



9th International Interdisciplinary Congress on Renewable Energies, Industrial Maintenance, Mechatronics and Informatics

Booklets



RENIECYT - LATINDEX - Research Gate - DULCINEA - CLASE - Sudoc - HISPANA - SHERPA UNIVERSIA - Google Scholar DOI - REDIB - Mendeley - DIALNET - ROAD - ORCID - V|LEX

Title: Estimation of lithium-ion battery state of health using an ensemble model integrated with random forest and linear regression techniques

Authors: Medina-Martínez, Sergio Iván, Juárez-Toledo, Carlos and Martínez-Carrillo, Irma

Unidad Académica Profesional Tianguistenco LBY-0431-2024 0000-0002-6094-2177 1083727
 Unidad Académica Profesional Tianguistenco C-1368-2016 0000-0002-7440-3246 39912
 Unidad Académica Profesional Tianguistenco B-9264-2016 0000-0002-7952-4418 39914

Editorial label ECORFAN: 607-8695
BCIERMMI Control Number: 2024-01
BCIERMMI Classification (2024): 241024-0001
RNA: 03-2010-032610115700-14
Pages: 13

CONAHCYT classification:

Area: Engineering
Field: Technological sciences
Discipline: Computer technology
Subdiscipline: Artificial intelligence

ECORFAN-México, S.C.

Park Pedregal Business. 3580,
Anillo Perif., San Jerónimo
Aculco, Álvaro Obregón,
01900 Ciudad de México, CDMX,
Phone: +52 1 55 6159 2296
Skype: ecorfan-mexico.s.c.
E-mail: contacto@ecorfan.org
Facebook: ECORFAN-México S. C.

Twitter: @EcorfanC

www.ecorfan.org

Holdings

Mexico	Colombia	Guatemala
Bolivia	Cameroon	Democratic
Spain	El Salvador	Republic
Ecuador	Taiwan	of Congo
Peru	Paraguay	Nicaragua

Contenido de la presentación

Introducción

Metodología

Resultados

Conclusiones

Referencias



Introducción



Ante la problemática del calentamiento global se está optado por el uso de fuentes de energías renovables en vez de combustibles fósiles en el sector automovilístico.

Y esto es posible por las baterías que almacenan energía química y la convierten en energía eléctrica

Entre las tecnologías disponibles en el mercado de baterías las de iones de litio son las más utilizadas debido a sus características físicas:

- Densidad Energética
- La energía de carga es similar a la de descargar
- Vida útil de las baterías
- Soporta más ciclos de carga y descarga
- Baja tasa de autodescarga
- No sufren el efecto memoria



Introducción



Sin embargo, una de las limitaciones de las baterías es la degradación que sufren con el tiempo que afecta la capacidad de la batería y a su vez se reduce la eficiencia de los vehículos eléctricos y dispositivos electrónicos portátiles.

Además, si la batería se sigue degradando existe el riesgo de incendio o explosión, para evitar esto se utiliza un sistema de gestión de baterías el cual determina el estado de carga, la vida útil y el estado de **salud de la batería**.

Para estimar el estado de salud existe diferentes enfoques:

Resumen de los métodos de estimación de salud de la batería

Enfoque	Método
Evaluación directa	Circuito abierto
	Contaje de Coulomb
	Espectroscopía de impedancia
Basado en datos	Red neuronal
	Lógica difusa
	Vectores de soporte
	Filtro de Kalman
Adaptativo	Filtrado de partículas
	Mínimos cuadrados
Otros	Entropía de muestra
	Función de densidad de probabilidad

Fuente: Habib et al., 2023



Introducción

Otra alternativa dentro de los métodos basados en datos es combinar múltiples técnicas de aprendizaje automático conocidas como métodos de ensamble, por ejemplo:

Lin et al., 2023 apilo modelos de regresión lineal, regresión por vectores de soporte y regresión de procesos gaussianos puede mejorar el rendimiento predictivo. Al apilar estos modelos, se genera y construye un nuevo conjunto de datos.

Gou et al., 2021 propone un ensamble de redes neuronales basado en algoritmos de aprendizaje aleatorio, donde cada modelo genera una estimación del estado de salud. Las reglas de toma de decisiones basadas en los resultados individuales del ensamble de redes neuronales se utilizan para realizar el modelo de ensamble.



