

A Correlation-based Method for the Estimation of the State-of-Health of Lithium Batteries in Electric Vehicles Using Data-Driven Methods

Milad Mohammadrezaei,¹ Zeinab Maleki,^{2*} Ahmadreza Tabesh³

¹Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan, Iran, m.mohammadrezaei@ec.iut.ac.ir

² Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan, Iran, zmaleki@iut.ac.ir

³ Department of Electrical and Computer Engineering, Isfahan University of Technology, Isfahan, Iran, a.tabesh@iut.ac.ir

Keywords:

Lithium battery,
SoH estimation,
feature selection,
correlation method,
partial charging/discharging pattern.

Abstract: This paper presents a correlation-based framework for feature selection to estimate the lithium batteries state of health (SoH) using data-driven methods. These features can be calculated online for partial charge/discharge (C/D) cycles in electric vehicles. The main contribution is to provide a framework to determine a subset of independent features with maximum impacts on SoH estimation. Despite statistical features, the selected features are independent of C/D profiles, without requiring a full cycle information. Using the correlation criterion reduces the computational burden in a data-driven model as required in an online battery health estimation method. Extracting features, considering battery electrochemical reactions, and reducing the number of selected features, using the suggested correlation criterion, increase the robustness of the model and avoid overfitting. NASA labeled battery aging dataset is used to evaluate the performance of the method under various partial and random C/D cycles. The results show that the correlation-based features in Gaussian data-driven model can estimate the battery SoH with an average error of 10% under random patterns in a partial C/D cycle.

Original Research Article

Paper History:

Received: 21/07/2024

Revise: 18/09/2024

Accepted: 20/11/2024

How to cite this article: Mohammadrezaei, M., Maleki, Z., Tabesh, A., "A Correlation-based Method for Data-Driven Lithium Batteries State-of-Health Estimation in Electric Vehicles", Energy Engineering and Management, Vol. 14, No. 2, PP. 2-11, 2024. <https://doi.org/10.22052/EEM.2024.255143.1076>

© 2023 University of Kashan Press.

This is an open access article under the CC BY license. (<http://creativecommons.org/licenses/by/4.0/>)



Introduction

This paper presents a correlation-based algorithm to select a subset of lithium battery features that significantly contribute in the battery state-of-health (SoH) estimation. The features are selected

considering the aging phenomenon of lithium batteries and the partial charging/discharging (C/D) cycles which are the case in electric vehicles. The proposed correlation-based algorithm determines a subset of independent features that can be used with

data-driven methods. The main advantage of the suggested algorithm is to reduce the computational burden, while avoiding overfitting phenomenon in data-driven methods that enables the implementation of on-line health estimation methods. The performance of the method is evaluated using NASA battery dataset, and the test results show that SoH can be estimated with a 10% error under random and partial C/D profiles that exist in electric vehicles applications.

Materials and Methods

Figure 1 shows the proposed correlation-based algorithm to determine independent features. In this algorithm, the correlation coefficient is calculated based on the Pearson method as given by:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}}$$

where x_i is the i -th sample of variable x , y_i is the i -th sample of variable y , and \bar{x} , \bar{y} are the means of variables x and y respectively. The method for selecting the most appropriate subset of features is shown in the flowchart of Figure 1, in which the features with the highest correlation are first identified based on a correlation threshold that is selected 70% in this paper and one of the features with highest impact on SoH is selected. The impact of feature on SoH is also determined based on correlation between features and SoH.

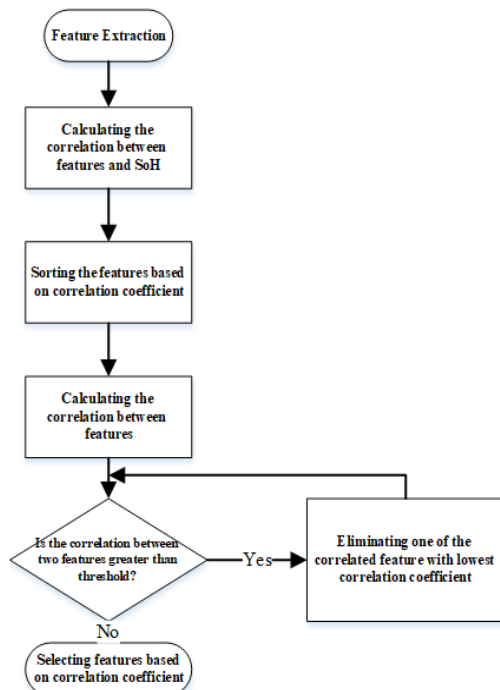


Figure 1: Flowchart of feature selection using the correlation method

Results and Discussions

Applying the proposed algorithm (Figure 1) to NASA battery data sets, 9 features out of the 15 features are determined as the independent features with highest impact on SoH are as follows:

- F1: Battery internal resistance
- F2: Charging time with constant current
- F3: Discharge energy
- F4: Current slope during constant voltage charging
- F5: Initial slope of the battery discharge voltage curve
- F6: Voltage slope during constant current charging
- F7: Capacitance
- F8: Discharge time
- F9: Charging time with constant voltage

The selected features, based on the proposed algorithm, can be justified based on physical behavior of the battery as follows:

1. Three features, F1, F3, and F7, physically indicate a reduction in power and a decrease in the number of ions due to the aging phenomenon.
2. Features F4 to F6, which are defined based on slope variations, are affected by the internal resistance of the battery. The main advantage of these features is that they are measurable in partial cycles as they are defined based on slope of change.
3. Features F2, F8, and F9 are defined based on charging discharging time variations. These features are mainly varied based on the battery time constants due to aging phenomenon. These changes in time constants occur as the battery capacity reduces due to a decrease in the number of active materials inside the battery.

Using labeled SoH battery data in NASA dataset and comparing with the SoH estimation, based on Gaussian Process data-driven model, show that the estimation error about 10% under random and partial charging/discharging cycles.

Conclusion

Aiming to select a minimum set of features with highest impacts on SoH, the proposed correlation-based method provides a tool for identifying and selecting these features among any set of available features. The test results show that the algorithm nominates the physical features such as internal resistance and charging/discharging times as the winning features with highest impact on SoH. The main advantages of the proposed method are reducing the computational burden and avoiding the overfitting that occurs in a data-driven model due to the elimination of dependency among the features.

