

Compensation of The Approximation Error of Support Vector Regression Using Semi-Parametric Model: Application to Lithium-Ion Battery State of Charge Estimation

Maryam Kiani, Saeed Khorashadizadeh, Mohammad-Ali Shamsi-Nejad * 

Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Ira

ARTICLE INFO

Article Type

Original Research

Article History

Received: November 02, 2025

Revised: December 02, 2025

Accepted: December 18, 2025

ePublished: January 30, 2026

ABSTRACT

An accurate estimation of the state of charge (SOC) is necessary for optimal management of the energy in electric vehicles (EV) and protection of the battery from going to the deep discharge or overcharge conditions. Nowadays, many different artificial intelligence methods have been broadly developed and applied to this problem. In this paper, support vector regression (SVR) and semi-parametric models are combined to improve the accuracy of estimation. The motivation of this idea stems from the similarity of the optimal hyper-plane of SVR and the equation used in parametric regression models. However, to have a more flexible and accurate model, semi-parametric model is used. In fact, semi-parametric model plays the role of compensation for the approximation error of the SVR. For validation of the proposed method, various profiles of currents are used. Comparison of SVR, Radial basis function (RBF) neural network, multilayer perceptron (MLP) neural network with the proposed method, shows that the proposed method is more accurate in SOC estimation. In addition, the proposed method shows high accuracy and fast convergence in real-world implementations. The results based on Urban Dynamometer Driving Schedule (UDDS) shows the superiority of the proposed approach under realistic operating conditions.

Keywords: Lithium-Ion Battery, State of Charge Estimation, Support Vector Regression, Semi-Parametric Model

How to cite this article

Kiani M, Khorashadizadeh S, Shamsi-Nejad M.A, "Compensation of The Approximation Error of Support Vector Regression Using Semi-Parametric Model: Application to Lithium-Ion Battery State of Charge Estimation". Modares Mechanical Engineering; 2026;26(02):141-156.

*Corresponding author's email: mshamsi@birjand.ac.ir

*Corresponding ORCID ID: 0000-0002-1941-7725



Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.



جبران خطای تقریب در رگرسیون بردار پشتیبان با استفاده از مدل نیمه پارامتری: کاربرد در تخمین وضعیت شارژ باتری لیتیوم-یون

مریم کیانی، سعید خراشادی زاده، محمدعلی شمسی نژاد* 

گروه مهندسی برق، دانشگاه بیرجند، بیرجند، ایران

چکیده

تخمین دقیق وضعیت شارژ برای مدیریت بهینه انرژی در وسایل نقلیه الکتریکی و حفاظت از باتری در برابر تخلیه عمیق یا شارژ بیش از حد ضروری است. امروزه، روش‌های مختلف هوش مصنوعی به طور گسترده‌ای برای حل این مسئله توسعه یافته و به کار گرفته شده‌اند. در این مقاله، رگرسیون بردار پشتیبان و مدل‌های نیمه پارامتری با هم ترکیب شده‌اند تا دقت تخمین بهبود یابد. انگیزه این ایده از شباهت ابرصفحه بهینه رگرسیون بردار پشتیبان و معادله استفاده شده در مدل‌های رگرسیون پارامتری نشأت می‌گیرد. با این حال، برای داشتن مدلی منعطف‌تر و دقیق‌تر، از مدل نیمه پارامتری استفاده شده است. در واقع، مدل نیمه پارامتری نقش جبران خطای تقریب رگرسیون بردار پشتیبان را ایفا می‌کند. برای اعتبارسنجی روش پیشنهادی، پروفایل‌های مختلف جریان مورد استفاده قرار گرفته‌اند. مقایسه رگرسیون بردار پشتیبان، شبکه عصبی با تابع پایه شعاعی، شبکه عصبی پرسپترون چندلایه با روش پیشنهادی نشان می‌دهد که روش پیشنهادی در تخمین وضعیت شارژ دقت بالاتری دارد. علاوه بر این، روش پیشنهادی در پیاده‌سازی‌های واقعی دقت بالا و همگرایی سریعی نشان می‌دهد. نتایج حاصل از برنامه رانندگی دینامومتر شهری برتری روش پیشنهادی را در شرایط عملیاتی واقعی نشان می‌دهد.

اطلاعات مقاله

نوع مقاله

مقاله پژوهشی

تاریخچه مقاله

دریافت: ۱۴۰۴/۰۸/۱۱

بازنگری: ۱۴۰۴/۰۹/۱۱

پذیرش: ۱۴۰۴/۰۹/۲۷

ارائه آنلاین: ۱۴۰۴/۱۱/۱۰

کلیدواژه‌ها: باتری لیتیوم-یون، تخمین وضعیت شارژ، رگرسیون بردار پشتیبان، مدل نیمه پارامتری

نحوه ارجاع به این مقاله

کیانی مریم، خراشادی زاده سعید، شمسی نژاد محمدعلی، "جبران خطای تقریب در رگرسیون بردار پشتیبان با استفاده از مدل نیمه پارامتری: کاربرد در تخمین وضعیت شارژ باتری لیتیوم-یون"، مهندسی مکانیک مدرس. ۱۵۷-۱۴۱:۲۶(۰۲):۱۴۰۴.

*پست الکترونیکی نویسنده عهده‌دار مکاتبات: mshamsi@birjand.ac.ir

*شناسه ارجاع نویسنده عهده‌دار مکاتبات: 0000-0002-1941-7725



Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.


۱- مقدمه

امروزه، به دلیل نگرانی‌های مربوط به تغییرات اقلیمی، تقاضا برای فناوری‌های دوست‌دار محیط زیست افزایش یافته است. نیاز به بهبود تخمین وضعیت شارژ باتری‌ها، مهم‌ترین انگیزه این مقاله بوده است. وضعیت شارژ باتری برای نظارت بر مدت زمان شارژ ضروری است [۱]. باتری‌های با فناوری لیتیوم-یون، سیستم‌هایی غیرخطی با عدم قطعیت و پیچیدگی بالا هستند که به طور گسترده در خودروهای الکتریکی استفاده می‌شوند [۲، ۳]. با این حال، وضعیت شارژ نمی‌تواند به طور مستقیم توسط حسگر اندازه‌گیری شود [۴، ۵] و باید تخمین زده شود.

بر اساس [۶]، مدل‌های تخمین مختلف ارائه شده در مقالات برای سیستم‌های مدیریت باتری را می‌توان به دو دسته اصلی طبقه‌بندی کرد: رویکردهای مبتنی بر مدل و مدل‌های مبتنی بر داده. در دسته رویکردهای مبتنی بر مدل، برخی مدل‌های شناخته‌شده وجود دارند مانند مدل‌های الکتروشیمیایی [۷]، مدل‌های مدار معادل [۸] و مدل‌های تجربی [۹]. همچنین، مدل‌های مبتنی بر داده به دو بخش رویکردهای یادگیری ماشین و یادگیری عمیق تقسیم می‌شوند. رویکردهای یادگیری ماشین خود به رگرسیون خطی [۱۰]، مدل‌های فرآیند گوسی [۱۱]، ماشین‌های بردار پشتیبان [۱۲-۱۳] و درخت‌های تصمیم [۱۴] تقسیم می‌شوند. در بین رویکردهای یادگیری عمیق، شبکه‌های عصبی عمیق [۱۵-۱۶]، شبکه‌های عصبی کانولوشنی [۱۷-۱۹] و شبکه‌های عصبی بازگشتی [۲۰-۲۱] محبوب‌تر هستند. این دسته‌بندی در شکل ۱ نشان داده شده است.

رویکردهای مبتنی بر مدل مانند مدل‌های الکتروشیمیایی به دلیل استفاده از معادلات دیفرانسیل جزئی در مدل‌های توصیفی خود، بار محاسباتی سنگینی دارند. علاوه بر این، عدم قطعیت‌های مختلف از جمله عدم قطعیت پارامتری و غیرپارامتری ممکن است دقت تخمین وضعیت شارژ را تحت تأثیر قرار دهند. روش‌های تخمین برای برآورد پارامترهای ناشناخته مدل نیاز است و سپس الگوریتم‌های مدیریت باتری مانند الگوریتم‌های تخمین وضعیت شارژ بر اساس این پارامترهای تخمینی توسعه می‌یابند. بنابراین، خطاهای پارامتری در الگوریتم‌های شناسایی پارامتر در الگوریتم تخمین وضعیت شارژ تجمع می‌یابد که رضایت‌بخش نیست. از سوی دیگر، رویکردهای مبتنی بر داده به درک عمیق از دانش پیشین نیازی ندارند [۲۲]. در نتیجه، به نظر می‌رسد که رویکردهای مبتنی بر داده دقیق‌تر هستند و در دهه‌های اخیر، روند رو به رشدی به سمت این رویکردها در علم مشاهده شده است.