Comparación de algoritmos basado en el promedio

Algoritmo	Error absoluto medio
Regresión lineal	$\approx 10 \%$
Regresión de soporte vectorial	$\approx 5\%$
Red neuronal de retro propagación	$\approx 7\%$
Red neuronal de memoria a corto y largo plazo	$\approx 1\%$
Red neuronal convolucional	$\approx 1 \%$

Fuente: Zhang et al., 2023



Metodología

Para estimar el estado de salud de la batería, es necesario utilizar un conjunto de datos adecuado. En este estudio, se emplea el conjunto de datos de acceso público proporcionado por la NASA.

Este conjunto de datos está etiquetado como B0005, B0006, B0007 y B0018

Especificaciones del modelo de batería 18650


Parámetro	Valor
Capacidad nominal	2.7 Ah
Material	Li(NiCoAl)O2 /Carbono
Rango de voltaje	2.5–4.2 V
Rango de temperatura de carga	10–45 °C
Rango de temperatura de descarga	-20–60 °C


Fuente: Y. Li et al., 2019



$$SoH = \frac{Capacity_{current}}{Capacity_{initial}}$$

$$Feature_{avg} = \frac{\sum_{i=1}^n f_i}{n}$$








Metodología

En el caso de la estimación del estado de salud de la batería se utiliza el modelo de la regresión lineal múltiple por medio de los coeficientes de regresión para cada una de las variables independientes.



En el caso de la estimación del estado de salud de la batería se utiliza el modelo de la regresión lineal múltiple por medio de los coeficientes de regresión para cada una de las variables independientes.





Resultados

Para evaluar el clasificador se utilizaron las métricas de Exactitud, Precisión, Recall y Puntaje F1 en el caso de regresión lineal se utiliza el error cuadrático medio, raíz del error cuadrático medio y el error absoluto medio







Métricas de Desempeño para los Modelos de RL y Ensamble				
	MSE	RMSE	MAE	R ²
B0005	8.25×10 ⁻⁶	2.87×10 ⁻³	2.38×10 ⁻³	0.9991
B0006	4.94×10 ⁻⁶	2.22×10 ⁻³	1.93×10 ⁻³	0.9997
B0007	2.98×10 ⁻⁶	1.73×10 ⁻³	1.17×10 ⁻³	0.9995
B0018	4.23×10 ⁻⁶	2.06×10 ⁻³	1.64×10 ⁻³	0.9994
EM	8.77×10 ⁻⁶	2.96×10 ⁻³	2.22×10 ⁻³	0.9989
Fuente: Elaboración propia				

Métricas de rendimiento		
	Prueba	Validación
Exactitud	0.984375	0.982375
Precisión	0.985351	0.985094
Recall	0.984375	0.981754
F1	0.984254	0.980542
Fuente: Elaboración propia		







Resultados





Resultados





Conclusiones



- El modelo de ensamble mostró gran eficacia en la predicción del estado de salud de las baterías de iones de litio.
- Se mantuvo un margen de error inferior al 1% durante la mayoría de los ciclos evaluados.
- El modelo mostró un coeficiente de determinación cercano al ideal, lo que indica robustez y capacidad predictiva.
- Se detectó una discrepancia significativa en el ciclo 166 de la batería B0007, señalando posibles valores atípicos.
- Se sugiere continuar refinando las técnicas del modelo para mejorar su precisión en escenarios desafiantes.
- Futuras investigaciones incluirán la aplicación del modelo a nuevos conjuntos de datos, con ajustes que mejoren su aplicabilidad general y exactitud.



Referencias



Edge, J. S., O’Kane, S., Prosser, R., Kirkaldy, N. D., Patel, A. N., Hales, A., Ghosh, A., Ai, W., Chen, J., Yang, J., Li, S., Pang, M.-C., Bravo Diaz, L., Tomaszewska, A., Marzook, M. W., Radhakrishnan, K. N., Wang, H., Patel, Y., Wu, B., & Offer, G. J. (2021). Lithium ion battery degradation: what you need to know. *Physical Chemistry Chemical Physics*, 23(14), 8200–8221. <https://doi.org/10.1039/D1CP00359C>

Gou, B., Xu, Y., & Feng, X. (2021). An Ensemble Learning-Based Data-Driven Method for Online State-of-Health Estimation of Lithium-Ion Batteries. *IEEE Transactions on Transportation Electrification*, 7(2), 422–436. <https://doi.org/10.1109/TTE.2020.3029295>

Gunay, D. (2023, August 11). Random Forest. <https://Medium.Com/@denizgunay/Random-Forest-Af5bde5d7e1e>.

