



تخمین زمانی وضعیت سلامت باتری‌های NiMH با استفاده از شبکه GRU و مدل جنگل تصادفی

مریم خادمی^{۱*}، علی اکبر کفش‌کنان^۲، محمود حیدری کیا^۳، امیرحسین پریور^۳

۱- گروه ریاضی کاربردی، دانشگاه آزاد اسلامی واحد تهران جنوب، تهران، ایران

۲- گروه مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

۳- شرکت تحقیق، طراحی و تولید موتور ایران خودرو (ایپکو)، تهران، ایران

* ایمیل نویسنده مسئول: maryam_khademi@iau.ac.ir

اطلاعات مقاله	چکیده
مقاله پژوهشی دریافت: ۱۷ خرداد ۱۴۰۵ پذیرش: ۳۰ تیر ۱۴۰۵	تخمین وضعیت سلامت باتری (SOH) برای عملکرد مطمئن سیستم‌های مدیریت باتری، به‌ویژه در خودروهای هیبریدی که از باتری‌های نیکل-فلز هیدرید استفاده می‌کنند، اهمیت دارد. در این مطالعه، یک روش داده‌محور برای تخمین شاخص SOH باتری NiMH بر اساس داده‌های ولتاژ و جریان ارائه شده است. از دیدگاه ساخت و تولید، روش پیشنهادی می‌تواند منجر به بهبود کنترل کیفیت، کاهش زمان آزمون پایان خط و کاهش وابستگی به آزمون‌های طولانی ظرفیت شود. داده‌ها با استفاده از بستر ابزار دقیق آزمایشگاهی شامل اندازه‌گیری ولتاژ، جریان و کنترل بار جمع‌آوری شدند. داده‌های خام با اعمال محدودیت‌های فیزیکی پالایش شدند تا داده‌های ثبت شده غیرعادی حذف شده و در عین حال هر دو رژیم جریان پایین و جریان بالا حفظ شوند. سپس داده‌های پالایش شده به پنجره‌هایی با طول ثابت تقسیم شده و ویژگی‌های مرتبط با ولتاژ و جریان استخراج گردیدند. برای تخمین شاخص SOH، دو مدل جنگل تصادفی و شبکه GRU ارزیابی شدند. بهترین عملکرد GRU در طول توالی ۲۰ با مقادیر $RMSE = 0.005022$ ، $MAE = 0.003012$ و $R^2 = 0.996177$ به دست آمد. در مقایسه در شرایط یکسان، جنگل تصادفی به مقادیر $RMSE = 0.016402$ ، $MAE = 0.003950$ و $R^2 = 0.959225$ دست یافت. نتایج نشان دادند هر دو مدل می‌توانند شاخص SOH را تخمین بزنند، اما GRU با استفاده از اطلاعات زمانی پنجره‌های متوالی عملکرد بهتری ارائه داد. همچنین نتایج نشان داد که افزایش بیش از حد طول توالی لزوماً باعث بهبود دقت نشده و می‌تواند عملکرد مدل بازگشتی را کاهش دهد.

Temporal state-of-health estimation of NiMH batteries using GRU networks and random forest models

Maryam Khademi^{1*}, Ali Akbar Kafshkanan², Mahmoud Heydari Kia³, Amirhossein Parivar³

1- Department of Applied Mathematics, Islamic Azad University South Tehran Branch, Tehran, Iran

2- Department of Electrical Engineering, Iran University of Science & Technology, Tehran, Iran

3- Irankhodro Powertrain Company (IPCO), Tehran, Iran

* Corresponding Author's Email: maryam_khademi@iau.ac.ir

Article Information	Abstract
Original Research Paper Received: 7 June 2026 Accepted: 21 July 2026	Estimating battery state of health (SOH) is important for the reliable operation of battery management systems, especially in hybrid vehicles using nickel-metal hydride batteries. In this study, a data-driven method is presented for estimating the SOH indicator of a NiMH battery module based on voltage and current data. From a manufacturing perspective, the proposed method can help improve quality control, reduce end-of-line testing time, and decrease dependence on long capacity tests. The data were collected using an experimental instrumentation platform including voltage measurement, current measurement, and load control. The raw data were filtered using physical limits to remove abnormal records while preserving both low-current and higher-current operating regimes. The filtered data were then divided into fixed-length windows, and voltage- and current-related features were extracted. Two models, Random Forest and GRU, were evaluated for SOH indicator estimation. The best GRU performance was obtained at a sequence length of 20, with $RMSE = 0.005022$, $MAE = 0.003012$, and $R^2 = 0.996177$. Under the same comparison condition, Random Forest achieved $RMSE = 0.016402$, $MAE = 0.003950$, and $R^2 = 0.959225$. The results showed that both models could estimate the SOH indicator, but GRU provided better performance by using temporal information from consecutive windows. The results also showed that excessively increasing the sequence length did not necessarily improve accuracy and could reduce the performance of the recurrent model.

Keywords:
NiMH Battery
SOH Indicator
GRU Network
Random Forest
Quality Control
End-Of-Line Testing
Instrumentation

Please cite this article using:

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Khademi M, Kafshkanan AA, Heydari Kia M, Parivar A. Temporal state-of-health estimation of NiMH batteries using GRU networks and random forest models. Iranian Journal of Manufacturing Engineering. 2026 Jan 21;12(11):46-58. doi: 10.22034/ijme.2026.585187.2190 [In Persian]

۱- مقدمه

باتری‌های نیکل-فلز هیدرید (NiMH) به دلیل ایمنی مناسب و پایداری عملکرد قابل قبول در چرخه‌های شارژ و دشارژ، در بسیاری از خودروهای الکتریکی هیبریدی به کار می‌روند [۱، ۲]. اگرچه در بسیاری از خودروهای جدید، به دلیل چگالی انرژی بالاتر از باتری‌های لیتیوم-یون استفاده می‌شود، باتری‌های NiMH همچنان جایگاه مهمی دارند. در شرایط واقعی، باتری معمولاً تحت الگوی جریان ثابت قرار ندارد، بلکه به دلیل شتاب‌گیری، ترمزگیری و شارژ و دشارژ متناوب، تغییرات مکرر جریان را تجربه می‌کند و می‌تواند رفتار الکتروشیمیایی و الکتریکی باتری را تغییر دهد؛ بنابراین پایش سلامت باتری، یکی از بخش‌های مهم سیستم مدیریت باتری است.