ارائه یک روش مبتنی بر همبستگی به منظور تخمین وضعیت سلامت باتری لیتیومی در روش‌های داده‌محور برای خودروهای برقی

میلاذ محمدرضائی^۱، زینب مالکی^{۲*}، احمدرضا تابش^۳

^۱ دانشجوی دکتری، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ایران، m.mohammadrezaei@ec.iut.ac.ir

^۲ استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ایران، zmaleki@iut.ac.ir

^۳ دانشیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه صنعتی اصفهان، اصفهان، ایران، a.tabesh@iut.ac.ir

چکیده: در این مقاله چارچوبی مبتنی بر روش همبستگی برای استخراج و انتخاب یک مجموعه از ویژگی‌های فیزیکی مناسب برای تخمین وضعیت سلامت باتری‌های لیتیومی بر مبنای روش‌های داده‌محور ارائه می‌شود. این ویژگی‌ها به صورت برخط (آنلاین) برای چرخه‌های شارژ/دشارژ جزئی (ناقص) در کاربردهایی مانند خودروی برقی قابل محاسبه‌اند. نوآوری اصلی این مقاله ارائه چارچوبی برای انتخاب زیرمجموعه‌ای از ویژگی‌های مستقل با حداکثر مشارکت در وضعیت سلامت از بین مجموعه ویژگی‌های باتری است. مجموعه ویژگی‌ها به گونه‌ای انتخاب شده که برخلاف ویژگی‌های آماری مرسوم، به الگوی شارژ/دشارژ بستگی نداشته و استخراج آن‌ها نیز به اطلاعات یک چرخه کامل نیاز نداشته باشد. روش پیشنهادی با استخراج ویژگی مبتنی بر مدل واکنش‌های الکتروشیمیایی ذاتی درون یک باتری، و کاهش آن‌ها با استفاده از معیار همبستگی باعث افزایش دقت مدل و جلوگیری از بیش‌برازش آن می‌شود. برای اعتبارسنجی روش پیشنهادی از مجموعه داده‌های سلامت باتری که توسط ناسا ارائه شده، تحت شرایط مختلف عملکرد باتری شامل چرخه‌های شارژ/دشارژ جزئی و تصادفی استفاده شده است. نتایج بررسی نشان می‌دهد که ویژگی‌های پیشنهادی بر مبنای الگوریتم همبستگی با استفاده از مدل داده‌محور گوسی قادر به تخمین وضعیت سلامت باتری با میانگین خطای کمتر از ۱/۵ درصد است که قابل مقایسه با روش‌های موجود برای چرخه شارژ/دشارژ کامل با جریان ثابت است. همچنین روش پیشنهادی در این مقاله امکان توسعه به الگوهای شارژ/دشارژ جریان متغیر تصادفی و تخمین وضعیت سلامت باتری با خطای میانگین حدود ۱۰ درصد برای این الگوها را دارد که این امکان برای روش‌های موجود گزارش نشده است.

مقاله علمی پژوهشی

تاریخ دریافت: ۱۴۰۳/۰۴/۳۱

تاریخ بازنگری: ۱۴۰۳/۰۶/۲۸

تاریخ پذیرش: ۱۴۰۳/۰۸/۳۰

۱. مقدمه

باتری‌های لیتیومی به دلیل چگالی انرژی بالا و عمر طولانی نسبت به سایر انواع باتری‌های مرسوم سربی، در کاربردهای مختلفی نظیر وسایل الکترونیکی قابل حمل، ماهواره‌ها و خودروهای برقی به‌طور گسترده مورد استفاده قرار گرفته‌اند. مشابه سایر انواع باتری‌ها، بازده عملکرد این باتری‌ها نیز بر اثر چرخه‌های متوالی شارژ/دشارژ به تدریج کاهش می‌یابد که می‌تواند منجر به وقوع خطا یا خرابی شود. بنابراین تشخیص باقی‌مانده عمر مفید باتری^۱ و وضعیت سلامت باتری^۲ و جایگزینی آن قبل از رسیدن به پایان عمر مفید باتری^۳ برای جلوگیری از وقوع خطاهای احتمالی ضروری است [۱]. از طرفی، تعویض زودهنگام باتری‌های لیتیومی به‌منظور پیشگیری از وقوع خطا، به دلیل هزینه سرمایه‌گذاری بالا مطلوب نیست. لذا استفاده بهینه از طول عمر مفید آن‌ها با کاهش محافظه‌کاری در تخمین زمان تعویض آن‌ها بر مبنای روش‌های تخمین وضعیت سلامت، از مباحث تحقیقاتی روز دنیا در این حوزه است [۲ و ۳].

در کاربرد خودروهای برقی، افت توان تحویلی در اواسط عمر باتری موجب اختلال در عملکرد خودرو می‌شود و نیاز به تعویض باتری وجود دارد. درحالی‌که همین باتری در کاربرد ذخیره‌ساز انرژی شبکه، می‌تواند تا پایان عمر مفید ظرفیت خود بر اثر خوردگی الکترودها و حذف یونها، مورد استفاده قرار گیرد. هر دو موضوع افت ظرفیت و کاهش توان باتری را پدیده پیر شدن باتری می‌نامند که تعیین وضعیت آن بر مبنای تخمین وضعیت سلامت باتری و از طریق بررسی ویژگی‌های آماری که از چرخه‌های شارژ/دشارژ به دست می‌آیند، انجام می‌پذیرد. این ویژگی‌های آماری به‌عنوان ورودی مدل تخمین در روش‌های داده‌محور و مبتنی بر یادگیری برای تخمین وضعیت سلامت باتری مورد استفاده قرار می‌گیرند [۴].

اگرچه در سال‌های اخیر روش‌های داده‌محور با ساختارهای متفاوت نظیر شبکه‌های عصبی [۵ و ۶]، یادگیری جمعی [۷ و ۸]، فرایند گوسی [۹ و ۱۰] و شبکه‌های کانولوشنی گرافی [۱۱ و ۱۲] برای تشخیص سلامت باتری ارائه شده‌اند، این روش‌ها از دو ضعف عمده رنج می‌برند. ضعف اول اکثر روش‌ها عدم امکان پیاده‌سازی آنلاین است که دلیل اصلی آن نیاز به کل داده‌های باتری برای محاسبه ویژگی‌های آماری نظیر میانگین و واریانس داده‌هاست.

ضعف دوم این روش‌ها که به‌طور برجسته در اکثر مراجع دیده می‌شود، بررسی کارایی ویژگی‌های استخراج‌شده صرفاً برای چرخه

شارژ/دشارژ کامل و جریان ثابت تحت شرایط آزمایشگاهی است که در عمل و در کاربردهایی نظیر خودروی برقی که شامل الگوهای تغییر جریان تصادفی است، کارایی ندارد.

این مقاله ابتدا ساختار و پدیده پیری باتری‌های لیتیومی را با کاربرد در خودرو برقی مورد بررسی قرار می‌دهد. در ادامه، ویژگی‌های آماری و فیزیکی مناسب شرایط شارژ/دشارژ جزئی یا ناقص که از ویژگی‌های اصلی چرخه‌های شارژ/دشارژ در خودروهای برقی است، استخراج می‌شوند. سپس زیرمجموعه‌ای از ویژگی‌های مستقل برای تخمین وضعیت سلامت باتری بر مبنای روش‌های داده‌محور استخراج می‌شود. علاوه بر نوآوری در معرفی ویژگی‌های جدید با مفهوم فیزیکی، مبتنی بر تحلیل پدیده پیری باتری، نوآوری اصلی این مقاله ارائه روشی برای تعیین یک مجموعه مناسب از ویژگی‌های مؤثر در تعیین وضعیت سلامت باتری است.

