos de aprendizaje automático basados en EIS no están suficientemente desarrollados para implementarse en sistemas embebidos, a pesar de su alta precisión.

Tabla 4. Análisis comparativo del costo computacional y la viabilidad de implementación embebida de los métodos de estimación del SOC

Método	Precisión típica	Costo de cálculo	Uso de memoria	Tiempo de inferencia	Viabilidad embebida	Plataforma validada
LKF	Alta ($\leq 2\%$)	Baja-Media	Baja-Media	<1 ms	Alta	STM32, ARM Cortex-M [38, 39]
PF	Muy alta ($\leq 1\%$)	Muy alta	Alta	10–100 ms (por partícula)	Baja	FPGA, STM32F4 [40, 41]
KNN	Alto	Alto	Muy alto	Variable	Bajo	Solo offline
RF	Alto	Medio	Medio–Alto	1–10 ms	Medio	Solo offline
(Basado en EIS)	($\leq 3\%$)					

4. Conclusiones

Este estudio ha demostrado que los métodos de estimación del estado de carga (SOC) varían significativamente en precisión, costo computacional y adaptabilidad a los comportamientos no lineales de la batería asociados con el ciclo de conducción aplicado. El enfoque KF proporciona estimaciones confiables bajo supuestos lineales, pero enfrenta desafíos ante modelos no lineales y ruido. No obstante, el método KF presenta alta viabilidad para su implementación en sistemas embebidos orientados a la predicción del SOC. El algoritmo PF presenta robustez en condiciones dinámicas. Por otro lado, debido a la dependencia de equipos

específicos, los algoritmos de aprendizaje automático basados en datos de EIS aplicados en este estudio no son capaces de predecir en línea el comportamiento del SOC.

Las investigaciones futuras deberían enfocarse en optimizar modelos híbridos de estimación del SOC que integren técnicas tradicionales de filtrado con otros enfoques de aprendizaje automático. Adicionalmente, deberían realizarse esfuerzos para mejorar la eficiencia computacional en aplicaciones en tiempo real y ampliar los conjuntos de datos de entrenamiento con el fin de mejorar la capacidad de generalización de los modelos basados en datos. La validación bajo condiciones reales de operación en vehículos eléctricos y sistemas de al-

macenamamiento de energía es necesaria para confirmar la aplicabilidad práctica y la confiabilidad de estos métodos de estimación y predicción.

Rol de los autores

- **Edwin Paccha-Herrera:** conceptualización, metodología, software y escritura – borrador original.
- **Ángel Recalde:** conceptualización, análisis formal y escritura – revisión y edición.
- **Francisco Jaramillo-Montoya:** metodología, validación y escritura – revisión y edición.
- **Darwin Tapia-Peralta:** análisis formal, visualización y recursos.