در حوزه ساخت و تولید سامانه‌های خودرویی، ارزیابی سلامت باتری علاوه بر مرحله بهره‌برداری، می‌تواند در کنترل کیفیت تولید، آزمون‌های پایان خط و تصمیم‌گیری درباره سرویس یا استفاده مجدد از باتری‌ها نیز نقش داشته باشد. در مطالعات مرتبط با تولید و پایش کیفیت، از روش‌های مبتنی بر داده، هوش مصنوعی و داده‌های ابزار دقیق برای تشخیص عیب، اندازه‌گیری کیفیت و پیش‌بینی شاخص‌های عملکرد فرایند استفاده شده است [۳، ۴]. همچنین در مطالعات مرتبط با تولید باتری، بر اهمیت کنترل کیفیت و آزمون‌های انتهای خط در زنجیره تولید سلول باتری تأکید شده است [۵]. از این رو، توسعه روش‌های داده‌محور مبتنی بر داده‌های ابزار دقیق می‌تواند به پایش کیفیت قطعات تولیدی و ارزیابی عملکرد آن‌ها کمک کند.

وضعیت سلامت باتری میزان پیری باتری نسبت به حالت اولیه یا نامی آن را بیان می‌کند. این شاخص در عملکرد ایمن و قابل اعتماد سیستم باتری اهمیت دارد [۱، ۶، ۷]. در بسیاری از مطالعات، SOH بر اساس نسبت ظرفیت قابل‌دسترس فعلی به ظرفیت نامی باتری تعریف می‌شود [۱]. با این حال، کمیت‌هایی مانند مقاومت داخلی، امپدانس، ولتاژ مدار باز و دما نیز می‌توانند برای توصیف یا تخمین وضعیت سلامت باتری استفاده شوند [۱، ۸].

روش‌های سنتی تخمین SOH معمولاً بر مدل‌های الکتروشیمیایی، مدل‌های مدار معادل، تحلیل امپدانس یا الگوریتم‌های فیلترینگ تکیه دارند [۶-۸]. این روش‌ها در شرایط کنترل‌شده دقت مناسبی دارند، اما در حضور بارگذاری دینامیکی، تغییر پارامترها، نویز اندازه‌گیری و الگوهای مختلف تخریب، عملکرد آن‌ها می‌تواند دچار اختلال شود. از سوی دیگر، روش‌های مبتنی بر مدل معمولاً به شناسایی دقیق پارامترها نیاز دارند و این موضوع استفاده از آن‌ها را در سامانه‌های واقعی دشوارتر می‌کند.

به همین دلیل، روش‌های داده‌محور در سال‌های اخیر در تخمین سلامت باتری مورد توجه قرار گرفته‌اند. این روش‌ها می‌توانند رابطه میان داده‌هایی مانند ولتاژ، جریان، دما و اطلاعات چرخه‌ای را با شاخص‌های تخریب باتری یاد بگیرند [۹-۱۱]. روش‌هایی مانند ماشین بردار پشتیبان، جنگل تصادفی و شبکه‌های عصبی برای تخمین SOH به کار رفته‌اند و توانایی مناسبی در مدل‌سازی روابط غیرخطی دارند [۱۲، ۱۳]. در این میان، جنگل تصادفی به دلیل مقاومت نسبی در برابر نویز، عملکرد مناسب روی داده‌های با اندازه متوسط و امکان تحلیل اهمیت ویژگی‌ها، گزینه‌ای مناسب برای ایجاد یک مدل پایه و تفسیرپذیر است [۱۲-۱۴].

با وجود این، رفتار تخریب باتری را نمی‌توان همیشه تنها با بررسی پنجره‌های اندازه‌گیری جداگانه توصیف کرد. تغییرات ولتاژ و جریان در پنجره‌های متوالی اطلاعات مهمی درباره وضعیت سلامت باتری فراهم می‌کنند. از این رو، مدل‌های زمانی و به‌ویژه شبکه‌های عصبی بازگشتی می‌توانند برای تخمین شاخص SOH مفید باشند. در مطالعات اخیر، معماری‌هایی مانند LSTM، LSTM دوطرفه و شبکه GRU برای مدل‌سازی الگوهای زمانی در سلامت باتری استفاده شده‌اند [۹، ۱۳]، [۱۵-۱۷]. شبکه GRU نسبت به معماری‌های بازگشتی پیچیده‌تر، دارای ساختار ساده‌تر و پارامترهای آموزشی کمتری است و در عین حال قادر است وابستگی‌های زمانی را مدل‌سازی کند؛ بنابراین برای مجموعه داده‌های نه‌چندان بزرگ گزینه مناسبی محسوب می‌شود.

اگرچه سایر روش‌ها مانند LSTM، XGBoost و ماشین بردار پشتیبان نیز در مطالعات پیشین برای تخمین SOH به کار رفته‌اند، هدف این پژوهش، مقایسه جامع بین این مدل‌ها نیست. در این مطالعه، جنگل تصادفی به عنوان یک مدل پایه و GRU به عنوان یک مدل بازگشتی با پیچیدگی کمتر نسبت به LSTM انتخاب شدند تا نقش اطلاعات زمانی در تخمین شاخص SOH بررسی شود. همچنین با توجه به اندازه نسبتاً محدود مجموعه داده، استفاده از GRU نسبت به معماری‌های عمیق‌تر مناسب‌تر ارزیابی شد.


در این پژوهش، یک رویکرد داده‌محور برای تخمین یک شاخص ساخته‌شده وضعیت سلامت باتری NiMH ارائه شده است. برخلاف بسیاری از مطالعات پیشین که بر باتری‌های لیتیوم‌یون و SOH مبتنی بر ظرفیت تمرکز داشته‌اند، این پژوهش بر داده‌های آزمایشگاهی یک پیمان‌ه باتری NiMH و یک شاخص ساخته‌شده مبتنی بر ویژگی‌های ولتاژ و جریان متمرکز است. این داده‌ها شامل شرایط کاری با

جریان پایین و جریان بالا بوده، پس از پاک‌سازی با محدودیت‌های فیزیکی، به پنجره‌هایی با طول ثابت تقسیم شدند و از هر پنجره، توصیف‌گرهای مبتنی بر ولتاژ و جریان استخراج شد. سپس مدل جنگل تصادفی به‌عنوان مدل پایه آموزش داده شد و شبکه GRU با استفاده از توالی پنجره‌های ویژگی به کار گرفته شد تا نقش اطلاعات زمانی و اثر طول توالی ورودی بررسی شود. برای مقایسه منصفانه، عملکرد مدل جنگل تصادفی نیز بر روی همان پنجره‌های مورد استفاده در آزمون مدل GRU ارزیابی شد. نوآوری اصلی این پژوهش، ارائه یک چارچوب داده‌محور برای تخمین شاخص نسبی SOH در باتری‌های NiMH بر پایه داده‌های ابزار دقیق، ترکیب ویژگی‌های استخراج‌شده از سیگنال‌های ولتاژ و جریان با مدل‌های یادگیری ماشین، مقایسه منصفانه عملکرد جنگل تصادفی و GRU و بررسی اثر طول توالی ورودی است. این رویکرد بخشی از خلأ موجود در مطالعات مربوط به باتری‌های NiMH، به‌ویژه در زمینه استفاده از داده‌های ابزار دقیق برای کاربردهای کنترل کیفیت و آزمون پایان خط، را پوشش می‌دهد و می‌تواند مبنایی برای توسعه روش‌های عملی در محیط‌های تولیدی باشد. از این منظر، روش پیشنهادی با تکیه بر داده‌های ابزار دقیق، بدون نیاز به آزمون‌های طولانی ظرفیت، می‌تواند به‌عنوان ابزاری کم‌هزینه برای پشتیبانی از کنترل کیفیت و آزمون پایان خط استفاده شود.