رویکردهای مبتنی بر داده دارای مزایا و معایب خاص خود هستند. رویکردهای رگرسیون خطی قادر به مدل‌سازی داده‌های غیرخطی نیستند. مدل‌های فرآیند گوسی بار محاسباتی بالایی دارند و نیازمند مجموعه داده‌های بزرگی هستند. درخت‌های تصمیم ساده و قابل فهم‌اند، اما اندازه نمونه، پارامتری حیاتی در این مدل‌ها محسوب می‌شود. شبکه‌های عصبی عمیق و شبکه‌های عصبی کانولوشنی قادر به یادگیری داده‌های بسیار غیرخطی هستند، اما فرایند آموزش این شبکه‌ها ممکن است دشوار و زمان‌بر باشد. شبکه‌های عصبی بازگشتی ابزارهای قدرتمندی برای مدل‌سازی داده‌های زمانی (سری زمانی) هستند، ولی در فرایند آموزش به دلیل مشکل ناپدید شدن گرادیان‌ها آسیب‌پذیرند.



شکل ۱ دسته‌بندی مدل‌های تخمین وضعیت شارژ

Fig. 1 Classification of SOC estimation models

ماشین بردار پشتیبان به طور موفقیت آمیزی در مسائل مختلف طبقه بندی و رگرسیون غیرخطی به کار گرفته شده است. ماشین بردار پشتیبان از توابع کرنل برای انجام یادگیری استفاده می کند. کرنل ها می توانند برای وظایف یادگیری مختلف و داده های متفاوت بهینه شوند [۲۳]. این موضوع امکان کاربرد ماشین بردار پشتیبان را در حوزه های مختلفی مانند زیست پزشکی، زیست اطلاعات و بینایی ماشین فراهم آورد [۲۴]. در [۲۵] برای تخمین وضعیت شارژ باتری لیتیوم-یون از ماشین بردار پشتیبان استفاده می شود. نویسندگان با انتخاب ویژگی های مؤثر و تنظیم پارامترهای ماشین بردار پشتیبان، یک مدل بهینه برای تخمین وضعیت شارژ توسعه داده اند. عملکرد مدل ماشین بردار پشتیبان با چند روش مرجع دیگر (از جمله مدل های یادگیری ماشین و روش های مبتنی بر مدار معادل) مقایسه شده و نشان داده شده که ماشین بردار پشتیبان دارای دقت بالا و خطای کم به ویژه در شرایط بار پویا است. همچنین در [۲۶]، یک ماشین بردار پشتیبان بهینه شده با استفاده از بهینه سازی ازدحام ذرات برای افزایش دقت تخمین وضعیت شارژ پیشنهاد شده است.


مشابه شبکه های عصبی که هم به عنوان طبقه بند و هم رگرسور قابل استفاده اند، ماشین های بردار پشتیبان نیز کاربردهای طبقه بندی و رگرسیون دارند. رگرسیون با استفاده از ماشین بردار پشتیبان به عنوان رگرسیون بردار پشتیبان شناخته می شود و به طور گسترده ای برای تخمین وضعیت شارژ به کار رفته است [۲۷-۳۰]. در [۲۷]، یک مدل رگرسیون بردار پشتیبان برای تخمین وضعیت شارژ باتری های Ni-MH در خودروهای هیبریدی توسعه یافته است. در [۲۸]، تحلیل مولفه های اصلی با رگرسیون بردار پشتیبان ترکیب شده تا وضعیت شارژ پیش بینی شود. در [۲۹] با آموزش رگرسیون بردار پشتیبان بر روی داده ها، مدلی بهینه برای تخمین وضعیت شارژ ایجاد و عملکرد آن با سایر مدل های رگرسیونی و شبکه عصبی مقایسه شده است. نتایج نشان می دهد که رگرسیون بردار خطای قابل قبولی داشته و می تواند به عنوان نقطه شروع برای روش های پیچیده تر در سیستم های مدیریت باتری مورد استفاده قرار گیرد. در [۳۰]، روش رگرسیون بردار پشتیبان بهبود یافته ای بر اساس بهینه سازی پارامترهای رگرسیون بردار پشتیبان با الگوریتم ژنتیک پیشنهاد شده است.

برای بهبود عملکرد رگرسیون بردار پشتیبان، در این مقاله، این روش با مدل های رگرسیون خطی نیمه پارامتری ترکیب شده است. در نتیجه، روش پیشنهادی قادر است غیرخطی بودن داده های آموزشی را با دقت بیشتری به دلیل انعطاف پذیری بیشتر ساختار برآوردگر پوشش دهد. در واقع، برآوردگر پیشنهادی از یک رگرسیون بردار پشتیبان معمولی و یک جمله رگرسیون نیمه پارامتری تشکیل شده است. به عبارتی دیگر، برآوردگر پیشنهادی می تواند خطای تقریب رگرسیون بردار پشتیبان معمولی را جبران کند. این مشابه جبران خطای تقریب تخمین گره های عصبی-فازی یا سایر

تخمین گره های عدم قطعیت توسط تابع علامت یا سایر عبارات تطبیقی در کنترل مقاوم و غیرخطی سیستم های دینامیکی است. خطای تقریب برآوردگرها به این معنی است که برآوردگر انتخاب شده برای یک مسئله تخمین خاص قادر به مدل سازی دقیق فرایند نیست. برای مثال، در [۳۱، ۳۲]، برخی جملات جبران کننده با استفاده از توابع علامت یا دیگر جملات کنترل مقاوم طراحی شده اند تا خطای دنبال کردن ربات ها کاهش یابد که در آن سیستم های فازی یا بسط سری فوریه به عنوان برآوردگرهای عدم قطعیت عمل می کنند. در [۳۳]، یک عبارت جبران کننده برای غلبه بر خطای تقریب یادگیری عاطفی مغز در هماهنگ سازی آشوب و ارتباط امن طراحی شده است. با این حال، جبران خطای تقریب تخمین گر وضعیت شارژ نادیده گرفته شده است. برای بهبود عملکرد رگرسیون بردار پشتیبان و جبران خطای بازسازی/تخمین آن، در این مقاله رگرسیون بردار پشتیبان با مدل های رگرسیون خطی نیمه پارامتری ترکیب شده است. در نتیجه، روش پیشنهادی به دلیل انعطاف پذیری بیشتر ساختار برآوردگر می تواند غیرخطی بودن داده های آموزشی را با دقت بیشتری پوشش دهد.

برای توضیح مزایا و معایب روش پیشنهادی، شایان ذکر است که روش های تخمین به دو دسته کلی پارامتری و غیرپارامتری تقسیم می شوند. با این حال، گاهی اوقات ممکن است با مسائلی مواجه شویم که به طور کامل و دقیق در یکی از این دو گروه جای نمی گیرند. بهترین راه حل در این موارد استفاده از مدل های نیمه پارامتری است. این اصلی ترین مزیت روش پیشنهادی در این مقاله است. در واقع، تمام برآوردگرهای قبلی وضعیت شارژ ارائه شده مانند شبکه های عصبی و سیستم های فازی می توانند با این ایده بهبود یابند. در این مقاله، ماشین بردار پشتیبان به کار گرفته شده است. البته مدل های نیمه پارامتری ممکن است بار محاسباتی پردازنده را افزایش دهند.

نوآوری این مقاله ارائه یک برآوردگر شارژ جدید بر پایه ترکیب ماشین بردار پشتیبان و مدل های نیمه پارامتری است. اکثر روش های مبتنی بر رگرسیون بردار پشتیبان موجود، پارامتری یا غیرپارامتری هستند. در روش های پارامتری، ضرایب برخی رگرسورهای مشخص محاسبه می شوند. اما در اکثر کاربردهای عملی، شناسایی دقیق رگرسورها غیرممکن است. البته اگر رگرسورها به درستی شناسایی شوند، نتایج دقیقی حاصل می شود. بنابراین، روش های غیرپارامتری به کار گرفته می شوند که در آن ها رگرسورها توسط طراح انتخاب می شوند. اما خطای تقریب این روش ها به دلیل ناسازگاری های ساختاری ممکن است زیاد باشد. این مقاله روش نیمه پارامتری را برای حل این مسئله ارائه می کند. در مقایسه با بسیاری از الگوریتم های مبتنی بر رگرسیون بردار پشتیبان، روش پیشنهادی به دلیل سادگی و بار محاسباتی کمتر، برتری دارد.



