

Comparación de modelo de predicción de degradación de batería de Li-ion con redes neuronales NAR, NARX y ANFIS

Comparison of Li-ion battery degradation prediction models based on NAR, NARX and ANFIS neural networks

Andrés Santos León  Francisco Santamaria 

Cesar Trujillo Rodríguez 

Universidad Distrital Francisco José de Caldas,
Colombia

OPEN  ACCESS

Recibido: 09/06/2023

Aceptado: 15/08/2023

Publicado: 31/10/2023

Correspondencia de autores:

aisantosl@udistrital.edu.co



Copyright 2020
by Investigación e
Innovación en Ingenierías

Resumen

Objetivo: Comparar modelos de degradación de batería de Li-ion basados en redes neuronales NAR, NARX y ANFIS. **Metodología:** Se usaron redes neuronales NAR, NARX y ANFIS para modelar la degradación de la batería de Li-ion. Las redes neuronales se entrenaron en Matlab con tres diferentes grupos de datos, cada grupo de datos representa un batería diferente y contiene ciclos de carga y descarga en forma de curvas de tensión y corriente, al final de un ciclo de carga-descarga el grupo de datos contiene la capacidad de la batería. Las redes NAR, NARX y ANFIS se comparan entre sí para determinar cual tiene un menor error cuadrático medio (MSE por sus siglas en ingles). **Resultados:** El mejor modelo que se logró está representado en una red NARX ($MSE=3.01 \times 10^{-5}$) con una sola capa de quince neuronas y dos datos antecesores tanto en la entrada como en la salida. **Conclusiones:** Al final se concluye que las redes neuronales NAR y NARX reproducen con mayor fidelidad el comportamiento de la degradación de la batería para los primeros cien ciclos de uso, en comparación a los modelos basados en sistemas ANFIS. En contraste los modelos ANFIS tienen mayor fidelidad, después de los cien primeros ciclos, que los modelos NAR y NARX.

Palabras clave: Modelos de degradación de batería de Li-ion, NAR, NARX, ANFIS.

Abstract

Objetivo: Compare Li-Ion battery degradation models based on NAR, NARX and ANFIS neural networks. **Methodology:** Neuronal networks NARX and ANFIS were used to model the degradation of the Li-Ion battery. Neural networks trained in Matlab with three different datasets, each dataset represents a different battery and contains charge and discharge cycles in the form of voltage and current curves, at the end of charge-discharge cycle the dataset contains battery capacity. NARX and ANFIS networks are compared to each other to determine which has a lower average quadratic error (MSE). **Results:** The best model that was achieved is represented in a NARX network ($MSE = 3.01 \times 10^{-5}$) with a single layer of fifteen neurons and two predecessor data both at the input and the output. **Conclusions:** In the end it is concluded that NARX neuronal networks reproduce more loyalty the behavior of battery degradation for the first one hundred cycles of use, compared to models based on ANFIS systems. In contrast the ANFIS models have greater loyalty, after the first one hundred cycles, than the NAR and NARX models.

Keywords: Li-ion battery degradation models, NAR, NARX, ANFIS.

Introducción

Los sistemas de almacenamiento de energía, donde la unidad básica de almacenamiento la conforma una batería de Li-ion, son ampliamente utilizados en diversas aplicaciones como dispositivos móviles, sistemas de generación distribuida, microrredes eléctricas, entre otros [1]. En particular el modelado de la degradación de la batería resulta adecuado como una herramienta para cuantificar su vida útil. Sin embargo, las baterías de Li-ion son sistemas electroquímicos complejos, lo cual dificulta su modelado.

En el campo de investigación de vehículos eléctricos el modelado de la degradación del sistema de almacenamiento conformado por baterías, resulta clave para optimizar la vida del sistema de almacenamiento, como se presenta en [2], en donde la velocidad del vehículo es controlada con el objetivo de extender la vida útil de las baterías. Por otro lado, en [3] se demuestra la relevancia que tiene la degradación y su modelado para determinar el rango de autonomía del vehículo.

