



# POSGRADOS

---

## MAESTRÍA EN INGENIERÍA AUTOMOTRIZ CON MENCIÓN EN NEGOCIOS AUTOMOTRICES

RPC-SO-36-NO.825-2021

OPCIÓN DE TITULACIÓN:

ARTÍCULOS PROFESIONALES DE ALTO NIVEL

TEMA:

EVALUACIÓN DEL RENDIMIENTO DEL  
VEHÍCULO ELÉCTRICO EN CUENCA A  
TRAVÉS DEL MODELADO DE LA BATERÍA

AUTOR:

MARCO VINICIO DELEG VILLA

DIRECTOR:

JUAN DIEGO VALLADOLID QUITOISACA

CUENCA – ECUADOR  
2025

**Autor:****Marco Vinicio Deleg Villa**

Ingeniero Mecánico.

Candidato a Magíster en Ingeniería Automotriz con Mención en Negocios Automotrices por la Universidad Politécnica Salesiana – Sede Cuenca.

mdelegv@est.ups.edu.ec

**Dirigido por:****Juan Diego Valladolid Quitoisaca**

Ingeniero Electrónico.

Magister en Control y Automatización

Doctor en Ingeniería

jvalladolid@ups.edu.ec

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

**DERECHOS RESERVADOS**

2025 © Universidad Politécnica Salesiana.

CUENCA – ECUADOR – SUDAMÉRICA

MARCO VINICIO DELEG VILLA

Evaluación del rendimiento del vehículo eléctrico en Cuenca a través del modelado de la batería

## **DEDICATORIA**

A mi querida mamá, por su amor incondicional y su incansable apoyo en cada paso de mi vida. Eres mi ejemplo de fortaleza y perseverancia.

A mi adorada hija, fuente de mi amor, inspiración y alegría. Todo lo que hago, lo hago pensando en brindarte un futuro lleno de oportunidades.

A mi familia, por estar siempre a mi lado, brindándome su amor, comprensión y apoyo incondicional. Este logro es tanto mío como suyo.

Con todo mi amor y gratitud.

## **AGRADECIMIENTO**

Quiero expresar mi más sincero agradecimiento a aquellas instituciones y personas que han sido fundamentales en la realización de este logro académico.

Al Dr. Juan Diego Valladolid Quitoisca, mi tutor, por su valiosa orientación, dedicación y paciencia a lo largo de este proceso. Su conocimiento y consejos han sido cruciales para alcanzar este objetivo.

A la Universidad Politécnica Salesiana, por brindarme la oportunidad de crecer académica y profesionalmente en un entorno de excelencia y aprendizaje continuo.

A la Empresa Eléctrica Regional Centro Sur C.A. por su apoyo y colaboración, facilitando los recursos necesarios para llevar a cabo esta investigación.

A todos, mi más profundo agradecimiento.

Con gratitud.

# TABLA DE CONTENIDO

---

Resumen .....	7
Abstract .....	8
1. Introducción .....	9
2. Materiales y metodología.....	12
2.1 Adquisición de datos.....	12
2.2 Modelo SOC .....	13
2.3 Modelo de batería .....	14
3. Resultados y discusión.....	16
4. Conclusiones.....	21
Referencias .....	23

# EVALUACIÓN DEL RENDIMIENTO DEL VEHÍCULO ELÉCTRICO EN CUENCA A TRAVÉS DEL MODELADO DE LA BATERÍA

AUTOR(ES):

MARCO VINICIO DELEG VILLA

## RESUMEN

---

Este artículo presenta un estudio sobre el rendimiento de un vehículo eléctrico (VE) en la ciudad de Cuenca, Ecuador, que se caracteriza por su altitud, baja densidad del aire y clima frío. Se utilizó un modelo de batería de Thevenin (2RC) para simular el comportamiento de la batería de un VE Skywell ET5 en tres rutas diferentes dentro de la ciudad. Los datos experimentales de corriente, voltaje, SOC y temperatura de la batería fueron recopilados mediante un escáner de diagnóstico avanzado y utilizados para la validación del modelo.

Los resultados mostraron una alta correlación entre los valores de SOC y voltaje de recuperación medidos y simulados. Se observó que las condiciones de cada ruta, como el tráfico y la topografía, influyeron en el comportamiento energético del VE. Además, se comparó el error cuadrático medio (ECM) del modelo con otros métodos de estimación, mostrando una precisión comparable e incluso superior en algunas rutas.

El estudio demuestra que el modelo de Thevenin (2RC) representa con alta precisión las dinámicas de voltaje y SOC de la batería bajo condiciones variables. Los hallazgos destacan su potencial para optimizar la gestión energética de vehículos eléctricos en entornos con características similares a las de Cuenca.

**Palabras clave:**

Vehículo eléctrico; Modelado matemático; Simulación; Batería.

## ABSTRACT

---

This paper presents a study on the performance of an electric vehicle (EV) in the city of Cuenca, Ecuador, which is characterized by altitude, low air density, and cold weather. A Thevenin battery model (2RC) was used to simulate the battery behavior of a Skywell ET5 EV on three different routes within the city. Experimental current, voltage, SOC and battery temperature data were collected using an advanced diagnostic scanner and used for model validation.

The results showed a high correlation between measured and simulated SOC and recovery voltage values. It was observed that the conditions of each route, such as traffic and topography, influenced the energy behavior of the EV. In addition, the mean square error (MSE) of the model was compared with other estimation methods, showing comparable and even higher accuracy on some routes.

The study demonstrates that the Thevenin (2RC) model represents with high accuracy the voltage and SOC dynamics of the battery under varying conditions. The findings highlight its potential for optimizing electric vehicle energy management in environments with characteristics similar to those of Cuenca.

**Keywords:**

Electric vehicle; Mathematical modeling; Simulation; Battery.

# 1. INTRODUCCIÓN

---

El rendimiento de los VE no depende únicamente de la tecnología del motor o la capacidad de la batería. Factores como la estructura del vehículo, nuestras prácticas de conducción, la topografía y las condiciones ambientales también juegan un papel crucial (Donkers et al., 2020)(Sweeting et al., 2011). Por otra parte, el rendimiento, el estado del paquete de baterías y su dinámica no lineal puede influir significativamente en la eficiencia energética y la autonomía del VE (Fotouhi et al., 2016) (Liu et al., 2022).