شکل ۲ نمایش ε ، ξ_i و ξ_i^* در مسئله رگرسیون

Fig. 2 Representation of ε ، ξ_i and ξ_i^* in the regression problem

جدول ۱ رایج‌ترین توابع کرنل مورد استفاده در مسائل خطی‌ناپذیر [۳۵]

Table 1 The most common kernel functions used in linear inseparable problems [۳۵]

function type	kernel function
Gaussian (Radial-basis) kernel	$K(x, x_i) = \exp(-\ x - x_i\ ^2 / 2\sigma^2)$
Linear kernel	$K(x, x_i) = x_i x_j$
Multi-layer perceptron (sigmoid)	$K(x, x_i) = \tanh(\beta_0 x^T x_i + \beta_1)$
Polynomial kernel	$K(x, x_i) = (x^T x_i + 1)^d$

تابع لاگرانژ برای روابط (۲) و (۳) به صورت زیر تعریف شده است [۴۴]:

$$L = \min \left\{ \frac{1}{2} \|\theta\|^2 + c \sum_{i=1}^N (\xi_i + \xi_i^*) + \sum_{i=1}^N \alpha_i (y_i - \theta^T x_i - b - (\varepsilon + \xi_i)) - \sum_{i=1}^N \eta_i \xi_i - \sum_{i=1}^N \eta_i^* \xi_i^* + \sum_{i=1}^N \alpha_i^* (\theta^T x_i + b - y_i - (\varepsilon + \xi_i)) \right\} \quad (4)$$

$$\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0$$

که در آن α_i^* و η_i ضرایب لاگرانژ هستند و پارامترهایی که باید بهینه شوند، شامل θ ، α ، α^* ، ξ ، ξ^* و η می‌باشند. برای حل این مسئله بهینه‌سازی، لازم است تابع لاگرانژ نسبت به پارامترهای بهینه‌سازی مشتق گرفته شده و مساوی صفر قرار داده شود.

$$\frac{\partial L}{\partial \theta} = 0 \Rightarrow \theta = \sum_{i=1}^N x_i (\alpha_i - \alpha_i^*) \quad (5)$$

$$\frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \quad (6)$$

$$\frac{\partial L}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \eta_i \begin{cases} \alpha_i \leq C \\ \eta_i \geq 0 \end{cases} \rightarrow 0 \leq \alpha_i \leq C \quad (7)$$

$$\frac{\partial L}{\partial \xi_i^*} = 0 \Rightarrow C = \alpha_i^* + \eta_i^* \begin{cases} \alpha_i^* \leq C \\ \eta_i^* \geq 0 \end{cases} \rightarrow 0 \leq \alpha_i^* \leq C \quad (8)$$

با جایگذاری روابط (۵) تا (۸) در رابطه (۴) و پس از انجام ساده‌سازی‌های لازم، فرم دوگان این مسئله بهینه‌سازی به صورت زیر حاصل می‌شود:

ساختار مقاله به شرح زیر است: در بخش ۲، توضیح مختصری از رگرسیون بردار پشتیبان ارائه شده است. در بخش ۳، روش پیشنهادی رگرسیون بردار پشتیبان با استفاده از رگرسیون خطی نیمه‌پارامتری تشریح شده است. در بخش ۴، مقایسه‌هایی با سایر روش‌ها ارائه می‌شود. در بخش ۵، نتایج تجربی نشان داده می‌شود. در نهایت، بخش ۶ نتیجه‌گیری مقاله را بیان می‌کند.

۲- رگرسیون بردار پشتیبان

ماشین‌های بردار پشتیبان به مجموعه‌ای از مدل‌های خطی تعمیم‌یافته تعلق دارند که پیش‌بینی‌ها درباره طبقه‌بندی یا رگرسیون بر اساس ترکیب‌های خطی ویژگی‌ها انجام می‌شود. رگرسیون بردار پشتیبان مشابه شبکه‌های عصبی مصنوعی، قادر است توابع چندمتغیره را با دقت دلخواه تقریب زده و برای مدل‌سازی فرآیندهای مختلف غیرخطی و پیچیده استفاده شود [۳۴]. فرض کنید (x_i, y_i) مجموعه‌ای از N نمونه است که در آن بردار ورودی x_i شامل p مؤلفه و بردار خروجی y_i مقادیر خروجی متناظر را نشان می‌دهد. در رگرسیون بردار پشتیبان، این رابطه به صورت زیر مدل‌سازی می‌شود:

$$g(x_i) = \theta^T x_i + b, \quad i = 1, 2, \dots, N \quad (1)$$

که در آن θ بردار وزن و b پارامتر بایاس است. یک مسئله بهینه‌سازی می‌تواند فرموله شود تا مقادیر بهینه θ و b به گونه‌ای به دست آید که خطای بین $g(x_i)$ و y_i حداقل شود. طبق مرجع [۳۴]، تابع هدف و قیود زیر برای حل این مسئله تعریف می‌شوند:

$$\text{minimize } \frac{1}{2} \theta^2 + C \sum_{i=1}^N (\xi_i + \xi_i^*) \quad (2)$$

$$\text{subject to } \begin{cases} y_i - \theta^T x_i - b \leq \varepsilon + \xi_i \\ \theta^T x_i + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0, \quad i = 1, 2, \dots, N \end{cases} \quad (3)$$

همان‌طور که در شکل ۲ نشان داده شده است، ε یک پارامتر تنظیمی است که سطح خطای تجربی را در مسئله بهینه‌سازی تعیین می‌کند. همچنین، ξ_i و ξ_i^* متغیرهای کمکی هستند و C یک پارامتر جریمه است که توسط کاربر تعریف می‌شود. با حل مسئله بهینه‌سازی مطرح شده در رابطه (۲)، یک رابطه خطی به دست می‌آید که به‌طور بهینه ارتباط بین ورودی و خروجی را توصیف می‌کند. این مسئله معمولاً به صورت فرم دوگان حل می‌شود.

برای مسائل غیرخطی، داده‌ها از یک فضای غیرخطی به یک فضای خطی نگاشت می‌شوند و سپس در این فضای جدید، هدف، یافتن یک رابطه خطی بهینه است که بتواند ارتباط بین ورودی و خروجی را توصیف کند. این رابطه خطی بهینه در فضای جدید، معادل یک رابطه غیرخطی در فضای اولیه است. عملیات نگاشت با استفاده از یک تابع کرنل انجام می‌شود. رایج‌ترین انواع توابع کرنل در جدول ۱ ارائه شده‌اند.

$$L_{new} = \max \left\{ -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i^* x_j^* - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \right\}$$

$$\text{subject to} \begin{cases} \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i \leq C \\ 0 \leq \alpha_i^* \leq C \end{cases} \quad (17)$$

۴- نتایج شبیه‌سازی روش پیشنهادی رگرسیون بردار پشتیبان در تخمین وضعیت شارژ


یکی از مهم‌ترین عوامل در سیستم مدیریت باتری خودروهای برقی و هیبریدی، که دارای دو حالت باتری و سوخت فسیلی هستند، پایش دقیق وضعیت شارژ است که به صورت زیر تعریف می‌شود:

$$SOC(t) = SOC_{start} - \frac{\int I dt}{Q_{nom}} \times 100 \quad (18)$$

در رابطه فوق، SOC_{start} مقدار اولیه وضعیت شارژ و Q_{nom} ظرفیت اسمی باتری است، و $\int I dt$ کل جریان شارژ یا دشارژ باتری را نشان می‌دهد.

مدل مدار معادل الکتریکی به دلیل سادگی ساختار، تعداد کم پارامترهای قابل تنظیم، کاربرپذیری در شرایط واقعی، دقت بالا (حدود ۹۵٪ تا ۹۹٪) و نیز شبیه‌سازی سریع‌تر و قدرتمندتر نسبت به روش‌های دیگر، به‌طور گسترده‌ای مورد استفاده قرار گرفته است. مدل‌های مختلفی از مدار معادل الکتریکی با سطوح دقت گوناگون برای پیش‌بینی رفتار باتری ارائه شده‌اند. چن و رینکن-مورا [۳۶] استفاده از دو گروه RC را به عبارت دیگر مدل مرتبه دوم را به عنوان یک مدل دقیق باتری توصیه می‌کنند که در عین دقت، جامع و نسبتاً ساده نیز هست، همان‌طور که در شکل ۳ نشان داده شده است.

مدلی که توسط این پژوهشگران ارائه شده، در بازه گسترده‌ای از وضعیت شارژ، خطای ولتاژ قابل قبولی را نشان می‌دهد. بر اساس [۴۵]، روابط (۱۹) تا (۲۴) ارتباط بین پارامترهای مدل باتری و وضعیت شارژ را برای باتری معرفی شده در جدول ۲ ارائه می‌کنند.