En escenarios particulares como centros de procesamiento de datos y subestaciones eléctricas también resulta de interés el modelo de degradación de los sistemas de almacenamiento basados en baterías. El modelado de la degradación contribuye al aumento de la disponibilidad del servidor del centro de procesamiento de datos, como se presenta en [4], mientras que para el caso de la subestación, el modelado de la degradación garantiza la disponibilidad de los servicios auxiliares, como se presenta en [5].

En casos específicos como calidad de potencia y mercados de energía, la degradación de la batería también es tema de estudio. Ejemplo de esto son los trabajos [6, 7] en los cuales la degradación se considera parte del análisis económico, en relación a la monetización de la batería, o técnico, en cuanto a la configuración del sistema de almacenamiento.

La industria aeroespacial no es ajena a los sistemas de almacenamiento y al reto que implica la degradación de los mismos. Una muestra son los trabajos [8, 9], en los cuales la degradación de la batería se modela como parte de la cuantificación de la vida útil del sistema.

Con la motivación de encontrar en la inteligencia computacional herramientas que permitan generalizar el fenómeno de la degradación de la batería de Li-ion, en este artículo se presenta una comparación de modelos de degradación basados en redes neuronales NAR y NARX y ANFIS.

Modelos de degradación de baterías basados en inteligencia computacional

Entre las ventajas que tienen los modelos de degradación basados en redes neuronales se pueden citar, capacidad de adaptación y modelado de datos no lineales. En particular las redes NAR y NARX tienen la propiedad de trabajar con series de tiempo considerando tanto el valor actual como los valores anteriores, esta propiedad hace de las redes NAR y NARX redes apropiadas para modelar la correlación de la degradación de la batería a lo largo del tiempo. En contraste las redes ANFIS combinan las ventajas de las redes neuronales y los sistemas difusos combinación que las hace apropiadas para predicciones de series de tiempo.

En consideración a que el presente artículo se soporta en el uso de las redes neuronales NAR, NARX y ANFIS para modelar la degradación de la batería, en esta sección se presentan algunos trabajos relacionados a este tipo de modelado.

Entre los trabajos que usan redes neuronales tipo NAR para modelar la degradación se puede citar a [10] en el cual se usa el Estado de Salud (SOH, por sus siglas en inglés), y una red neuronal NAR para determinar la vida útil remanente de la batería. En [11] se comparan varios tipos de redes neuronales para el modelado

de la degradación y se concluye que el mejor pronóstico es el de la red tipo NAR. En otros trabajos como el presentado en [12] se usan las redes neuronales tipo NAR para la predicción de la degradación, pero dividiendo el modelo empíricamente en varios componentes, cada uno de los cuales es determinado por una red neuronal NAR independiente.

En [13] se tiene un modelo de degradación con una red NARX de complejidad lo suficientemente baja como para ser conveniente para aplicaciones de ejecución en tiempo real. De forma similar, en el trabajo expuesto en [14] se tiene un modelo de degradación construido con una red NARX donde se centra la atención en determinar las variables que conforman las entradas de la red NARX con el objetivo de reducir el error en la predicción. Otro trabajo que parte de un análisis de las variables de entrada de la red NARX y como estas pueden ser redundantes o estar débilmente correlacionadas, se presenta en [15], en este trabajo se muestra un modelo de degradación construido con una red NARX que maneja el problema de convergencia, al mismo tiempo que mejora el error de la predicción.

Finalmente, en el modelo presentado en [16] se considera el fenómeno de la recuperación aparente de la capacidad de la batería y se aborda el problema dividiendo el mismo, empíricamente, en diferentes factores cada uno con una red ANFIS dedicada, factores que en conjunto modelan la degradación de la batería. Los modelos ANFIS, en contextos más particulares, como el caso de los vehículos eléctricos, también se han utilizado para modelar la degradación de la batería, como por ejemplo, en el trabajo presentado en [17] en el que se usa la tensión en bornes de la batería para determinar el SOH con un modelo ANFIS.

Metodología

En esta sección se presenta la fuente de los datos, su tratamiento y la descripción general de las condiciones bajo las cuales se configuraron y entrenaron los modelos NAR, NARX y ANFIS.

