

APLICACIÓN DE RED NEURONAL EN EL PRONÓSTICO DE FALLAS DE BATERÍAS DE IONES DE LITIO

Maria Victoria Rios Hernández
Estudiante de Ingeniería de Sistemas
Universidad Bicentenaria de Aragua
mavi.rios@gmail.com

Resumen

Este artículo presenta el desarrollo de un sistema de predicción de fallas en baterías recargables de iones de litio mediante redes neuronales artificiales. Metodológicamente, se adopta un enfoque de desarrollo tecnológico con diseño cuantitativo y experimental basado en datos, empleando registros del *Battery Prognostics Data Set* desarrollado por el Centro de Excelencia en Pronóstico de la NASA. Se seleccionaron variables operacionales como voltaje, corriente, temperatura y número de ciclo para el entrenamiento supervisado. El modelo se diseñó como una red neuronal tipo perceptrón multicapa en Keras y TensorFlow, entrenado para estimar la capacidad como variable continua del Estado de Salud (SoH). El fallo se definió bajo el criterio técnico estándar de una caída por debajo del 70% de la capacidad original. La evaluación del sistema contrastó los resultados mediante una división tradicional (*Hold-Out* 80/20) y una estrategia de validación cruzada dejando una batería fuera (*LOBO-CV*). Este proyecto demuestra el potencial de las redes neuronales para el monitoreo inteligente de baterías, aportando una herramienta tecnológica útil para el mantenimiento predictivo y la toma de decisiones.

Palabras clave: Baterías Recargables; Mantenimiento Predictivo; Predicción de Capacidad; Redes Neuronales.

NEURAL NETWORK APPLICATION IN LITHIUM-ION BATTERY FAULT PROGNOSIS

Abstract

This article presents the development of a fault prediction system for rechargeable lithium-ion batteries using artificial neural networks. Methodologically, a technological development approach with a quantitative and experimental data-driven design is adopted, employing records from the *Battery Prognostics Data Set* developed by the Prognostics Center of Excellence at NASA Ames Research Center. Operational variables such as voltage, current, temperature, and cycle number were selected for supervised training. The model was designed as a multilayer perceptron neural network implemented in Keras and TensorFlow, trained to estimate capacity as a continuous variable of the State of Health (SoH). Failure was defined under the

standard technical criterion of a drop below 70% of the original capacity. The evaluation of the system contrasted the results using a traditional split (*Hold-Out* 80/20) and a cross-validation strategy leaving one battery out (*LOBO-CV*). This project demonstrates the potential of neural networks for the intelligent monitoring of batteries, providing a useful technological tool for predictive maintenance and decision-making.

Keywords: Capacity Prediction; Neural Networks; Predictive Maintenance; Rechargeable Batteries.

APPLICATION DE RÉSEAUX NEURONAUX POUR LE PRONOSTIC DE DÉFAILLANCES DES BATTERIES IONS-LITHIUM

Résumé

Cet article présente le développement d'un système de prédiction de défaillances pour les batteries rechargeables au lithium-ion à l'aide de réseaux de neurones artificiels. Du point de vue méthodologique, une approche de développement technologique avec une conception quantitative et expérimentale basée sur les données est adoptée, utilisant les enregistrements du Battery Prognostics Data Set développé par le Centre d'Excellence en Pronostic de la NASA. Des variables opérationnelles telles que la tension, le courant, la température et le nombre de cycles ont été sélectionnées pour l'apprentissage supervisé. Le modèle a été conçu comme un réseau de neurones de type perceptron multicouche implémenté sous Keras et TensorFlow, entraîné pour estimer la capacité en tant que variable continue de l'État de Santé (SoH). La défaillance a été définie selon le critère technique standard d'une baisse inférieure à 70 % de la capacité d'origine. L'évaluation du système a permis de comparer les résultats à l'aide d'une division traditionnelle (*Hold-Out* 80/20) et d'une stratégie de validation croisée en laissant une batterie de côté (*LOBO-CV*). Ce projet démontre le potentiel des réseaux de neurones pour la surveillance intelligente des batteries, fournissant un outil technologique utile pour la maintenance prédictive et la prise de décision.

Mots-clés: Prédiction de Capacité; Réseaux de Neurones; Maintenance Prédictive; Batteries Rechargeables.

