



دانشگاه صنعتی سهند

DOR:

[20.1001.1.23223146.1401.9.2.4.2](https://doi.org/10.1001.1.23223146.1401.9.2.4.2)

نشریه سالانه غیرخطی در مهندسی برق

دوره ۱۰ - شماره ۲

پاییز و زمستان ۱۴۰۲

صفحات ۳۰ الی ۵۴

ISSN: 2322-3146

<http://journals.sut.ac.ir/jnsee>

تخمین وضعیت شارژ باتری لیتیوم یون با استفاده از فیلتر ذره‌ای حاشیه‌ای کمکی بهبود یافته با عملگرهای ژنتیک و الگوریتم M-H

رمضان هاونگی

نویسنده مسئول، دانشیار گروه کنترل، دانشگاه بیرجند. Havangi@Birjand.ac.ir

چکیده

واژه‌های کلیدی

باتری لیتیوم یون،

تخمین وضعیت شارژ،

فیلتر ذره‌ای حاشیه‌ای،

الگوریتم ژنتیک،

الگوریتم M-H.

تخمین وضعیت شارژ باتری‌های لیتیوم یون نه تنها برای مدیریت بهینه انرژی، بلکه برای اطمینان از عملکرد امن، جلوگیری از شارژ، دشارژ و در نتیجه کاهش عمر باتری از اهمیت بالایی برخوردار است. با این وجود، این پارامتر به طور مستقیم از پایانه‌های باتری قابل اندازه‌گیری نیست. بنابراین نیاز به تخمین آن وجود دارد. در این مقاله فیلتر ذره‌ای حاشیه‌ای کمکی بهبود یافته برای تخمین وضعیت شارژ باتری‌های لیتیوم یون ارائه شده است. در روش پیشنهادی، برخلاف فیلتر ذره‌ای، نمونه‌برداری بر روی توزیع حاشیه‌ای انجام می‌شود و ابعاد نمونه‌برداری با گذشت زمان افزایش نمی‌یابد. بعلاوه، در روش پیشنهادی از عملگرهای ژنتیک و الگوریتم M-H برای افزایش تنوع میان ذرات استفاده شده است. استفاده از عملگرهای ژنتیک و الگوریتم M-H باعث می‌شود ذراتی که نمونه برداری مجدد شده‌اند، بطور مجانبی نمونه‌ها را از تابع چگالی احتمال پسین حالت واقعی تقریب بزنند و سازگاری افزایش یابد. عملکرد روش پیشنهادی برای تخمین وضعیت شارژ باتری، با تخمین وضعیت شارژ براساس فیلتر ذره‌ای توسعه یافته و فیلتر ذره‌ای بی‌رد مقایسه شده است. نتایج نشان دهنده عملکرد موثر روش پیشنهادی در مقایسه با سایر روش‌ها است. روش پیشنهادی برای بدست آوردن دقت تخمین یکسان با فیلتر ذره‌ای به ذرات به مراتب کمتری نیاز دارد و حجم محاسبات آن پایین است. جذر میانگین مربعات خطا در روش پیشنهادی با ذرات مختلف ۰/۰۰۷٪ نزدیک است در حالی که در سایر روش‌ها با کاهش ذرات، جذر میانگین مربعات خطا افزایش می‌یابد.



Sahand University
of Technology

DOR:

[20.1001.1.23223146.1401.9.2.4.2](https://doi.org/10.1001.1.23223146.1401.9.2.4.2)

Journal of Nonlinear
Systems in Electrical
Engineering

Vol.10, No.2

Autumn and Winter 2023

ISSN: 2322 – 3146

<http://journals.sut.ac.ir/jnsee>

Estimation of Charge State of Li-ion Battery Using Improved Auxiliary Marginal Particle Filter with Genetic Operators and M-H Algorithm

Ramazan Havangi

Corresponding Author, University of Birjand, Havangi@Birjand.ac.ir

ABSTRACT

Keywords

Lithium-ion battery,
state of charge estimation,
marginal particle filter,
genetic algorithm,
M-H algorithm.