لازم به ذکر است که شاخص SOH در این پژوهش، یک شاخص ساخته‌شده مبتنی بر ویژگی‌های ولتاژ و جریان است و نه مقدار واقعی SOH که بر اساس آزمون ظرفیت تعیین می‌شود. بنابراین، هدف این پژوهش توسعه و ارزیابی یک شاخص نسبی برای پایش وضعیت سلامت باتری بر پایه داده‌های ابزار دقیق است و نتایج آن باید در چارچوب همین شاخص تفسیر شوند. بررسی قابلیت تعمیم این رویکرد به SOH واقعی، مستلزم در اختیار داشتن داده‌های مستقل آزمون ظرفیت است.


۲- مجموعه داده تجربی و استخراج ویژگی

داده‌های تجربی برای مطالعه حاضر در آزمایشگاه اپتیک بخش سوخت و احتراق شرکت تحقیق، طراحی و تولید موتور ایران خودرو جمع‌آوری شده است. تجهیزات آزمایشگاهی برای استخراج داده‌های لازم از باتری NiMH در شکل ۱ نشان داده شده است.



شکل ۱ تجهیزات آزمایشگاهی برای جمع‌آوری داده‌ها

همچنین نمودار مدار استفاده شده در تجهیزات آزمایشگاهی شکل ۱، در شکل ۲ به تصویر کشیده شده است. همان‌طور که در شکل ۲ نشان داده شده است، برد آردوینو برای تولید سیگنال PWM برای کنترل گیت ماسفت و مقاومت بار، و ثبت سیگنال‌های ولتاژ و جریان به کار رفت. ولتاژ باتری از طریق تقسیم‌کننده ولتاژ و جریان از طریق مقاومت شانت اندازه‌گیری و به ورودی میکروکنترلر اعمال شد. این بستر ابزار دقیق امکان ثبت هم‌زمان ولتاژ و جریان را فراهم کرد و از این نظر مشابه یک سامانه آزمون عملکرد قطعه است که می‌تواند در کنترل کیفیت و ارزیابی سلامت پیمانه‌های باتری به کار رود. از آنجا که پاسخ ولتاژ و جریان باتری تحت تأثیر پیری و شرایط کاری قرار دارد، این سیگنال‌ها اطلاعات مناسبی برای تخمین SOH فراهم می‌کنند.



شکل ۲ مدار اندازه‌گیری و کنترل مورد استفاده برای جمع‌آوری داده‌های باتری

در مرحله پیش‌پردازش، داده‌ها بر اساس محدودیت‌های فیزیکی پالایش شدند؛ به‌طوری‌که ولتاژهای خارج از بازه ۶ تا ۱۰ ولت حذف و مقادیر جریان به آمپر تبدیل شدند. پس از این مرحله، ۲۰۰۵۶۸ نمونه باقی ماند که خلاصه آن‌ها در جدول ۱ ارائه شده است. وجود مقادیر جریان تا حدود ۳/۸ آمپر نیز به دلیل حضور هر دو رژیم جریان پایین و جریان بالا در داده‌ها است.

جدول ۱ خلاصه‌ای از داده‌های خام اندازه‌گیری پس از پالایش

شاخص	میانگین	انحراف معیار	کمینه	بیشینه
ولتاژ (V)	۸/۲۸۲	۰/۲۵۳	۶/۸۲۰	۹/۲۸۰
جریان (A)	۰/۷۱۰	۰/۵۸۳	۰/۰۰۰	۳/۷۶۶
زمان (s)	۲۴۲۹۵/۵۸۷	۱۹۰۵۲/۴۰۹	۰/۰۰۰	۶۴۹۹۲/۰۰۰

برای جلوگیری از نشت اطلاعات ناشی از همپوشانی پنجره‌ها، داده‌های خام پالایش شده ابتدا به مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شدند. سپس به نمونه‌هایی در سطح پنجره تبدیل شدند. سیگنال‌های ولتاژ و جریان با فیلتر ساویتزکی-گولای^۱ با طول پنجره ۳۱ و چندجمله‌ای درجه ۳ هموار شدند تا اثر نویز کاهش یابد. سپس، هر سری زمانی به پنجره‌هایی با اندازه ۳۰۰ نمونه و گام ۱۵۰ نمونه تقسیم شد. بنابراین، همپوشانی پنجره‌های متوالی برابر با ۵۰ درصد بود. پس از پنجره‌بندی، ویژگی‌های مربوط به ولتاژ و جریان از هر پنجره استخراج شد. در نتیجه، ۲۰۰۵۶۸ نقطه داده به ۱۳۲۸ نمونه ویژگی در سطح پنجره تبدیل شد. استفاده از پنجره‌های همپوشان باعث حفظ رفتار محلی سیگنال‌ها شد.

ویژگی‌های ولتاژی شامل میانگین ولتاژ، تغییرات ولتاژ، افت ولتاژ، بازیافت ولتاژ و شیب ولتاژ در ابتدا و انتهای پنجره بودند. افت ولتاژ به صورت اختلاف حداکثر و حداقل ولتاژ محاسبه شد و بازیافت ولتاژ از اختلاف ولتاژ نهایی و حداقل ولتاژ در همان پنجره به دست آمد. شیب‌های ابتدا و انتهای پنجره نیز به ترتیب با استفاده از ۳۰ نمونه اول و ۳۰ نمونه آخر محاسبه شدند. ویژگی‌های جریانی شامل میانگین جریان، میانگین قدرمطلق جریان، انحراف معیار جریان و حداکثر قدرمطلق جریان بودند. همچنین یک توصیف‌گر نسبی مرتبط با مقاومت از نسبت تغییرات ولتاژ به تغییرات متناظر جریان محاسبه شد. این توصیف‌گر فقط به عنوان شاخص نسبی در سطح پنجره استفاده شد و نباید به عنوان اندازه‌گیری مستقیم مقاومت اهمی یا امپدانس مطلق پیمانه تفسیر شود.