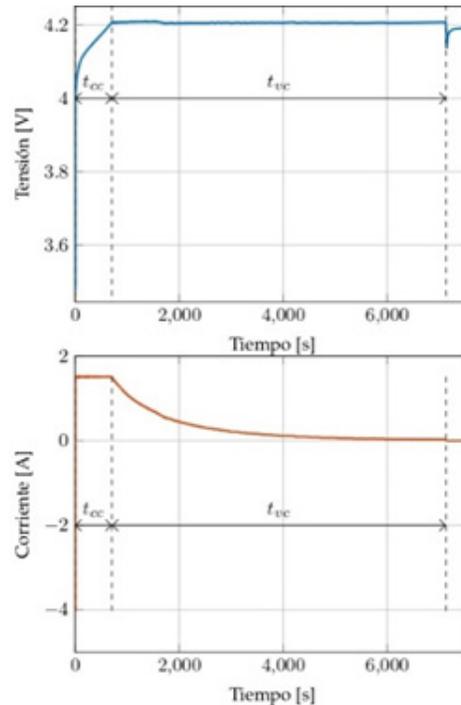
Grupos de datos

Se usaron tres grupos de datos, tomados de [18], para el entrenamiento de las redes neuronales, estos grupos de datos son identificados como B0005, B0006 y B0007. Cada grupo de datos tiene la información de corriente y tensión, en función del tiempo de carga y descarga de tres baterías distintas, cada una con una capacidad de 2Ah. Durante la carga para la fase de corriente constante se utilizó un nivel de corriente de 1.5 A y durante la fase de tensión constante se utilizó una tensión de 4.2 V. El proceso de carga se detiene cuando la corriente cae por debajo de 20 mA. La descarga se realiza a corriente constante de 2 A hasta que cada una de las baterías alcanza su nivel mínimo de tensión (2.7 V, 2.5 V, 2.2 V para B0005, B0006 y B0007, respectivamente). En la parte del grupo de datos donde se almacenan los datos del ciclo de descarga también se encuentra la capacidad en Ah de la batería. Todo el experimento se realizó en un cuarto con temperatura controlada.

Tratamiento del grupo de datos

El grupo de datos se procesó con el objetivo de establecer tres entradas para los modelos, el tiempo de corriente constante en segundos, $t_{cc_{n-k}}$, el tiempo de tensión constante durante la carga en segundos, $t_{vc_{n-k}}$, y el tiempo entre un ciclo y el siguiente, t_{rn-k} , donde un ciclo lo constituye un proceso de carga seguido por un proceso de descarga, n denota el ciclo actual y $n - k$, el k -ésimo ciclo anterior. En la Figura 1 se presenta la tensión y la corriente durante carga para el primer ciclo de la batería B0005, en esta figura se evidencian los tiempos antes definidos, los cuales hacen parte de las entradas de los modelos que se presentarán en la siguiente sección.

Figura 1 Tensión y corriente de carga. Tiempos que se utilizan como entradas en los modelos



Fuente: Elaboración propia

Desarrollo de los modelos de degradación

En esta subsección se presentan las principales características y procedimientos de las redes neuronales NAR, NARX y ANFIS que se usaron para la construcción de los modelos de degradación. Cada tipo de red neuronal se entrenó con Matlab 2019 usando cada uno de los grupos de datos disponibles, posteriormente, se presentan las tres mejores configuraciones en función del menor error cuadrático medio (MSE por sus siglas en inglés), obtenido con datos diferentes a los del entrenamiento. El MSE se usa en este trabajo como una forma de medir el rendimiento del modelo, a menor MSE, el modelo es mejor.