Las baterías de iones de litio (Li-ion) se han convertido en la opción preferida por su alta densidad energética, larga vida útil y capacidad para soportar múltiples ciclos de carga (S. Rangarajan et al., 2022). No obstante, la temperatura de la batería es un factor crítico; variaciones extremas pueden afectar su rendimiento y durabilidad. Por ello, contar con sistemas avanzados de gestión de baterías (BMS) y controles térmicos es esencial para optimizar su funcionamiento y prolongar su vida útil (Mahmud et al., 2023).

Además de los factores internos de la batería, los ciclos de conducción juegan un rol clave en esta evaluación del rendimiento. Ciclos como el Urban Dynamometer Driving Schedule UDDS, que simulan la conducción urbana, demandan mayor torque a bajas velocidades, reduciendo la eficiencia (Huynh & Hsieh, 2018)(Kakouche et al., 2023). Las condiciones de la carretera también son determinantes; las pendientes ascendentes de solo un 3% pueden incrementar el consumo energético hasta un 50%, mientras que en las descendentes se observa una reducción del 80% gracias al frenado regenerativo (Al-Wreikat et al., 2021). Por otro lado, la conducción agresiva puede incrementar el consumo energético en un 22%. En cuanto a las condiciones ambientales, la conducción en bajas temperaturas (menores a 12°C) aumentan el consumo energético en comparación con temperaturas moderadas (Donkers et al., 2020).

Estudios recientes sobre el rendimiento de baterías en vehículos eléctricos han explorado modelos como el Thevenin, que alcanza errores de estimación del SOC menores al 0.014% (Susanna et al., 2019). Este modelo se destaca por su precisión en la simulación de descarga de la batería bajo diferentes demandas energéticas (Ramsey et al., 2020). Además, se ha demostrado que incluir las pérdidas por unión de cables (Aditya, 2023) y los efectos de la temperatura (Ding et al., 2019)(Valladolid et al., 2019) en los modelos, mejora la precisión en la estimación del SOC. Para la optimización de los parámetros del modelo, se han utilizado algoritmos como PSO (Peng et al., 2018) y filtro de Kalman (Hawsawi et al., 2023) logrando reducir el error de estimación del SOC a menos del 2% (Kim et al., 2020). (Shin et al., 2023) validaron experimentalmente modelos 1RC y 2RC con un bajo error cuadrático medio, demostrando su alta precisión en la simulación del comportamiento de las baterías.

Este estudio evalúa el rendimiento de un VE en Cuenca, Ecuador, ubicada a 2610 m.s.n.m., con condiciones de menor densidad de aire, baja presión, y un clima promedio de 14°C y 969 mm de precipitación anual (Seidel et al., 2019). Se utiliza el modelo de Thevenin (2RC) que simula con precisión las dinámicas de voltaje y SOC de la batería bajo condiciones variables. Datos experimentales de corriente, voltaje, SOC y temperatura, adquiridos mediante un escáner de diagnóstico avanzado en escenarios reales de conducción, validan el modelo y permiten una caracterización detallada del comportamiento de la batería. Los resultados destacan implicaciones clave para optimizar la gestión energética y orientar el diseño de infraestructuras en regiones similares.

Si bien los modelos existentes, como los circuitos equivalentes (1RC y 2RC) y los modelos electroquímicos P2D, han sido ampliamente utilizados para la estimación del estado de carga (SOC) en baterías de vehículos eléctricos (VE), su aplicación se limita en gran medida a condiciones controladas o ciclos de conducción estandarizados como UDDS y HWFET. Estas metodologías no consideran de forma integral las dinámicas no lineales introducidas por entornos urbanos reales, donde factores como la topografía variable, las bajas temperaturas y la intermitencia del tráfico generan fluctuaciones significativas en el voltaje y la temperatura de la

batería. Además, los modelos electroquímicos, aunque precisos, poseen una elevada demanda computacional que limita su implementación en tiempo real. Por otro lado, los modelos equivalentes simples, aunque menos exigentes computacionalmente, carecen de validación en escenarios donde las pendientes pronunciadas, las frenadas regenerativas y los ciclos de aceleración/desaceleración son predominantes. Este estudio aborda estas limitaciones al implementar y validar experimentalmente el modelo Thevenin 2RC, utilizando datos reales de corriente, voltaje, SOC y temperatura obtenidos en tres rutas urbanas de la ciudad de Cuenca, Ecuador. Dichas rutas permiten analizar con mayor precisión las dinámicas energéticas de la batería bajo condiciones operativas exigentes, lo que posiciona al modelo como una herramienta robusta y eficiente para estimar el SOC y optimizar la gestión energética en entornos complejos.

El artículo se organiza de la siguiente manera: La Sección II describe la metodología, incluyendo la aplicación del modelo, ecuaciones y proceso de simulación. La Sección III presenta los resultados de las simulaciones, mostrando métricas como autonomía, consumo energético y el error cuadrático medio (ECM) para evaluar la precisión del modelo, y compara los resultados con datos experimentales. Finalmente, la Sección IV presenta un análisis de las conclusiones del estudio, destacando las implicaciones para el rendimiento de los VE en Cuenca y la efectividad del modelo de Thevenin utilizado.

## 2. MATERIALES Y METODOLOGÍA

Este estudio adopta un enfoque cuantitativo para modelar y evaluar el rendimiento de las baterías de VE en el contexto urbano de Cuenca.

### 2.1 ADQUISICIÓN DE DATOS

Para obtener los datos del sistema de gestión de baterías (BMS) se utiliza un vehículo eléctrico Skywell ET5, modelo 2023, equipado con una batería ternaria de iones de litio, compuesta por 96 celdas conectadas en serie, que proporciona una capacidad total de 244 Ah (Jiangsu Skywell Automobile, 2021). Estos datos son recolectados a lo largo de tres rutas distintas realizadas en la ciudad de Cuenca, Azuay.

La combinación de estas rutas permite evaluar el desempeño del modelo en entornos con diferentes niveles de exigencia energética, replicando situaciones típicas de uso en ciudades con dinámicas vehiculares complejas. Estas rutas fueron definidas considerando factores como patrones de tráfico, topografía predominante y duración de la conducción, variables críticas en la evaluación del rendimiento energético de los vehículos eléctricos.