شکل ۳ مدل مرتبه دوم مدار معادل الکتریکی باتری [۳۶]

Fig.3 Second-order model of battery electric equivalent circuit [۳۶]

$$L_D = \max_{\alpha, \alpha^*} \left\{ -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) x_i x_j - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha_i^*) + \sum_{i=1}^N y_i (\alpha_i - \alpha_i^*) \right\}$$

$$\text{subject to} \begin{cases} \sum_{i=1}^N (\alpha_i - \alpha_i^*) = 0 \\ 0 \leq \alpha_i \leq C \\ 0 \leq \alpha_i^* \leq C \end{cases} \quad (9)$$

۳- روش پیشنهادی رگرسیون بردار پشتیبان مبتنی بر رگرسیون خطی نیمه پارامتری

فرض می‌کنیم بین ورودی و خروجی مجموعه داده آموزشی یک رابطه خطی وجود دارد، همان‌طور که در رابطه (۱) نشان داده شده است، که در آن $\theta, x_i \in \mathbb{R}^p$ تعریف می‌شوند به صورت:

$$\theta^T = [\theta_1 \quad \theta_2 \quad \dots \quad \theta_p]$$

$$x_i^T = [x_{i1} \quad x_{i2} \quad \dots \quad x_{ip}] \quad (10)$$

می‌توان رابطه (۱) را به صورت زیر بازنویسی کرد:

$$\theta^T x_i - f(x_i) = 0 \quad (11)$$

شایان ذکر است که پارامتر b در رابطه (۱) معادل $f(x_i)$ در رابطه (۱۱) است. به عبارت دیگر، مدل پارامتری (۱) را به مدل نیمه پارامتری (۱۱) تبدیل می‌کند که این امر به دلیل انعطاف‌پذیری بیشتری که به مدل اضافه می‌کند، منجر به عملکرد بهتر رگرسیون می‌شود. از آنجا که $f(x_i)$ ناشناخته است، می‌توان آن را به صورت $\hat{f}(x_i)$ برآورد کرد، به شکل زیر:

$$\hat{f}(x_i) = \sum_{j=1}^m W_j(x_i) (\theta^T x_j) \quad (12)$$

$$W_j(x_i) = \frac{K\left(\frac{x_j - x_i}{h}\right)}{\sum_{j=1}^m K\left(\frac{x_j - x_i}{h}\right)} \quad (13)$$

که در آن $K(\cdot)$ یک تابع کرنل است که می‌تواند از جدول ۱ انتخاب شود و h پارامتر هموارسازی است. جایگذاری $\hat{f}(x_i)$ از رابطه (۱۲) در رابطه (۱) منجر به حاصل زیر می‌شود:

$$\theta^T x_j - \sum_{j=1}^m W_j(x_i) (\theta^T x_j) = 0 \quad (14)$$

برای داشتن فرم فشرده‌تر، می‌توان رابطه (۱۴) را به صورت زیر بازنویسی کرد:

$$\theta^T x_i^* = 0 \quad (15)$$

که در آن

$$x_i^* = x_i - \sum_{j=1}^m W_j(x_i) x_j \quad (16)$$

حال از رابطه (۱۶) باید در مسئله بهینه‌سازی (۱۰) جایگذاری شود که نتیجه به صورت زیر خواهد بود:

به خروجی‌های واقعی نزدیک خواهند بود و ضریب همبستگی عددی نزدیک به یک خواهد داشت. ضریب همبستگی به صورت زیر محاسبه می‌شود:

$$R = \text{corr}(y_i, \hat{y}_i) = \frac{\text{COV}(y_i, \hat{y}_i)}{\sigma_{y_i} \sigma_{\hat{y}_i}} \quad (25)$$

که در آن y_i نمایانگر مقدار واقعی وضعیت شارژ باتری در زمان i و $\hat{y}_i$ مقدار تخمینی وضعیت شارژ در همان زمان است. همچنین، σ_{y_i} و $\sigma_{\hat{y}_i}$ به ترتیب انحراف معیار متغیرهای تصادفی y_i و $\hat{y}_i$ هستند. میانگین مربعات خطا یک معیار رایج برای ارزیابی میزان تطابق مدل با متغیر وابسته است و به صورت زیر محاسبه می‌شود:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (26)$$

میانگین مربعات خطا میزان اختلاف بین نتایج به‌دست‌آمده و مقادیر واقعی را نشان می‌دهد. مقدار کمتر میانگین مربعات خطا به این معنی است که مدل عملکرد خوبی داشته و تفاوت بین خروجی تخمینی مدل و خروجی واقعی کوچک است. معیار ریشه میانگین مربعات خطا بر اساس میانگین مربعات خطا و با استفاده از رابطه (۲۷) محاسبه می‌شود. مقدار کمتر ریشه میانگین مربعات خطا نشان‌دهنده دقت بالاتر نتایج است.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (27)$$

نمودار بلوکی روش پیشنهادی تخمین وضعیت شارژ در شکل ۴ ارائه شده است.

در محیط سیمولینک، یک باتری لیتیوم-یون مدل ۱۸۶۵۰ در یک سیکل با سه پروفایل جریان دلخواه مختلف به طور کامل دشارژ شده است. خروجی واقعی و خروجی‌های تخمینی به وسیله شبکه عصبی تابع پایه شعاعی، پرسپترون چند لایه، رگرسیون بردار پشتیبان و روش پیشنهادی با یکدیگر مقایسه شده‌اند. شبکه عصبی تابع پایه شعاعی با حداکثر ۱۰ نورون و مقدار پراکندگی برابر ۰/۱ تنظیم شده است. مدل پرسپترون چند لایه شامل ۳ لایه مخفی با ۹ نورون است. تابع فعال‌سازی به صورت پیش‌فرض انتخاب شد (معمولاً tansig برای لایه‌های مخفی و purelin برای لایه خروجی)، نرخ یادگیری توسط الگوریتم آموزش تعیین گردید (الگوریتم Levenberg-Marquardt به طور پیش‌فرض در تابع train متلب)، و آموزش تا ۱۰۰ تکرار انجام شد. در مدل پیشنهادی، از کرنل گاوسی استفاده شده است. پارامتر تنظیم (C) برابر با ۱۰۰ تنظیم شده است. ابرپارامترها از طریق تنظیم تجربی انتخاب شدند

$$V_{oc}(SOC) = -1.031e^{-35.5SOC} + 3.685 + 0.2156.SOC - 0.1178.SOC^2 + 0.3201.SOC^3 \quad (19)$$

$$R_{Series}(SOC) = 0.1562e^{-24037.SOC} + 0.07446 \quad (20)$$

$$R_{Transient-S}(SOC) = 0.3208e^{-29.14SOC} + 0.04669 \quad (21)$$

$$R_{Transient-L}(SOC) = 6.603e^{-155.2SOC} + 0.04984 \quad (22)$$

$$C_{Transient-S}(SOC) = -752.9e^{-13.51SOC} + 703.6 \quad (23)$$

$$C_{Transient-L}(SOC) = -6056e^{-27.12SOC} + 4475 \quad (24)$$

در این روابط، $V_{oc}(SOC)$ ولتاژ مدار باز باتری است. شایان ذکر است که ولتاژ مدار باز همان ولتاژ ترمینال باتری بوده و زمانی اندازه‌گیری می‌شود که باتری به تعادل شیمیایی داخلی رسیده و هیچ جریان شارژ/دشارژ یا باری به آن اعمال نشده باشد. بر اساس $V_{oc}(SOC)$ ، [۳۶] تابعی از وضعیت شارژ است.

همچنین، R_{Series} مقاومت داخلی باتری، $R_{Transient-S}$ مقاومت گذرای مربوط به ثابت زمانی بلند، $C_{Transient-S}$ خازن حالت گذرا متناظر با ثابت زمانی کوتاه و $C_{Transient-L}$ خازن حالت گذرا متناظر با ثابت زمانی بلند می‌باشد. باتری مورد استفاده در این مقاله، از نوع باتری‌هایی است که در خودروهای برقی به کار می‌روند و مشخصات این نوع باتری در جدول ۲ ارائه شده است.


به‌منظور نشان دادن برتری مدل پیشنهادی در مقایسه با سایر روش‌های موجود در تخمین وضعیت شارژ، روش‌های رگرسیون بردار پشتیبان معمولی، شبکه عصبی با تابع پایه شعاعی و پرسپترون چندلایه انتخاب شده‌اند. برای مقایسه کمی عملکرد این روش‌ها، شاخص‌هایی مانند ضریب همبستگی، میانگین مربعات خطا و ریشه میانگین مربعات خطا مورد ارزیابی قرار گرفته‌اند.