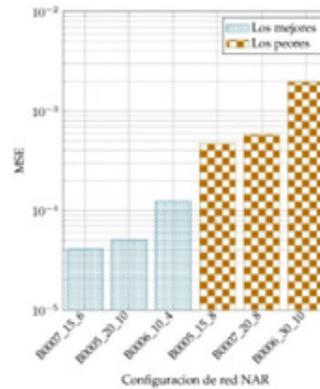
Redes NAR y NARX

Las redes NAR y NARX usan solamente una capa oculta con un número de neuronas que está dentro del conjunto {5, 10, 15, 20, 30}. Adicionalmente, se usó una retroalimentación abierta, lo que implica que los datos antecesores no provienen de la salida de la red sino del grupo de datos directamente, y se usó la función de entrenamiento Levenberg-Marquardt. Se entrenó una configuración de red neuronal por cada una de las combinaciones resultantes entre los tres grupos de datos, el número de neuronas en la capa oculta y el número de datos antecesores en el conjunto {2, 4, 6, 8, 10}. Este último conjunto aplica tanto para entradas como para la salida en el caso de los modelos NARX y solamente aplica a la salida para el caso de los modelos NAR. Los datos de entrenamiento corresponden al 70% del total de datos y los de validación al 15%, al igual que los de prueba. Cada una de estas fracciones se seleccionó aleatoriamente.

Modelos NAR

La Figura 2 presentan los tres mejores y los tres peores modelos NAR, en función del MSE logrado. En esta figura se evidencia que el nivel de error cambia abruptamente en función de la configuración de la red neuronal NAR entrenada.

Figura 2 Los tres mejores y los tres peores modelos NAR entrenados (Grupo de datos_ Numero de neuronas_numero de datos antecesores de la salida)

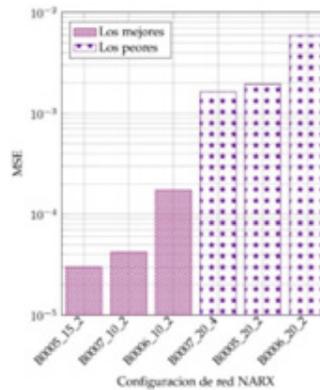


Fuente: Elaboración propia

Modelos NARX

Los mínimos y máximos de rendimiento por grupo de datos utilizados, para la red NARX se presentan en la Figura 3, en este caso también se evidencia cambios abruptos en función de la configuración de red utilizada.

Figura 3 Los tres mejores y los tres peores modelos NARX entrenados (Grupo de datos_Numero de neuronas_número de datos antecesores en la salida y en la entrada)