La Ruta 1 corresponde a una vía principal suburbana con topografía plana y tráfico vehicular moderado, lo que permite evaluar la eficiencia en condiciones de conducción estable y con mínimas oportunidades para el frenado regenerativo; esta ruta tuvo una duración de 733 segundos. La Ruta 2 se desarrolla en el centro histórico, una zona de alta densidad vehicular y paradas frecuentes debido al tráfico, con ligeras variaciones en la altitud que ofrecen múltiples oportunidades para aprovechar el frenado regenerativo; su duración fue de 872 segundos. Finalmente, la Ruta 3 recorre el trayecto del tranvía, conectando las zonas norte y sur de la ciudad a través de una vía extensa con pendientes significativas y tramos prolongados de conducción continua, lo que permite evaluar la descarga sostenida

de la batería en condiciones de mayor exigencia energética; esta ruta tuvo una duración de 4,559 segundos.

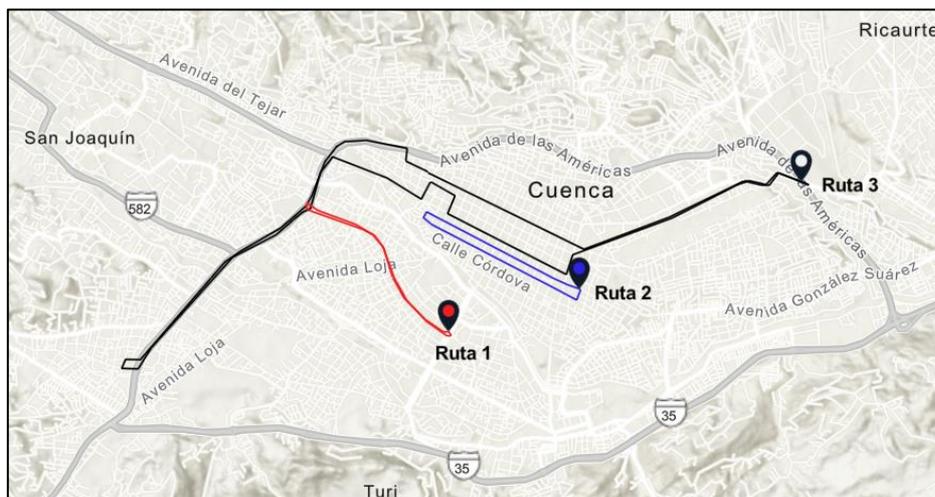


Figura 1. Rutas de recorrido.

## 2.2 MODELO SOC

El estado de carga (SOC, por sus siglas en inglés) representa el porcentaje de energía restante en la batería con respecto a su capacidad nominal y se expresa como se muestra en la ecuación (1).

$$SOC(t) = SOC(t_0) - \frac{\eta}{Q} \int_{t_0}^t i(t) \cdot dt + \varpi \quad (1)$$

Donde,  $i(t)$  es la corriente instantánea de la batería,  $Q$  es la capacidad nominal,  $\varpi$  corresponde a las pérdidas internas y el factor  $\eta$  representa el producto de parámetros que dependen del rendimiento, temperatura y número de ciclos de la batería. Considerando que la batería es nueva y no ha excedido los 25 ciclos de carga y que durante las pruebas realizadas la temperatura de las celdas no variaba entre 24°C y 27°C, el factor  $\varpi$  es inferior al 3% y el factor  $\eta$  tiende a 1. (Valladolid et al., 2019). Por lo tanto, la expresión del SOC se puede considerar como se muestra en la ecuación (2).

$$SOC(t) = SOC(t_0) - \frac{1}{Q} \int_{t_0}^t i(t) \cdot dt \quad (2)$$

En la Figura 2 se muestra el modelado del SOC, desarrollado en el software Simulink, que se utilizó para realizar la estimación. La estimación del SOC es fundamental para el funcionamiento eficiente y seguro de los vehículos eléctricos, ya que impacta directamente en las estrategias de carga, la previsión de autonomía y el rendimiento general del vehículo (Azis et al., 2019).

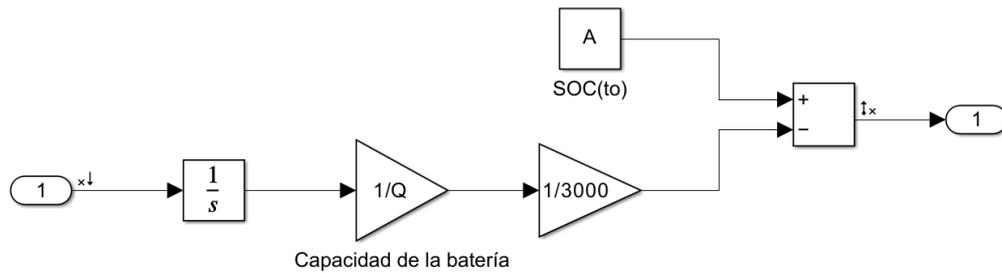


Figura 2. Modelo de SOC en Simulink

### 2.3 MODELO DE BATERÍA

El modelo 2RC de Thevenin configura la batería del VE con una fuente de voltaje de circuito abierto ( $V_{OC}$ ), una resistencia interna ( $R_0$ ) que refleja la caída de voltaje instantánea cuando se extrae corriente, y dos ramas RC en paralelo ( $R_1C_1$  y  $R_2C_2$ ) (Figura 3). La rama  $R_1C_1$  refleja los transitorios rápidos y la rama  $R_2C_2$  los transitorios más lentos, facilitando así una representación más fiel del comportamiento de la batería en distintas condiciones de operación. Esta configuración facilita la modelación del comportamiento dinámico de la batería. (Monsalve et al., 2022)(Belmajdoub et al., 2024).

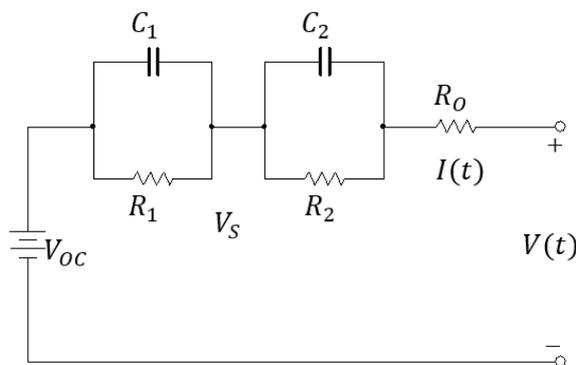


Figura 3. Modelo de batería Thevenin 2RC (Monsalve et al., 2022).

