

KNO-1102-4407

## تخمین وضعیت شارژ باتری لیتیوم یونی در وسایل نقلیه الکتریکی با استفاده از مدل یادگیری عمیق

محمود مقدسیان، m.moghadasian@scu.ac.ir

استادیار پردیس صنعتی شهدای هویزه، دانشگاه شهید چمران اهواز، سوسنگرد، ایران

### چکیده

در این مطالعه یک روش مبتنی بر داده برای تخمین وضعیت شارژ باتری‌های لیتیوم یونی پیشنهاد شده است تا محدودیت‌های رویکردهای مرسوم مبتنی بر مدل را که به پارامترهای دقیق نیاز دارند، برطرف کند. عملکرد مدل پیشنهادی با استفاده از برآورد دقت تخمین وضعیت شارژ (SOC) باتری در هر محیط اندازه‌گیری می‌گردد. در نتیجه، روش پیشنهادی دقت تخمین بالایی (میانگین خطای مطلق کمتر از ۴ درصد) را در طیف وسیعی از دمای رانندگی (۰ تا ۲۵ درجه سانتیگراد) تنها با داده‌های رانندگی محدود نشان می‌دهد.

**کلید واژه‌ها:** باتری لیتیوم یونی، شبکه‌های عصبی مصنوعی، وضعیت شارژ، یادگیری عمیق.

### ۱. مقدمه

با هدف غلبه بر بحران آب و هوایی، یک جنبش جهانی با رویکرد تولید کربن صفر در حال گسترش است. وسایل نقلیه الکتریکی به عنوان یک انتخاب مهم در این جنبش ظاهر شده‌اند، زیرا به جای موتورهای احتراق داخلی سنتی به باتری متکی هستند [۱-۲]. همانطور که اهمیت باتری‌ها برای تامین انرژی خودروها افزایش یافته است، اهمیت سیستم‌های مدیریت باتری برای تخمین و نظارت بر وضعیت شارژ باتری، عمر و ایمنی نیز افزایش یافته است. با این حال، ماهیت الکتروشیمیایی پیچیده باتری‌های لیتیوم یونی، اندازه‌گیری دقیق پارامترهای داخلی آنها را دشوار می‌کند. تخمین دقیق وضعیت شارژ<sup>۱</sup> (SOC) باتری، وظیفه حیاتی سیستم مدیریت باتری (BMS) است. SOC نشان دهنده سطح شارژ فعلی باتری است که بصورت ظرفیت موجود نسبت به ظرفیت کاملاً شارژ شده آن بیان می‌شود. تخمین دقیق و کارآمد SOC برای ارزیابی انرژی موجود و بهینه‌سازی استراتژی‌های شارژ و دشارژ ضروری است. بطور خاص، تخمین SOC سلول‌های منفرد باتری برای تعیین محدوده رانندگی باقیمانده و متعادل کردن بسته باتری<sup>۱</sup> بسیار مهم است [۳-۵].

<sup>۱</sup>state of charge

<sup>۲</sup>battery management systems

<sup>۳</sup>battery pack

بر اساس پژوهش‌ها، تاکنون روش‌های متعددی برای تخمین SOC پیشنهاد شده است که به چهار رویکرد اصلی قابل تفکیک است. اولین مورد، روش شمارش کولن است که SOC را با جمع کردن جریان در طول زمان و کم کردن آن از ظرفیت باتری از پیش تعریف شده محاسبه می‌کند. با این حال، این روش مستعد خطا است، به ویژه زمانی که باتری به طور کامل شارژ یا دشارژ نشده باشد، که منجر به خطاهای قابل توجهی می‌شود [۶]. روش دوم بر همبستگی بین ولتاژ مدار باز (OCV) و SOC متکی است و در آن برای تخمین SOC از داده‌های OCV استفاده می‌شود. با این حال، OCV را فقط می‌توان در شرایط تعادل اندازه‌گیری کرد که چالش‌هایی را برای کاربردهای زمان واقعی ایجاد می‌کند [۷]. روش سوم از رویکردهای مبتنی بر مدل استفاده می‌کند، مانند تخمین SOC از طریق مدل‌های مدار یا الکتروشیمیایی مانند مدل‌های دوپل-فولر-نیومن و تک ذره‌ای. در حالی که مدل‌های الکتروشیمیایی یک چارچوب قوی از نظر تئوری ارائه می‌دهند، پیچیدگی محاسباتی آنها را برای کاربردهای زمان واقعی غیرعملی می‌کند. برعکس، اگرچه مدل‌های مدار معادل پیچیدگی کمتری دارند، اما در ثبت دقیق اثرات پیری و حساسیت دما محدود هستند [۸]. روش چهارم و نهایی، روش مبتنی بر داده است که برای تخمین SOC به داده‌های اندازه‌گیری متکی است. شبکه‌های عصبی مصنوعی اخیراً برای استفاده در این روش محبوبیت پیدا کرده‌اند. با این حال، نتایج بدست آمده از این روش اغلب در مجموعه داده‌های به اندازه کافی بزرگ قابل اعتماد هستند [۹].