در ابتدا مجموعه بزرگ‌تری از توصیف‌گرهای ولتاژ و جریان استخراج شد. از میان آن‌ها، توصیف‌گرهایی که مستقیماً در محاسبه شاخص هدف SOH به کار رفته بودند (از جمله میانگین ولتاژ، افت ولتاژ و شاخص نسبی مقاومت) از ورودی مدل حذف شدند، اما سایر ویژگی‌های ولتاژی مستقل مانند حداقل ولتاژ، حداکثر ولتاژ و انحراف معیار ولتاژ حفظ شدند. مجموعه نهایی ورودی شامل ۱۱ توصیف‌گر بود که در جدول ۲ گزارش شده‌اند.

¹ Savitzky-Golay

جدول ۲ ویژگی‌های ورودی گزینش شده جهت تخمین شاخص SOH

ویژگی	توصیف	ویژگی	توصیف
duration_s	مدت زمان پنجره اندازه‌گیری انتخابی	final_voltage_slope	نرخ تغییرات ولتاژ در انتها
std_voltage	انحراف معیار ولتاژ درون پنجره	mean_current	مقدار میانگین جریان درون پنجره
min_voltage	حداقل مقدار ولتاژ درون پنجره	mean_abs_current	مقدار میانگین قدرمطلق جریان
max_voltage	حداکثر مقدار ولتاژ درون پنجره	std_current	انحراف معیار جریان
voltage_recovery	رفتار بازیافت ولتاژ درون پنجره	max_abs_current	حداکثر قدرمطلق جریان
initial_voltage_slope	نرخ تغییرات ولتاژ در ابتدا		

در فرایند پیش‌بینی، متغیر هدف به گونه‌ای ساخته شد که یک شاخص SOH حساس به تخریب باشد که بر اساس مقادیر نرمال شده همین شاخص محاسبه می‌گردد. دلیل انتخاب این رویکرد، عدم وجود یک اندازه‌گیری مرجع از ظرفیت کامل برای هر پنجره بود. برای تعریف متغیر هدف، ابتدا چندین شاخص تخریب که از ولتاژ درون هر پنجره به دست آمده بودند، با استفاده از روش نرمال‌سازی حداقل-حداکثر، نرمال‌سازی شدند. در نتیجه، شاخص SOH را می‌توان به صورت ترکیب وزنی این مقادیر در نظر گرفت:

$$SOH_{ind} = 0.6V_{norm} + 0.2(1 - D_{norm}) + 0.2(1 - R_{norm}) \quad (1)$$

که در آن V_{norm} میانگین ولتاژ نرمال شده، D_{norm} افت ولتاژ نرمال شده و R_{norm} تخمین مقاومت داخلی نرمال شده است. مقدار بالای میانگین ولتاژ نشانه عملکرد مطلوب مازول است، در حالی که افت ولتاژ زیاد و مقاومت داخلی بزرگ، رفتار تخریب شدیدی را نشان می‌دهند. بنابراین، هر دو پارامتر به صورت معکوس در نظر گرفته شدند.

ضرایب رابطه ۱ پس از چندین آزمون اولیه و با هدف حفظ پایداری شاخص و سازگاری آن با روند تغییرات مشاهده شده در داده‌های آزمایشگاهی انتخاب شدند و حاصل یک فرایند بهینه‌سازی عددی نیستند. در این ترکیب، میانگین ولتاژ با ضریب ۰.۶ بیشترین وزن را دریافت کرده است، زیرا در داده‌های مورد استفاده پایدارترین و قابل‌اعتمادترین شاخص مرتبط با وضعیت عملکرد باتری در مجموعه داده حاضر محسوب می‌شود. در مقابل، افت ولتاژ و شاخص نسبی مقاومت داخلی هر یک با ضریب ۰.۲ در نظر گرفته شدند، زیرا اگرچه هر دو با فرایند تخریب مرتبط هستند، اما حساسیت بیشتری به شرایط کاری و تغییرات جریان دارند. هدف از این وزن‌دهی، ایجاد یک شاخص نسبی و پایدار برای مقایسه وضعیت سلامت نمونه‌ها بوده است، نه ارائه یک تعریف استاندارد از SOH.

در مرحله نهایی، مقدار شاخص SOH به بازه $[0, 1]$ محدود شد. مقادیر به دست آمده از شاخص SOH در محدوده ۰/۲۹۶۰ تا ۰/۹۸۵۱ متغیر بود، با مقدار میانگین برابر با ۰/۶۹۴۱، در حالی که انحراف معیار ۰/۰۷۸۷ بود.

ماتریس همبستگی بین ویژگی‌های استخراج شده و شاخص SOH در شکل ۳ نشان داده شده است. مشاهده می‌شود که همبستگی بین ویژگی‌های ولتاژی و شاخص SOH بیش‌تر از سایر ویژگی‌ها است. به عبارت دیگر، همبستگی قوی بین حداقل و حداکثر ولتاژ با شاخص SOH وجود دارد. این موضوع منطقی است زیرا پاسخ ولتاژ به شدت به وضعیت سلامت و شرایط کاری مازول وابسته است.

۳- روش‌شناسی پیشنهادی

معماری کلی تخمین شاخص SOH در شکل ۴ نشان داده شده است. در این چارچوب، سیگنال‌های خام ولتاژ و جریان اندازه‌گیری شده باتری NiMH ابتدا پیش‌پردازش و پنجره‌بندی می‌شوند. سپس توصیف‌گرهای مبتنی بر ولتاژ و جریان از هر پنجره استخراج شده و برای دو مسیر تخمین به کار می‌روند. مسیر نخست، مدل جنگل تصادفی و مسیر دوم، مدل GRU است. در نهایت، مقادیر تخمین زده شده با شاخص SOH ساخته شده و بر اساس معیارهای رگرسیونی ارزیابی می‌شوند.


۳-۱- تعریف شاخص SOH

در مطالعات باتری، تعریف رایج برای وضعیت سلامت، نسبت ظرفیت فعلی در دسترس به ظرفیت نامی اولیه باتری است:


$$SOH = \frac{C_{available}}{C_{rated}} \quad (2)$$

که در آن $C_{available}$ ظرفیت قابل دسترس در وضعیت پیری فعلی باتری و C_{rated} ظرفیت نامی باتری است. این رویکرد معمولاً زمانی به کار می‌رود که مراجع کامل مربوط به ظرفیت باتری در طول فرایند پیری قابل ارائه باشند. در این پژوهش، به دلیل نبود داده ظرفیت، شاخص SOH به صورت نرمال شده در بازه [0, 1] تعریف شده است.

با توجه به در دسترس نبودن مقادیر مرجع ظرفیت باتری، هدف مدل‌ها در این پژوهش تخمین شاخص نسبی SOH معرفی شده در بخش قبل است. از این‌رو، مقادیر SOH گزارش شده بیانگر یک شاخص داده‌محور مبتنی بر ویژگی‌های ولتاژ و جریان هستند، نه SOH متعارف مبتنی بر ظرفیت.