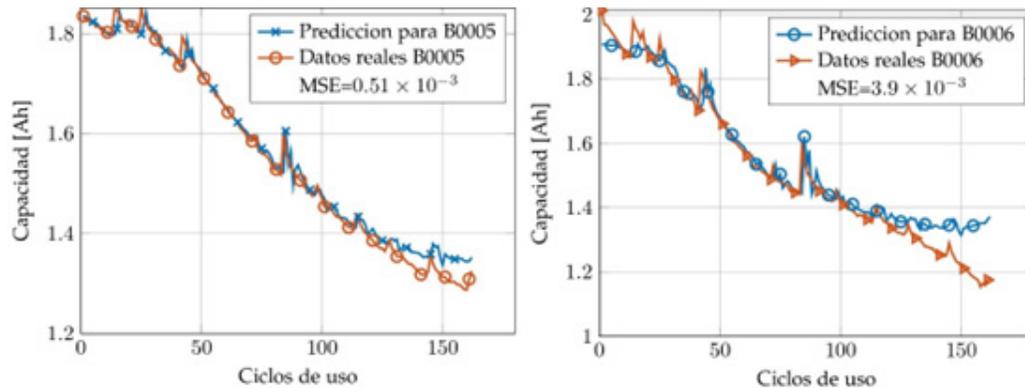


Fuente: Elaboración propia

Predicciones de los modelos NAR y NARX

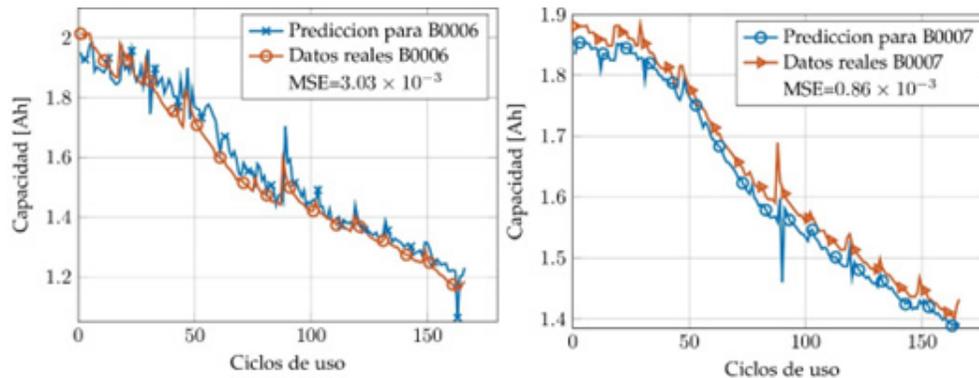
Por último, en la Figura 4 y en la Figura 5, se presentan las predicciones del mejor modelo NAR y NARX, respectivamente, que se logró para los datos de los grupos de datos, diferentes al que se utilizó para entrenamiento.

Figura 4 Predicción para los grupos de datos B0005 y B0006 con el mejor modelo NAR logrado el cual se entrenó con el grupo de datos B0007



Fuente: Elaboración propia

Figura 5 Predicción para los grupo de datos B0006 y B0007 con el mejor modelo NARX logrado el cual se entrenó con el grupo de datos B0005



Fuente: Elaboración propia

En la Figura 4 se presenta la predicción, para los grupos de datos B0005 y B0006, de la degradación de la capacidad realizada por el mejor modelo NAR, el cual corresponde al que se entrenó con el grupo de datos B0007 con quince neuronas y seis datos anteriores de la salida. El menor MSE (0.51×10^{-3}) alcanzado corresponde a la predicción realizada para el grupo de datos B0005, en este caso es posible evidenciar como el modelo reproduce con fidelidad la degradación tanto en su tendencia general como en los picos, en los cuales parece encontrarse una recuperación momentánea de la capacidad. Por otro lado, la predicción que realiza este modelo para los datos del grupo B0006 presenta un peor MSE (3.9×10^{-3}), en este caso se evidencia que el modelo tiene problemas para predecir fielmente la degradación de la capacidad al inicio de los ciclos. Es importante mencionar que ambos modelos empiezan a empeorar en su predicción a partir del ciclo 100, siendo más evidente para la predicción realizada sobre el grupo de datos B0006.

La Figura 5 presenta la predicción del mejor modelo NARX logrado, el cual corresponde al que se entrenó con el grupo de datos B0005, con quince neuronas y solo dos datos antecesores para la entrada y todas las salidas. En este caso, para la predicción realizada sobre el grupo de datos B0006, la cual corresponde al peor MSE (3.03×10^{-3}), se evidencia como el modelo tiene problemas para describir el comportamiento real de la degradación en los primeros setenta y cinco ciclos. Por otro lado, para la predicción realizada sobre los datos del grupo B0007, la cual corresponde al mejor MSE (0.86×10^{-3}), se evidencia como el modelo tiende a proporcionar una predicción que siempre se encuentra por debajo de los datos reales, pero siguiendo la tendencia general de estos datos, en este caso también se resalta el comportamiento del modelo en los

puntos donde se generan picos abruptos y la capacidad cae rápidamente para después recuperarse y seguir con más fidelidad los datos reales.

Redes ANFIS

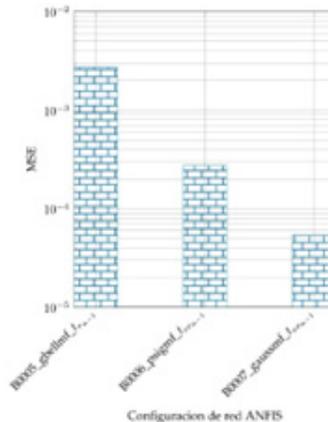
Las redes ANFIS entrenadas usan el 70% del grupo de datos para entrenamiento y el restante para validación. Se usaron tres funciones de membresía por cada entrada: *{gbellmf, gaussmf, gauss2mf, trimf, dsigmf, psigmf, pimf}* [19]. También se usó la opción de clusteringType=GridPartition con lo cual se obtiene un sistema difuso de salida única. El conjunto de posibles entradas es descrito por la ecuación (1).