مطالعات متعددی برای حل مشکل انباشت خطای روش شمارش کولن انجام شده است، از جمله روشی برای کالیبره کردن SOC اولیه و ظرفیت واقعی بر اساس تجزیه و تحلیل ظرفیت افزایشی و رگرسیون فرآیند گاوسی [۱۰] و همچنین کالیبره کردن خطای انباشته شده با استفاده از مشتق ظرفیت (dQ/dV) و مشتق ولتاژ (dV/dQ) [۱۱]. از آنجایی که اعمال روش مبتنی بر OCV در یک محیط داینامیک دشوار است، به طور کلی از فیلتر کالمن یا یک مدل مدار معادل بدین منظور استفاده می‌شود. مطالعات قبلی OCV را با اعمال یک الگوریتم کنترل ماتریس دینامیکی جدید و فیلتر کالمن توسعه یافته تخمین زده‌اند و تلاش کردند از الگوریتم فیلتر H-infinity استفاده کنند [۱۲].

پژوهش‌هایی نیز بر روی روش‌های مبتنی بر داده با استفاده از مدل یادگیری عمیق مبتنی بر شبکه‌های عصبی بازگشتی انجام شده است. علاوه بر این، بر اساس ساختارهای بازگشتی<sup>۳</sup> (RNN)، حافظه بلندمدت-کوتاهمدت<sup>۴</sup> (LSTM) و واحد بازگشتی گیت‌دار<sup>۵</sup> (GRU) مطالعاتی برای تخمین SOC با استفاده از داده‌های ولتاژ، جریان و دما انجام شده است [۱۳-۱۴] و آنها عملکرد تخمین با دقت بالا را گزارش کرده‌اند. همچنین تلاش‌هایی برای توسعه ساختارهای شبکه عصبی جدید مناسب برای تخمین یا ترکیب شبکه‌های عصبی با فیلترهای کالمن برای بهبود عملکرد تخمین انجام شده است [۱۵].

<sup>۱</sup>open-circuit voltage

<sup>۲</sup>recurrent neural network

<sup>۳</sup>long short-term memory

<sup>۴</sup>gate recursive unit

ww.kahrobaonline.ir



هدف از این مطالعه توسعه یک مدل مبتنی بر داده است که SOC را در موقعیت‌های با داده‌های دمایی مختلف با کمترین خطا پیش‌بینی کند. در ادامه، این مقاله به شرح زیر سازماندهی شده است: در بخش ۲، مجموعه داده مورد مطالعه، مدل یادگیری عمیق و نحوه اعمال داده‌ها بر مدل پیشنهادی شرح داده شده است. در بخش ۳، نتایج بدست آمده از الگوریتم بکار گرفته شده از ارایه شده و در نهایت در بخش ۴ نتیجه‌گیری بیان شده است.