جدول ۲ مشخصات باتری خودروی برقی تحت آزمون [۳۷]

Table 2 Specifications of electric vehicle battery under test [۳۷]

۱۸۶۵۰ Li-ion Battery (3.3V/1.4Ah)	
Item	Specification
Model NO.	3.3V_1400 mAh
Nominal Capacity	1400 mAh
Nominal Voltage	3.3 V
Charging Voltage	3.65 V
Charging Method	Constant current/Constant voltage
Standard Charging Time	1.5*Nominal Capacity/Charging Current
Discharge cut off Voltage	2.0 V

ضریب همبستگی میزان شباهت بین خروجی‌های تخمینی مدل رگرسیون و خروجی‌های واقعی را اندازه‌گیری می‌کند. در صورتی که مدل رگرسیون عملکرد مناسبی داشته باشد، خروجی‌های تخمینی



شکل ۴ نمودار بلوکی روش پیشنهادی تخمین وضعیت شارژ

Fig. 4 The block diagram of the proposed SOC estimation

سری‌های زمانی مختلف، از جمله تخمین وضعیت شارژ باتری، مورد استفاده قرار گرفته‌اند [۳۸].

با توجه به اهمیت این روش‌ها و اینکه تعداد زیادی از مطالعات اخیر مدل‌های خود را با رویکردهای یادگیری عمیق مقایسه کرده‌اند، ما نیز این مقایسه‌ها را در این پژوهش گنجانده‌ایم. برای این منظور، یک تحلیل مقایسه‌ای بین روش پیشنهادی و مدل LSTM برای تخمین وضعیت شارژ انجام شده است. نتایج این مقایسه بر اساس پروفایل جریان نشان داده شده در شکل ۵ در شکل ۱۱ ارائه شده است.


از دیدگاه کمی، مقایسه‌ای بین روش پیشنهادی و سایر روش‌ها با استفاده از سه پروفایل جریان اول (شکل ۵)، دوم (شکل ۶) و سوم (شکل ۷) به ترتیب در جدول‌های ۳، ۴ و ۵ انجام شده است. در هر جدول، بهترین مقدار تابع هزینه با اعداد پررنگ مشخص شده است.

همان‌گونه که مشاهده می‌شود، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری در تمامی پروفایل‌های جریان، در برآورد وضعیت شارژ باتری لیتیوم-یونی عملکرد مطلوبی دارد. از آنجا که روش پیشنهادی شامل اجزای پارامتری و غیرپارامتری است، این روش شباهت بیشتری به مقادیر واقعی وضعیت شارژ نسبت به سایر روش‌ها نشان می‌دهد. این موضوع بیانگر آن است که روش پیشنهادی برای تخمین وضعیت شارژ مناسب بوده و می‌تواند در شرایطی که جریان دارای نوسان است، عملکرد دقیقی ارائه دهد. بر اساس نتایج جدول‌ها، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری نسبت به رگرسیون بردار پشتیبان عملکرد بهتری دارد که بیانگر تأثیر مدل نیمه پارامتری به کاررفته در این پژوهش است. به عبارت دیگر، این روش می‌تواند خطای


و عملکرد مدل با استفاده از روش استاندارد تقسیم داده‌ها به مجموعه آموزش و آزمون اعتبارسنجی گردید. برای انجام فرایند آموزش، ولتاژ و جریان باتری به عنوان ورودی و وضعیت شارژ به عنوان خروجی به مدل داده شدند. سه پروفایل جریان دلخواه که در فرایند آموزش استفاده شده‌اند، همراه با ولتاژها و وضعیت شارژهای مربوطه در شکل‌های ۵، ۶ و ۷ ارائه شده‌اند.

برای مقایسه عملکرد روش پیشنهادی با استفاده از پروفایل‌های جریان دلخواه رسم شده در بالا و مقایسه آن با مقادیر تخمینی وضعیت شارژ توسط روش‌های شبکه عصبی تابع پایه شعاعی، پرسپترون چندلایه و رگرسیون بردار پشتیبان، به شکل‌های ۸، ۹ و ۱۰ توجه کنید. عملکرد تخمین با استفاده از پروفایل جریان اول (شکل ۵)، پروفایل دوم (شکل ۶) و پروفایل سوم (شکل ۷) به ترتیب در شکل‌های ۸، ۹ و ۱۰ نشان داده شده است. همان‌طور که مشاهده می‌شود، از دیدگاه ارزیابی کیفی، روش پیشنهادی کمترین خطای تخمین را داشته و بهترین عملکرد را نشان می‌دهد.


در چند دهه اخیر، یادگیری عمیق به دلیل قدرت نمایشی بالا و عملکرد تجربی چشمگیر خود توجه زیادی را جلب کرده و در بسیاری از حوزه‌های کاربردی به عنوان روش غالب مطرح شده است. شبکه‌های عصبی بازگشتی به منظور غلبه بر مشکل ناپدید شدن گرادیان طراحی شده‌اند. شبکه‌های حافظه طولانی-کوتاه مدت (LSTM) این مشکل را با استفاده از سلول‌های حافظه و مکانیزم‌های دروازه‌ای (دروازه‌های ورودی، فراموشی و خروجی) حل می‌کنند که به آن‌ها اجازه می‌دهد وابستگی‌های بلندمدت در داده‌های دنباله‌دار را به طور مؤثر ثبت و حفظ کنند. به دلیل این قابلیت، شبکه‌های LSTM به طور گسترده‌ای در وظایف پیش‌بینی




شکل ۶ یک پروفایل جریان دلخواه و ولتاژ و وضعیت شارژ مربوط به آن
Fig.6 An arbitrary current profile and its voltage and SOC 6




شکل ۵ مقادیر واقعی جریان، ولتاژ و وضعیت شارژ باتری لیتیوم-یونی ۱۸۶۵۰ در پروفایل جریان پالسی
Fig. 5 Actual values of current, voltage and SOC of 18650 Li-Ion battery in pulse current




شکل ۸ تخمین وضعیت شارژ باتری لیتیوم-یونی ۱۸۶۵۰ تحت جریان پالسی با استفاده از الگوریتم‌های مختلف
Fig.8 Estimation of the SOC for an 18650 Li-Ion battery under pulse current using various algorithms pulse current



شکل ۷ یک پروفایل جریان دلخواه دیگر و ولتاژ و وضعیت شارژ مربوط به آن
Fig.7 Another arbitrary current profile and its voltage and SOC




شکل ۱۰ تخمین وضعیت شارژ با پروفایل جریان نشان داده شده در شکل ۷
Fig.10 Estimation of the SOC with current profile illustrated in Fig



شکل ۹ تخمین وضعیت شارژ با پروفایل جریان نشان داده شده در شکل ۶
Fig.9 Estimation of the SOC with current profile illustrated in Fig. 6

بهتری نسبت به رگرسیون بردار پشتیبان استاندارد (بدون جبران خطای تقریب) دارد. به طور مشخص، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری موجب ۰/۳٪ بهبود در شاخص R، ۲۳/۴۳٪ کاهش در MSE و ۱۲/۴۰٪ کاهش در RMSE شده است.



شکل ۱۱ تخمین وضعیت شارژ با استفاده از روش پیشنهادی و LSTM با پروفایل جریان نشان داده شده در شکل ۵

Fig. 11 Estimation of the SoC using SP-SVR and LSTM with the current profile shown in Fig. 5

تقریب موجود در رگرسیون بردار پشتیبان را جبران کند. شایان ذکر است که بردار ۰ در هر دو روش رگرسیون بردار پشتیبان و رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری یکسان است، زیرا اعداد تصادفی استفاده شده برای مقدار اولیه در هر دو الگوریتم مشابه هستند. این امر به دلیل استفاده از تابع twister در کد متلب برای تولید اعداد تصادفی می باشد.

همان گونه که در جدول ۳ نشان داده شده است، روش پیشنهادی (با جبران خطای تقریب) در تمامی شاخص های ارزیابی عملکرد بهتری نسبت به رگرسیون بردار پشتیبان استاندارد (بدون جبران خطای تقریب) دارد. به طور مشخص، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتریک به میزان ۰/۵۲٪ بهبود در شاخص R، ۹۳/۸۲٪ کاهش در MSE و ۷۴/۷۷٪ کاهش در RMSE را به دست آورده است.