شکل ۳ ماتریس همبستگی بین ویژگی‌های استخراج شده و شاخص SOH ساخته شده



شکل ۴ معماری کلی روش پیشنهادی برای تخمین شاخص SOH

۳-۲- مدل رگرسیونی جنگل تصادفی

جنگل تصادفی، به دلیل استحکام، سادگی در آموزش و قابلیت کاربرد در مسائل رگرسیون غیرخطی، به عنوان الگوریتم یادگیری ماشین پایه انتخاب شد. علاوه بر این، جنگل تصادفی در مطالعات مختلف تخمین وضعیت سلامت باتری نیز به کار رفته است، زیرا می‌تواند روابط غیرخطی بین ویژگی‌های ورودی را شناسایی کرده و تفاسیر قابل فهمی از اهمیت ویژگی‌ها ارائه دهد [۱۳، ۱۴]. فرمول پیش‌بینی برای مسئله رگرسیون با استفاده از جنگل تصادفی را می‌توان به صورت زیر توصیف کرد:

$$\hat{y}(x) = \frac{1}{M} \sum_{m=1}^M f_m(x) \quad (3)$$

در رابطه (۳)، x بردار ویژگی ورودی، M تعداد درخت‌های تصمیم، $f_m(x)$ نتیجه درخت m -ام، و $\hat{y}(x)$ شاخص تخمین زده شده SOH است. در این پژوهش، بردار ویژگی ورودی شامل مجموعه ویژگی‌های انتخابی مبتنی بر ولتاژها و جریان‌های ارائه شده در جدول ۲ است. آموزش جنگل تصادفی با هدف یادگیری رابطه بین این ویژگی‌های ورودی و شاخص محاسبه شده SOH انجام شد.

۳-۳- مدل زمانی مبتنی بر GRU

اگرچه جنگل تصادفی شاخص SOH را با استفاده از پنجره‌های ویژگی مجزا تخمین می‌زند، اما توانایی استخراج ویژگی‌های زمانی را ندارد. از سوی دیگر، فرایند تخریب باتری و تغییرات ولتاژ و جریان دارای ماهیت زمانی هستند و ممکن است اطلاعات ارزشمندی در رفتار قبلی باتری‌ها نهفته باشند. از این رو، یک شبکه GRU در رویکرد دوم تخمین مورد توجه قرار گرفت.

GRU با ساختار در پیچه‌ای خود می‌تواند اطلاعات مهم پنجره‌های قبلی را حفظ کند و در عین حال نسبت به LSTM ساختار ساده‌تر و پارامترهای کمتری دارد. بنابراین، برای داده‌های محدود این پژوهش و مدل‌سازی وابستگی‌های زمانی بین پنجره‌های ویژگی، گزینه مناسبی است [۹، ۱۴، ۱۶]. در شبکه GRU، به جای استفاده از بردارهای ویژگی در ورودی، یک توالی از بردارهای ویژگی متوالی در نظر گرفته می‌شود. اگر L طول توالی و F تعداد ویژگی‌های انتخابی باشد، مقدار ورودی را می‌توان به صورت زیر نمایش داد:

$$X_t = [x_{t-L+1}, x_{t-L+2}, \dots, x_t] \in R^{L \times F} \quad (4)$$

که در آن x_t بردار ویژگی در اندیس t است. در آزمایش، $F = 11$ است که متناظر با ویژگی‌های ورودی انتخابی است. مقادیر مختلف L به منظور بررسی تأثیر اندازه پنجره زمانی بر عملکرد پیش‌بینی شاخص SOH مورد بررسی قرار گرفته‌اند. ورودی مدل GRU توالی ویژگی‌ها X_t و خروجی آن مقدار شاخص SOH متناظر با آخرین پنجره توالی است. GRU با به‌روزرسانی حالت پنهان خود از طریق در پیچه‌ها، می‌تواند اطلاعات مفید از تاریخچه را حفظ کرده و در عین حال واریانس نامربوط را فراموش کند.

۳-۴- تحلیل طول توالی

تعداد گام‌های زمانی مورد استفاده در مدل‌های بازگشتی برای رمزگذاری تاریخچه اخیر، پارامتر مهمی است که هم بر پایداری یادگیری و هم بر دقت پیش‌بینی‌ها تأثیر می‌گذارد [۱۵-۱۷]. بنابراین، یکی از جنبه‌های مهمی که در زمینه تخمین شاخص SOH توسط شبکه GRU پیشنهادی مورد تحلیل قرار گرفت، نقش طول توالی است. طول توالی تعیین می‌کند که چه تعداد از پنجره‌های ویژگی قبلی در پیش‌بینی مقدار فعلی شاخص SOH در نظر گرفته شوند.

اگر تعداد گام‌های زمانی ناکافی باشد، مدل ممکن است اطلاعات کافی در مورد فرایند تغییر در رفتار عملیاتی باتری نداشته باشد. با این حال، در مقابل، انتخاب طول توالی بسیار بزرگ، علاوه بر کاهش تعداد نمونه‌های آموزشی، ممکن است باعث یادگیری الگوهای غیرضروری و کاهش قابلیت تعمیم مدل شود. برای بررسی این موضوع، طول‌های توالی متعدد، یعنی $L=5, 10, 15, 20, 30, 40, 50$ در نظر گرفته شدند. عملکرد شبکه GRU در هر یک از حالات فوق، مورد تحلیل و ارزیابی قرار گرفته شد.

۳-۵- جزئیات پیاده‌سازی و معیارهای ارزیابی

پس از تقسیم داده‌ها و استخراج ویژگی‌ها، پارامترهای نرمال‌سازی تنها از مجموعه آموزش محاسبه شدند و همان پارامترها برای مجموعه‌های اعتبارسنجی و آزمون نیز اعمال گردیدند. آموزش مدل جنگل تصادفی با استفاده از ۱۱ ویژگی انتخابی به عنوان نمونه‌های مستقل در سطح پنجره انجام شد. کیفیت پیش‌بینی‌های مدل‌ها با معیارهای RMSE، MAE و R^2 اندازه‌گیری شد.