## ۲. روش پیشنهادی

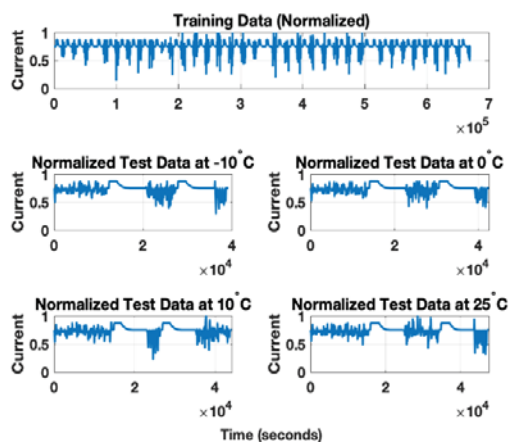
### ۱.۲. مجموعه داده مورد مطالعه

در این مطالعه از مجموعه داده باتری لیتیوم یونی Panasonic NCR18650PF استفاده شده و مشخصات باتری و اطلاعات مربوط به مجموعه داده در جدول ۱ ارائه شده است. آزمایش‌های سیکل رانندگی برای این داده‌ها در دانشگاه ویسکانسین مدیسون انجام شده است. داده‌های مورد استفاده در این مطالعه به دو قسمت داده‌های آموزش (۶۷۰۲ نمونه) و آزمایش (۱۷۳۸ نمونه) تقسیم‌بندی شده‌اند. داده‌های آزمایش شامل داده‌های دمایی ۱۰- درجه سانتیگراد (۳۹۳ نمونه)، ۰ درجه سانتیگراد (۴۲۶ نمونه)، ۱۰ درجه سانتیگراد (۴۴۳ نمونه) و ۲۵ درجه سانتیگراد (۴۷۶ نمونه) می‌باشند.

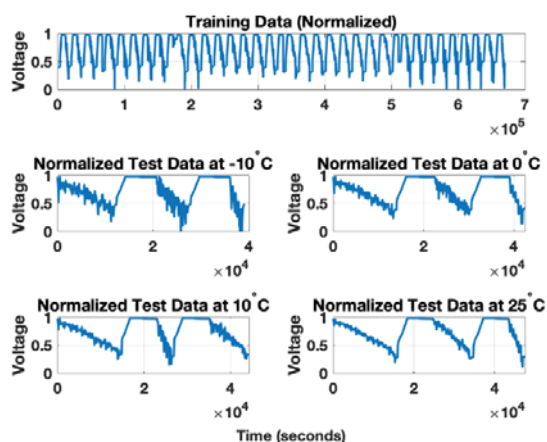
همانطور که در شکل ۱ (الف) تا (ث) قابل مشاهده است، داده‌های ورودی به شبکه به ترتیب شامل ولتاژ، جریان، دما، ولتاژ متوسط و جریان متوسط می‌باشند. همه داده‌های ورودی در بازه [۰ ۱] نرمال‌سازی شده‌اند. شکل ۱ (ج) نیز خروجی مدل یادگیری عمیق، یعنی SOC را نشان می‌دهد.

جدول ۱. مشخصات باتری لیتیوم یونی Panasonic NCR18650PF

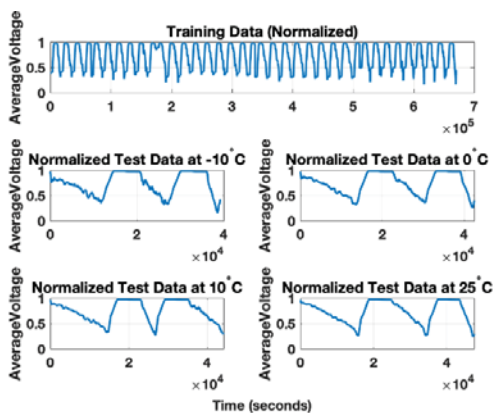
ویژگی	مقدار	ویژگی	مقدار
ولتاژ نامی مدار باز	۳/۶ ولت	نسبت جرم به ذخیره انرژی	۴۸ گرم بر ۹/۹ وات ساعت
ظرفیت	کمینه ۲/۷۵ و نامی ۲/۹ آمپر ساعت	دمای شارژ کمینه	۱۰ درجه سانتیگراد
ولتاژ کمینه و بیشینه	۲/۵ ولت / ۴/۲ ولت	دوره مورد نیاز تا رسیدن به ظرفیت ۸۰٪	۵۰۰