$$\{t, Q_{n-1}\} \forall t \in \{t_{cc_{n-k}}, t_{vc_{n-k}}, t_{r_{n-k}}\} k = \{0,1\}$$

Los modelos se entrenaron con los primeros cien datos de cada grupo con el objetivo de utilizar el resto de los datos para probar el modelo. Con el fin de evitar el sobre-ajuste del modelo del conjunto de entrenamiento, se seleccionó aleatoriamente un 30% de datos para validación. La codificación que permitió entrenar tiene como base los ejemplos presentados en [20], del cual se utilizó la forma en que se configura la red neuronal a través del comando genfisOptions.

En la Figura 6 se presentan los tres mejores valores de rendimiento para cada uno de los grupos de datos utilizados.

Figura 6 El mejor modelo ANFIS por cada grupo de datos utilizado (Data-Set_ función de pertenencia_ variable utilizada en como parte de las entradas)



Fuente: Elaboración propia

Predicción de los modelos ANFIS

En este apartado se presenta la predicción de los mejores modelos ANFIS contra los datos reales. En la Figura 7 se presenta la mejor predicción lograda, la cual alcanzó un MSE de 0.05x10⁻³. En este caso se aprecia como el modelo es capaz de reproducir con fidelidad la tendencia general de la degradación, pero con cierto desfase, en otras palabras, la curva de predicción tiene un atraso respecto a los datos reales.

Resultados

En la Figura 8 se presentan los tres mejores modelos logrados según el MSE para cada una de las topologías de red neuronal utilizada, NAR, NARX y ANFIS. El modelo NARX (MSE=3.01x10⁻⁵) identificado como NARX_5_15_2, es el mejor que se presentó en la Figura 3, en esta figura estaba identificado como B0005_15_2 y fue el modelo entrenado con el grupo de datos B0005 con 15 neuronas y dos datos antecesores en la entrada y en la salida. De forma análoga el modelo NAR (MSE=4.10x10⁻⁵) identificado como NAR_7_15_6 es

el mejor presentado en la Figura 2 el cual se entrenó con el grupo de datos B0007 con 15 neuronas y 6 datos antecesores de la salida. Por último, se tiene el modelo ANFIS, identificado como ANFIS_gaussmf_ $t_{vc_{n-1}}$ (MSE=5.35x10⁻⁵), el mejor modelo presentado en la Figura 6, el cual se entrenó con el grupo de datos B0007 con la función de pertenencia gaussmf y que usa como variable de entrada el tiempo de tensión constante del ciclo anterior $t_{vc_{n-1}}$.

Si bien, el mejor modelo es el NARX_5_15_2 la diferencia con el peor, que es el ANFIS_gaussmf_ $t_{vc_{n-1}}$, implica menos de 3x10⁻⁵ en MSE. Sin embargo, la principal diferencia radica en la capacidad que tiene el modelo NARX de entrenar con un grupo de datos y predecir para un conjunto de datos diferentes, capturando la tendencia de la degradación, propiedad que no tiene el modelo ANFIS, el cual requiere entrenar con el mismo grupo de datos para el que se desea realizar la predicción.

En lo que atañe al modelo NAR, este utiliza 15 neuronas, las mismas que utiliza el modelo NARX, pero a diferencia de este, hace uso de 2 datos antecesores más, el modelo NARX usa un total de 4 datos antecesores, dos para la entrada y dos para salida. Cabe resaltar que el modelo ANFIS supera a los modelos NAR y NARX capturando la tendencia de la degradación a partir del ciclo 100.

En la Figura 9 se presentan los tres mejores valores de MSE para los modelos NAR junto con los tres modelos NARX. En esta figura se aprecia que la red NAR solo es superada por la red NARX en el grupo de datos B0005, con un menor número de neuronas, pero con 4 veces más datos antecesores. Para los otros dos grupos de datos, B0006 y B0007, la red NAR tiene un menor MSE, pero en contraste, usa más o igual número de neuronas que la red NARX. Por último, para el caso del grupo de datos B0006 la red NARX usa más datos antecesores que su homóloga NAR alcanzando un peor MSE.