Estimating the charge state of lithium- ion batteries has great importance, not only for optimal energy management, but also for ensuring safe operation, preventing charging and discharging, and as a result reducing the life of the battery. However, this parameter cannot be measured directly from the battery terminals. Therefore, there is a need to estimate it. In this paper, an improved auxiliary marginal particle filter is presented to estimate the charge state of lithium-ion batteries. In the proposed method, unlike the particle filter, sampling is done on the marginal distribution and the sampling dimensions do not increase with time. In addition, genetic operators and the M-H algorithm have been used in the proposed method to increase diversity among particles. The use of genetic operators and the M-H algorithm causes the resampled particles to asymptotically approximate the samples from the posterior probability density function of the true state and increases the compatibility. The performance of the proposed method for estimating the state of charge of the battery has been compared to the estimation of the state of charge based on the developed particle filter and traceless particle filter. The results show the effective performance of the proposed method in comparison to other methods. The proposed method leads to the same estimation accuracy as the particle filter while requires fewer particles and the amount of calculations is low. The root mean square error in the proposed method with different particles is about 0.007, while in other methods, the root mean square error increases with the decrease of particles.

۱- مقدمه

با کاهش ذخایر سوخت‌های فسیلی به دلیل مصرف بیش از حد، وسایل نقلیه الکتریکی به شدت مورد توجه قرار گرفته‌اند. به علت مزایای زیاد از قبیل توان بالا، چگالی انرژی بالا، ولتاژ بالا، آلودگی کمتر، اثر نداشتن حافظه، عمر طولانی‌تر و میزان خود تخلیه کمتر، باتری‌های لیتیوم-یون به‌طور گسترده‌ای نسبت به سایر باتری‌ها در وسایل نقلیه الکتریکی مورد استفاده قرار گرفته‌اند [۳-۱]. برای عملکرد بهتر باتری لیتیوم-یون و اطمینان از ایمنی و عمر طولانی‌تر آن، نیاز به سیستم مدیریت باتری (BMS)^۱ وجود دارد. سیستم مدیریت باتری باید قادر به تامین تخمین دقیق وضعیت شارژ باتری (SOC)^۲، وضعیت سلامت باتری و عمر مفید باقیمانده باشد [۴]. SOC به‌طور ساده، نسبت شارژ فعلی باتری به ظرفیت کلی آن را نشان می‌دهد و به عنوان یک شاخص مهم برای درک وضعیت باتری و پیش‌بینی عمر مفید آن استفاده می‌شود. تخمین SOC باتری لیتیوم یون از اهمیت بالایی برخوردار است؛ زیرا اطلاعات دقیق در مورد میزان شارژ باقی‌مانده در باتری، به کاربران و سیستم‌هایی که از باتری استفاده می‌کنند، کمک می‌کند تا به‌طور دقیق بتوانند ظرفیت باقی‌مانده باتری را پیش‌بینی کنند و برنامه‌ریزی مناسبی را برای استفاده از آن انجام دهند. با وجود این، تخمین دقیق SOC مشکل است. این بدان علت است که SOC وابسته به وضعیت داخلی سلول باتری است و نمی‌توان به‌طور مستقیم اندازه‌گیری کرد. بنابراین SOC باید تخمین زده شود.

تاکنون روش‌های مختلفی برای تخمین وضعیت شارژ باتری پیشنهاد شده است. از جمله روش‌های استفاده شده برای تخمین SOC باتری لیتیوم یون می‌توان به روش‌های کلاسیک اشاره کرد. روش‌های کلاسیک شامل روش آمپر-ساعت (Ah)^۳ یا شمارش کولن [۷-۵] و ولتاژ مدار باز (OCV)^۴ [۹-۸] است. در روش ولتاژ مدار باز، SOC بر حسب OCV بدست می‌آید. اما از آنجایی که در این روش باتری برای مدت طولانی قبل از اندازه‌گیری OCV باید به حالت پایدار برسد، این روش برای کاربردهای برخط نامناسب است. این روش می‌تواند با شمارش آمپر ساعت ترکیب شود. چنین ترکیبی اجازه می‌دهد که SOC بعد از یک دوره آرامش با استفاده از رابطه OCV-SOC محاسبه شود. یکی دیگر از روش‌های تخمین SOC استفاده از الگوریتم‌های یادگیری است. شبکه‌های عصبی و روش‌های یادگیری ماشین از جمله این روش‌ها هستند [۱۲-۱۰].