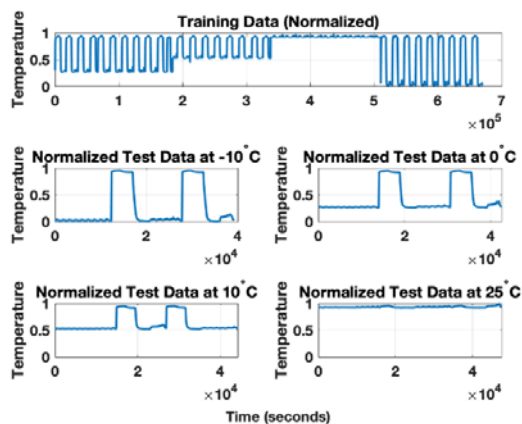
(ب) جریان (ورودی)



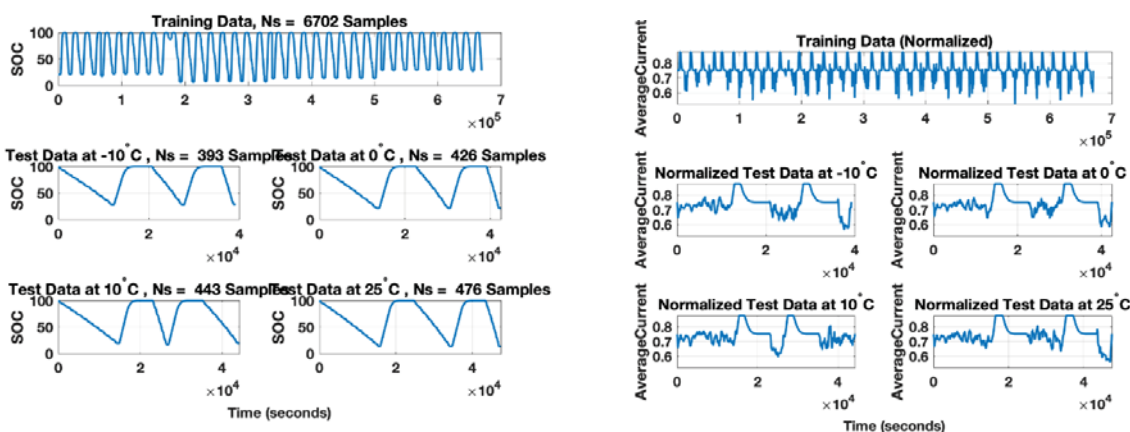
(الف) ولتاژ (ورودی)



(ت) متوسط ولتاژ (ورودی)



(پ) دما (ورودی)



(ج) SOC (خروجی)

(ث) متوسط جریان ورودی

شکل ۱. ورودی‌ها و خروجی مدل یادگیری عمیق (داده‌های آموزش و آزمایش)

## ۲.۲. مدل یادگیری عمیق

بعلت ساختار مناسب و توانایی تخمین داده‌ها، معمولا از ساختارهای بازگشتی (RNN)، حافظه بلندمدت-کوتاهمدت (LSTM) و واحد بازگشتی گیت‌دار (GRU) به عنوان مدل‌های یادگیری عمیق برای حل مسایل کلاسه‌بندی و بررسی آماری ارتباط بین دو یا چند متغیر (رگرسیون) استفاده می‌شود. RNN ها از حالت‌های مخفی برای انتقال اطلاعات از یک نقطه زمانی به نقطه دیگر استفاده می‌کنند. LSTM دارای حالت‌های سلولی است که حافظه بلندمدت را برای جبران نقص RNN ها در فراموش کردن ویژگی‌های بلندمدت حفظ می‌کند. GRU برای تکمیل LSTM طراحی شده است که به حافظه قابل توجهی نیاز دارد. GRU شامل دو گیت بدون واحد سلولی جداگانه است. بنابراین پارامترهای کمتر و سرعت آموزش سریع‌تری دارد. ورودی‌های مدل مبتنی بر داده، مقادیر جریان، ولتاژ و دما هستند و داده‌ی خروجی SOC است. در این مقاله از شبکه LSTM برای تخمین SOC استفاده شده است.