Conclusiones

Tanto para los modelos desarrollados con redes neuronales NAR y NARX y los modelos neurodifusos no es posible establecer por inspección una relación sencilla que modele el rendimiento de la predicción en función de los parámetros explorados en este trabajo, los cuales fueron el número de neuronas y la cantidad de datos considerados anteriormente.

Por otro lado, los modelos basados en redes neuronales NAR y NARX presentan un nivel de ajuste aceptable para los datos en los primeros cien ciclos, después de este punto, el modelo empieza a disminuir su rendimiento [21]. Es importante mencionar que este tipo de modelos permite entrenar con los datos de una batería y predecir de forma adecuada la degradación de otra batería del mismo tipo, lo que indica que este tipo de red neuronal tiene propiedades convenientes para generalizar el comportamiento de la degradación de las baterías de Li-ion.

En contraste, los modelos ANFIS requieren, para este caso en particular, entrenar con los datos de la misma batería para la cual se pretende realizar la predicción, en este trabajo se entrenaron los modelos ANFIS con los primeros cien datos y se realizó predicción para los siguientes sesenta y cinco datos, encontrando que esta predicción presentaba un rendimiento aceptable para dos de los tres casos presentados.

Aprovechando el nivel de generalización que se alcanza con los modelos basados en redes neuronales NAR y NARX y el rendimiento de los modelos ANFIS entrenados con los primeros cien ciclos se puede proponer un modelo híbrido con redes NAR y NARX para la predicción de los primeros cien ciclos en conjunto con un modelo ANFIS que se entrenaría con los primeros cien ciclos para predecir la degradación a partir de este punto.