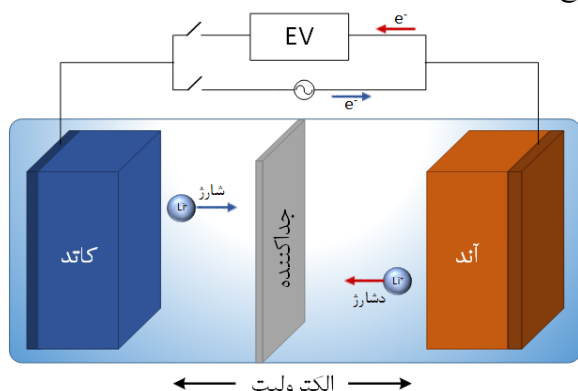
روش پیشنهادی با استفاده از تعیین همبستگی بین ویژگی‌ها، استقلال ویژگی‌های پیشنهادی را بررسی نموده و یک زیرمجموعه از ویژگی‌های مستقل را تعیین می‌کند. در ادامه با تحلیل همبستگی بین ویژگی و وضعیت سلامت، مجموعه مناسبی از ویژگی‌ها که بیشترین نقش را در تخمین وضعیت سلامت دارند مشخص می‌شوند. از آنجاکه تعیین همبستگی مستقل از نوع روش داده‌محور است، روش پیشنهادی برای هر روش داده‌محوری از جمله روش‌های آماری و روش‌های مبتنی بر یادگیری ماشین قابل استفاده خواهد بود.

مزایای اصلی روش پیشنهادی کاهش حجم محاسبات به دلیل حذف ویژگی‌های دارای اطلاعات تکراری و جلوگیری از بیش‌برازش به دلیل حذف ویژگی‌های وابسته است. کاهش حجم محاسبات امکان پیاده‌سازی برخط (آنلاین) روش پیشنهادی تخمین وضعیت سلامت باتری را فراهم می‌سازد. همچنین تعریف ویژگی‌های جدید مبتنی بر شیب تغییرات ولتاژ و جریان، امکان تخمین بر مبنای چرخه‌های شارژ (جزئی و کامل) و دشارژ (جزئی و کامل) را برای کاربرد خودرو برقی فراهم می‌سازد.

به‌منظور ارزیابی صحت عملکرد و کارایی روش پیشنهادی از مجموعه داده‌های استاندارد باتری شامل چرخه‌های شارژ/دشارژ جزئی استفاده شده است. برای این منظور، تعداد ۱۵ ویژگی از ۱۸ حالت مختلف از ترکیب گروه‌های چهارگانه مجموعه داده‌های استاندارد باتری ناسا مورد بررسی قرار گرفته است [۱۳]. نتایج بررسی نشان می‌دهد که از بین این ۱۵ ویژگی، تعداد ۹ ویژگی مستقل شامل مقاومت باتری، زمان‌های شارژ با ولتاژ و جریان ثابت، زمان دشارژ در یک بازه ولتاژ مشخص، انرژی دشارژ، شیب جریان در شارژ با ولتاژ

1. Remaining Useful Life (RUL)
2. State of Health (SoH)
3. End of Life (EOL)

محوشدن ظرفیت باتری شده و ایجاد لایه‌های رسوبی نیز بر اثر افزایش مقاومت داخلی باتری، موجب افت یا محو شدن توان در این نوع باتری‌ها می‌شود [۱۴].



شکل (۱): ساختار باتری لیتیومی

بررسی سازوکار الکتروشیمیایی باتری‌ها نشان داده است که عوامل متعددی از جمله دمای داخلی، دمای محیط، وضعیت شارژ (SoC)، عمق دشارژ و الگوی جریان‌های شارژ/دشارژ، در پیری باتری تأثیر گذارند. افزایش دما بر سرعت واکنش‌های شیمیایی درون باتری لیتیومی و رسانایی یونی الکترودها و الکترولیت‌ها اثر می‌گذارد. از طرفی، کاهش شدید دما نیز بر خواص فیزیکی و شیمیایی الکترولیت درون باتری تأثیر گذار است. هر دو عامل افزایش یا کاهش شدید دما می‌توانند باعث کاهش کارایی عملکرد باتری شوند. اضافه شارژ نیز موجب انجام واکنش‌های شیمیایی برگشت‌ناپذیر و افزایش دما شده که می‌تواند بر کارایی باتری اثر بگذارد. همچنین اضافه شارژ باعث آزاد شدن گاز در باتری لیتیومی می‌شود که می‌تواند موجب انفجار در باتری شود. افزایش جریان شارژ یا دشارژ باتری نیز به دلیل افزایش تلفات داخلی و در نتیجه افزایش دمای باتری، موجب تسریع در کاهش طول عمر باتری می‌شوند [۱۵-۱۸].

خودروهای برقی به دو دسته خودروهای هیبریدی و الکتریکی تقسیم‌بندی می‌شوند. خودروهای هیبریدی علاوه بر موتور الکتریکی از موتور بنزینی نیز استفاده می‌کنند، در حالی که خودروهای الکتریکی فقط از موتور الکتریکی و باتری استفاده می‌کنند. چرخه شارژ/دشارژ یک باتری لیتیومی در هر دو نوع خودروی الکتریکی و هیبریدی از الگوی دشارژ ناقص یا جزئی در هنگام شتاب گرفتن و شارژ جزئی (در وضعیت ترمز)، یا شارژ کامل هنگام اتصال به شبکه از طریق شارژر تشکیل می‌شود.

چرخه کاری و نرخ نوسانات ولتاژ و جریان در الگوهای شارژ/دشارژ در خودروهای برقی به‌نحو چشمگیری با الگوهای

ثابت، شیب اولیه منحنی دشارژ، شیب ولتاژ در شارژ با جریان ثابت و ظرفیت خازن معادل باتری مناسب‌ترین گروه از ویژگی‌های مستقل را تشکیل می‌دهند. همگی این ویژگی‌ها از قابلیت محاسبه بر مبنای اندازه‌گیری برخط داده‌های ولتاژ و جریان باتری در چرخه‌های شارژ/دشارژ کامل و جزئی برخوردارند.

نوآوری‌های اصلی کار انجام‌شده در این مقاله در مقایسه با روش‌های داده‌محور ارائه‌شده برای تخمین سلامت باتری در مراجع اخیر در دو بخش زیر خلاصه می‌شوند:

۱. روش ارائه‌شده برخلاف روش‌های موجود قابل توسعه به کاربردهایی است که در آن چرخه شارژ/دشارژ باتری کامل نیست و دارای الگوهای شارژ/دشارژ جزئی و تصادفی است. این روش به‌صورت آنلاین قابل پیاده‌سازی است.
۲. ویژگی‌های انتخاب‌شده در روش پیشنهادی مبتنی بر مشخصه‌های فیزیکی و الکتروشیمیایی ذاتی باتری است و با استفاده از فرایند گوسی، آن دسته از ویژگی‌هایی که بیشترین مشارکت را در سلامت باتری دارند، انتخاب شده‌اند؛ در نتیجه راهکار ارائه‌شده در این مقاله مانع از بیش‌برازش در تخمین سلامت باتری می‌شود.

۲. پدیده پیری باتری خودرو برقی و تخمین سلامت

این بخش به معرفی اجمالی ویژگی‌های اصلی چرخه شارژ/دشارژ خودرو برقی و تأثیر آن بر پیری باتری خودرو می‌پردازد. بررسی عوامل مؤثر در پیری باتری از این جنبه مهم است که می‌تواند راهگشای تعریف ویژگی‌های مناسب با تعریف فیزیکی برای تخمین عمر باتری باشد. در روش‌های مرسوم داده‌محور استخراج ویژگی‌ها عموماً بر مبنای ویژگی‌های آماری و صرفاً ریاضی نظیر میانگین، واریانس و انحراف معیار داده‌هاست که نیازمند جمع‌آوری کل داده‌ها در طول عمر باتری است. تعریف ویژگی‌های فیزیکی امکان استفاده از داده‌های شارژ/دشارژ جزئی را در تخمین سلامت باتری فراهم می‌سازد.