به منظور بهبود دقت تخمین وضعیت شارژ باتری، روش‌های تخمین مبتنی بر مدل گسترش یافته‌اند [۱۵-۱۳]. در روش‌های مبتنی بر مدل، ابتدا باتری مدلسازی و سپس از یک تخمینگر برای تخمین وضعیت شارژ باتری استفاده می‌شود. فیلتر کالمن تعمیم یافته (EKF)^۵ یکی از معروف‌ترین تخمینگرها برای تخمین وضعیت شارژ باتری در روش‌های مبتنی بر مدل است [۱۹-۱۶]. به دلیل مزایای EKF، بسیاری از پژوهشگران از این روش در تخمین SOC باتری استفاده کرده‌اند. در [۱۷-۱۸] از EKF دوگانه برای تخمین وضعیت شارژ باتری استفاده شده است. در [۱۹-۲۰] یک فیلتر کالمن توسعه یافته تطبیقی (AEKF)^۶ با استفاده از یک مدل باتری مبتنی بر شبکه RC درجه دو برای تخمین وضعیت شارژ باتری پیشنهاد شده است. نتایج شبیه‌سازی نشان می‌دهد که AEKF از نظر دقت بهتر از EKF عمل می‌کند.

¹ Battery management system

² State of charge

³ Ampere-hour

⁴ Open circuit voltage

⁵ Extended Kalman filter

⁶ Adaptive extended Kalman filter

در [۲۱] یک مدل مدار معادل تکه‌ای خود تطبیقی (PECM^۱) بر اساس EKF پیشنهاد شده است. در حالی که مدل‌های مدار معادل سنتی (ECM^۱) معمولاً برای محدوده خاصی از شرایط کاری (دما، جریان و غیره) پارامتر و اعتبارسنجی می‌شوند، PECM قادر است خود را با هر شرایط کاری در زمان واقعی وفق دهد. پارامترهای مدل که در قالب ترکیبی از توابع تکه‌ای خطی و غیر خطی ایجاد شده‌اند، به طور مداوم بر اساس اندازه‌گیری ولتاژ، جریان و دما تنظیم می‌شوند. یکی دیگر از مزایای PECM این است که نیازی به آزمایشات قبلی در آزمایشگاه ندارد، به عنوان مثال آزمایش ولتاژ مدار باز که زمان بر است و در زمان قدیمی شدن باید کالیبره شود. PECM دقیق، انعطاف پذیر و کارآمد است. علاوه بر این، PECM با تخمین وضعیت شارژ و وضعیت سلامت (SOH) همراه است که در فرآیند اعتبارسنجی مدل و مطالعه تخریب نشان داده شده است. برخی از نویسندگان تخمین وضعیت شارژ باتری را با استفاده از فیلتر کالمن توسعه یافته مقاوم پیشنهاد داده‌اند. روش تخمین SOC بر اساس فیلتر مقاوم، یک ابزار قدرتمند برای حذف تأثیر اختلالات خارجی بر تخمین SOC باتری است [۲۲-۲۳]. در مقایسه با EKF و UKF، تخمین SOC بر اساس H_∞ بیشتر سازگار بوده و تخمین‌های دقیق‌تری در برابر عدم قطعیت‌ها دارد.

با این وجود، در روشهای مبتنی بر EKF محاسبه ماتریس ژاکوبین می‌تواند باعث ناپایداری فیلتر و تخمین نادرست برای بسیاری از مدل‌های غیرخطی باتری شود. برای حل این مشکل روش‌های تخمین وضعیت شارژ باتری بر اساس فیلتر کالمن بی-رد (UKF^۲) ارائه شده است [۲۴-۲۶]. این روش با ترکیب تبدیل بی‌رد و فیلتر کالمن بر ضعف‌های دقت پایین و پایداری ضعیف روش مبتنی بر فیلتر کالمن توسعه یافته غلبه می‌کند. در حقیقت UKF یک نسخه به‌روز شده از EKF است که از تبدیل بی‌رد استفاده می‌کند تا ضعف بسط سری تیلور در EKF را از بین ببرد. در [۲۸-۳۰]، یک فیلتر کالمن بی‌رد تطبیقی (AUKF^۳) برای تخمین SOC باتری‌های لیتیوم-یون با استفاده از یک مدل تونن بهبود یافته پیشنهاد شده است. در [۲۷]، روش شمارش کولومب برای تخمین SOC بر اساس UKF را مورد بررسی قرار دادند. در این روش از UKF برای تنظیم خودکار پارامترهای مدل استفاده می‌شود تا خطا در SOC ناشی از تغییرات شرایط محیطی و خودتخلیه باتری کاهش یابد. کارایی این روش از طریق جمع‌آوری داده‌ها از باتری‌های LiFePO₄ در آزمون‌های مختلف بررسی شده است. در [۲۸]، SOC باتری لیتیوم-یون بر اساس AUKF با استفاده از یک ماشین یادگیری پیش‌بین تعیین شده است.