El término  $V(t)$  representa la tensión de salida de la batería y  $V_S$  corresponde a la tensión que existe en la red RC, y puede definirse como se ve en la ecuación (3) (Valladolid et al., 2019).

$$V(t) = V_{OC} + R_o \cdot I(t) + V_S \quad (3)$$

Para determinar  $V_{OC}$  se utiliza una regresión de quinto orden, como se muestra en (4).

$$V_{OC} = p_1 \cdot SOC^5 + p_2 \cdot SOC^4 + p_3 \cdot SOC^3 + p_4 \cdot SOC^2 + p_5 \cdot SOC + 100 \quad (4)$$

La Figura 4 muestra el modelo de  $V_{OC}$  implementado en el software Simulink, obteniendo los siguientes parámetros:  $p_1 = -8.52 \cdot 10^5$ ,  $p_2 = 1.56 \cdot 10^6$ ,  $p_3 = -1.05 \cdot 10^6$ ,  $p_4 = 3.04 \cdot 10^5$  y  $p_5 = -29592$ .

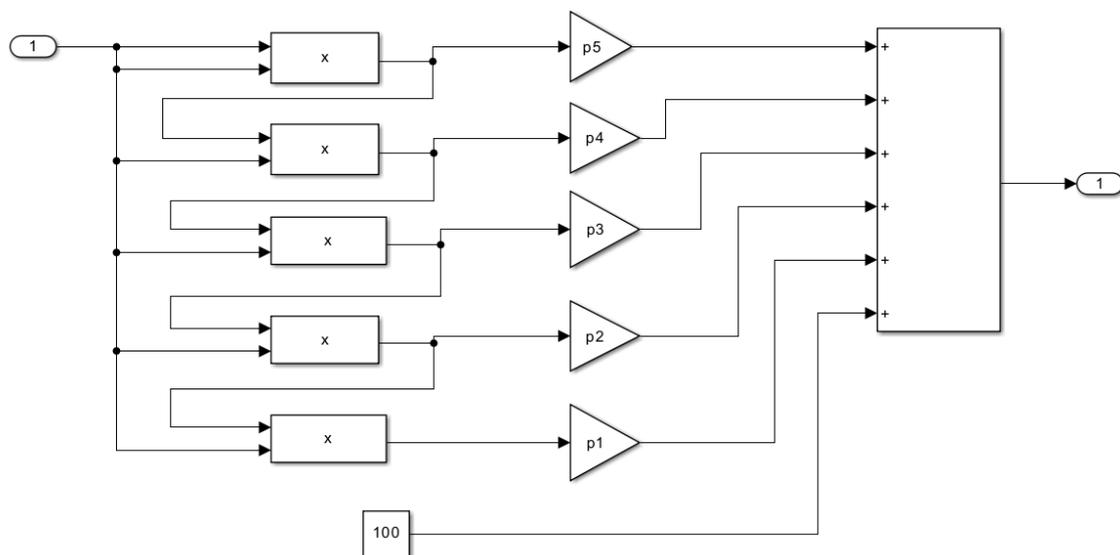


Figura 4. Modelo de  $V_{OC}(SOC)$ .

Se aplica un modelo de Thevenin a cada celda, lo cual implica la existencia de 96 redes RC conectadas en serie. Esta configuración incrementa la complejidad al intentar determinar los valores de los parámetros distribuidos R y C para cada elemento, que conforman el modelo completo de la batería. Para este modelo, se sustituye la red RC por una función de transferencia, que tiene como entrada la corriente de la batería  $I(s)$  y como salida  $V(s)$ , como se muestra en la ecuación (5).

$$\frac{V(s)}{I(s)} = \frac{0.096s + 0.008}{s^2 + 2.189s + 0.115} \quad (5)$$

En la Figura 5 se muestra el modelo de la batería en Simulink, donde el factor  $A$  es el valor inicial de SOC de cada ruta y  $Q$  la capacidad de la batería.

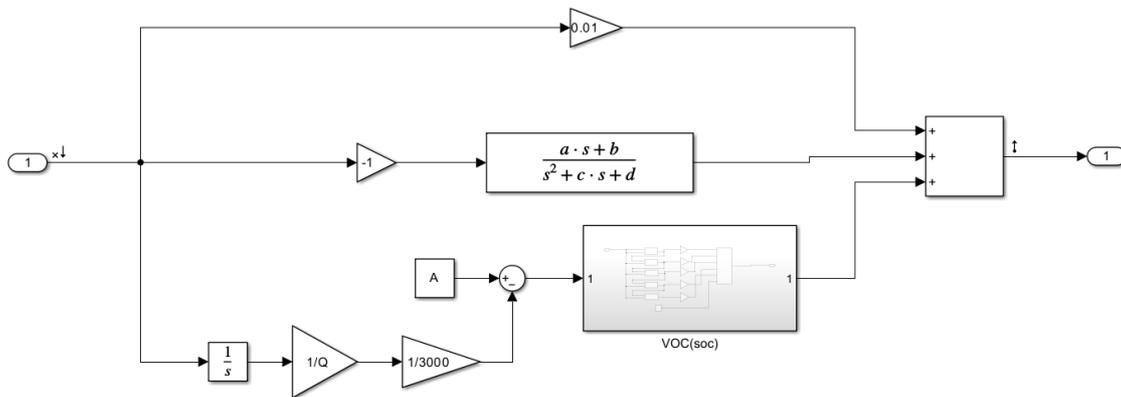


Figura 5. Modelo de batería.

### 3. RESULTADOS Y DISCUSIÓN

Para la estimación del SOC y el voltaje de recuperación se implementa un modelo de mínimos cuadrados no lineales (MCNL). Este método consiste en ajustar una función no lineal a datos experimentales mediante un proceso iterativo de optimización que minimiza la suma de los errores cuadrados (SEC) entre los valores observados y los predichos. Los MCNL resuelven la minimización de a través de la ecuación (6) (Suykens, 2002).

$$\min \sum_{i=1}^n (f(x_i) - y_i)^2 \quad (6)$$

Donde  $f(x_i)$  es una función no lineal determinada por el modelo de la batería e  $y_i$  corresponde a los datos experimentales. La función objetivo, definida como la SEC, cuantifica la discrepancia entre el modelo y los datos empíricos. Al minimizar esta métrica, el modelo MCNL captura de forma efectiva la relación no lineal entre las variables de entrada y el SOC o voltaje de recuperación, permitiendo así una estimación robusta de estos parámetros (Elmarghichi et al., 2020).