Referencias bibliográficas

1. T. Horiba, "Lithium-Ion Battery Systems", *Proceedings of the IEEE*, vol. 102, n.º 6, pp. 939-950, jun. 2014, DOI 10.1109/JPROC.2014.2319832.
2. Y. Jia, G. Luo, y Y. Zhang, "Development of optimal speed trajectory control strategy for electric vehicles to suppress battery aging", *Green Energy and Intelligent Transportation*, vol. 1, n.º 2, p. 100030, sep. 2022, DOI 10.1016/j.geits.2022.100030.
3. A. García, J. Monsalve-Serrano, S. Martínez-Boggio, y D. Golke, "Energy assessment of the ageing phenomenon in Li-Ion batteries and its impact on the vehicle range efficiency", *Energy Conversion and Management*, vol. 276, p. 116530, ene. 2023, DOI 10.1016/j.enconman.2022.116530.
4. L. Liu, H. Sun, C. Li, T. Li, J. Xin, y N. Zheng, "Managing Battery Aging for High Energy Availability in Green Datacenters", *IEEE Transactions on Parallel and Distributed Systems*, vol. 28, n.º 12, pp. 3521-3536, dic. 2017, DOI 10.1109/TPDS.2017.2712778.
5. X. Liu *et al.*, "A new dynamic SOH estimation of lead-acid battery for substation application", *International Journal of Energy Research*, vol. 41, n.º 4, pp. 579-592, 2017, DOI 10.1002/er.3662.
6. H. Aaltonen, S. Sierla, V. Kyrki, M. Pourakbari-Kasmaei, y V. Vyatkin, "Bidding a Battery on Electricity Markets and Minimizing Battery Aging Costs: A Reinforcement Learning Approach", *Energies*, vol. 15, n.º 14, Art. n.º 14, ene. 2022, DOI 10.3390/en15144960.
7. S. Dambone Sessa, A. Tortella, M. Andriollo, y R. Benato, "Li-Ion Battery-Flywheel Hybrid Storage System: Countering Battery Aging During a Grid Frequency Regulation Service", *Applied Sciences*, vol. 8, n.º 11, Art. n.º 11, nov. 2018, DOI 10.3390/app8112330.
8. S. Jang y H. Yang, "A Real-Time Scheduling Approach to Mitigation of Li-Ion Battery Aging in Low Earth Orbit Satellite Systems", *Electronics*, vol. 10, n.º 1, Art. n.º 1, ene. 2021, DOI 10.3390/electronics10010086.
9. I. P. Rodrigues, P. A. S. Oliveira, A. M. Ambrosio, y R. A. J. Chagas, "Modeling satellite battery aging for an operational satellite simulator", *Advances in Space Research*, vol. 67, n.º 6, pp. 1981-1999, mar. 2021, DOI 10.1016/j.asr.2020.12.031.
10. B. Gou, Y. Xu, y X. Feng, "State-of-health estimation and remaining-useful-life prediction for lithium-ion battery using a hybrid data-driven method", *IEEE Transactions on Vehicular Technology*, vol. 69, n.º 10, pp. 10854-10867, 2020, DOI 10.1109/TVT.2020.3014932.
11. B. Long, X. Li, X. Gao, y Z. Liu, "Prognostics Comparison of Lithium-Ion Battery Based on the Shallow and Deep Neural Networks Model", *ENERGIES*, vol. 12, n.º 17, sep. 2019, DOI 10.3390/en12173271.
12. P. Wang, X. Dan, y Y. Yang, "A multi-scale fusion prediction method for lithium-ion battery capacity based on ensemble empirical mode decomposition and nonlinear autoregressive neural networks", *International Journal of Distributed Sensor Networks*, vol. 15, n.º 3, p. 1550147719839637, 2019, DOI 10.1177/1550147719839637.
13. S. Bamati y H. Chaoui, "Lithium-ion batteries long horizon health prognostic using machine learning", *IEEE Transactions on Energy Conversion*, vol. 37, n.º 2, pp. 1176-1186, 2022, DOI 10.1109/TEC.2021.3111525.
14. S. Khaleghi *et al.*, "Online health diagnosis of lithium-ion batteries based on nonlinear autoregressive neural network", *Applied Energy*, vol. 282, p. 116159, 2021, DOI <https://doi.org/10.1016/j.apenergy.2020.116159>.
15. Z. Cui, C. Wang, X. Gao, y S. Tian, "State of health estimation for lithium-ion battery based on the coupling-loop nonlinear autoregressive with exogenous inputs neural network", *Electrochimica Acta*, vol. 393, p. 139047, oct. 2021, DOI 10.1016/j.electacta.2021.139047.

16. H. Meng, M. Geng, J. Xing, y E. Zio, "A hybrid method for prognostics of lithium-ion batteries capacity considering regeneration phenomena", *Energy*, vol. 261, p. 125278, dic. 2022, DOI 10.1016/j.energy.2022.125278.
17. O. Rahbari, C. Mayet, N. Omar, y J. Van Mierlo, "Battery aging prediction using input-time-delayed based on an adaptive neuro-fuzzy inference system and a group method of data handling techniques", *Applied Sciences*, vol. 8, n.º 8, 2018, DOI 10.3390/app8081301.
18. B Saha y K Goebel, "Battery Data Set", presentado en NASA Ames Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA, 2007. [En línea]. Disponible en: <https://www.nasa.gov/content/prognostics-center-of-excellence-data-set-repository>
19. The MathWorks Inc., "Option set for genfis command - genfisOptions". <https://la.mathworks.com/help/fuzzy/genfisoptions.html> (accedido 7 de junio de 2020).
20. The MathWorks Inc., "Adaptive Noise Cancellation Using ANFIS". <https://la.mathworks.com/help/fuzzy/adaptive-noise-cancellation-using-anfis.html> (accedido 29 de mayo de 2020).
21. C. A. Ruíz Ramírez, D. M. Montoya Quintero, y J. A. Jimenez Builes, "Un Ambiente visual integrado de desarrollo para el aprendizaje de programación en robótica", *Investigación e Innovación en Ingenierías*, vol. 9, n.º 1, pp. 7-21, 2021. DOI: <https://doi.org/10.17081/invinno.9.1.3957>