با این وجود، روش تخمین وضعیت شارژ باتری بر اساس فیلتر کالمن بی‌رد تحت شرایط اولیه نادقیق، نویزهای غیرگوسی، توزیع‌های غیرگوسی و مشکل چولسکی در تجزیه ماتریس‌های غیر مثبت منجر به واگرایی آن می‌شود. با توجه به مشکلات گفته شده، در سال‌های اخیر تخمین وضعیت شارژ باتری با استفاده از فیلتر ذره‌ای مورد توجه قرار گرفته است [۲۹-۳۰]. در فیلتر ذره‌ای تابع چگالی احتمال پسین با مجموعه‌ای از ذرات وزن داده شده تخمین زده می‌شود [۳۱]. الگوریتم PF با روش شبیه‌سازی مونت کارلو با مجموعه‌ای از ذرات تصادفی، تابع چگالی احتمال یک سیستم غیرخطی را تقریب می‌زند. در [۳۲-۳۳]، فیلتر ذره‌ای توسعه

¹ Piecewise equivalent circuit model

² Equivalent circuit models

³ Unscented Kalman filter

⁴ Adaptive unscented Kalman filter

یافته (EPF^۱) برای تخمین وضعیت شارژ باتری ارایه شده است. در [۳۴-۳۵] فیلتر ذره‌ای بی رد (UPF^۲) برای تخمین SOC باتری‌های لیتیوم-یون با توان بالا معرفی شده است. نتایج نشان می‌دهد که این روش در مقایسه با روش‌های UKF، EKF و PF، عملکرد بهتری دارد. در [۳۶] یک فیلتر ذره‌ای مکعبی (CPF^۳) برای تخمین دقیق و قابل اعتماد SOC پیشنهاد شده است. در همه نسخه‌های فیلتر ذره‌ای، از آنجایی که تابع چگالی پسین مشترک حالت با استفاده از نمونه‌برداری پراهمیت بازگشتی تقریب زده می‌شود، فرآیند نمونه برداری پر اهمیت باید بر روی کل مسیر اجرا شود [۳۱]. با وجود این، در پیاده‌سازی فیلتر ذره‌ای، نمونه‌برداری مجدد روی فضای حاشیه‌ای انجام می‌شود که اگر سیستم نسبت به خطاهای گذشته‌اش فراموشی نمایی نداشته باشد، با تعداد ذره محدود یک تخمین ناسازگار بوجود می‌آورد [۳۱].

برای غلبه بر این مشکلات، در این مقاله از فیلتر ذره‌ای حاشیه‌ای کمکی بهبود یافته با عملگرهای ژنتیک و الگوریتم M-H^۴ برای تخمین SOC باتری‌های لیتیوم یون استفاده شده است که سبب افزایش دقت، ایجاد تنوع میان ذرات و سازگاری می‌شود. علاوه، نمونه‌برداری با استفاده از عملگرهای الگوریتم ژنتیک و الگوریتم M-H بهبود داده شده است. برتری استفاده از روش پیشنهادی نسبت به فیلتر ذره‌ای این است که عملکرد آن در اصلاح واریانس وزن پراهمیت، دقت تخمین و سازگاری برتری دارد. مهمترین نوآوریهای این مقاله به شرح زیر است:

۱- در روش پیشنهادی، برخلاف فیلتر ذره‌ای استاندارد، نمونه‌برداری بر روی توزیع حاشیه‌ای انجام می‌شود و ابعاد نمونه‌برداری با گذشت زمان افزایش نمی‌یابد.

۲- ارایه فیلتر ذره‌ای حاشیه‌ای کمکی به جای فیلتر ذره‌ای به منظور بهبود دقت تخمین وضعیت شارژ باتری.

۳- افزایش تنوع میان ذرات با اعمال عملگرهای ژنتیک و زنجیره مارکوف مونت کارلو.

در روش پیشنهادی، نمونه برداری مجدد روی بخشی از ذرات که دارای وزن کمی هستند انجام می‌شود. در این روش ذرات به صورت ذرات با وزن ناچیز و ذرات با وزن قابل توجه دسته بندی می‌شوند. ذرات با وزن کم با ذرات با وزن زیاد با اعمال عملگرهای ژنتیک و زنجیره مارکوف مونت کارلو اصلاح می‌شوند.