Para garantizar una convergencia robusta, se utiliza el algoritmo Trust Region Reflective (TRR). Este algoritmo optimiza la función objetivo mediante la construcción iterativa de regiones de confianza, ajustando dinámicamente su tamaño en función del progreso de la optimización. Además, TRR emplea una estrategia de reflexión para asegurar que los parámetros permanezcan dentro de los límites predefinidos, previniendo así divergencias o soluciones no factibles (Hu et al., 2024).

La Figura 6 presenta la respuesta del modelo SOC en tres rutas. El proceso de optimización mostró una convergencia eficiente en cada caso. El algoritmo TRR detectó que el punto inicial estaba en un mínimo local, y la medida de optimalidad del gradiente fue menor a la tolerancia de 0.001. Los resultados específicos fueron: en la ruta 1, la optimización se completó en 6 segundos con una medida de optimalidad de 0.00019; en la ruta 2, en 4 segundos, con una medida de 0.00051; y en la ruta 3, en 8 segundos, alcanzando una medida de optimalidad de 0.000037. Estos resultados indican que el modelo converge rápidamente y con precisión en la estimación del SOC.

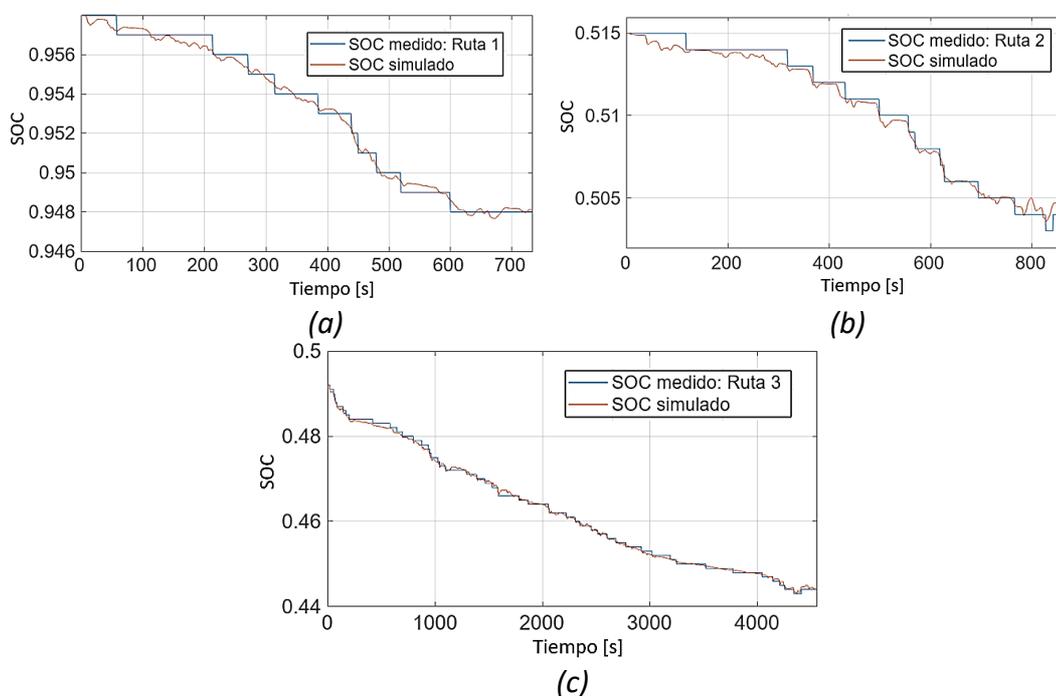


Figura 6. Evaluación del modelo SOC de la batería del VE para diferentes rutas. (a) Ruta 1, (b) Ruta 2 y (d) Ruta 3.

Las gráficas muestran una alta correlación entre el SOC medido y simulado, destacando la precisión del modelo en diversos escenarios de conducción. En la ruta 1 (Figura 6a), el SOC desciende de forma gradual, debido a una conducción estable con poco tráfico y mínimas oportunidades para el uso del freno regenerativo, al ser una zona con perfil topográfico mayormente plano. En cuanto a la ruta 2 (Figura 6b) presenta variaciones en el SOC, lo que indica condiciones de tráfico urbano con más frenadas, especialmente al final, donde la mayor densidad vehicular permitió recuperar energía mediante el freno regenerativo configurado al 50%.

Finalmente, en la ruta 3 (Figura 6c), al extenderse por un periodo mayor, refleja un perfil de conducción en carretera o en condiciones de tráfico moderado sin regeneración significativa, resultando en una descarga continua del SOC. Este análisis evidencia cómo las condiciones de cada ruta (como el tráfico y la topografía) influyen en el comportamiento energético y en la efectividad del freno regenerativo, demostrando que el modelo utilizado captura adecuadamente las variaciones del SOC en diferentes contextos de conducción.

Al comparar los ECM de este estudio con el método Unscented Kalman Filter (UKF) (Bhat et al., 2022) utilizado en ciclos estandarizados de conducción de VE, se observa que el modelo de estimación actual logra una precisión destacable en rutas reales. En particular, la ruta 1, con un ECM de 0.0011, destaca al superar en precisión a ciclos estandarizados como US06 (0.0035) y HWFET (0.0067), y logra valores comparables a ciclos controlados como UDDS (0.00034) y LA92 (0.00020). La ruta 3, con un ECM de 0.0018, presenta un rendimiento intermedio, posicionándose entre las rutas 1 y 2 y superando a ciclos como NN (0.0022) en precisión. Sin embargo, en la ruta 2, el ECM de 0.0023 refleja una menor precisión frente a ciclos como LA92, lo que podría atribuirse a factores topográficos y al uso variable del frenado regenerativo. Estos hallazgos sugieren que, si bien el UKF demuestra una alta efectividad en escenarios de conducción controlada, el modelo de estimación actual muestra una robustez adecuada para rutas reales, particularmente bajo condiciones de baja variabilidad.