۲.۱. عوامل پیری باتری خودرو برقی

باتری‌های لیتیومی مطابق شکل (۱) از سه بخش اصلی شامل الکترودها، الکترولیت و غشای جداکننده تشکیل شده‌اند. این باتری‌ها بر اثر شارژ و دشارژ‌های متوالی در گذر زمان و به دلیل خوردگی الکترودها و ایجاد رسوب روی آن‌ها، کارایی اولیه خود را از دست می‌دهند. خوردگی الکترودها و کاهش یون‌ها موجب افت یا

در روش های مبتنی بر مدل های مداری یا تحلیلی، رفتار پیر شدن باتری با استفاده از مدار معادل الکتریکی یا مدل الکتروشیمیایی توصیف می شود. در این راستا، از روش های تخمین پارامترهای مدل نظیر فیلتر کالمن و فیلتر ذرات برای تعیین وضعیت سلامت باتری و عمر مفید باقی مانده استفاده می شود که وجود نامعینی ها در مدل به دلیل اثر هیستریزس و فرایندهای غیرخطی پیچیده، دقت مدل را محدود می کند [۱۹].

در رویکردهای داده محور، ابتدا یک استنتاج کننده احتمالاتی نظیر فرایند گوسی یا یک مدل یادگیرنده نظیر شبکه عصبی، با استفاده از داده های موجود در یک مجموعه از داده های استاندارد باتری، آموزش داده می شود. سپس بر مبنای پایش برخط کمیت های قابل اندازه گیری باتری شامل ولتاژ، جریان و دما، و استخراج ویژگی های مورد نیاز مدل داده محور، تخمین عمر انجام می پذیرد [۲۰-۲۲].

مجموعه کمیت های اندازه گیری شده در هر چرخه شارژ/دشارژ، از طریق یک بلوک پیش پردازش، ویژگی هایی را مبتنی بر رفتارهای آماری و مشخصه های فیزیکی نظیر شیب تغییرات ولتاژ در ابتدای چرخه استخراج می کند. در کاربردهایی مانند خودروی برقی امکان استخراج برخط این ویژگی ها در چرخه های شارژ/دشارژ جزئی اهمیت پیدا می کند. اگرچه مجموعه ویژگی های متنوعی در سال های اخیر برای باتری معرفی شده اند، شکاف تحقیقاتی شامل فقدان روش هایی است که هر دو قابلیت پیاده سازی آنلاین و دقت مناسب برای چرخه های شارژ/دشارژ جزئی با الگوهای تصادفی را دارا باشند.



۳. روش پیشنهادی تخمین وضعیت سلامت باتری

۱.۳. معرفی و ارائه ویژگی های فیزیکی

در روش تعیین وضعیت سلامت باتری لیتیومی با رویکرد داده محور، استخراج و انتخاب ویژگی ها در دقت تخمین وضعیت سلامت باتری بسیار تأثیرگذار است. در رویکرد داده محور ورودی های مدل ویژگی ها هستند که روش های استخراج آن ها به طور کلی به دو دسته تقسیم می شوند: روش های استخراج ویژگی به صورت مستقیم که بر پایه اندازه گیری کمیت های باتری نظیر ولتاژ و جریان و دما به دست می آیند و دارای منشأ فیزیکی هستند؛ دسته دوم روش های غیرمستقیم هستند که بر مبنای پیش پردازش کمیت های اندازه گیری شده و استخراج پارامترهای آماری و غیر آماری از آن ها پایه گذاری می شوند و لزوماً دارای تعبیر فیزیکی نیستند.

ویژگی های منتخب دسته اول که از طریق اندازه گیری به دست می آیند، شامل سه ویژگی زمان شارژ با جریان و ولتاژ ثابت و زمان دشارژ در جریان ثابت است که به طور معمول در مقالات مختلف

شارژ/دشارژ در سایر کاربردها، نظیر خدمات جانبی در شبکه های الکتریکی هوشمند متفاوت اند. به طور مشخص، تعداد چرخه های جزئی شارژ/دشارژ در طول عمر مفید باتری خودروهای برقی بیشتر و عمق دشارژ کمتر از سایر کاربردها نظیر استفاده از باتری در کنار انرژی های تجدیدپذیر است. شکل (۲) یک نمونه از چرخه های شارژ/دشارژ جزئی با توزیع آماری تصادفی را نشان می دهد که معمولاً در مجموعه داده های استاندارد و معتبر، چنین داده هایی برای شبیه سازی وضعیت خودرو وجود دارد.





شکل (۲): الگوی شارژ/دشارژ خودرو برقی

۲.۲. مروری بر روش های تخمین وضعیت سلامت

باتری

اگرچه باتری های لیتیومی در ظرفیت ها و با فناوری های مختلفی ساخته می شوند، همگی این باتری ها از قوانین فیزیکی و شیمیایی مشخصی در پدیده پیرشدگی پیروی می کنند و دارای عوامل مشترکی در تسریع این پدیده هستند، به همین دلیل می توان با تعریف و استخراج شاخص های مناسبی، وضعیت سلامت باتری را پایش نمود. با استفاده از این شاخص ها روش های مختلفی در مراجع برای تخمین سلامت باتری ارائه شده است که این روش ها در سه دسته کلی شامل تعیین وضعیت سلامت باتری با رویکرد اندازه گیری مستقیم، رویکرد مبتنی بر مدل مداری و روش های داده محور تقسیم بندی می شوند.

در رویکرد اندازه گیری مستقیم از دو روش برای تعیین وضعیت سلامت استفاده می شود: روش اول شمارش بار است که در آن پس از شارژ کامل باتری، از طریق محاسبه انتگرال جریان در یک چرخه دشارژ کامل، ظرفیت باتری محاسبه می شود. این روش نیازمند قطع باتری از مسیر اصلی و انجام آزمون های غیربرخط در محیط آزمایشگاه است که در کاربردهایی نظیر خودرو برقی عملاً امکان پذیر نیست.



شکل (۳): تعیین وضعیت سلامت با استفاده از روش داده‌محور

در فاز آموزش از مدل‌های داده‌محور مختلفی نظیر شبکه‌های عصبی، مدل‌های مبتنی بر سری‌های زمانی و یادگیری عمیق، و مدل‌های احتمالاتی بی‌زی نظیر فرایند گوسی می‌توان استفاده کرد. در این مقاله از فرایند گوسی به‌عنوان هسته اصلی آموزش مدل داده‌محور استفاده می‌شود. علت انتخاب فرایند گوسی انعطاف‌پذیری و مقاوم بودن روش گوسی در برابر نویز داده و کاهش اثر بیش‌برازش است که این دو ویژگی در فرایند آموزش با مجموعه داده‌های باتری که شامل نویز اندازه‌گیری است، بسیار کلیدی است. در ساختار پیشنهادی مبتنی بر فرایند گوسی، آموزش فرایند با استفاده از داده‌های استاندارد و با به‌کارگیری یک تابع معیار نظیر کمینه مجموع مربعات خطا تا زمانی ادامه می‌یابد که خطای تخمین از آستانه مشخصی کمتر شود.