Referencias

- [1] R. Hema and M. J. Venkatarangan, “Advancing sustainable development: Introducing a novel fast charging technique for li-ion batteries with supercapacitor integration,” *Computers and Electrical Engineering*, vol. 120, p. 109810, 2024. [Online]. Available: <https://doi.org/10.1016/j.compeleceng.2024.109810>
- [2] D. V. S. R. Sesidhar, C. Badachi, and R. C. Green II, “A review on data-driven SOC estimation with Li-ion batteries: Implementation methods & future aspirations,” *Journal of Energy Storage*, vol. 72, p. 108420, 2023. [Online]. Available: <https://doi.org/10.1016/j.est.2023.108420>
- [3] Y. Tavakol-Moghaddam, M. Boroushaki, and M. Astaneh, “Reinforcement learning for battery energy management: A new balancing approach for Li-ion battery packs,” *Results in Engineering*, vol. 23, p. 102532, 2024. [Online]. Available: <https://doi.org/10.1016/j.rineng.2024.102532>
- [4] O. Demirci, S. Taskin, E. Schaltz, and B. Acar Demirci, “Review of battery state estimation methods for electric vehicles - Part I: SOC estimation,” *Journal of Energy Storage*, vol. 87, p. 111435, 2024. [Online]. Available: <https://doi.org/10.1016/j.est.2024.111435>
- [5] Q. Wang, J. Wang, P. Zhao, J. Kang, F. Yan, and C. Du, “Correlation between the model accuracy and model-based SOC estimation,” *Electrochimica Acta*, vol. 228, pp. 146–159, 2017. [Online]. Available: <https://doi.org/10.1016/j.electacta.2017.01.057>
- [6] A. Tabine, E. M. Laadissi, H. Mastouri, A. Elachhab, S. Bouzaid, and A. Hajjaji, “A novel fitting polynomial approach for an accurate SOC estimation in Li-ion batteries in view of temperature variations,” *Results in Engineering*, p. 103962, 2025. [Online]. Available: <https://doi.org/10.1016/j.rineng.2025.103962>
- [7] C. Zou, L. Zhang, X. Hu, Z. Wang, T. Wik, and M. Pecht, “A review of fractional-order techniques applied to lithium-ion batteries, lead-acid batteries, and supercapacitors,” *Journal of Power Sources*, vol. 390, pp. 286–296, 2018. [Online]. Available: <https://doi.org/10.1016/j.jpowsour.2018.04.033>
- [8] C. Xu, T. Cleary, and H. K. Fathy, “Improving Li-S battery SOC estimation using an SOC-dependent resistance model,” *IFAC-PapersOnLine*, vol. 56, no. 3, pp. 439–444, 2023, 3rd Modeling, Estimation and Control Conference MECC 2023. [Online]. Available: <https://doi.org/10.1016/j.ifacol.2023.12.063>
- [9] H. Ren, L. Jia, L. Yin, C. Dang, and Z. Chen, “Research on battery pack SOC consistency based on the electric-thermal-fluid coupling model,” *Journal of Energy Storage*, vol. 97, p. 112924, 2024. [Online]. Available: <https://doi.org/10.1016/j.est.2024.112924>
- [10] A. C. Lazanas and M. I. Prodromidis, “Electrochemical impedance spectroscopy—A tutorial,” *ACS Measurement Science Au*, vol. 3, no. 3, pp. 162–193, 2023. [Online]. Available: <https://doi.org/10.1021/acsmeasuresciau.2c00070>
- [11] H. Mustafa, C. Bourelly, M. Vitelli, F. Milano, M. Molinara, and L. Ferrigno, “SOC estimation on Li-ion batteries: A new EIS-based dataset for data-driven applications,” *Data in Brief*, vol. 57, p. 110947, 2024. [Online]. Available: <https://doi.org/10.1016/j.dib.2024.110947>
- [12] C. Wang, M. Yang, X. Wang, Z. Xiong, F. Qian, C. Deng, C. Yu, Z. Zhang, and X. Guo, “A review of battery SOC estimation based on equivalent circuit models,” *Journal of Energy Storage*, vol. 110, p. 115346, 2025. [Online]. Available: <https://doi.org/10.1016/j.est.2025.115346>
- [13] E. Paccha-Herrera, W. R. Calderón-Muñoz, M. Orchard, F. Jaramillo, and K. Medjaher, “Thermal modeling approaches for a LiCoO₂ lithium-ion battery—A comparative study with experimental validation,” *Batteries*, vol. 6, no. 3, 2020. [Online]. Available: <https://doi.org/10.3390/batteries6030040>
- [14] E. Almaita, S. Alshkoor, E. Abdelsalam, and F. Almomani, “State of charge estimation for a