شبکه LSTM شامل سه بخش اساسی است: گیت فراموشی، گیت ورودی و گیت خروجی که در شکل ۲ نشان داده شده و فرمول بروزرسانی وزن‌های آن نیز به قرار زیر است:

$$f_t = \sigma(w_f \times h_{(t-1)} + w_f \times x_t + b_f) \quad (۱)$$

$$i_t = \sigma(w_i \times h_{(t-1)} + w_i \times x_t + b_i) \quad (۲)$$

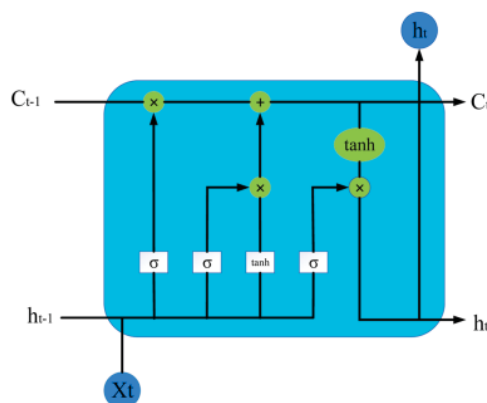
$$o_t = \sigma(w_o \times h_{(t-1)} + w_o \times x_t + b_o) \quad (۳)$$

$$C_t = \tanh(w_c \times h_{(t-1)} + w_c \times x_t + b_c) \quad (۴)$$

$$c_t = f_t \times c_{(t-1)} + i_t \times C_t \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

که در آن  $x_t$  داده در لحظه فعلی،  $c_{(t-1)}$  وضعیت سلول در لحظه قبل،  $c_t$  وضعیت سلول در لحظه فعلی؛  $C_t$  اطلاعات ورودی در لحظه فعلی و  $h_t$  خروجی در لحظه فعلی است.



شکل ۲. ساختمان شبکه LSTM

در شکل ۲،  $h_t$  در پایین نشان دهنده خروجی حالت پنهان در گام زمانی فعلی است که عمدتاً برای انتقال اطلاعات به گام زمانی بعدی ( $t+1$ ) استفاده می‌شود و تضمین می‌کند که LSTM وابستگی‌های بین گام‌های زمانی را ثبت و منتقل می‌کند.  $h_t$  در داخل پس زمینه آبی در بالا نیز نشان دهنده خروجی حالت پنهان در گام زمانی فعلی است و به عنوان پارامتر مهمی در خروجی نهایی مدل تاثیرگذار است که معمولاً به لایه‌های شبکه عصبی بعدی یا لایه‌های خروجی متصل می‌شود.

### ۳.۲. اعمال مدل یادگیری عمیق به داده‌های SOC

اطلاعات تکمیلی شبکه LSTM بکار گرفته شده در این مقاله در جدول ۲ آورده شده است.

جدول ۲. مشخصات شبکه عصبی LSTM

ویژگی	مقدار	ویژگی	مقدار
تعداد واحدهای پنهان	۲۰۰	حداکثر تعداد تکرار داده‌ها (epoch)	۵۰
تعداد واحدهای کاملاً متصل	۵۰	کمترین تعداد داده در هر تکرار	۲۰
احتمال حذف عناصر ورودی	۰/۵	نرخ یادگیری اولیه	۰/۱

از آنجایی که SOC مقداری در بازه [۰ ۱] دارد، بدون تغییر است، در حالی که مقادیر جریان، ولتاژ و دما با استفاده از نرمال‌سازی min-max مطلق با استفاده از معادله (۱) نرمال‌سازی می‌شوند:

$$X_{norm} = \frac{x}{|X_{max}|} \quad (7)$$

که در آن  $X_{max}$  مقدار بیشینه،  $x$  مقدار اولیه و  $X_{norm}$  مقدار نرمال سازی متغیر در بازه  $[0, 1]$  می باشد.


### ۳. نتایج شبیه سازی

همانطور که پیشتر اشاره شد، مدل یادگیری عمیق پیشنهادی ابتدا با ۵ ورودی شامل ولتاژ، جریان، دما، متوسط ولتاژ و متوسط جریان، برای تخمین SOC باتری آموزش می بیند و سپس داده های آزمایش به آن اعمال می شود. شماتیک این سیستم در شکل ۳ نشان داده شده است.