ساختار بقیه مقاله به شرح زیر است. در بخش ۲، مدل‌سازی باتری لیتیوم-یون با استفاده از مدار معادل RC مرتبه اول ارائه شده است. در بخش ۳، تخمین وضعیت شارژ باتری با فیلتر ذره‌ای ارایه شده است. در بخش ۴ تخمین وضعیت شارژ باتری براساس فیلتر ذره‌ای حاشیه‌ای هوشمند ارایه شده است. در بخش ۵ نتایج ارائه شده است. در بخش ۶ نتیجه‌گیری مقاله مطرح شده است.

۲- مدل‌سازی باتری لیتیوم-یون

مدل‌سازی باتری مساله‌ای مهم و چالش برانگیز در سیستم مدیریت باتری است. تاکنون مدل‌های متعددی برای باتری گزارش شده است که بطور کلی به چهار دسته‌بندی می‌شوند [۱-۲]. مدل ایده‌آل، مدل رفتاری، مدل الکترو شیمیایی و مدل مدار معادل

^۱ Extended Kalman filter

^۲ Unscented kalman filter

^۳ Cubature particle filter

^۴ Metropolis-Hastings

الکتریکی. مدل‌های مدار معادل الکتریکی شامل شبکه RC مرتبه n ام هستند که برای توصیف مشخصه دینامیک باتری به کار برده می‌شوند. هر چه مرتبه مدل بالاتر باشد مدل دقیق‌تر است و حجم محاسبات بالاتری دارد. در این مقاله برای داشتن محاسبات کمتر، مدل RC مرتبه اول استفاده شده است که در شکل (۱) نشان داده شده است [۳]. این مدل شامل ترکیبی از منبع ولتاژ V_{OC} ، مقاومت اهمی R_0 ، مقاومت پلاریزاسیون R_1 و خازن C_1 می‌باشد که همانند سایر مدل‌ها سعی می‌کند رفتار باتری را مدل کند. معادلات فضای حالت این مدل به صورت زیر است:

$$\dot{SOC} = -\frac{1}{Q_n} I \quad (1)$$

$$\dot{V}_1 = -\frac{1}{R_1 C_1} V_1 + \frac{1}{C_1}$$

$$V_b = V_{OC}(SOC) - V_1 - R_0 I \quad (2)$$


که V_1 ولتاژ خازن، Q_n ظرفیت مجاز سلول باتری، V_b ولتاژ ترمینال سلول، I جریان سلول با مقدار مثبت در دشارژ و مقدار منفی در شارژ، V_{OC} ولتاژ مدار باز سلول و تابعی از SOC می‌باشد. در حالت کلی فرم گسسته معادلات باتری را می‌توان به صورت زیر نوشت:

$$\begin{aligned} x_k &= f(x_{k-1}, u_k) + w_k \\ P(\omega_k) &\sim N(0, Q_k) \\ z_k &= h(x_k, u_k) + v_k \\ P(v_k) &\sim N(0, R_k) \end{aligned} \quad (3)$$

$$f(x_{k-1}, u_k) = \begin{bmatrix} e^{-\frac{T}{R_{1,k} C_{1,k}}} & 0 \\ 0 & 1 \end{bmatrix} x_{k-1} + \begin{bmatrix} R_{1,k} \cdot \left(1 - e^{-\frac{T}{R_{1,k} C_{1,k}}}\right) \\ -T \\ C \cdot 3600 \end{bmatrix} I_k$$

$$h(x_k, U_k) = V_{OC,k} - V_{1,k} - R_{0,k} I_k$$

که x_k بردار حالت، u_k بردار ورودی سیستم، z_k بردار اندازه‌گیری، w_k بردار نویز فرآیند، v_k بردار نویز اندازه‌گیری، Q_k و R_k به ترتیب کواریانس نویز فرآیند و اندازه‌گیری هستند. همچنین $f(\cdot)$ و $h(\cdot)$ توابع غیرخطی و I_k بردار ورودی سیستم است. با توجه به معادلات مدل باتری ملاحظه می‌شود این سیستم، یک سیستم غیرخطی است.