همان گونه که در جدول ۴ نشان داده شده است، روش پیشنهادی (با جبران خطای تقریب) در تمامی شاخص های ارزیابی عملکرد بهتری نسبت به رگرسیون بردار پشتیبان استاندارد (بدون جبران خطای تقریب) دارد. به طور مشخص، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری موجب ۰/۵٪ بهبود در شاخص R، ۳۳/۴۱٪ کاهش در MSE و ۱۵/۸۶٪ کاهش در RMSE شده است. همان گونه که در جدول ۵ نشان داده شده است، روش پیشنهادی (با جبران خطای تقریب) در تمامی شاخص های ارزیابی عملکرد

جدول ۳ شاخص های ارزیابی برای تخمین وضعیت شارژ باتری لیتیوم-یونی در پروفایل جریان پالسی (مطابق شکل ۵) با استفاده از روش های مختلف
Table 3 Evaluation metrics for estimation of the SOC for a Li-Ion battery in pulse current profile illustrated in Fig. 5 using different methods

Current profile	Estimation Method	Evaluation criteria		
		R	MSE ($\times 10^{-4}$)	RMSE
Pulse current (Fig. 5)	RBF	0.9992	1.628	0.0128
	MLP	0.9994	1.285	0.0113
	SVR	0.9944	11	0.0329
	SP-SVR	0.9996	0.68	0.0083

جدول ۴ شاخص های ارزیابی برای تخمین وضعیت شارژ باتری لیتیوم-یونی بر اساس پروفایل جریان نشان داده شده در شکل ۶ با استفاده از روش های مختلف
Table 4 Evaluation metrics for estimation of the SOC for a Li-Ion battery based on the current profile illustrated in Fig. 6 using different methods

Current profile	Estimation Method	Evaluation criteria		
		R	MSE ($\times 10^{-4}$)	RMSE
current profile illustrated in Fig. 6	RBF	0.9811	15	0.0391
	MLP	0.9955	4.9024	0.0221
	SVR	0.9977	2.1026	0.0145
	SP-SVR	0.9982	1.4	0.0122

جدول ۵ شاخص‌های ارزیابی برای تخمین وضعیت شارژ باتری لیتیوم-یونی بر اساس پروفایل جریان نشان داده شده در شکل ۷ با استفاده از روش‌های مختلف
Table 5 Evaluation metrics for estimation of the SOC for a Li-Ion battery based on the current profile illustrated in Fig. 7 using different methods

Current profile	Estimation Method	Evaluation criteria		
		R	MSE ($\times 10^{-4}$)	RMSE
Current profile illustrated in Fig. 7	RBF	0.9921	7.9163	0.0281
	MLP	0.9973	2.4266	0.0156
	SVR	0.9984	1.6629	0.0129
	SP-SVR	0.9987	1.2731	0.0113

هستند که برای مشخصه‌یابی عملکرد باتری‌ها، به‌ویژه در خودروهای برقی، مورد استفاده قرار می‌گیرند. رفتار جریان در شکل ۱۸ نشان داده شده است. همان‌طور که در این شکل مشاهده می‌شود، این آزمون شامل اعمال مجموعه‌ای از پالس‌های شارژ و دشارژ با اندازه‌های مختلف به باتری تحت شرایط کنترل شده است. شکل ۱۹ وضعیت شارژ متناظر را با استفاده از روش پیشنهادی نشان می‌دهد. بر اساس این شکل، روش پیشنهادی قادر است وضعیت شارژ باتری را در کاربردهای مرتبط با UDDS با دقت بالایی تخمین بزند.

از دیدگاه کمی، مقایسه‌ای میان روش پیشنهادی و سایر روش‌ها در جدول ۶ ارائه شده است. بر اساس این جدول، در پروفایل جریان دلخواه مربوط به شکل ۱۸، بالاترین میزان همبستگی به روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری اختصاص دارد که مقدار $R = 0.9998$ را به دست آورده است. در مورد دو شاخص ارزیابی دیگر نیز، کمترین مقادیر به روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری مربوط می‌شود، به‌طوری‌که $MSE = 1/1622 \times 10^{-4}$ و $RMSE = 0.0107$ به دست آمده است. در نتیجه، روش پیشنهادی در مقایسه با سایر روش‌ها دارای کمترین میزان خطا و بهترین عملکرد در تخمین وضعیت شارژ باتری است. همان‌گونه که در جدول ۶ نشان داده شده است، روش پیشنهادی (با جبران خطای تقریب) در تمامی شاخص‌های ارزیابی عملکرد بهتری نسبت به روش رگرسیون بردار پشتیبان استاندارد (بدون جبران خطای تقریب) دارد. به‌طور مشخص، روش رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری موجب ۱۵٪ بهبود در شاخص R ، ۵۴/۸۶٪ کاهش در MSE و ۳۳/۱۳٪ کاهش در $RMSE$ شده است.

همان‌گونه که برای جدول‌های ۳، ۴ و ۵ توضیح داده شد، در جدول ۶ نیز بردار θ در هر دو روش رگرسیون بردار پشتیبان و رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری یکسان است، زیرا اعداد تصادفی استفاده شده برای مقدار اولیه در هر دو الگوریتم مشابه هستند. این موضوع به دلیل به‌کارگیری تابع twister در کد متلب برای تولید اعداد تصادفی است.


در مدل پیشنهادی، اگرچه دما به‌صورت مستقیم به‌عنوان ورودی لحاظ نشده است، اما اثر آن به شکل غیرمستقیم در فرآیند یادگیری مدل وارد شده است. در باتری‌های لیتیومی، پارامترهای معادل مانند مقاومت‌ها و ظرفیت خازن‌ها تابعی از وضعیت شارژ (SOC) هستند و از آنجا که دما بر SOC و همچنین بر رفتار ولتاژ-جریان باتری تأثیر می‌گذارد، تغییرات دمایی عملاً در شکل سیگنال‌های جریان و ولتاژ منعکس می‌شود. از آنجا که ورودی مدل تنها شامل جریان و ولتاژ است، شبکه با تحلیل همین داده‌ها می‌تواند وابستگی غیرمستقیم پارامترهای باتری به دما را یاد بگیرد. بنابراین بدون استفاده از سنسور دما، اثرات حرارتی در داده‌ها حضور دارند و مدل توانسته است این تغییرات را در فرآیند تخمین SOC لحاظ کند.

۵- نتایج تجربی با استفاده از داده‌های NASA و UDDS

داده‌های آنلاین ارائه شده توسط سازمان ملی هوا فضا و تحقیقات فضایی آمریکا (NASA) [۳۹] بسیار شناخته شده و پرکاربرد هستند و بسیاری از پژوهشگران برای اعتبارسنجی نتایج خود در کاربردهای واقعی از این داده‌ها استفاده می‌کنند. به این ترتیب، در زمان لازم برای آزمایش باتری به‌طور قابل توجهی صرفه‌جویی می‌شود. برای نمونه، در [۴۰-۴۲] نیز از مجموعه داده‌های پیش‌بینی ناسا بهره گرفته شده است.


داده‌های اندازه‌گیری شده ولتاژ و جریان از مجموعه داده ناسا [۳۸] در الگوریتم رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری برای فرآیند تخمین وضعیت شارژ در محیط متلب وارد شده‌اند. پروفایل‌های جریان و ولتاژ در شکل‌های ۱۲، ۱۴ و ۱۶ ارائه شده‌اند و وضعیت‌های شارژ تخمینی با استفاده از روش پیشنهادی در شکل‌های ۱۳، ۱۵ و ۱۷ نشان داده شده است. همان‌طور که در این شکل‌ها مشاهده می‌شود، روش پیشنهادی قادر است وضعیت شارژ باتری را در کاربردهای واقعی با دقت بالایی تخمین بزند.