- group of lithium-ion batteries using long short-term memory neural network,” *Journal of Energy Storage*, vol. 52, p. 104761, 2022. [Online]. Available: <https://doi.org/10.1016/j.est.2022.104761>
- [15] M. K. Al-Alawi, A. Jaddoa, J. Cugley, and H. Hassanin, “A novel enhanced SOC estimation method for lithium-ion battery cells using cluster-based LSTM models and centroid proximity selection,” *Journal of Energy Storage*, vol. 97, p. 112866, 2024. [Online]. Available: <https://doi.org/10.1016/j.est.2024.112866>
- [16] G. Chen, W. Peng, and F. Yang, “An LSTM-SA model for SOC estimation of lithium-ion batteries under various temperatures and aging levels,” *Journal of Energy Storage*, vol. 84, p. 110906, 2024. [Online]. Available: <https://doi.org/10.1016/j.est.2024.110906>
- [17] Z. Cui, W. Hu, G. Zhang, Z. Zhang, and Z. Chen, “An extended Kalman filter based SOC estimation method for Li-ion battery,” *Energy Reports*, vol. 8, pp. 81–87, 2022, iCPE 2021 - The 2nd International Conference on Power Engineering. [Online]. Available: <https://doi.org/10.1016/j.egy.2022.02.116>
- [18] Y. Chen, R. Li, Z. Sun, L. Zhao, and X. Guo, “SOC estimation of retired lithium-ion batteries for electric vehicle with improved particle filter by H-infinity filter,” *Energy Reports*, vol. 9, pp. 1937–1947, 2023. [Online]. Available: <https://doi.org/10.1016/j.egy.2023.01.018>
- [19] N. Meddings, M. Heinrich, F. Overney, J.-S. Lee, V. Ruiz, E. Napolitano, S. Seitz, G. Hinds, R. Raccichini, M. Gaberšček, and J. Park, “Application of electrochemical impedance spectroscopy to commercial Li-ion cells: A review,” *Journal of Power Sources*, vol. 480, p. 228742, 2020. [Online]. Available: <https://doi.org/10.1016/j.jpowsour.2020.228742>
- [20] E. Buchicchio, A. De Angelis, F. Santoni, P. Carbone, F. Bianconi, and F. Smeraldi, “Battery SOC estimation from EIS data based on machine learning and equivalent circuit model,” *Energy*, vol. 283, p. 128461, 2023. [Online]. Available: <https://doi.org/10.1016/j.energy.2023.128461>
- [21] Y. Miao and Z. Gao, “Estimation for state of charge of lithium-ion batteries by adaptive fractional-order unscented Kalman filters,” *Journal of Energy Storage*, vol. 51, p. 104396, 2022. [Online]. Available: <https://doi.org/10.1016/j.est.2022.104396>
- [22] A. Barai, K. Uddin, W. D. Widanage, A. McGordon, and P. Jennings, “A study of the influence of measurement timescale on internal resistance characterisation methodologies for lithium-ion cells,” *Scientific Reports*, vol. 8, no. 1, pp. 1–13, 2018. [Online]. Available: <https://doi.org/10.1038/s41598-017-18424-5>
- [23] H. Thomas and M. H. Weatherspoon, “Capacity and state-of-health prediction of lithium-ion batteries using reduced equivalent circuit models,” *Batteries*, vol. 11, no. 4, 2025. [Online]. Available: <https://doi.org/10.3390/batteries11040162>
- [24] X. Zhang, L. Zhang, J. Wu, W. Bai, H. Dai, H. Lin, F. Zhang, and Y. Yang, “SOC estimation of lithium-ion batteries using equivalent circuit model and Nyquist plots from EIS data: A machine learning approach,” *Journal of Electroanalytical Chemistry*, vol. 987, p. 119093, 2025. [Online]. Available: <https://doi.org/10.1016/j.jelechem.2025.119093>
- [25] D. Simon, *Optimal State Estimation: Kalman, H-Infinity, and Nonlinear Approaches*. John Wiley & Sons, 2006. [Online]. Available: <http://doi.org/10.1002/0470045345>
- [26] P. Zarchan and H. Musoff, *Fundamentals of Kalman Filtering: A Practical Approach*, 4th ed. American Institute of Aeronautics and Astronautics, Inc., 2015. [Online]. Available: <https://doi.org/10.2514/4.102776>
- [27] M. S. Grewal and A. P. Andrews, *Kalman Filtering: Theory and Practice Using MATLAB*, 3rd ed. John Wiley & Sons, 2008. [Online]. Available: <https://doi.org/10.1002/9780470377819>
- [28] D. Pola, H. Navarrete, M. Orchard, R. Rabie, M. Cerda, B. Olivares, J. Silva, P. Espinoza, and A. Perez, “Particle-filtering-based discharge time prognosis for lithium-ion batteries with a statistical characterization of use profiles,” *IEEE Transactions on Reliability*, vol. 64, pp. 1–11, 2015. [Online]. Available: <https://doi.org/10.1109/TR.2014.2385069>
- [29] M. S. Arulampalam, S. Maskell, N. Gordon, and T. Clapp, “A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking,” *IEEE Trans. Signal Process.*, vol. 50, no. 2, pp. 174–188, 2002. [Online]. Available: <https://doi.org/10.1109/78.978374>
- [30] C. Díaz, V. Quintero, A. Pérez, F. Jaramillo, C. Burgos-Mellado, H. Rozas, M. E. Orchard, D. Sáez, and R. Cárdenas, “Particle-filtering-based prognostics for the state of maximum power available in lithium-ion batteries at electromobility applications,” *IEEE Trans. Veh. Technol.*, vol. 69, no. 7, pp. 7187–7200, 2020. [Online]. Available: <https://doi.org/10.1109/TVT.2020.2993949>