Introducción

Las baterías de ion-litio son el pilar de tecnologías contemporáneas que abarcan desde dispositivos portátiles hasta vehículos eléctricos y sistemas estacionarios de almacenamiento de energía (Edge et al., 2021). La capacidad de una batería para almacenar carga disminuye con el uso, un proceso de degradación

que afecta directamente su rendimiento y seguridad. Predecir con precisión la capacidad restante, un indicador clave del Estado de Salud (State of Health - SoH), es fundamental para la gestión eficiente, el mantenimiento predictivo y la prevención de fallos (Lu et al., 2023).

Los métodos para estimar el SoH se dividen tradicionalmente en modelos físicos y enfoques basados en datos. Si bien los modelos físicos ofrecen una alta interpretabilidad, su complejidad y dependencia de parámetros específicos limitan su aplicación generalizada.

Por otro lado, los enfoques basados en datos, y en particular las técnicas de aprendizaje profundo como las Redes Neuronales Artificiales (ANN), han demostrado una notable capacidad para aprender los complejos patrones de degradación no lineal directamente desde datos operacionales históricos, sin necesidad de conocimientos detallados de la química interna (Lu et al., 2023; Che et al., 2023).

Además, las redes neuronales permiten una actualización constante y en tiempo real del modelo a medida que se dispone de nuevos datos, lo que hace posible ajustar las predicciones sin requerir una reconfiguración manual del sistema.

El presente trabajo propone y valida un sistema basado en una red neuronal densa para predecir la capacidad de descarga de baterías de ion-litio utilizando datos del Prognostics Center of Excellence (PCoE) de la NASA. El objetivo es evaluar no solo la precisión del modelo en condiciones ideales, sino también su capacidad de generalización a baterías completamente nuevas, un desafío clave para su aplicación en el mundo real. Para finalizar, Para facilitar el análisis de la investigación, este artículo se estructura secuencialmente en las secciones de revisión literaria, metodología aplicada, análisis de resultados junto a su discusión, y conclusiones finales.

Revisión Literaria

Baterías de ion-litio y su degradación

Las baterías de ion-litio (Li-ion) son una de las tecnologías de almacenamiento de energía más utilizadas. Sin embargo, estas baterías sufren un proceso de degradación progresiva que reduce su capacidad de carga y descarga, afectando la eficiencia y seguridad del sistema donde se emplean. El envejecimiento de las baterías se clasifica en dos tipos: envejecimiento calendarístico (por el paso del tiempo) y envejecimiento cíclico (por el uso repetido). Entre los mecanismos de degradación destacan la pérdida de litio activo, la formación de la capa SEI (Solid Electrolyte Interphase), y la pérdida de integridad mecánica del electrodo (Birkel et al., 2017).

La capacidad, es el principal indicador que refleja el deterioro progresivo del sistema. El concepto de SoH se define generalmente como el cociente entre la capacidad actual de la celda y su capacidad nominal, expresado en porcentaje. Cuando esta relación cae por debajo del 70%, se considera que la batería ha alcanzado el final de su vida útil (End of Life, EOL).

Arquitectura de Redes de Tipo Perceptrón Multicapa y su Aplicación en Problemas de Regresión

El Perceptrón Multicapa (MLP, por sus siglas en inglés) es una arquitectura fundamental de red neuronal artificial de tipo feedforward, organizada en una capa de entrada, una o más capas ocultas y una capa de salida. Su estructura le permite modelar relaciones complejas y no lineales, transmitiendo la información de manera unidireccional (Goodfellow et al., 2016). La capacidad del MLP para aproximar cualquier función continua lo convierte en un estimador universal, siendo ideal para tareas de regresión donde se busca modelar la relación entre variables independientes y una dependiente continua (Hornik et al., 1989).

Arquitectónicamente, tras la capa de entrada que recibe los datos brutos, las capas ocultas procesan la información. Cada neurona en estas capas aplica una función de activación no lineal —como la Unidad Lineal Rectificada (ReLU), preferida por su eficiencia computacional— a la suma ponderada de las entradas de la capa anterior (Goodfellow et al., 2016). Para problemas de regresión, la capa de salida se configura típicamente con una sola neurona y una función de activación lineal (o de identidad), permitiendo que la predicción final sea un valor continuo y no acotado (Ciaburro & Venkateswaran, 2017).