دقت و پایداری روش پیشنهادی با استفاده از پروفایل‌های جریان کاری مربوط به دوره رانندگی دینامومتری شهری (UDDS) مورد ارزیابی قرار گرفته است. این پروفایل‌ها روش‌های آزمایشگاهی




شکل ۱۳ مقایسه وضعیت شارژ تخمینی و واقعی با استفاده از داده‌های تجربی در شکل ۱۲

Fig.13 Comparison of estimated and actual SOC using the experimental data in Fig. 12




شکل ۱۲ پروفایل‌های جریان و ولتاژ داده‌های تجربی

Fig.12 Current and voltage profiles of the experimental data




شکل ۱۵ مقایسه وضعیت شارژ تخمینی و واقعی با استفاده از داده‌های تجربی در شکل ۱۴

Fig.15 Comparison of estimated and actual SOC using the experimental data in Fig. 14




شکل ۱۴ پروفایل‌های جریان و ولتاژ داده‌های تجربی

Fig.14 Current and voltage profiles of the experimental data




شکل ۱۷ مقایسه وضعیت شارژ تخمینی و واقعی با استفاده از داده‌های تجربی در شکل ۱۶

Fig.17 Comparison of estimated and actual SOC using the experimental data in Fig. 16




شکل ۱۶ پروفایل‌های جریان و ولتاژ داده‌های تجربی

Fig.16 Current and voltage profiles of the experimental data



شکل ۱۹ مقایسه وضعیت شارژ تخمینی و واقعی با استفاده از جریان باتری در شکل ۱۸

Fig.19 Comparison of estimated and actual SOC using the battery current in Fig. 18



شکل ۱۸ پروفایل جریان UDDS

Fig.18 UDDS current profile

جدول ۶ شاخص‌های ارزیابی برای تخمین وضعیت شارژ باتری لیتیوم-یونی بر اساس پروفایل جریان نشان داده شده در شکل ۱۸ با استفاده از روش‌های مختلف
Table 6 Evaluation metrics for estimation of the SOC for a Li-Ion battery based on the current profile illustrated in Fig. 18 using different methods

Current profile	Estimation Method	Evaluation criteria		
		R	MSE ($\times 10^{-4}$)	RMSE
Current profile illustrated in Fig. 18	RBF	0.9991	1.5051	0.0122
	MLP	0.9986	1.3258	0.0115
	SVR	0.9983	2.5638	0.0160
	SP-SVR	0.9998	1.1622	0.0107

روش پیشنهادی در تمامی شرایط جریان عملکرد بهتری نسبت به شبکه عصبی تابع پایه شعاعی، شبکه عصبی پرسپترون چند لایه و رگرسیون بردار پشتیبان معمولی نشان داد؛ ضریب همبستگی بالاتر (حدود 0.03% – 0.07% افزایش)، میانگین مربعات خطا کمتر (12% – 17% کاهش) و ریشه میانگین مربعات خطا پایین‌تر (7% – $26/5\%$ کاهش) همه گویای دقت، پایداری و قابلیت اطمینان بالاتر مدل در تخمین وضعیت شارژ باتری هستند.

برای کارهای آینده، پیشنهاد می‌شود که عدم قطعیت‌های ناشی از نوسانات در شیمی باتری، اثرات پیرشدگی از طریق طراحی قوانین سازگارکننده برای وزن‌ها جبران شوند. این وزن‌ها می‌توانند به صورت آنلاین و در کاربردهای بلادرنگ با استفاده از الگوریتم‌های تطبیقی مانند کمترین مربعات بازگشتی یا گرادینت کاهشی به‌روزرسانی شوند.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیرایرانی منتشر نشده است.

تعارض منافع: تعارض منافعی برای اظهار وجود ندارد.

این امر به روشنی برتری روش پیشنهادی را نسبت به رگرسیون بردار پشتیبان نشان می‌دهد، چرا که مدل نیمه‌پارامتری به‌کاررفته در رگرسیون بردار پشتیبان مبتنی بر مدل نیمه پارامتری با جبران خطای بازسازی یا تقریب، موجب بهبود دقت و عملکرد روش پیشنهادی شده است.

۶- نتیجه‌گیری

در این مقاله، تخمین وضعیت شارژ برای یک باتری لیتیوم-یونی نوع ۱۸۶۵۰ مورد بررسی قرار گرفت. نوآوری اصلی روش پیشنهادی، ترکیب مدل رگرسیون بردار پشتیبان کلاسیک با مدل رگرسیون نیمه‌پارامتری است. در نتیجه، مدل پیشنهادی در مقایسه با رگرسیون بردار پشتیبان معمولی از انعطاف‌پذیری بالاتری برخوردار است، چرا که امکان پیش‌بینی دقیق‌تر داده‌های بحرانی را فراهم می‌سازد. کرنل‌های مورد استفاده در تبدیل داده‌ها و همچنین در مدل نیمه‌پارامتری، کرنل‌های ساده‌ای همچون کرنل گوسی هستند. همچنین، روش پیشنهادی با موفقیت با استفاده از داده‌های تجربی موجود در پایگاه اینترنتی مرکز پیش‌آگاهی ناسا و پروفایل رانندگی آزمایشگاهی شهری مورد آزمون قرار گرفت. به طور کلی،

- [8] N. Tian, Y. Wang, J. Chen, H. Fang, "One-shot parameter identification of the Thevenin's model for batteries: Methods and validation," *Journal of Energy Storage*, Vol. 29, p. 101282, 2020.
doi:10.1016/j.est.2020.101282
- [9] Y. Jiang, J. Zhang, L. Xia, Y. Liu, "State of health estimation for lithium-ion battery using empirical degradation and error compensation models," *IEEE Access*, Vol. 8, pp. 123858-123868, 2020.
doi:10.1109/ACCESS.2020.3005229
- [10] K. A. Severson, P. M. Attia, N. Jin, N. Perkins, B. Jiang, Z. Yang, R. D. Braatz, "Data-driven prediction of battery cycle life before capacity degradation," *Nature Energy*, Vol. 4 no. 5, pp. 383-391, 2019.
doi:10.1038/s41560-019-0356-8
- [11] J. Wang, Z. Deng, T. Yu, A. Yoshida, L. Xu, G. Guan, A. Abudula, "State of health estimation based on modified Gaussian process regression for lithium-ion batteries," *Journal of Energy Storage*, Vol. 51, p. 104512, 2022.
doi:10.1016/j.est.2022.104512
- [12] L. Zhang, K. Li, D. Du, C. Zhu, M. Zheng, "A sparse least squares support vector machine used for SOC estimation of Li-ion Batteries," *IFAC-PapersOnLine*, Vol. 52, no. 11, pp. 256-261, 2019.
doi:10.1016/j.ifacol.2019.09.150
- [13] S. Jumah, A. Elezab, O. Zayed, R. Ahmed, M. Narimani, A. Emadi, "State of Charge Estimation for EV Batteries Using Support Vector Regression," In 2022 IEEE Transportation Electrification Conference & Expo (ITEC), pp.964-969, 2022.
doi:10.1109/ITEC53557.2022.9813811
- [14] S. Zhu, N. Zhao, J. Sha, "Predicting battery life with early cyclic data by machine learning," *Energy Storage*, Vol. 1, no. 6, e98, 2019.
doi:10.1002/est2.98
- [15] L. Song, K. Zhang, T. Liang, X. Han, Y. Zhang, "Intelligent state of health estimation for lithium-ion battery pack based on big data analysis," *Journal of Energy Storage*, Vol. 32, p. 101836, 2020.
doi:10.1016/j.est.2020.101836
- [16] C. W. Hsu, R. Xiong, N. Y. Chen, J. Li, N. T. Tsou, "Deep neural network battery life and voltage prediction by using data of one cycle only," *Applied Energy*, Vol. 306, p. 118134, 2022.
- [1] T. M. B. Marques, J. L. F. dos Santos, D. S. Castanho, M. B. Ferreira, S. L. Stevan Jr, C. H. Illa Font, T. Antonini Alves, C. M. Piekarski, H. V. Siqueira, and F. C. Corrêa, "An Overview of Methods and Technologies for Estimating Battery State of Charge in Electric Vehicles," *Energies*, vol. 16, no. 13, p. 5050, 2023. doi:10.3390/en16135050
- [2] P. Saechan, and I. Dhuchakallaya, "Numerical Study on the Air-Cooled Thermal Management of Lithium-Ion Battery Pack for Electrical Vehicles," *Energy Reports*, vol. 8, pp.1264-1270, 2022.
doi:10.1016/j.egyr.2021.11.089
- [3] M. S. Chitnis, S. P. Pandit, and M. N. Shaikh, "Electric Vehicle Li-Ion Battery State of Charge Estimation Using Artificial Neural Network," In 2018 International Conference on Inventive Research in Computing Applications (ICIRCA), IEEE, pp. 992-995, 2018. doi:10.1109/ICIRCA.2018.8597234
- [4] S. Ceven, and R. Bayır, "Implementation of Hardware-in-the-Loop Based Platform for Real-Time Battery State of Charge Estimation on Li-Ion Batteries of Electric Vehicles Using Multilayer Perceptron," *Int. J. Intell. Syst. Appl. Eng.*, vol. 8, no. 4, pp. 195-205, 2020.
doi:10.18201/ijisae.2020466313
- [5] M. S. Hossain Lipu, M. A. Hannan, A. Hussain, M. H. Saad, A. Ayob, and M. N. Uddin, "Extreme Learning Machine Model for State-of-Charge Estimation of Lithium-Ion Battery Using Gravitational Search Algorithm," *IEEE Transactions on Industry Applications*, vol. 55, no. 4, pp. 4225-4234, 2019. doi:10.1109/tia.2019.2902532
- [6] K. Luo, X. Chen, H. Zheng, Z. Shi, "A review of deep learning approach to predicting the state of health and state of charge of lithium-ion batteries," *Journal of Energy Chemistry*. Vol. 74, pp. 159-173, 2022.
doi:10.1016/j.jechem.2022.06.049
- [7] J. Kuchly, A. Goussian, M. Merveillaut, I. Baghdadi, S. Franger, D. Nelson-Gruel, C. Nouillant, and Y. Chamaillard, "Li-ion battery SOC estimation method using a Neural Network trained with data generated by a P2D model," *IFAC-PapersOnLine*, vol. 54, no. 10, pp. 336-343, 2021.
doi:10.1016/j.ifacol.2021.10.185