داده‌ها ابتدا با انجام یک تقسیم به داده‌های آزمایش (۲۰٪) و سپس یک تقسیم به داده‌های اعتبارسنجی (۲۰٪) تفکیک گردیدند. برای مدل جنگل تصادفی، از ۵۰۰ درخت تصمیم با حداکثر عمق ۱۴ استفاده شد. علاوه بر این، حداقل نمونه برگ برابر با ۲ و حداقل نمونه برای تقسیم برابر با ۴ تنظیم گردید. در مورد مدل GRU، یک مدل دو لایه با اندازه پنهان ۶۴ و نرخ حذف^۱ 0.20 استفاده شد. GRU با استفاده از بهینه‌ساز AdamW^۲ با نرخ یادگیری 1e-3 و کاهش وزن^۳ 1e-5 آموزش داده شد. اندازه دسته^۴ برابر با ۳۲ و حداکثر دوره^۵ برابر با ۳۰۰ استفاده گردید. برای جلوگیری از بیش‌برازش^۶، از رویکرد توقف زودهنگام^۷ با شکیبایی^۸ معادل ۳۵ دوره استفاده شد. مقدار اولیه تصادفی^۹ تقسیم بر روی ۴۲ تنظیم شد. در نهایت، به منظور انجام مقایسه نهایی با GRU، تقسیم‌های پنجره هدف از داده‌های آزمایش برای مدل جنگل تصادفی نیز با استفاده از مقدار پارامتر L=20 مدل GRU ایجاد گردید.

ابزار پارامترهای مدل GRU شامل تعداد لایه‌ها، اندازه حالت پنهان، نرخ حذف (Dropout)، نرخ یادگیری، اندازه دسته، تعداد دوره‌های آموزش و پارامترهای توقف زودهنگام، بر اساس مجموعه‌ای از آزمایش‌های مقدماتی و با توجه به عملکرد مدل روی مجموعه اعتبارسنجی انتخاب شدند. هدف از این فرایند، دستیابی به تعادل میان دقت پیش‌بینی، پایداری آموزش و جلوگیری از بیش‌برازش بود. در این پژوهش از روش‌های خودکار بهینه‌سازی ابزار پارامتر مانند Grid Search یا Bayesian Optimization استفاده نشد، زیرا هدف اصلی مطالعه، بررسی اثر اطلاعات زمانی و طول توالی ورودی بر عملکرد مدل بود.

۴- نتایج و بحث

عملکرد چارچوب پیشنهادی تخمین شاخص SOH در سه مرحله ارزیابی شد. ابتدا، مدل جنگل تصادفی با استفاده از مجموعه داده ویژگی‌های استخراج‌شده آموزش داده شد تا اهمیت ویژگی‌ها تحلیل گردد. سپس، مدل GRU با طول‌های توالی مختلف آموزش داده شد تا تأثیر اندازه پنجره زمانی بر عملکرد تخمین بازگشتی بررسی شود. در نهایت، برای مقایسه منصفانه، عملکرد مدل جنگل تصادفی بر روی همان پنجره‌های هدف آزمایشی مورد استفاده در بهترین مدل GRU ارزیابی شد.

۴-۱- نتایج جنگل تصادفی

پس از آموزش این مدل پایه، مقادیر $RMSE = 0.012332$ ، $MAE = 0.003429$ و $R^2 = 0.970166$ به دست آمدند. این نتایج نشان می‌دهد که ویژگی‌های استخراج‌شده حاوی اطلاعات مناسبی برای تخمین شاخص SOH هستند. نتایج تحلیل اهمیت ویژگی‌ها در مدل جنگل تصادفی در شکل ۵ ارائه شده است. تحلیل اهمیت ویژگی‌ها نشان می‌دهد که حداقل و حداکثر ولتاژ بیشترین سهم را در تصمیم‌گیری مدل جنگل تصادفی دارند. این موضوع با نتایج حاصل از شکل ۳، سازگاری دارد. علاوه بر این، توصیف‌گرهای میانگین جریان و میانگین قدرمطلق جریان، نیز تأثیراتی بر الگوریتم دارند.

۴-۲- تأثیر طول توالی بر عملکرد GRU

برای بررسی میزان تأثیر تاریخچه زمانی بر تخمین شاخص SOH، عملکرد مدل GRU با طول‌های توالی مختلف ارزیابی شد. در این آزمایش، طول‌های توالی برابر با 5, 10, 15, 20, 30, 40, 50 در نظر گرفته شدند. همان‌طور که در شکل ۶ نشان داده می‌شود، عملکرد مدل GRU به شدت تحت تأثیر طول توالی قرار می‌گیرد. بالاترین R^2 به دست آمده مربوط به طول توالی ۲۰ است که مقدار R^2 برابر با ۰/۹۹۶۱۷۷ را ارائه می‌کند. شکل ۷ نیز همین روند را تأیید می‌کند. اگرچه کمترین مقدار MAE در L=30 مشاهده شد، مدل با L=20 به دلیل داشتن کمترین RMSE و بیشترین مقدار R^2 به‌عنوان بهترین پیکربندی انتخاب شد. کاهش عملکرد در L=40 و L=50 احتمالاً ناشی از کاهش تعداد نمونه‌های آموزشی مؤثر در اثر افزایش طول توالی است.

¹ Drop Out

² AdamW Optimizer

³ Weight Decay

⁴ Batch Size


⁵ Epoch

⁶ Overfitting

⁷ Early Stopping

⁸ Patience


⁹ Random Seed




شکل ۵ اهمیت ویژگی‌ها در مدل جنگل تصادفی به شیوه GRU با طول توالی ۲۰

جدول ۳ تأثیر طول توالی بر تخمین شاخص SOH مبتنی بر GRU

مدل	طول توالی	RMSE	MAE	R^2
GRU	۵	۰/۰۱۲۱۹۳	۰/۰۰۳۶۰۸	۰/۹۶۸۶۶۳
	۱۰	۰/۰۰۵۶۰۹	۰/۰۰۲۷۵۵	۰/۹۹۴۱۵۰
	۱۵	۰/۰۰۶۸۸۶	۰/۰۰۴۱۱۱	۰/۹۹۱۱۲۶
	۲۰	۰/۰۰۵۰۲۲	۰/۰۰۳۰۱۲	۰/۹۹۶۱۷۷
	۳۰	۰/۰۰۵۵۴۵	۰/۰۰۲۵۷۸	۰/۹۹۴۲۰۰
	۴۰	۰/۰۰۷۷۳۸	۰/۰۰۳۲۹۳	۰/۹۸۶۲۴۴
	۵۰	۰/۰۰۸۵۹۰	۰/۰۰۴۱۲۰	۰/۹۸۵۰۱۴



شکل ۶ تأثیر طول توالی مدل GRU بر عملکرد R^2




شکل ۷ تغییرات خطای پیش‌بینی مدل GRU برای طول‌های توالی مختلف

۴-۳- بهترین مدل GRU با طول توالی ۲۰


از سوی دیگر، مطابق با یافته‌های حاصل از تحلیل طول‌های توالی، بهترین مدل بازگشتی برای استفاده، GRU با طول توالی ۲۰ ($L=20$) است. برای این مدل، مقادیر به‌دست‌آمده عبارتند از: $RMSE = 0.005022$ ، $MAE = 0.003012$ و $R^2 = 0.996177$. این نتایج نشان می‌دهد که انتخاب طول توالی مناسب می‌تواند دقت تخمین شاخص SOH را به‌طور قابل توجهی بهبود دهد.