در مرحله تخمین برخط، از کمیت‌های قابل اندازه‌گیری باتری نمونه‌برداری شده و پردازش‌های لازم برای محاسبه ویژگی‌ها در فاصله هر دو نمونه‌برداری انجام می‌شود. ویژگی‌های پیشنهادی مبتنی بر محاسبه شیب ولتاژ یا جریان، دارای این ویژگی هستند که برای هر دو الگوی چرخه شارژ/دشارژ کامل یا جزئی قابل محاسبه‌اند. این ویژگی امکان تخمین برخط وضعیت سلامت را به‌طور خاص برای کاربردهایی نظیر خودرو برقی که دارای چرخه‌های متعدد شارژ/دشارژ جزئی است فراهم می‌سازد.

دقت تخمین برخط در روش داده‌محور و به‌طور خاص در روش گوسی متأثر از استخراج و انتخاب ویژگی‌های مناسب است. از آنجاکه ویژگی‌های پیشنهادی در این مقاله مبتنی بر خواص فیزیکی و الکتروشیمیایی باتری پایه‌گذاری شده است، می‌توان انتظار داشت که

مورد استفاده قرار گرفته‌اند. از لحاظ فیزیکی و الکتروشیمیایی، هرچه باتری پیرتر شود، زمان شارژ و دشارژ آن کوتاه‌تر می‌شود که علت اصلی آن، کاهش یون‌های فعال بر اثر رسوب لایه الکترولیت جامد روی سطح الکترودهای باتری است.

ویژگی‌های پیشنهادی دسته دوم در این مقاله عبارت‌اند از: شیب ولتاژ شارژ با جریان ثابت، شیب جریان شارژ با ولتاژ ثابت، مقاومت داخلی باتری، نرخ تغییرات ولتاژ به ظرفیت، انرژی خروجی در چرخه شارژ، و ظرفیت باتری در چرخه‌های کامل یا جزئی شارژ/دشارژ. تمامی ویژگی‌های پیشنهادی ارائه‌شده مبتنی بر شیب دارای ویژگی کلیدی امکان محاسبه در چرخه‌های جزئی شارژ/دشارژ هستند و از این جنبه در کاربردهایی نظیر خودرو برقی و برای تخمین‌های برخط قابل استفاده هستند. تغییر فیزیکی ویژگی‌های مبتنی بر شیب، افزایش شیب بر اثر افزایش مقاومت لایه الکترولیتی جامد و کاهش زمان‌های شارژ و دشارژ بر اثر کاهش تعداد یون‌هاست.

۲.۳. ساختار روش برخط تخمین سلامت پیشنهادی

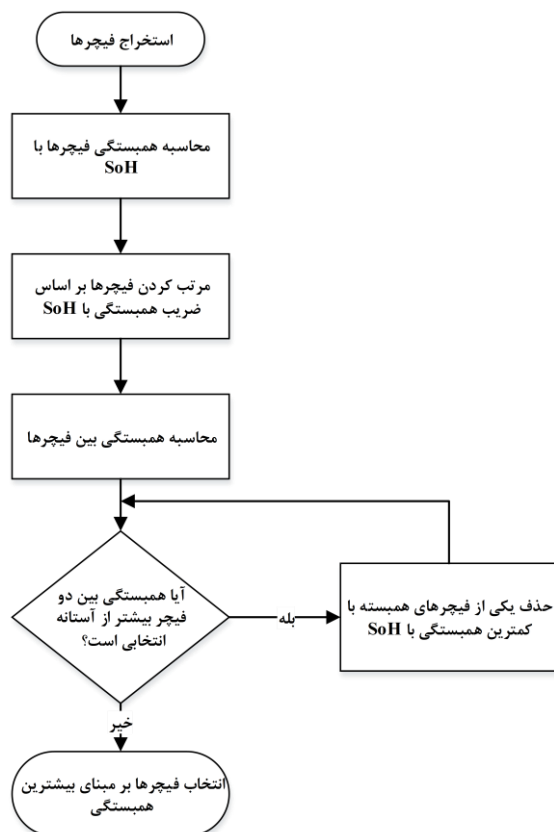
تخمین برخط سلامت باتری مبتنی بر ویژگی‌های پیشنهادی شامل دو بخش است: در بخش اول که مرحله یادگیری و آموزش مدل داده‌محور است، مجموعه داده‌های موجود به دو بخش داده‌های آموزش و تست تقسیم‌بندی می‌شود. با استفاده از مجموعه داده‌های دارای برچسب، مدل تخمین باتری آموزش داده می‌شود و با استفاده از مجموعه داده‌های دارای برچسب تست، کارایی و دقت مدل تخمین به روش اعتبارسنجی متقابل، ارزیابی می‌شود.

در بخش دوم با اندازه‌گیری برخط داده‌های باتری بدون برچسب وضعیت سلامت و محاسبه ویژگی‌ها، وضعیت سلامت باتری با استفاده از مدل آموزش یافته تخمین زده می‌شود. در هر دو بخش آموزش و تخمین، ابتدا ویژگی‌های معرفی شده، در مرحله پیش‌پردازش از داده‌های باتری استخراج می‌شوند. مرحله تمیز کردن ویژگی‌ها از طریق حذف داده‌های پرت و نرمالیزه کردن آن‌ها نیز در همین بخش پیش‌پردازش انجام می‌شود. سپس ویژگی‌های محاسبه‌شده به‌همراه برچسب تخمین سلامت باتری که از طریق آزمایش‌های استاندارد به دست آمده، برای آموزش مورد استفاده قرار می‌گیرد. شکل (۳) مراحل این روش را نشان می‌دهد.

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

که در آن، x_i نمونه نام از متغیر x ، y_i نمونه نام از متغیر y ، \bar{x} میانگین متغیر x ، \bar{y} میانگین متغیر y و r_{xy} ضریب همبستگی پیرسون بین دو متغیر x و y است. هر چقدر وابستگی خطی دو متغیر بیشتر باشد، این ضریب به یک نزدیک تر می شود و ضریب همبستگی دو کمیت کاملاً مستقل صفر خواهد بود.

روش انتخاب مناسب ترین مجموعه ویژگی در روند نامی شکل (۴) نشان داده شده است که در آن ابتدا ویژگی هایی که بیشترین همبستگی را با یکدیگر دارند مشخص می شوند، سپس همبستگی بین ویژگی ها و SoH محاسبه می شود. از بین ویژگی های انتخابی، علاوه بر حذف ویژگی های دارای همبستگی زیاد (در اینجا بیشتر از ۷۰٪) با یکدیگر، ویژگی هایی که همبستگی کم با SoH دارند (در اینجا کمتر از ۷۰٪) نیز حذف شده تا یک مجموعه از ویژگی های مستقل با بیشترین همبستگی با SoH به دست آید.



شکل (۴): روند نامی انتخاب ویژگی با روش همبستگی

با اعمال الگوریتم پیشنهادی ترکیبی در روند نامی شکل (۴)، تعداد ۹ ویژگی از ۱۵ ویژگی معرفی شده در بخش قبلی، به عنوان

روش پیشنهادی در مقابل نویز و داده های گم شده مقاوم بوده و از تخمین ارائه شده تحت این شرایط، از دقت مناسبی برخوردار باشد.