Tabla I. Comparación del ECM del SOC en las rutas de prueba y ciclos de conducción estandarizados

Método / Ruta	ECM	Intervalo de confianza (95%)
Ruta 1 (MCNL)	0.0011	0.0011 ± 0.000124
Ruta 2 (MCNL)	0.0023	0.0023 ± 0.00026
Ruta 3 (MCNL)	0.0018	0.0018 ± 0.000204
UDDS (UKF)	0.00034	---
US06 (UKF)	0.0035	---
LA92 (UKF)	0.00020	---
NN (UKF)	0.0022	---
HWFET (UKF)	0.0067	---

La Tabla I presenta los errores cuadráticos medios (ECM) obtenidos en cada ruta evaluada, junto con sus respectivos intervalos de confianza al 95%. En este contexto, la precisión del modelo se mantiene robusta, especialmente en la Ruta 1, donde el intervalo es más estrecho ( $\pm 0.000124$ ), evidenciando mayor estabilidad en condiciones de conducción suburbana. Por otro lado, las Rutas 2 y 3 muestran intervalos ligeramente más amplios debido a las variaciones introducidas por el tráfico urbano denso y las pendientes prolongadas, respectivamente. Aunque el tamaño de la muestra es limitado, estos intervalos permiten validar la confiabilidad del modelo al demostrar que los valores del ECM se mantienen en rangos consistentes para cada escenario de conducción.

La Figura 7 muestra la respuesta del modelo 2RC de Thevenin que representa el comportamiento de la batería de polímero de litio en el VE a lo largo de diversas rutas establecidas. Para la ruta 1, la optimización inició y concluyó en menos de un minuto, y el valor de la medida de optimalidad de primer orden fue 0.000042, inferior a la tolerancia especificada de 0.001, lo que indica estabilidad en el punto inicial. En la ruta 2, el algoritmo encontró un mínimo local con un valor de optimalidad aún menor, 0.0000395, sugiriendo una mejor convergencia en comparación con la ruta 1.

Finalmente, para la ruta 3, la optimización detectó un posible mínimo local al detenerse debido a cambios mínimos en la suma de cuadrados relativa, cumpliendo así con la tolerancia funcional establecida de 0.001. Estos resultados reflejan un

comportamiento consistente del modelo de estimación en distintos escenarios de ruta.

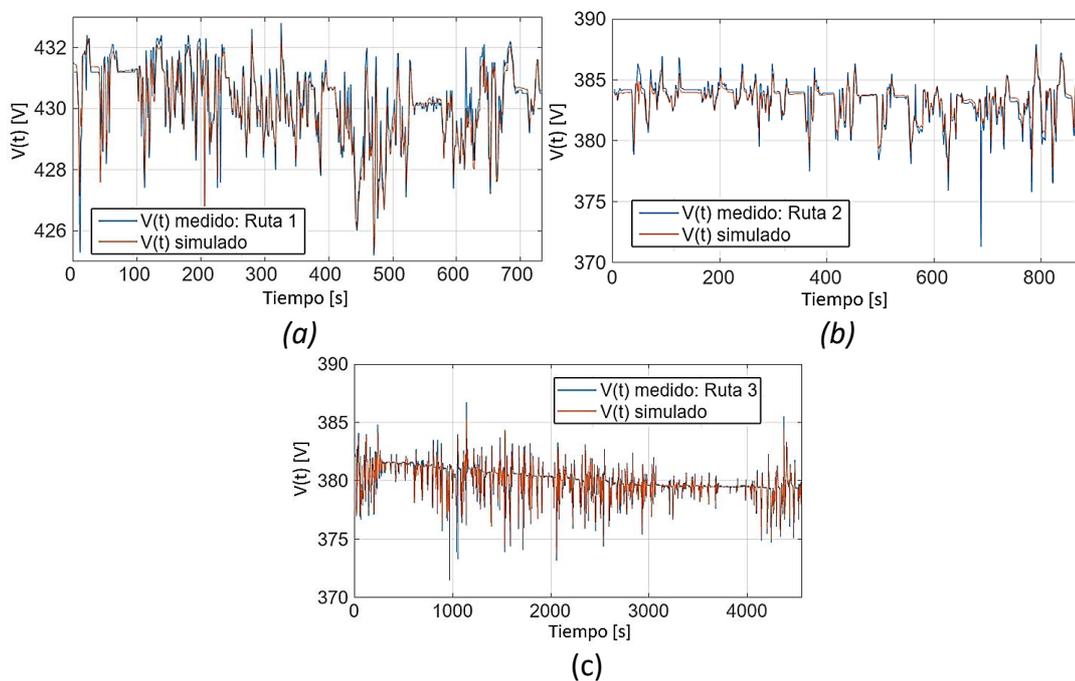


Figura 7. Voltaje de recuperación real vs estimado para diferentes rutas. (a) Ruta 1, (b) Ruta 2 y (d) Ruta 3.

Al comparar los ECM de este estudio con otros modelos de estimación de baterías, se observa que el modelo 2RC de Thevenin (ECM de 0.0052 en ruta 1, 0.0045 en ruta 2 y 0.006 en ruta 3) logra una precisión comparable con métodos como el filtro de Kalman extendido (EKF), que típicamente presenta ECM en el rango de 0.0040 a 0.0055 en rutas estandarizadas (Kim et al., 2020)(Marques et al., 2023), y el modelo P2D electroquímico, que puede alcanzar un ECM de hasta 0.0032 en simulaciones de laboratorio (Shin et al., 2023)(Arun et al., 2021). En particular, la ruta 2 del presente estudio, con un ECM de 0.0045, muestra una precisión cercana a la del EKF, mientras que la ruta 3 refleja un ECM más alto (0.006), indicando posibles limitaciones en terrenos con mayor variabilidad. Comparado con redes neuronales, que en condiciones controladas logran ECM de aproximadamente 0.0028 (Umayal et al., 2023)(Vijaya Saraswathi et al., 2023), el modelo 2RC de Thevenin ofrece una precisión razonable con menor demanda computacional, siendo adecuado para rutas de baja a media complejidad. Estos resultados subrayan que, aunque métodos avanzados como el P2D y las redes neuronales mejoran la precisión en condiciones

de laboratorio, el modelo actual brinda un desempeño robusto en rutas reales, especialmente en trayectos con condiciones estables.