شکل ۸ مقایسه بین مقادیر مرجع شاخص SOH ساخته‌شده و خروجی مدل GRU را در حالت $L=20$ نشان می‌دهد. همان‌طور که مشاهده می‌شود، بیشتر نقاط داده در نزدیکی خط تخمین ایده‌آل قرار دارند که با نتایج عددی جدول ۳ هم‌خوان است.

شکل ۹ روند شاخص SOH را برای مقادیر مرجع و پیش‌بینی‌شده نشان می‌دهد. منحنی پیش‌بینی در طول بیشتر فرایند آزمایش، به خوبی با منحنی مرجع منطبق می‌شود. این موضوع نشان می‌دهد که مدل GRU قادر است تغییرات تدریجی و موضعی شاخص SOH را با استفاده از اطلاعات زمانی پنجره‌های متوالی دنبال کند.



شکل ۸ مقادیر مرجع در مقابل شاخص SOH پیش‌بینی‌شده برای بهترین مدل GRU با $L=20$



شکل ۹ ردیابی روند شاخص SOH با استفاده از بهترین مدل GRU با طول توالی ۲۰

۴-۴- مقایسه منصفانه بین جنگل تصادفی و GRU

به منظور انجام یک مقایسه منصفانه بین هر دو روش، آزمایش مدل جنگل تصادفی بر روی پنجره‌های هدف با همان اندازه $L=20$ ، مشابه آزمایش مدل GRU ارزیابی شد. از آنجا که مدل GRU داده‌های ورودی خود را بر اساس توالی قبلی پنجره‌ها می‌سازد، پنجره هدف به عنوان نمونه‌های آزمایشی برای روش جنگل تصادفی انتخاب شد. نتایج تجربی در جدول ۴ ارائه شده است. با توجه به جدول ۴، مدل GRU از نظر معیارهای RMSE، MAE و R^2 نتایج بهتری نسبت به مدل جنگل تصادفی ارائه داده است.

جدول ۴ مقایسه منصفانه روش‌های جنگل تصادفی و GRU با $L=20$ بر روی پنجره‌های هدف آزمایشی یکسان

مدل	RMSE	MAE	R^2
جنگل تصادفی	۰/۰۱۶۴۰۲	۰/۰۰۳۹۵۰	۰/۹۵۹۲۲۵
GRU با $L=20$	۰/۰۰۵۰۲۲	۰/۰۰۳۰۱۲	۰/۹۹۶۱۷۷

نتایج نشان می‌دهند که شاخص SOH عمدتاً تحت تأثیر ویژگی‌های مرتبط با ولتاژ، به‌ویژه حداقل و حداکثر ولتاژ، قرار دارد. این موضوع با نحوه تعریف شاخص SOH و رفتار ولتاژی باتری در شرایط کاری مختلف هم‌خوان است. با این حال، ویژگی‌های جریان نیز به دلیل وجود رژیم‌های جریان پایین و بالا در داده‌های پاک‌سازی‌شده، در فرایند تخمین نقش معناداری دارند.

مقایسه جنگل تصادفی و GRU نشان داد که اگرچه جنگل تصادفی عملکرد مناسبی دارد، مدل GRU با بهره‌گیری از اطلاعات زمانی دقت بالاتری ارائه می‌دهد. این موضوع نشان می‌دهد که تاریخچه کوتاه‌مدت تغییرات ولتاژ و جریان می‌تواند اطلاعات ارزشمندی برای تخمین شاخص SOH فراهم کند.

از منظر کاربرد صنعتی، روش پیشنهادی می‌تواند در آزمون پایان خط یا کنترل کیفیت تولید مورد استفاده قرار گیرد؛ به‌گونه‌ای که تنها با ثبت یک آزمون کوتاه ولتاژ و جریان توسط تجهیزات ابزار دقیق، ویژگی‌های مورد نیاز استخراج شده و شاخص سلامت نسبی هر پیمانه توسط مدل آموزش‌دیده برآورد شود. در نتیجه، بدون نیاز به آزمون‌های طولانی ظرفیت یا اندازه‌گیری‌های پیچیده امپدانس، امکان دسته‌بندی پیمانه‌ها و تصمیم‌گیری درباره پذیرش، رد، سرویس یا استفاده مجدد آن‌ها فراهم می‌شود.

همچنین نتایج تحلیل طول توالی نشان دادند که افزایش بیش از حد طول ورودی الزاماً باعث بهبود عملکرد نمی‌شود. بهترین نتیجه برای $L=20$ به دست آمد، در حالی که طول‌های $L=40$ و $L=50$ دقت کمتری داشتند. بنابراین، انتخاب طول توالی مناسب یکی از عوامل مهم در تخمین SOH با شبکه GRU است. لازم به تأکید است که نتایج این پژوهش بر مبنای شاخص نسبی SOH معرفی شده‌اند؛ از این رو، عملکرد مدل‌ها نباید معادل تخمین مستقیم SOH مبتنی بر ظرفیت تفسیر شود.

۵- نتیجه‌گیری

در این پژوهش، یک رویکرد داده‌محور برای تخمین شاخص SOH باتری NiMH با استفاده از مدل‌های جنگل تصادفی و GRU ارائه شد. پس از پالایش داده‌های ولتاژ و جریان بر اساس حدود فیزیکی، هر دو رژیم جریان پایین و جریان بالا در مجموعه داده حفظ شدند. سپس داده‌ها به پنجره‌های زمانی همپوشان تقسیم و ویژگی‌های مبتنی بر ولتاژ و جریان استخراج شدند. مدل GRU برای بررسی نقش اطلاعات زمانی به کار گرفته شد و بهترین عملکرد آن در طول توالی $L=20$ به دست آمد؛ به‌طوری‌که $MAE = 0.003012$ ، $RMSE = 0.005022$ و $R^2 = 0.996177$ حاصل شد. در مقایسه در شرایط برابر، جنگل تصادفی روی همان اهداف آزمون به مقادیر $MAE = 0.003950$ ، $RMSE = 0.016402$ و $R^2 = 0.959225$ دست یافت. تحلیل طول توالی نشان داد که افزایش بیش از حد طول ورودی الزاماً باعث بهبود دقت نمی‌شود و توالی‌های طولانی می‌توانند عملکرد مدل بازگشتی را کاهش دهند. بنابراین، انتخاب طول توالی مناسب در تخمین شاخص SOH با شبکه GRU اهمیت دارد. این نتایج نشان می‌دهد که ترکیب ویژگی‌های استخراج‌شده از داده‌های ابزار دقیق با مدل‌های یادگیری ماشین، رویکردی مؤثر برای تخمین شاخص نسبی SOH در باتری‌های NiMH بوده و می‌تواند مبنایی برای توسعه سامانه‌های پایش سلامت و کنترل کیفیت باتری باشد.