برای مجموعه ویژگی های استخراج شده، برخی از آن ها ذاتاً نمی توانند مستقل باشند. برای نمونه، ویژگی مقاومت یا امپدانس درونی باتری دارای وابستگی خطی با شیب افت ولتاژ است. هر چه مقاومت درونی باتری بر اثر افزایش لایه رسوب بیشتر شود، شیب افت ولتاژ نیز افزایش می یابد. در ساختار ارائه شده هدف این است که برای جلوگیری از افزایش تأثیر خطای ناشی از بیش برآزش در تخمین وضعیت سلامت باتری، مرحله آموزش مدل داده محور بر مبنای ویژگی های مستقل انجام شود. برای این منظور، از ابزارهای آماری مناسب نظیر آنالیز مؤلفه های اصلی جهت تشخیص بعد فضایی کمینه داده های مستقل استفاده می شود.

۴. روش پیشنهادی و اعتبارسنجی آن

۴.۱. معرفی مجموعه داده های تست

به منظور بررسی پدیده پیری در باتری های لیتیومی و ارزیابی نتایج در این مقاله از داده های جمع آوری شده توسط ناسا استفاده می شود. داده های ناسا از ۲۸ باتری لیتیومی تجاری ۱۸۶۵۰ با ظرفیت دو آمپر ساعت تشکیل شده است که در ۷ گروه ۴ تایی تقسیم بندی شده اند. در گروه یک تا پنج از این دسته از باتری ها، آزمایش های شارژ و دشارژ باتری در دمای اتاق انجام شده است. در گروه ۶ و ۷ شارژ و دشارژ باتری در دمای ۴۰ درجه سانتی گراد انجام شده است. در این دسته از باتری ها، شارژ و دشارژ باتری با الگوی جریان پالسی شکل تصادفی که دامنه آن در بازه های زمانی مختلف تغییر می کنند، انجام شده و فقط در نقاط تست مرجع که هر ۵۰ چرخه یک بار انجام شده است، شارژ و دشارژ باتری به صورت کامل انجام می شود. در این دسته از باتری های به منظور جداسازی چرخه های شارژ و دشارژ از یکدیگر، فاصله بین دو شارژ متوالی یک چرخه تعریف می شود.

۴.۲. تحلیل نتایج با روش همبستگی

برای انتخاب مجموعه کمینه و مستقل از ویژگی های فیزیکی، از روش ترکیبی استفاده می شود که در آن ابتدا همبستگی بین ویژگی ها و SoH بررسی شده و ویژگی هایی که دارای بیشترین درجه همبستگی با SoH هستند، انتخاب می شوند. سپس برای تعیین ویژگی های مستقل، همبستگی بین ویژگی ها نیز بررسی می شود. ضریب همبستگی بر مبنای روش پیرسون و از رابطه (۱) محاسبه می شود:

- مجموعه مناسب از ویژگی‌ها برای تخمین سلامت باتری تعیین شدند که این مجموعه عبارت است از:
- F1: مقاومت؛
 F2: زمان شارژ با جریان ثابت؛
 F3: انرژی دشارژ؛
 F4: شیب جریان در شارژ با ولتاژ ثابت؛
 F5: شیب اولیه منحنی ولتاژ دشارژ باتری؛
 F6: شیب ولتاژ در شارژ با جریان ثابت؛
 F7: خازن؛
 F8: زمان دشارژ؛
 F9: زمان شارژ با ولتاژ ثابت.
- تحلیل و تفسیر فیزیکی ویژگی‌های انتخاب شده بر مبنای روش پیشنهادی، بدین شرح است:
- سه ویژگی مقاومت (F1)، انرژی دشارژ (F3) و خازن (F7) بیانگر کاهش توان و کاهش تعداد یون برآثر پدیده پیری هستند.
 - تغییر ویژگی‌های تعریف شده بر مبنای شیب، شامل F4 تا F6، متأثر از تغییر مقاومت درونی باتری است که به دلیل استفاده از شیب تغییرات در چرخه‌های جزئی قابل اندازه‌گیری است.
 - تغییر ویژگی‌های زمانی، شامل F2، F8 و F9، متأثر از تغییر ثابت زمانی مدل مداری باتری برآثر پیری هستند که علت فیزیکی آن کاهش ظرفیت در اثر کاهش تعداد مواد فعال درون باتری و افزایش مقاومت داخلی باتری است.
- براساس تحلیل فوق، نتایج به دست آمده از روش آماری همبستگی با نتایج مورد انتظار از رفتار فیزیکی پیری باتری مطابقت دارد.

جدول (۱): مقایسه ویژگی‌ها و خطای روش پیشنهادی با روش‌های داده‌محور در مراجع اخیر

عنوان روش	شرح مختصر روش استفاده شده	نوع روش	چرخه شارژ/دشارژ	خطای تخمین
یادگیری جمعی [۲۳]	یک روش یادگیری جمعی پشته‌ای (stacking) به منظور تخمین سلامت باتری لیتیومی به منظور بهبود دقت نسبت به مدل‌های پایه	آنلاین	کامل	<۳٪
فرایند خودبرگشتی [۲۴]	ارائه یک مدل تخمین سلامت باتری با شبکه عصبی خودبرگشتی بدون نیاز به جایگزینی داده‌های گم شده	آفلاین	کامل	<۱/۵٪
شبکه عصبی پیش‌خور [۲۵]	استفاده از اطلاعات فیزیکی در شبکه عصبی مرسوم به منظور بهبود دقت پیش‌بینی وضعیت سلامت باتری‌های لیتیومی	آفلاین	کامل	<۳٪
بهینه‌سازی فیلتر ذرات [۲۶]	استفاده از مدل‌های تک‌مرحله‌ای، چندمرحله‌ای و بلندمدت به منظور بهبود دقت پیش‌بینی وضعیت سلامت باتری لیتیومی	آفلاین	جزئی	<۳٪
روش پیشنهادی در این مقاله: فرایند گوسی	استفاده از فرایند گوسی به منظور تعیین ویژگی‌های با بیشترین تأثیر و مشارکت در تشخیص سلامت باتری در روش‌های داده‌محور	آنلاین	جزئی	<۱/۵٪

در ستون اول جدول (۱)، عنوان روش‌های داده‌محور بر مبنای مدل‌های مختلف بیان شده و شرح مختصر روش نیز در ستون دوم ارائه شده است. تمامی روش‌های انتخابی از مراجع مربوط به سه سال اخیرند که هدف مشترک آن‌ها بهبود دقت تخمین سلامت باتری لیتیومی است. بنابراین خطای گزارش شده هر روش که در ستون آخر ارائه شده، در واقع در مقایسه با سایر مراجع قبلی که برای تخمین سلامت باتری استفاده شده‌اند گزارش شده است. این خطا بر مبنای شاخص جذر مجموع مربعات خطا برای مجموعه داده‌های استاندارد محاسبه شده است. گستره تغییرات خطاهای ارائه شده از ۱/۵ تا ۳ درصد است که در آن کمترین خطا مربوط به فرایند خودبرگشتی است. البته باید توجه داشت که این روش فقط برای چرخه کامل

جدول (۱) به مقایسه ویژگی‌ها و برتری روش پیشنهادی در این مقاله با سایر روش‌های داده‌محور به منظور تشخیص سلامت باتری می‌پردازد. به منظور انجام یک مقایسه منصفانه شرایط تست مشترک بین همه روش‌ها که شامل شارژ و دشارژ با جریان ثابت است، در نظر گرفته شده است. شایان ذکر است که نتایج ارائه شده و خطای گزارش شده در اکثر روش‌های ارائه شده در مقالات مبتنی بر جریان دشارژ ثابت و چرخه کامل شارژ/دشارژ هستند. یکی از برتری‌های روش ارائه شده امکان استفاده آن در چرخه‌های ناقص با الگوی شارژ/دشارژ تصادفی است که توسعه این روش را برای کاربردهایی نظیر خودروی برقی امکان‌پذیر می‌سازد.