- [31] M. Zajac, “Online fault detection of a mobile robot with a parallelized particle filter,” *Neurocomputing.*, vol. 126, pp. 151–165, 2014. [Online]. Available: <https://doi.org/10.1016/j.neucom.2012.11.049>
- [32] M. Sami Fadali, *Introduction to random signals, estimation theory, and Kalman filtering*, 1st ed. Springer Singapore, 2024. [Online]. Available: <https://doi.org/10.1007/978-981-99-8063-5>
- [33] A. Tulsyan, B. Huang, R. Bhushan Gopaluni, and J. Fraser Forbes, “On simultaneous on-line state and parameter estimation in non-linear state-space models,” *J. Process Control.*, vol. 23, no. 4, pp. 516–526, 2013. [Online]. Available: <https://doi.org/10.1016/j.jprocont.2013.01.010>
- [34] Z. Hong, L. Xu, and J. Chen, “Artificial evolution based cost-reference particle filter for nonlinear state and parameter estimation in process systems with unknown noise statistics and model parameters,” *J. Taiwan Inst. Chem. Eng.*, vol. 112, pp. 377–387, 2020. [Online]. Available: <https://doi.org/10.1016/j.jtice.2020.04.009>
- [35] Y. Hu, P. Baraldi, F. Di Maio, and E. Zio, “Online performance assessment method for a model-based prognostic approach,” *IEEE Trans. Reliab.*, vol. 65, no. 2, pp. 718–735, 2016. [Online]. Available: <https://doi.org/10.1109/TR.2015.2500681>
- [36] M. E. Orchard, F. A. Tobar, and G. J. Vachtsevanos, “Outer Feedback Correction Loops in Particle Filtering-based Prognostic Algorithms: Statistical Performance Comparison,” *Stud. Informatics Control.*, vol. 18, no. 4, pp. 295–304, 2009. [Online]. Available: <https://upsalesiana.ec/ing36ar10r36>
- [37] M. O. Oloyede, G. A. Akpakwu, H. C. Myburgh, A. De Freitas, and T. Kunatsa, “A review on state-of-charge estimation methods, energy storage technologies and state-of-the-art simulators: Recent developments and challenges,” *World Electric Vehicle Journal*, vol. 15, no. 9, 2024. [Online]. Available: <https://doi.org/10.3390/wevj15090381>
- [38] A. Valade, P. Acco, P. Grabolosa, and J.-Y. Fourniols, “A study about kalman filters applied to embedded sensors,” *Sensors*, vol. 17, no. 12, 2017. [Online]. Available: <https://doi.org/10.3390/s17122810>
- [39] G. Nishanth, M. M. Krishnan, B. Parandhaman, and J. Harinarayanan, “Hardware implementation of EKF based SOC estimate for lithium-ion batteries in electric vehicle applications,” *Scientific Reports*, vol. 15, no. 1, p. 15551, 2025. [Online]. Available: <https://doi.org/10.1038/s41598-025-99931-8>
- [40] J. Michalski, M. Retinger, P. Koziarski, and J. Zietkiewicz, “Temperature control unit—modeling and implementation of a particle filter on a microcontroller,” *Applied Sciences*, vol. 12, no. 15, 2022. [Online]. Available: <https://doi.org/10.3390/app12157631>
- [41] J. Schönefeld and D. Möller, “Mathematical aspects of the implementation of particle filters on FPGA,” *IFAC Proceedings Volumes*, vol. 45, no. 2, pp. 1243–1248, 2012, 7th Vienna International Conference on Mathematical Modelling. [Online]. Available: <https://doi.org/10.3182/20120215-3-AT-3016.00220>