Habib, A. K. M. A., Hasan, M. K., Issa, G. F., Singh, D., Islam, S., & Ghazal, T. M. (2023). Lithium-Ion Battery Management System for Electric Vehicles: Constraints, Challenges, and Recommendations. In *Batteries* (Vol. 9, Issue 3). MDPI. <https://doi.org/10.3390/batteries9030152>

Lee, J. H., Kim, H. S., & Lee, I. S. (2021, January 31). State of charge estimation and state of health diagnostic method using multilayer neural networks. 2021 International Conference on Electronics, Information, and Communication, ICEIC 2021. <https://doi.org/10.1109/ICEIC51217.2021.9369782>



Referencias



- Li, L., Li, Z., Zhao, J., & Guo, W. (2018). Lithium-ion battery management system for electric vehicles. *International Journal of Performability Engineering*, 14(12), 3184–3194. <https://doi.org/10.23940/ijpe.18.12.p28.31843194>
- Li, Y., Zhong, S., Zhong, Q., & Shi, K. (2019). Lithium-ion battery state of health monitoring based on ensemble learning. *IEEE Access*, 7, 8754–8762. <https://doi.org/10.1109/ACCESS.2019.2891063>
- Lin, C., Xu, J., Hou, J., Liang, Y., & Mei, X. (2023). Ensemble Method with Heterogeneous Models for Battery State-of-Health Estimation. *IEEE Transactions on Industrial Informatics*, 19(10), 10160–10169. <https://doi.org/10.1109/TII.2023.3240920>
- Linden, David., & Reddy, T. B. (2002). *Handbook of batteries*. McGraw-Hill.
- Rahman, T., & Alharbi, T. (2024). Exploring Lithium-Ion Battery Degradation: A Concise Review of Critical Factors, Impacts, Data-Driven Degradation Estimation Techniques, and Sustainable Directions for Energy Storage Systems. *Batteries*, 10(7), 220. <https://doi.org/10.3390/batteries10070220>
- Ranjith Kumar, R., Bharatiraja, C., Udhayakumar, K., Devakirubakaran, S., Sekar, K. S., & Mihet-Popa, L. (2023). Advances in Batteries, Battery Modeling, Battery Management System, Battery Thermal Management, SOC, SOH, and Charge/Discharge Characteristics in EV Applications. In *IEEE Access* (Vol. 11, pp. 105761–105809). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2023.3318121>



Referencias



Weisberg, S. (2005). Applied linear regression. John Wiley.

Xing, Y., Ma, E. W. M., Tsui, K. L., & Pecht, M. (2011). Battery management systems in electric and hybrid vehicles. In *Energies* (Vol. 4, Issue 11, pp. 1840–1857). MDPI AG. <https://doi.org/10.3390/en4111840>

Zhang, M., Yang, D., Du, J., Sun, H., Li, L., Wang, L., & Wang, K. (2023). A Review of SOH Prediction of Li-Ion Batteries Based on Data-Driven Algorithms. In *Energies* (Vol. 16, Issue 7). MDPI. <https://doi.org/10.3390/en16073167>



ECORFAN®

© Ecorfan-Mexico, S.C.

No part of this document covered by the Federal Copyright Law may be reproduced, transmitted or used in any form or medium, whether graphic, electronic or mechanical, including but not limited to the following: Citations in articles and comments Bibliographical, compilation of radio or electronic journalistic data. For the effects of articles 13, 162, 163 fraction I, 164 fraction I, 168, 169, 209 fraction III and other relative of the Federal Law of Copyright. Violations: Be forced to prosecute under Mexican copyright law. The use of general descriptive names, registered names, trademarks, in this publication do not imply, uniformly in the absence of a specific statement, that such names are exempt from the relevant protector in laws and regulations of Mexico and therefore free for General use of the international scientific community. BCIERMMI is part of the media of Ecorfan-Mexico, S.C., E: 94-443.F: 008- (www.ecorfan.org/ booklets)