*Tabla II. Comparación del ECM del voltaje de recuperación en las rutas de prueba y ciclos de conducción estandarizados*

<b>Método / Ruta</b>	<b>ECM</b>
Ruta 1 (MCNL)	0.0052
Ruta 2 (MCNL)	0.0045
Ruta 3 (MCNL)	0.006
EKF	0.0040 - 0.0055
P2D Electroquímico	0.0032
Redes Neuronales	0.0028

## 4. CONCLUSIONES

Este estudio demostró que el modelo de Thevenin (2RC) es una herramienta robusta y eficiente para estimar el SOC y el voltaje de recuperación en baterías de vehículos eléctricos bajo condiciones variables de conducción. Las tres rutas seleccionadas en Cuenca permitieron evaluar el modelo en escenarios de conducción suburbanos, urbanos y mixtos, validando su precisión frente a modelos estándar como el UKF. El análisis reveló que la Ruta 1 presentó el menor error cuadrático medio (ECM) debido a condiciones de conducción estable y predecible. Por el contrario, la Ruta 2 mostró un ECM más elevado, atribuido a las frecuentes paradas y aceleraciones propias del tráfico denso urbano. La Ruta 3, con una duración más prolongada y pendientes significativas, permitió evaluar la descarga sostenida del SOC, logrando un ECM intermedio y confirmando la robustez del modelo ante condiciones de conducción exigentes.

La ventaja del modelo 2RC reside en su capacidad para capturar las dinámicas no lineales de los sistemas de almacenamiento de energía, adaptándose a los cambios en el comportamiento de la batería y las condiciones de conducción específicas. Esta característica permite integrar de manera eficiente las particularidades geográficas y de tráfico de ciudades como Cuenca, optimizando el rendimiento energético en entornos urbanos complejos.

Aunque el modelo presenta un rendimiento destacado, su precisión podría verse afectada en condiciones extremas de temperatura o con baterías que han experimentado un alto número de ciclos de carga. Además, la implementación en tiempo real podría requerir ajustes adicionales en los algoritmos de optimización para escenarios con variabilidad operativa más pronunciada. Los resultados obtenidos sugieren que el modelo puede ser utilizado para mejorar la gestión energética en vehículos eléctricos, particularmente en ciudades donde la topografía y la dinámica vehicular influyen significativamente en el consumo energético. Finalmente, se recomienda ampliar el estudio en regiones con condiciones climáticas extremas y baterías de tecnologías alternativas, así como integrar algoritmos avanzados, como redes neuronales, para perfeccionar aún más la precisión y adaptabilidad del modelo.

## REFERENCIAS

- Aditya, K. (2023). Simulation and Validation of a Precise 2RC Model of Lithium-Ion cell Incorporating Wire-bond Losses. *2023 International Conference on Control, Communication and Computing, ICC 2023*, 1–4. <https://doi.org/10.1109/ICCC57789.2023.10165007>
- Al-Wreikat, Y., Serrano, C., & Sodr , J. R. (2021). Driving behaviour and trip condition effects on the energy consumption of an electric vehicle under real-world driving. *Applied Energy*, 297(May). <https://doi.org/10.1016/j.apenergy.2021.117096>
- Arun, S. K., Anida, I. N., Norbakyah, J. S., & Salisa, A. R. (2021). Modelling and simulation of driving cycle using simulink. *International Journal of Power Electronics and Drive Systems*, 12(3), 1450–1458. <https://doi.org/10.11591/ijpeds.v12.i3.pp1450-1458>
- Azis, N. A., Joelianto, E., & Widyotriatmo, A. (2019). State of Charge (SoC) and State of Health (SoH) Estimation of Lithium-Ion Battery Using Dual Extended Kalman Filter Based on Polynomial Battery Model. *Proceedings of the 2019 6th International Conference on Instrumentation, Control, and Automation, ICA 2019, August*, 88–93. <https://doi.org/10.1109/ICA.2019.8916734>
- Belmajdoub, N., Lajouad, R., Magri, A. El, Boudoudouh, S., & Zaggaf, M. H. (2024). Review of battery models and experimental parameter identification for lithium-ion battery equivalent circuit models. *Indonesian Journal of Electrical Engineering and Computer Science*, 33(3), 1336–1346. <https://doi.org/10.11591/ijeecs.v33.i3.pp1336-1346>
- Bhat, C., Herle, A., Channegowda, J., & Narahariseti, K. (2022). Battery Parameter Evaluation Using Unscented Kalman Filter for Electric Vehicle Drive Cycles. *2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE)*, 1–5. <https://api.semanticscholar.org/CorpusID:247108665>
- Ding, X., Zhang, D., Cheng, J., Wang, B., & Luk, P. C. K. (2019). An improved Thevenin model of lithium-ion battery with high accuracy for electric vehicles. *Applied Energy*, 254(July), 113615. <https://doi.org/10.1016/j.apenergy.2019.113615>
- Donkers, A., Yang, D., & Viktorovi , M. (2020). Influence of driving style, infrastructure, weather and traffic on electric vehicle performance. *Transportation Research Part D: Transport and Environment*, 88(October). <https://doi.org/10.1016/j.trd.2020.102569>
- Elmarghichi, M., Bouzi, M., & Ettalabi, N. (2020). Robust parameter estimation of an electric vehicle lithium-ion battery using adaptive forgetting factor recursive least squares. *International Journal of Intelligent Engineering and Systems*, 13(5), 74–84. <https://doi.org/10.22266/ijies2020.1031.08>
- Fotouhi, A., Auger, D. J., Propp, K., Longo, S., & Wild, M. (2016). A review on electric vehicle battery modelling: From Lithium-ion toward Lithium-Sulphur. *Renewable and Sustainable Energy Reviews*, 56, 1008–1021. <https://doi.org/10.1016/j.rser.2015.12.009>
- Hawsawi, T., Alolaiwy, M., Taleb, Y., Mezaael, A., & Zohdy, M. (2023). An Improved Thevenin Model-based State-of-Charge Estimation of a Commercial Lithium-Ion Battery Using Kalman Filter. *Proceedings - 2023 IEEE SmartWorld, Ubiquitous Intelligence and Computing, Autonomous and Trusted Vehicles, Scalable Computing and Communications, Digital Twin, Privacy Computing and Data Security*,