- [25] A. Harinarayanan and R. Balamurugan, "Deep learning based state of charge estimation of lithiumion battery for electric vehicle application," Discover Internet of Things, 2025, doi: 10.1007/s43926-025-00148-y
- [26] F. G. Guo, L. Shui, X. Lan Wu, B. Gang Cao, "SOC Estimation for Li-Ion Battery Using SVM Based on Particle Swarm Optimization," Advanced Materials Research, Vol. 1051, pp. 1004-1008, 2014. doi:10.4028/www.scientific.net/AMR.1051.1004
- [27] X. Wu, L. Mi, W. Tan, J. L. Qin, M. N. Zhao, "State of charge (SOC) estimation of ni-mh battery based on least square support vector machines," Advanced Materials Research, Vol. 211, pp. 1204-1209, 2011. doi:10.4028/www.scientific.net/AMR.211-1204
- [28] G. Gruosso, G. S. Gajani, J. D. Valladolid, D. Patino, F. Ruiz, "State of charge estimation of lifepo4 battery used in electric vehicles using support vector regression, PCA and DP battery model," In 2019 IEEE vehicle power and propulsion conference (VPPC), pp.1-5, 2019. doi:10.1109/VPPC46532.2019.8952458
- [29] A. Harinarayanan and R. Balamurugan, "Advanced Techniques for Estimating State of Charge (SoC) in Lithium-Ion Batteries," J. Energy Storage, vol. 45, 2025. doi:10.21608/astj.2025.391150.1065
- [30] C. G. Manriquez-Padilla, I. Cueva-Perez, A. Dominguez-Gonzalez, D. A. Elvira-Ortiz, A. Perez-Cruz, J. J. Saucedo-Dorantes, "State of Charge Estimation Model Based on Genetic Algorithms and Multivariate Linear Regression with Applications in Electric Vehicles," Sensors, Vol. 23, no. 6, p. 2924 2023. doi:10.3390/s23062924
- [31] S. Khorashadizadeh, M. Sadeghijaleh, "Adaptive fuzzy tracking control of robot manipulators actuated by permanent magnet synchronous motors," Computers & Electrical Engineering, Vol. 72, pp. 100-111, 2018. doi:10.1016/j.compeleceng.2018.09.010
- [32] S. Khorashadizadeh, M. M. Fateh, "Uncertainty estimation in robust tracking control of robot manipulators using the Fourier series expansion," Robotica, Vol. 35, no. 2, pp. 310-336, 2017. doi:10.1017/S026357471500051X
- [33] M. Samimi, M. H. Majidi, S. Khorashadizadeh, "Secure communication doi:10.1016/j.apenergy.2021.118134
- [17] C. Qian, B. Xu, L. Chang, B. Sun, Q. Feng, D. Yang, Z. Wang, "Convolutional neural network based capacity estimation using random segments of the charging curves for lithium-ion batteries," Energy, Vol. 227, p. 120333, 2021. doi:10.1016/j.energy.2021.120333
- [18] N. Yang, Z. Song, H. Hofmann, J. Sun, Robust "State of Health estimation of lithium-ion batteries using convolutional neural network and random forest," Journal of Energy Storage, Vol. 48, p. 103857, 2022. doi:10.1016/j.est.2021.103857
- [19] C. Bian, S. Yang, J. Liu, E. Zio, "Robust state-of-charge estimation of Li-ion batteries based on multichannel convolutional and bidirectional recurrent neural networks," Applied Soft Computing, Vol. 116, p. 108401, 2022. doi:10.1016/j.asoc.2021.108401
- [20] F. Heinrich, M. Pruckner, "Virtual experiments for battery state of health estimation based on neural networks and in-vehicle data," Journal of Energy Storage, Vol. 48, p. 103856, 2022. doi:10.1016/j.est.2021.103856
- [21] J. Chen, X. Feng, L. Jiang, Q. Zhu, "State of charge estimation of lithium-ion battery using denoising autoencoder and gated recurrent unit recurrent neural network," Energy, Vol. 227, p. 120451, 2021. doi:10.1016/j.energy.2021.120451
- [22] H. Xu, J. Ma, P. Tan, B. Chen, Z. Wu, Y. Zhang, H. Wang, J. Xuan, M. Ni, "Towards online optimisation of solid oxide fuel cell performance: Combining deep learning with multi-physics simulation," Energy and AI, Vol. 1, p. 100003, 2020. doi:10.1016/j.egyai.2020.100003
- [23] J. Alvarez Anton, P. Garcia Nieto, F. de Cos J uez, F. Sanchez Lasheras, M. Gonzalez Vega, M. Roqu eni Gutierrez, "Battery state-of-charge estimator using the SVM technique," Applied Mathematical Modelling, Vol. 37, no. 9, pp. 6244-6253, 2013. doi:10.1016/j.apm.2013.01.024
- [24] J. C. Alvarez Anton, P. J. Garcia Nieto, C. Blanco Viejo, J. A. Vilan, "Support vector machines used to estimate the battery state of charge," IEEE Transactions on power electronics, Vol. 28, no. 12, pp. 5919-5926, 2013. doi:10.1109/TPEL.2013.2243918

- Mechanical Engineering, vol. 19, no. 1, pp. 43-52, 2019.
 dor:20.1001.1.10275940.1397.19.1.11.1
- [38] S. Hochreiter, J. Schmidhuber, "Long short-term memory," *Neural computation*, Vol. 9, no. 8, pp. 1735-1780, 1997.
 doi:10.1162/neco.1997.9.8.1735
- [39] B. Saha, K. Goebel, "Battery Data Set," NASA Prognostics Data Repository, NASA Ames Research Center, Moffett Field, CA, 2007.
- [40] A. Maheshwari, S. Nageswari, "Real-time state of charge estimation for electric vehicle power batteries using optimized filter," *Energy*, Vol. 254, p. 124328, 2022.
 doi:10.1016/j.energy.2022.124328
- [41] Y. Boujoudar, H. Elmoussaoui, T. Lamhamdi, "Lithium-ion batteries modeling and state of charge estimation using artificial neural network," *International Journal of Electrical and Computer Engineering*, Vol. 9, no. 5, p. 3415, 2019. doi:10.11591/ijece.v9i5.pp3415-3422
- [42] S. Jo, S. Jung, T. Roh, "Battery State-of-Health Estimation Using Machine Learning and Preprocessing with Relative State-of-Charge," *Energies*, Vol. 14, no. 21, p. 7206, 2021. doi:10.3390/en1421720
- based on chaos synchronization using brain emotional learning," *AEU-International Journal of Electronics and Communications*, Vol. 127, p. 153424, 2020.
 doi:10.1016/j.aeue.2020.153424
- [34] H. Drucker, C. J. Burge, L. Kaufman, A. Smola, V. Vapnik, "Support Vector Regression Machines," *Advances in neural information processing systems*, Vol. 9, 1996.
<https://proceedings.neurips.cc/paper/1996/hash/d38901788c533e8286cb6400b40b386d-Abstract.html>
- [35] M. Gh. Akbari, Saeed Khorashadizadeh, M. H. Majidi, "Support vector machine classification using semi-parametric model," *Soft Computing*, vol. 25, pp. 10040-10062, 2022.
 doi:10.1007/s00500-022-07376-2
- [36] M. Chen, G. A. Rincon-Mora, "Accurate electrical battery model capable of predicting runtime and I-V performance," *IEEE transactions on energy conversion*, Vol. 21, no. 2, pp. 504-511, 2006.
 doi:10.1109/TEC.2006.874229
- [37] M. Nouri Khajavi, Gh. R. Bayat, "Comparison of Li-Ion Battery State of Charge Prediction by Artificial Neural Network and Adaptive Neuro Fuzzy Inference System," *Modares*