جزئی با الگوی تصادفی را به صورت هم‌زمان دارد و در شرایط تست مشابه با سایر روش‌ها، خطای آن ۱/۵ درصد است. این جدول برتری روش پیشنهادی نسبت به سایر روش‌های موجود در مراجع اخیر را نشان می‌دهد. علت این برتری استفاده از ویژگی‌های فیزیکی و الکتروشیمیایی ذاتی باتری به جای پارامترهای صرفاً آماری و ریاضی نظیر میانگین و واریانس در رویکرد داده‌محور است.

شارژ/دشارژ و تحت شرایط آفلاین (تست در آزمایشگاه) که در آن تمامی داده‌های تست موجود است انجام شده و قابل توسعه به شرایط آنلاین و چرخه شارژ/دشارژ جزئی با الگوهای تصادفی نیست. در بین تمام روش‌های ارائه شده با قابلیت پیاده‌سازی آنلاین و/یا چرخه شارژ/دشارژ جزئی و تصادفی کمترین خطای گزارش شده ۳ درصد است. این درحالی است که روش پیشنهادی در این مقاله قابلیت توسعه و پیاده‌سازی تحت شرایط آنلاین و چرخه شارژ/دشارژ

جدول (۲): نتایج خطای تخمین با استفاده از مجموعه ویژگی‌ها

گروه‌های آموزش	درصد خطای تخمین با استفاده از مجموعه ویژگی‌ها								
	فقط ۱	۲ تا ۱	۳ تا ۱	۴ تا ۱	۵ تا ۱	۶ تا ۱	۷ تا ۱	۸ تا ۱	۹ تا ۱
زوج	۱۳/۴	۱۱/۸	۱۰/۱	۹/۹	۹/۶	۹/۳	۹/۳	۸/۲	۸/۱
فرد	۱۳/۶	۱۲/۱	۱۱/۴	۱۱/۳	۱۱	۱۰/۴	۱۰	۹/۶	۹/۲
همه به جز ۱	۱۲/۵	۱۳/۲	۱۳/۶	۱۴/۵	۱۴/۸	۱۱/۸	۱۱/۷	۱۱	۱۰/۶
همه به جز ۲	۱۶/۵	۱۵/۷	۱۳/۷	۱۵/۵	۱۴/۹	۱۴/۹	۱۷/۸	۱۶/۱	۱۶
همه به جز ۳	۱۷/۵	۱۷	۱۶	۱۷/۸	۱۷	۱۵/۷	۱۴/۱	۱۶/۲	۱۵/۹
همه به جز ۴	۱۸	۱۷	۱۶	۱۴/۸	۱۶/۵	۱۸/۱	۱۶/۷	۱۳/۷	۱۳/۶
همه به جز ۵	۷/۶	۹	۱۰/۶	۱۱	۱۰	۱۰/۲	۸/۳	۹/۱	۹/۶
همه به جز ۶	۱۰/۲	۷/۱	۸/۷	۸/۸	۸/۱	۶/۲	۶/۳	۷/۱	۷
همه به جز ۷	۲۱/۳	۱۵/۱	۱۲/۸	۱۳/۶	۱۴/۳	۱۳/۳	۱۳/۲	۱۳	۱۳/۴
میانگین	۱۴/۵	۱۳/۱	۱۲/۵	۱۳	۱۲/۹	۱۲/۲	۱۲	۱۱/۶	۱۱/۵

تعداد ویژگی‌ها، میانگین درصد خطا کاهش می‌یابد که با توجه به مستقل بودن ویژگی‌ها قابل انتظار است.

۵. نتیجه‌گیری

در این مقاله مجموعه‌ای از ویژگی‌های فیزیکی که رفتار ذاتی یک باتری لیتیومی را نشان می‌دهند معرفی شده‌اند. این ویژگی‌ها را می‌توان برای تخمین وضعیت سلامت باتری در انواع روش‌های تخمین داده‌محور استفاده کرد. این ویژگی‌ها دارای امکان استخراج آنلاین در چرخه‌های شارژ/دشارژ جزئی هستند که پیاده‌سازی روش تخمین سلامت را در کاربردهایی نظیر خودروی برقی فراهم می‌سازد. کارایی و دقت فیچرها با استفاده از روش گوسی در این مقاله با استفاده از مجموعه داده‌های ناسا اعتبارسنجی شده است. نتایج بررسی نشان می‌دهد که با کاهش تعداد ویژگی‌های فیزیکی معرفی شده توسط روش همبستگی به یک زیرمجموعه مستقل ۷ تا ۹ تایی از ویژگی‌ها می‌توان تخمین وضعیت سلامت باتری‌ها را با دقت مناسب به دست آورد.

به منظور بررسی کارایی ویژگی‌های انتخاب شده در تخمین سلامت باتری، این مجموعه ویژگی‌ها در ۹ زیرمجموعه $[F1], [F1, F2], [F1, F2, \dots, F9]$ و با انتخاب گروه‌های آموزش مختلف مورد بررسی قرار گرفته است. این گروه‌های آموزش شامل باتری‌های زوج، فرد و همه باتری‌ها به جز یک گروه باتری به طور گردشی به منظور اعتبارسنجی متقابل انتخاب شده‌اند. حذف گردشی یک گروه باتری از مجموعه باتری‌های آموزش، برای تأیید عدم بیش‌برازش در تخمین سلامت باتری لازم است. نتایج این بررسی‌ها در جدول (۲) خلاصه شده است. سطرهای این جدول میانگین درصد خطاهای تخمین وضعیت سلامت سایر باتری‌ها با آموزش مدل توسط گروه منتخب بیان شده در ستون اول را نشان می‌دهد. این خطاها برای زیرمجموعه‌های ۹ گانه از ویژگی‌ها در ستون‌های جدول (۲) ارائه شده است که در گستره ۶/۳ تا ۲۱/۳ درصد تغییر می‌کند. نتایج این بررسی نشان می‌دهد که با افزایش