- Metaverse, SmartWorld/UIC/ATC/ScalCom/DigitalTwin/PCDS/Me*, 735–741. <https://doi.org/10.1109/SWC57546.2023.10448568>
- Hu, Y., Fang, X., & Zeng, W. (2024). Nonlinear least-squares solutions to the TLS multi-station registration adjustment problem. *ISPRS Journal of Photogrammetry and Remote Sensing*, 218(January), 220–231. <https://doi.org/10.1016/j.isprsjprs.2024.09.014>
- Huynh, T. A., & Hsieh, M. F. (2018). Performance analysis of permanent magnet motors for electric vehicles (EV) traction considering driving cycles. *Energies*, 11(6). <https://doi.org/10.3390/en11061385>
- Jiangsu Skywell Automobile, L. C. (2021). User manual Skywell ET5. In *Sustainability (Switzerland)* (Vol. 11, Issue 1). [http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484\\_SISTEM\\_PEMBETUNGAN\\_TERPUSAT\\_STRATEGI\\_MELESTARI](http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI)
- Kakouche, K., Oubelaid, A., Mezani, S., Rekioua, T., Bajaj, M., Jurado, F., & Kamel, S. (2023). Energy Management Strategy of Dual-Source Electric Vehicles Based on Fuzzy Logic Control Considering Driving Cycles. *Proceedings - 2023 IEEE 5th Global Power, Energy and Communication Conference, GPECOM 2023*, 92–97. <https://doi.org/10.1109/GPECOM58364.2023.10175709>
- Kim, M. J., Chae, S. H., & Moon, Y. K. (2020). Adaptive Battery State-of-Charge Estimation Method for Electric Vehicle Battery Management System. *Proceedings - International SoC Design Conference, ISOCC 2020*, 288–289. <https://doi.org/10.1109/ISOCC50952.2020.9332950>
- Liu, W., Placke, T., & Chau, K. T. (2022). Overview of batteries and battery management for electric vehicles. *Energy Reports*, 8, 4058–4084. <https://doi.org/10.1016/j.egy.2022.03.016>
- Mahmud, M., Rahman, K. S., Rokonzaman, M., Habib, A. K. M. A., Islam, M. R., Motakabber, S. M. A., Channumsin, S., & Chowdhury, S. (2023). Lithium-ion battery thermal management for electric vehicles using phase change material: A review. *Results in Engineering*, 20(August), 101424. <https://doi.org/10.1016/j.rineng.2023.101424>
- Marques, T. M. B., dos Santos, J. L. F., Castanho, D. S., Ferreira, M. B., Stevan, S. L., Illa Font, C. H., Antonini Alves, T., Piekarski, C. M., Siqueira, H. V., & Corrêa, F. C. (2023). An Overview of Methods and Technologies for Estimating Battery State of Charge in Electric Vehicles. *Energies*, 16(13), 1–18. <https://doi.org/10.3390/en16135050>
- Monsalve, G., Cardenas, A., & Martinez, W. (2022). Analysis of two Equivalent Circuit Models for State of Charge Estimation using Kalman Filters. *IEEE International Symposium on Industrial Electronics, 2022-June*, 347–353. <https://doi.org/10.1109/ISIE51582.2022.9831758>
- Peng, W., Yang, Z., Liu, C., Xiu, J., & Zhang, Z. (2018). *An Improved PSO Algorithm for Battery Parameters Identification Optimization Based on Thevenin Battery Model*. 295–298.
- Ramsey, D., German, R., Bouscayrol, A., & Boulon, L. (2020). Comparison of equivalent circuit battery models for energetic studies on electric vehicles. *2020 IEEE Vehicle Power and Propulsion Conference, VPPC 2020 - Proceedings*, 2. <https://doi.org/10.1109/VPPC49601.2020.9330891>

- S. Rangarajan, S., Sunddararaj, S. P., Sudhakar, A. V. V., Shiva, C. K., Subramaniam, U., Collins, E. R., & Senjyu, T. (2022). Lithium-Ion Batteries—The Crux of Electric Vehicles with Opportunities and Challenges. *Clean Technologies*, 4(4), 908–930. <https://doi.org/10.3390/cleantechnol4040056>
- Seidel, J., Trachte, K., Orellana-Alvear, J., Figueroa, R., Célleri, R., Bendix, J., Fernandez, C., & Huggel, C. (2019). Precipitation characteristics at two locations in the tropical andes by means of vertically pointing micro-rain radar observations. *Remote Sensing*, 11(24), 1–18. <https://doi.org/10.3390/rs11242985>
- Shin, J., Kim, W., Yoo, K., Kim, H., & Han, M. (2023). Vehicular level battery modeling and its application to battery electric vehicle simulation. *Journal of Power Sources*, 556(November 2022), 232531. <https://doi.org/10.1016/j.jpowsour.2022.232531>
- Susanna, Dewangga, B. R., Wahyungoro, O., & Cahyadi, A. I. (2019). Comparison of simple battery model and thevenin battery model for SOC estimation based on OCV method. *2019 International Conference on Information and Communications Technology, ICOIACT 2019*, 738–743. <https://doi.org/10.1109/ICOIACT46704.2019.8938495>
- Suykens, J. A. K. (2002). *Least Squares Support Vector Machines: an Overview*. <https://api.semanticscholar.org/CorpusID:17616228>
- Sweeting, W. J., Hutchinson, A. R., & Savage, S. D. (2011). Factors affecting electric vehicle energy consumption. *International Journal of Sustainable Engineering*, 4(3), 192–201. <https://doi.org/10.1080/19397038.2011.592956>
- Umayal, R. M., Darapaneni, N., Aditya, V., & Paduri, A. R. (2023). Machine Learning based Remaining Useful Life Prediction of Lithium-ion Batteries in Electric Vehicle Battery Management System. *2023 International Conference on Communication, Security and Artificial Intelligence, ICCSAI 2023*, 547–551. <https://doi.org/10.1109/ICCSAI59793.2023.10421014>
- Valladolid, J. D., Patiño, D., Ortiz, J. P., Minchala, I., & Gruosso, G. (2019). Proposal for modeling electric vehicle battery using experimental data and considering temperature effects. *2019 IEEE Milan PowerTech, PowerTech 2019*, 1–6. <https://doi.org/10.1109/PTC.2019.8810611>
- Vijaya Saraswathi, R. J., Krishnakumar, V., & Vasan Prabhu, V. (2023). Review of Various Algorithms Used to Monitor the Performance of EV Battery. *Proceedings of 2023 International Conference on Signal Processing, Computation, Electronics, Power and Telecommunication, IConSCEPT 2023*, 1–7. <https://doi.org/10.1109/IConSCEPT57958.2023.10170048>