با توجه به این‌که شاخص SOH در این پژوهش یک شاخص ساخته‌شده مبتنی بر ویژگی‌های ولتاژ و جریان است، نتایج ارائه‌شده بیانگر توانایی مدل‌ها در تخمین این شاخص بوده و نباید معادل تخمین مستقیم SOH مبتنی بر ظرفیت تفسیر شوند. با این حال، اتکای روش پیشنهادی به داده‌های ساده ولتاژ و جریان، امکان استفاده از آن را در آزمون‌های پایان خط و کنترل کیفیت تولید فراهم می‌کند. در پژوهش‌های آینده، اعتبارسنجی این چارچوب با استفاده از مقادیر SOH حاصل از آزمون‌های مستقل ظرفیت، همراه با بررسی پیمانه‌های بیشتر NiMH و شرایط دمایی و باری متنوع‌تر، می‌تواند به ارزیابی دقیق‌تر و افزایش تعمیم‌پذیری روش منجر شود.

تقدیر و تشکر

نویسندگان مراتب سپاسگزاری خود را از آزمایشگاه اپتیک شرکت تحقیق، طراحی و تولید موتور ایران خودرو (IPCO) به دلیل تأمین تجهیزات و تسهیلات آزمایشگاهی این پژوهش ابراز می‌دارند.

References

- [1] Yang H, Qiu Y, Guo X. Prediction of state-of-health for nickel-metal hydride batteries by a curve model based on charge-discharge tests. *Energies*. 2015 Nov 4;8(11):12474-87. doi: 10.3390/en81112322
- [2] Kafshkanan AA, Shahabiniya MP, Heydarikia M, Parivar AH, Kharazmi S. State-of-health prediction of nickel-metal hydride battery of Toyota Prius hybrid vehicle using features extracted from charge-discharge curves and machine learning. In: *Proceedings of the 14th International Conference on Electrical Engineering, Computer, Mechanics and Artificial Intelligence*; 2026 Jun; Mashhad, Iran. [In Persian]
- [3] Maghamfar A, Shahbazi M, Hashemi R. Detection and measurement of warping in FDM additive manufacturing process using artificial intelligence and machine vision. *Iranian Journal of Manufacturing Engineering*. 2025 Feb 19;11(12):1-5. (In Persian). doi: 10.22034/ijme.2024.479491.2011
- [4] Zangene Najafi M, Shahbazi M, Niknam SA. Developing surface roughness prediction model using deep convolutional network. *Iranian Journal of Manufacturing Engineering*. 2025 Jan 20;11(11):26-36. doi: 10.22034/ijme.2024.474664.2000 [In Persian]
- [5] Schnell J, Reinhart G. Quality management for battery production: a quality gate concept. *Procedia CIRP*. 2016 Jan 1;57:568-73. doi: 10.1016/j.procir.2016.11.098
- [6] Salkind AJ, Fennie C, Singh P, Atwater T, Reisner DE. Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology. *Journal of Power sources*. 1999 Jul 1;80(1-2):293-300. doi: 10.1016/S0378-7753(99)00079-8
- [7] Zhang J, Li K. State-of-health estimation for lithium-ion batteries in hybrid electric vehicles—a review. *Energies*. 2024 Nov 18;17(22):5753. doi: 10.3390/en17225753
- [8] Chehab Z, Serrao L, Guezennec YG, Rizzoni G. Aging characterization of nickel: Metal hydride batteries using electrochemical impedance spectroscopy. In *ASME International Mechanical Engineering Congress and Exposition* 2006 Jan 1 (Vol. 47683, pp. 343-349). doi: 10.1115/IMECE2006-14608
- [9] Dong Q, Liu Z, Wang H, Wang L, Dong R, Lv L. SOH Estimation of Lithium Battery Under Improved CNN-BIGRU-Attention Model Based on Hiking Optimization Algorithm. *World Electric Vehicle Journal*. 2025 Aug 25;16(9):487. doi: 10.3390/wevj16090487

- [10] Yamashita A, Berg S, Figgemeier E. Unsupervised learning of charge-discharge cycles from various lithium-ion battery cells to visualize dataset characteristics and to interpret model performance. *Energy and AI*. 2024 Sep 1;17:100409. doi: [10.1016/j.egyai.2024.100409](https://doi.org/10.1016/j.egyai.2024.100409)
- [11] Severson KA, Attia PM, Jin N, Perkins N, Jiang B, Yang Z, Chen MH, Aykol M, Herring PK, Fraggedakis D, Bazant MZ. Data-driven prediction of battery cycle life before capacity degradation. *Nature energy*. 2019 May;4(5):383-91. doi: [10.1038/s41560-019-0356-8](https://doi.org/10.1038/s41560-019-0356-8)
- [12] Klass V, Behm M, Lindbergh G. A support vector machine-based state-of-health estimation method for lithium-ion batteries under electric vehicle operation. *Journal of Power Sources*. 2014 Dec 15;270:262-72. doi: [10.1016/j.jpowsour.2014.07.116](https://doi.org/10.1016/j.jpowsour.2014.07.116)
- [13] Yang N, Song Z, Hofmann H, Sun J. Robust State of Health estimation of lithium-ion batteries using convolutional neural network and random forest. *Journal of Energy Storage*. 2022 Apr 1;48:103857. doi: [10.1016/j.est.2021.103857](https://doi.org/10.1016/j.est.2021.103857)
- [14] Wang X, Hu B, Su X, Xu L, Zhu D. State of health estimation for lithium-ion batteries using random forest and gated recurrent unit. *Journal of Energy Storage*. 2024 Jan 15;76:109796. doi: [10.1016/j.est.2023.109796](https://doi.org/10.1016/j.est.2023.109796)
- [15] Wu Y, Rao B, Tian J, Du J, Jiang J. SSA-BiLSTM Model-Based SOH Estimation for Lithium-Ion Batteries. *Energies*. 2026 Mar 17;19(6):1499. doi: [10.3390/en19061499](https://doi.org/10.3390/en19061499)
- [16] Huang Z, Dang L, Xie Y, Ma W, Chen B. Gate recurrent unit network based on hilbert-schmidt independence criterion for state-of-health estimation. *arXiv preprint arXiv:2303.09497*. 2023 Mar 16. doi: [10.48550/arXiv.2303.09497](https://doi.org/10.48550/arXiv.2303.09497)
- [17] Uddin K, Schofield J, Widanage WD. State of health estimation of lithium-ion batteries in vehicle-to-grid applications using recurrent neural networks for learning the impact of degradation stress factors. *arXiv preprint arXiv:2205.07561*. 2022 May 16. doi: [10.48550/arXiv.2205.07561](https://doi.org/10.48550/arXiv.2205.07561)