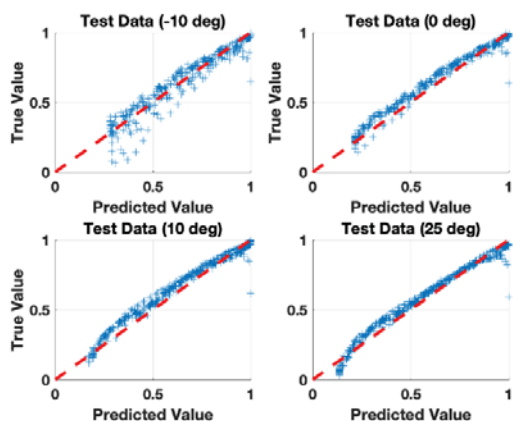
شکل ۳. شماتیک سیستم پیشنهادی برای تخمین SOC

نمودار آموزش شبکه LSTM در شکل ۴ آورده شده است. همانطور که ملاحظه می شود، در این شکل خطای RSME و تابع ضرر داده های آموزش با ادامه روند آموزش و افزایش تکرار تا ۵۰ مرتبه در حال کاهش است.

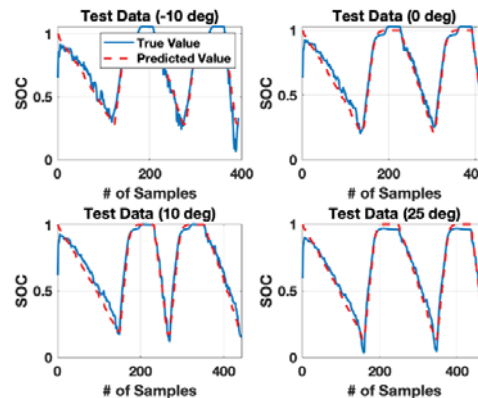


شکل ۴. نمودار آموزش شبکه LSTM

شکل ۵ نمودارهای خروجی داده های تست را در ۴ دمای مختلف کاری باتری نشان می دهد. شکل ۵ (الف) داده های واقعی و تخمین زده شده توسط شبکه LSTM بر حسب شماره نمونه و شکل ۵ (ب) این داده ها را بر حسب یکدیگر نشان می دهد. در صورت عملکرد بدون خطای شبکه LSTM، این داده ها می بایست روی خط  $x = y$  در صفحه که با رنگ قرمز نشان داده شده است می افتادند.



(ب) داده‌های واقعی بر حسب خروجی تخمینی



(الف) داده‌های واقعی و تخمینی بر حسب شماره نمونه

شکل ۵. نمودار داده‌های آزمایش در دماهای مختلف

همانگونه که این نمودارها مشخص است، فرایند تخمین داده‌های SOC با دقت نسبتاً خوبی انجام گرفته است. برای ارزیابی بهتر عملکرد الگوریتم پیشنهادی، این مقاله از معیارهای ارزیابی رایج استفاده می‌کند. این شاخص‌ها شامل میانگین خطای مطلق (MAE)<sup>۱</sup>، میانگین درصد مطلق خطا<sup>۲</sup> (MAPE)، میانگین مربعات خطا<sup>۳</sup> (MSE) و ریشه میانگین مربعات خطا<sup>۴</sup> (RMSE) می‌باشد که به صورت زیر تعریف شده است:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_{true} - y_{pre}| \quad (۸)$$

$$MAPE = \left( \frac{1}{N} \sum_{i=1}^N |y_{true} - y_{pre}| \right) \times 100\% / y_{true} \quad (۹)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_{true} - y_{pre})^2 \quad (۱۰)$$

$$RMSE = \sqrt{MSE} \quad (۱۱)$$

در این معادلات،  $y_{true}$  نشان دهنده مقدار خروجی واقعی مجموعه تست،  $y_{pre}$  نشان دهنده مقدار خروجی تخمین زده شده توسط مدل یادگیری عمیق و  $(N)$  نشان دهنده تعداد نمونه‌ها در مجموعه تست است. نتایج اعمال الگوریتم پیشنهادی بر داده‌های آزمایش در دماهای مختلف با محاسبه روابط (۸) - (۱۱) در شکل ۶ و جدول ۳ نشان داده شده است. مقادیر کمینه این پارامترها نیز بر روی شکل