Validación Cruzada Dejando una Batería Fuera (Leave-One-Battery-Out)

La validación cruzada (CV) es una técnica fundamental para evaluar la capacidad de generalización de un modelo de pronóstico y mitigar el sobreajuste (overfitting). En lugar de dividir los datos en un único conjunto de entrenamiento y uno de prueba, la validación cruzada utiliza los datos de manera más eficiente al crear múltiples divisiones

La estrategia de Validación Cruzada Dejando una Batería Fuera (Leave-One-Battery-Out Cross-Validation, LOBO-CV) es un caso especializado de la metodología Leave-One-Group-Out. En este enfoque, el modelo se entrena utilizando los datos de todas las baterías del conjunto de datos excepto una, la cual se reserva íntegramente para la validación. Este proceso se repite sucesivamente, dejando fuera una batería diferente en cada iteración, hasta que cada una de las baterías ha sido utilizada como conjunto de prueba una vez. Finalmente, los resultados de rendimiento de cada iteración se promedian para obtener la evaluación final del modelo.

Al forzar al modelo a predecir sobre una unidad de batería entera y no vista, LOBO-CV proporciona una estimación más realista y pesimista de su rendimiento en un escenario de despliegue real, en comparación con una validación cruzada estándar que podría mezclar aleatoriamente datos de todas las baterías en los pliegues de entrenamiento y prueba (Feng et al., 2020).

Metodología

El desarrollo del modelo se estructuró en diversas fases. En primer lugar, se utilizó el conjunto de datos de baterías de ion-litio del PCoE de la NASA, y para este proyecto, únicamente se consideraron los ciclos de descarga, ya que la degradación de la capacidad es más evidente en esta fase.

El modelo implementado es una red neuronal artificial secuencial de tipo denso, se realizó utilizando TensorFlow y Keras, dos de las bibliotecas más robustas para el desarrollo de modelos de aprendizaje profundo. La arquitectura que consta de una capa de entrada con 128 neuronas y activación ReLU, seguida de capas ocultas con 64 y 32 neuronas, respectivamente, también con activación ReLU y regularización Dropout al 20%. Esta técnica Dropout consiste en desactivar aleatoriamente un porcentaje de neuronas durante cada ciclo de entrenamiento. Al hacerlo, se obliga a la red a no depender excesivamente de unas pocas neuronas, fomentando el aprendizaje de patrones más robustos y distribuidos. La salida consiste en una sola neurona con activación lineal para predecir la capacidad. El modelo fue compilado con el optimizador Adam y la función de pérdida MSE, monitoreando el MAE como métrica de rendimiento.

Se emplearon dos estrategias de evaluación. En la primera, la división estándar (Hold-Out), los datos de todas las baterías se combinaron y dividieron en un conjunto de entrenamiento (80%) y uno de prueba (20%), con el modelo entrenado durante 200 épocas.

En la segunda, validación cruzada de dejar una batería fuera (Leave-One-Out), se utilizó una batería como conjunto de prueba en cada iteración, mientras que las otras tres se usaron para entrenamiento. Este proceso se repitió cuatro veces, una para cada batería, entrenando un modelo nuevo en cada iteración.

Resultados

En este proyecto, se desarrolló un sistema para la predicción del Estado de Salud (SoH) de baterías de ion-litio, basado en redes neuronales artificiales (ANN) de tipo denso, una arquitectura eficaz para modelar relaciones complejas en datos tabulares.

La arquitectura del modelo se compone de múltiples capas densas. La función principal de estas capas es aprender las complejas e intrincadas relaciones no lineales entre las características operacionales de la batería (como el voltaje, la corriente y la temperatura promedio por ciclo) y su capacidad de descarga restante.

Cada capa densa recibe la información procesada por la capa anterior y la transforma, permitiendo que el modelo construya una representación interna cada vez más refinada del proceso de degradación de la batería.


Al final de la red, se implementó una capa de salida densa diseñada específicamente para la tarea de regresión. Esta configuración le permite al modelo emitir un valor numérico continuo, que corresponde directamente a la predicción de la capacidad de la batería, la métrica clave para evaluar su estado de salud

La evaluación del modelo se llevó a cabo mediante las dos estrategias definidas en la metodología, arrojando resultados diferenciados que cuantifican el rendimiento del sistema en distintos escenarios.

En la evaluación inicial, donde los datos de todas las baterías fueron combinados y divididos en conjuntos de entrenamiento (80%) y prueba (20%), el modelo demostró una alta precisión. Se obtuvo un Error Absoluto Medio (MAE) de 0.0275 y un coeficiente de determinación (R^2) de 0.9552 en el conjunto de prueba.