- [1] Jafari, M., Gauchia, A., Zhao, S., Zhang, K., Gauchia, L., "Electric vehicle battery cycle aging evaluation in real-world daily driving and vehicle-to-grid services", IEEE Transactions on Transportation Electrification, Vol. 4, No. 1, pp. 122-134, 2018. <https://doi.org/10.1109/TTE.2017.2764320>.
- [2] Babaeiyazdi, I., Rezaei-Zare, A., Shokrzadeh, S., "Transfer learning with deep neural network for capacity prediction of Li-Ion batteries using EIS measurement", IEEE Transactions on Transportation Electrification, Vol. 9, No. 1, pp. 886-895, 2023. <https://doi.org/10.1109/TTE.2022.3170230>.
- [3] Li, J., Deng, Z., Che, Y., Xie, Y., Hu, X., Teodorescu, R., "Degradation pattern recognition and features extrapolation for battery capacity trajectory prediction", IEEE Transactions on Transportation Electrification, pp. 1-1, 2024. <https://doi.org/10.1109/TTE.2023.3336618>.
- [4] Wu, Y., Xue, Q., Shen, J., Lei, Z., Chen, Z., Liu, Y., "State of health estimation for lithium-ion batteries based on healthy features and long short-term memory", IEEE Access, Vol. 8, pp. 28533-28547, 2020. <https://doi.org/10.1109/ACCESS.2020.2972344>.
- [5] Naguib, M., Kollmeyer, P., Emadi, A., "Application of deep neural networks for lithium-ion battery surface temperature estimation under driving and fast charge conditions", IEEE Transactions on Transportation Electrification, Vol. 9, No. 1, pp. 1153-1165, 2023. <https://doi.org/10.1109/TTE.2022.3200225>.
- [6] Dai, H., Zhao, G., Lin, M., Wu, J., Zheng, G., "A novel estimation method for the state of health of lithium-ion battery using prior knowledge-based neural network and Markov Chain", IEEE Transactions on Industrial Electronics, Vol. 66, No. 10, pp. 7706-7716, 2019. <https://doi.org/10.1109/TIE.2018.2880703>.
- [7] Gou, B., Xu, Y., Feng, X., "An ensemble learning-based data-driven method for online state-of-health estimation of lithium-ion batteries", IEEE Transactions on Transportation Electrification, Vol. 7, No. 2, pp. 422-436, 2021. <https://doi.org/10.1109/TTE.2020.3029295>.
- [8] Shu, X., Chen, Q., Shen, J., Shen, S., Guo, F., Zhang, Y., Liu, Y., "Ensemble learning and voltage reconstruction based state of health estimation for lithium-ion batteries with twenty random samplings", IEEE Transactions on Power Electronics, Vol. 38, No. 4, pp. 5538-5548, 2023. <https://doi.org/10.1109/TPEL.2023.3235872>.
- [9] Zhang, S., Yuan, W., Wang, Y., Cheng, S., Wang, J., "Capacity estimation for lithium-ion batteries based on impedance spectral dynamics and deep gaussian process", IEEE Transactions on Power Electronics, Vol. 39, No. 8, pp. 10287-10298, 2024. <https://doi.org/10.1109/TPEL.2024.3395513>.
- [10] Liu, K., Li, Y., Hu, X., Lucu, M., Widanage, W.D., "Gaussian process regression with automatic relevance determination kernel for calendar aging prediction of lithium-ion batteries", IEEE Transactions on Industrial Informatics, Vol. 16, No. 6, pp. 3767-3777, 2020. <https://doi.org/10.1109/TII.2019.2941747>.
- [11] Wei, Y., Wu, D., "State of health and remaining useful life prediction of lithium-ion batteries with conditional graph convolutional network", Expert Systems with Applications, Vol. 238: 122041, 2024. <https://doi.org/10.1016/j.eswa.2023.122041>.
- [12] Wei, Y., Wu, D., "Prediction of state of health and remaining useful life of lithium-ion battery using graph convolutional network with dual attention mechanisms", Reliability Engineering & System Safety, Vol. 230:108947, 2023. <https://doi.org/10.1016/j.res.2022.108947>.
- [13] Bole, B., Kulkarni, C.S., Daigle, M., "Adaptation of an electrochemistry-based li-ion battery model to account for deterioration observed under randomized use", Annual Conference of the PHM Society, Vol. 6, No. 1, 2014. <https://doi.org/10.36001/phmconf.2014.v6i1.2490>.
- [14] Palacín, M.R., "Understanding ageing in li-ion batteries: a chemical issue", Chemical Society Reviews, Vol. 47, No. 13, pp. 4924-4933, 2018. <https://doi.org/10.1039/C7CS00889A>.
- [15] Danzer, M.A., Liebau, V., Maglia, F., "Aging of lithium-ion batteries for electric vehicles", Advances in Battery Technologies for Electric Vehicles, pp. 359-387, 2015. <https://doi.org/10.1016/B978-1-78242-377-5.00014-5>.
- [16] Ma, S., Jiang, M., Tao, P., Song, C., Wu, J., Wang, J., Deng, T., Shang, W., "Temperature effect and thermal impact in lithium-ion batteries: A review", Progress in Natural Science: Materials International, Vol. 28, No. 6, pp. 653-666, 2018. <https://doi.org/10.1016/j.pnsc.2018.11.002>.
- [17] Ren, D., Smith, K., Guo, D., Han, X., Feng, X., Lu, L., Ouyang, M., Li, J., "Investigation of lithium plating-stripping process in li-ion batteries at low temperature using an electrochemical model", Journal of The Electrochemical Society, Vol. 165, No. 10, pp. A2167-A2178, 2018. <https://doi.org/10.1149/2.0661810jes>.
- [18] Ouyang, D., Weng, J., Chen, M., Liu, J., Wang, J., "Experimental analysis on the degradation behavior of overdischarged lithium-ion battery combined with the effect of high-temperature environment", International Journal of Energy Research, Vol. 44, No. 1, pp. 229-241, 2019. <https://doi.org/10.1002/er.4898>.
- [19] Hu, X., Che, Y., Lin, X., Onori, S., "Battery health prediction using fusion-based feature selection and machine learning", IEEE Transactions on Transportation Electrification, Vol. 7, No. 2, pp. 382-398, 2021. <https://doi.org/10.1109/TTE.2020.3017090>.
- [20] Liu, K., Hu, X., Wei, Z., Li, Y., Jiang, Y., "Modified gaussian process regression models for cyclic capacity prediction of lithium-ion batteries", IEEE Transactions on Transportation Electrification, Vol. 5, No. 4, pp. 1225-1236, 2019. <https://doi.org/10.1109/TTE.2019.2944802>.
- [21] Choi, Y., Yun, J., Jang, P., "A deep learning approach for state of health estimation of lithium-ion batteries based on differential thermal voltammetry", IEEE Access, Vol. 12, pp. 89921-89932, 2024. <https://doi.org/10.1109/ACCESS.2024.3419837>.
- [22] Mao, L., Wen, J., Zhao, J., Qu, K., "Online state-of-health estimation of lithium-ion batteries based on a novel equal voltage range sampling count number health indicator", IEEE Transactions on Transportation Electrification, Vol. 10, No. 1, pp. 2277-2292, 2024. <https://doi.org/10.1109/TTE.2023.3283572>.
- [23] Lin, C., Xu, J., Hou, J., Liang, Y., Mei, X., "Ensemble method with heterogeneous models for battery state-of-health estimation", IEEE Transactions on Industrial

- Informatics, Vol. 19, No. 10, pp. 10160-10169, 2023.
<https://doi.org/10.1109/TII.2023.3240920>.
- [24] Bamati, S., Chaoui, H., "Developing an online data-driven state of health estimation of lithium-ion batteries under random sensor measurement unavailability", IEEE Transactions on Transportation Electrification, Vol. 9, No. 1, pp. 1128-1141, 2023.
<https://doi.org/10.1109/TTE.2022.3199115>.
- [25] Ye, J., Xie, Q., Lin, M., Wu, J., "A method for estimating the state of health of lithium-ion batteries based on physics-informed neural network", Energy, Vol. 294:130828, 2024.
<https://doi.org/10.1016/j.energy.2024.130828>.
- [26] Cai, L., Lin, J., Liao, X., "A data-driven method for state of health prediction of lithium-ion batteries in a unified framework", Journal of Energy Storage, Vol. 51: 104371, 2022.
<https://doi.org/10.1016/j.est.2022.104371>.