<sup>۱</sup>mean absolute error

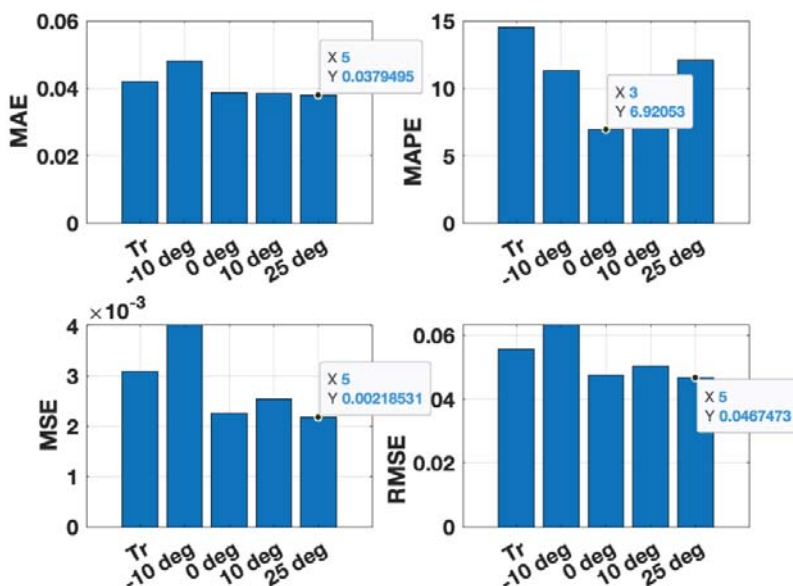
<sup>۲</sup>mean absolute percentage error

<sup>۳</sup>mean square error

<sup>۴</sup>root mean square error



مشخص شده است. با توجه به جدول ۳، کمترین مقدار MAE، MSE و RMSE مربوط به مجموعه داده SOC در دمای ۲۵ درجه سانتیگراد است. همچنین انتظار می‌رفت که مقادیر خطای مجموعه داده آموزش کمتر از مجموعه داده‌های آزمایش باشد، لیکن دلیل این عدم تطابق، تعداد زیاد داده‌های مجموعه آموزش (بیش از ۱۵ برابر) و ماهیت غیرخطی مدل تخمین SOC می‌باشد.



شکل ۶. نمودار انواع پارامترهای ارزیابی خطای داده‌های آزمایش در دماهای مختلف

جدول ۳. خطاهای شبکه عصبی LSTM در مجموعه داده‌های مختلف

مجموعه داده	MAE	MAPE	MSE	RMSE
آموزش	۰/۰۴۱۹	۱۴/۵۳۰۸	۰/۰۰۳۱	۰/۰۵۵۶
آزمایش (۱۰- درجه)	۰/۰۴۸۲	۱۱/۲۹۱۷	۰/۰۰۴۰	۰/۰۶۳۴
آزمایش (۰- درجه)	۰/۰۳۸۷	۶/۹۲۰۵	۰/۰۰۲۳	۰/۰۴۷۴
آزمایش (۱۰- درجه)	۰/۰۳۸۳	۷/۳۴۱۳	۰/۰۰۲۵	۰/۰۵۰۵
آزمایش (۲۵- درجه)	۰/۰۳۷۹	۱۲/۰۹۶۲	۰/۰۰۲۲	۰/۰۴۶۷

#### ۴. نتیجه‌گیری

در این مطالعه، یک روش مبتنی بر داده برای تخمین دقیق SOC با استفاده از مدل یادگیری عمیق ارائه شد. این مدل قادر است SOC را به طور قابل اعتمادی با خطای RMSE حدود ۴ درصد به طور متوسط در شرایط دمایی بالای ۰ درجه سانتیگراد تخمین بزند. در این مدل برای تخمین SOC، داده‌های ولتاژ، جریان و دما به عنوان ورودی به شبکه LSTM ارائه می‌گردد و شبکه با این داده‌ها آموزش می‌بیند. برای ارزیابی عملکرد مدل، MAE، MAPE، MSE و RMSE داده‌های آزمایش در دماهای مختلف با یکدیگر مقایسه گردید

و نشان داده شد روش پیشنهادی در دمای ۲۵ درجه سانتیگراد بهترین عملکرد را نشان می‌دهد. بعنوان موضوعی برای تحقیقات آتی، می‌توان این مدل مبتنی بر داده را با دیگر الگوریتم‌های مبتنی بر مدل و مبتنی بر دانش ترکیب نمود تا به خطاهای کمتری در تخمین SOC دست یافت.