Figura 1.

Rendimiento del sistema



85

Muestra las curvas de aprendizaje del modelo durante 200 épocas. Se observa una rápida convergencia tanto en la pérdida (MSE) como en el error absoluto medio (MAE). Las curvas de validación siguen de cerca a las de entrenamiento, indicando un buen ajuste al conjunto de datos.

Esta monitorización es crucial para diagnosticar el comportamiento del modelo, detectar el punto de convergencia y asegurar que no se produzca un sobreajuste significativo.

En la segunda evaluación, la estrategia de validación cruzada de dejar una batería fuera (Leave-One-Out Cross-Validation) se utilizó para evaluar la capacidad de generalización del modelo a baterías no vistas. Los resultados para cada una de las cuatro iteraciones se detallan en la Tabla 1.

Tabla 1:

Resultados de rendimiento por cada iteración de la validación cruzada

Baterías	R ²	MAE
B0005	0.1232	0.4407
B0006	0.1345	0.6274
B0007	0.0335	0.8839
B0018	0.0429	0.8495

En síntesis, mientras que el modelo ha alcanzado un nivel de precisión impresionante en escenarios donde los patrones de degradación son más regulares (B0007, B0018), sus predicciones en baterías con comportamientos más atípicos o complejos no se vuelven tan exactas (B0005, B0006).

Al promediar estos resultados, el rendimiento general del modelo en esta evaluación más exigente fue de un MAE promedio de 0.0835 (con una desviación estándar de 0.0456) y un R² promedio de 0.7004 (con una desviación estándar de 0.1793).

Funcionamiento del Sistema

El sistema desarrollado sigue un flujo de trabajo estructurado para pasar de los datos crudos a una predicción de capacidad. El proceso se puede dividir en tres fases principales:

Extracción y Procesamiento de Datos: El sistema ingiere archivos de datos en formato mat, que contienen series temporales de mediciones para cada ciclo de carga y descarga de una batería. Para cada ciclo de descarga, se extraen las mediciones de voltaje, corriente y temperatura. Estas series temporales se agregan calculando su valor promedio, transformando los datos de alta dimensionalidad de cada ciclo en un único vector de características. Además, se registra el número de ciclo y un

identificador único para cada batería. El resultado de esta fase es una tabla de datos estructurada.

Preparación y Normalización: Con los datos ya estructurados en un DataFrame, las características seleccionadas (voltaje medio, corriente media, temperatura media e identificador de la batería) son convertidas a un formato numérico y normalizadas a una escala de 0 a 1 utilizando un MinMaxScaler. Esta normalización es un paso crucial para garantizar una convergencia rápida y estable durante el entrenamiento de la red neuronal.

Figura 2.

Primeras filas del dataframe

```
→ Datos combinados (primeras filas):  
  battery_id  ciclo  capacidad  voltaje_medio  corriente_medio  temperatura_medio  
0      B0005     1   1.856487    3.529829    -1.818702         32.572328  
1      B0005     3   1.846327    3.537320    -1.817560         32.725235  
2      B0005     5   1.835349    3.543737    -1.816487         32.642862  
3      B0005     7   1.835263    3.543666    -1.825589         32.514876  
4      B0005     9   1.834646    3.542343    -1.826114         32.382349  
  
✓ Datos preparados correctamente.  
>> X_train: (508, 4), y_train: (508,)   
>> X_test: (128, 4), y_test: (128,)
```

Fuente: Ríos, M. (2025)

Modelado y Predicción: En la etapa final, los datos ya normalizados se utilizan para alimentar a la red neuronal. El modelo consta de varias capas densas intercaladas con capas de Dropout para prevenir el sobreajuste, y emplea la función de activación ReLU en sus capas ocultas. La salida del modelo es un único valor continuo, correspondiente a la capacidad estimada de la batería para un ciclo determinado.

Durante el entrenamiento, se minimiza el error cuadrático medio (MSE) utilizando el optimizador Adam, y se monitorea el error absoluto medio (MAE) como métrica secundaria. Una vez entrenado, el modelo puede predecir con alta precisión la capacidad de cualquier ciclo nuevo, siempre que se le suministre un vector de características con la misma estructura de entrada.