## ۵. مراجع

- [1] M.H. Zafar, N.M. Khan, M. Abou Houran, M. Mansoor, N. Akhtar, F. Sanfilippo, A novel hybrid deep learning model for accurate state of charge estimation of Li-Ion batteries for electric vehicles under high and low temperature, *Energy* 292, ۱۳۰۵۸۴ (۲۰۲۴).
- [2] 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, *Appl. Soft Comput.* 116 (2022) 108401.
- [3] Y. Wang, J. Tian, Z. Sun, L. Wang, R. Xu, M. Li, Z. Chen, A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems, *Renew. Sustain. Energy Rev.* 131 (2020) 110015.
- [4] Marco Mussi, Luigi Pellegrino, Marcello Restelli, Francesco Trovò, A voltage dynamic-based state of charge estimation method for batteries storage systems, *Journal of Energy Storage*, Vol. 44, Part B, 2021.
- [5] S.V. Pandey, N. Parikh, D. Prochowicz, A.K.I.N. Şeckin, S. Satapathi, M. M. Tavakoli, P. Yadav, Predicting the state parameters of Lithium ion batteries: the race between filter based and data driven approaches, *Sustain. Energy Fuel* 7 (3) ۶۲۸-۵۹۸ (۲۰۲۳).
- [6] Kiarash Movassagh, Arif Raihan, Balakumar Balasingam, Krishna Pattipati, A Critical Look at Coulomb Counting Approach for State of Charge Estimation in Batteries, *MDPI Energies*, 14(14), 2021.
- [7] Y. Wang, Y. Cheng, Y. Xiong, Q. Yan, Estimation of battery open-circuit voltage and state of charge based on dynamic matrix control-extended Kalman filter algorithm, *J. Energy Storage* 52 (2022) 104860.
- [8] Y. Bi, S.Y. Choe, An adaptive sigma-point Kalman filter with state equality constraints for online state-of-charge estimation of a Li (NiMnCo) O<sub>2</sub>/carbon battery using a reduced-order electrochemical model, *Appl. Energy* 258 (2020) ۱۱۳۹۲۵.
- [9] 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* 227 (2021) 120451.
- [10] S. Zhang, X. Guo, X. Dou, X. Zhang, A data-driven coulomb counting method for state of charge calibration and estimation of lithium-ion battery, *Sustain Energy Technol Assess* 40 (2020) 100752.
- [11] Y. Zhu, Y. Xiong, J. Xiao, T. Yi, C. Li, Y. Sun, An improved coulomb counting method based on non-destructive charge and discharge differentiation for the SOC estimation of NCM lithium-ion battery, *J. Energy Storage* 73 (2023) 108917.
- [12] Z. Chen, J. Zhou, F. Zhou, S. Xu, State-of-charge estimation of lithium-ion batteries based on improved H infinity filter algorithm and its novel equalization method, *J. Clean. Prod.* 290 (2021) 125180.
- [13] E. Chemali, P.J. Kollmeyer, M. Preindl, R. Ahmed, A. Emadi, Long short-term memory networks for accurate state-of-charge estimation of Li-ion batteries, *IEEE Trans Ind Electron* 65 (8) (2017) 6730-6739.
- [14] J. Chen, Y. Zhang, J. Wu, W. Cheng, Q. Zhu, SOC estimation for lithium-ion battery using the LSTM-RNN with extended input and constrained output, *Energy* 262 (2023) 125375.
- [15] Z. Cui, L. Kang, L. Li, L. Wang, K. Wang, A hybrid neural network model with improved input for state of charge estimation of lithium-ion battery at low temperatures, *Renew. Energy* 198 (2022) 1328-1340.