Discusión

Los resultados obtenidos revelan una dualidad interesante en el rendimiento del modelo. En la evaluación con la división estándar (80/20), el sistema alcanzó un rendimiento excelente, con un Error Absoluto Medio (MAE) de 0.0275 y un coeficiente de determinación (R^2) de 0.9552. Las curvas de entrenamiento y validación (Figura 1) muestran una convergencia suave y estable, donde la pérdida de validación sigue de cerca a la de entrenamiento, sugiriendo que no hay un sobreajuste significativo en este escenario. Este resultado indica que el modelo es altamente eficaz para predecir la capacidad cuando los datos de la batería a evaluar (o baterías con un comportamiento similar) ya forman parte del conjunto de entrenamiento.

Sin embargo, la validación cruzada de dejar una fuera, que simula un escenario más realista donde el modelo debe predecir el comportamiento de una batería completamente nueva, arrojó resultados más modestos. El rendimiento promedio disminuyó a un MAE de 0.0835 y un R^2 de 0.7004. Más importante aún es la alta variabilidad en los resultados: mientras que el modelo generalizó bien para las baterías B0007 ($R^2=0.88$) y B0018 ($R^2=0.85$), su rendimiento fue notablemente inferior para las baterías B0005 ($R^2=0.44$) y B0006 ($R^2=0.63$). La desviación estándar del R^2 (0.1793) confirma esta inconsistencia.

Esta discrepancia sugiere que, si bien el modelo es potente, las características extraídas (voltaje, corriente y temperatura promedios) pueden no ser suficientes para capturar la totalidad de las firmas de degradación únicas de cada batería. El modelo

parece ser sensible a la varianza entre baterías, y su rendimiento predictivo depende de la similitud entre la batería de prueba y las vistas durante el entrenamiento.

Conclusiones

En este trabajo se ha desarrollado y validado con éxito un sistema completo, desde la extracción de datos crudos hasta la predicción de capacidad de baterías de ion-litio mediante redes neuronales. Se ha demostrado que el modelo puede alcanzar una alta precisión ($R^2 > 0.95$) en condiciones donde los datos de prueba provienen de la misma distribución que los de entrenamiento.

Esto valida el modelo como una herramienta potente para aplicaciones de monitoreo donde se cuenta con datos históricos del activo, como en la gestión de una flota de vehículos eléctricos.

No obstante, la implementación de una validación cruzada rigurosa ha proporcionado una estimación realista de la capacidad de generalización del modelo. Si bien esta validación reveló las limitaciones del sistema al enfrentarse a baterías completamente nuevas ($R^2 \approx 0.70$), con un rendimiento variable que depende de la batería específica, su principal contribución es precisamente la cuantificación de esta brecha de rendimiento.

Adicionalmente, este trabajo abre la posibilidad de futuras mejoras, como explorar arquitecturas alternativas, como las redes LSTM o GRU, que puedan procesar directamente las series temporales de cada ciclo sin necesidad de agregarlas, conservando así más información y entrenar el modelo con un conjunto de datos más grande y diverso, que incluya una mayor variedad de baterías y condiciones operativas, para mejorar su capacidad de generalización.

Referencias

- Birkel, C. R., Roberts, M. R., McTurk, E., Bruce, P. G., & Howey, D. A. (2017). Degradation diagnostics for lithium ion cells. *Journal of Power Sources*, 341, 373–386. doi.org
- Che, Y., Liu, Y., Zhou, Y., Chen, Y., & Song, K. (2023). Increasing generalization capability of battery health estimation using continual learning. *Cell Reports Physical Science*, 4(12), Article 101743. doi.org
- Ciaburro, G., & Venkateswaran, B. (2017). *Neural networks with R*. Packt Publishing.
- Edge, J. S., Trask, S. E., Nelson, K. J., Dunlop, A. R., Harvey, D., Reid, C. N., ... & Bloom, I. (2021). Lithium ion battery degradation: What you need to know. *Physical Chemistry Chemical Physics*, 23(15), 8200–8221. doi.org
- Feng, X., Li, M., He, D., & Lu, L. (2020). A data-driven approach based on deep learning for state of health estimation of lithium-ion batteries. *IEEE Transactions on Industrial Informatics*, 16(7), 4567–4576. doi.org
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Lu, J., Zhang, X., Sun, J., Wang, Q., Yang, H., & He, H. (2023). Deep learning to estimate lithium-ion battery state of health without additional degradation experiments. *Scientific Reports*, 13, Article 9622. doi.org