شکل ۱- مدل مرتبه اول باتری

۳- تخمین وضعیت شارژ با فیلتر ذره‌ای

فیلتر ذره‌ای یک روش موثر برای حل مسئله تخمین در مواجهه با سیستم‌های غیرخطی با نویز غیر گوسی می‌باشد. این روش جزء روش‌های آماری مونت کارلو است [۲۵]. برای توصیف تخمین وضعیت شارژ باتری با استفاده از فیلتر ذره‌ای استاندارد، معادلات گسسته غیرخطی باتری لیتیوم-یون به صورت زیر در نظر گرفته می‌شود:

$$x_k = f(x_{k-1}, u_k) + w_k \quad (۴)$$

$$z_k = h(x_k, u_k) + v_k \quad (۵)$$

فیلتر ذره‌ای تابع چگالی احتمال پسین $p(x_{0:k} | z_{1:k})$ را بصورت مجموعه‌ای از ذرات وزن داده شده به صورت زیر بیان می‌کند:

$$S_k = \{(x_k^{(i)}, w_k^{(i)}) | i=1, \dots, N\} \quad (۶)$$

که N بیانگر تعداد ذرات و $w_k^{(i)}$ وزن مربوط به $x_k^{(i)}$ است. در این حالت $p(x_{0:k} | z_{1:k})$ با مجموع وزن داده شده‌ای به صورت زیر تقریب زده می‌شود [۲۵]:

$$p(x_{0:k} | z_{1:k}) \approx \sum_{i=1}^N w_k^{(i)} \delta(x_k - x_k^{(i)}) \quad (۷)$$

که $\delta(x)$ تابع دلتای دیراک، $w_k^{(i)} > 0$ وزن مربوط به $x_k^{(i)}$ و $\sum_{i=1}^N w_k^{(i)} = 1$ است. با توجه به اینکه نمونه برداری مستقیم از تابع چگالی احتمال اصلی که به تابع توزیع هدف معروف است ممکن نیست، از روش نمونه برداری پر اهمیت استفاده می‌شود. در این روش به جای نمونه برداری از تابع هدف از یک تابع توزیع پیشنهادی نمونه برداری می‌شود. با در نظر گرفتن تابع چگالی پیشنهادی به صورت $q(x_{0:k} | z_{1:k})$ ، وزن ذرات به صورت زیر است [۲۵]:

$$w_k^{(i)} = \frac{p(x_{0:k}^{(i)} | z_{1:k})}{q(x_{0:k}^{(i)} | z_{1:k})} \quad (۸)$$

الگوریتم SIS^۱ با نمونه‌گیری مجدد به الگوریتم SIR^۲ معروف است که به‌طور خلاصه دارای گام‌های زیر است:

۱- نمونه برداری: ذرات جدید از جمعیت قدیم آنها و با نمونه برداری از توزیع پیشنهادی $q(x_{0:k} | z_{1:k})$ بدست می‌آیند.

۲- محاسبه وزن نمونه‌ها: به هر ذره، یک وزن اختصاص داده می‌شود که از رابطه زیر به دست می‌آید:

$$w_k^{(i)} = w_{k-1}^{(i)} \frac{p(z_k | x_k^{(i)}) p(x_k^{(i)} | x_{k-1}^{(i)}, u_k)}{q(x_k^{(i)} | x_{k-1}^{(i)}, z_k)} \quad (۹)$$

^۱ Sequential importance sampling

^۲ Sequential importance resampling

۳- نرمال سازی وزن‌ها

$$w_k^{(i)} = \frac{w_k^{(i)}}{\sum_{i=1}^N w_k^{(i)}} \quad (10)$$

۴- نمونه برداری مجدد

۴- تخمین وضعیت شارژ باتری بر اساس فیلتر ذره‌ای حاشیه‌ای کمکی

بر خلاف فیلتر ذره‌ای، فیلتر ذره‌ای حاشیه‌ای بر روی توزیع حاشیه‌ای $p(x_k | z_{1:k})$ انجام می‌شود و ابعاد نمونه‌برداری با زمان افزایش نمی‌یابد. گام‌های بروز رسانی و پیش بینی در فیلتر ذره‌ای حاشیه‌ای به صورت زیر است:

$$p(x_k | z_{1:k-1}) = \int p(x_k | x_{k-1}, u_k) p(x_{k-1} | z_{1:k-1}) dx_{k-1} \quad (11)$$

$$p(x_k | z_{1:k}) = \frac{p(z_k | x_k) P(x_k | z_{1:k-1})}{P(z_k | z_{1:k-1})} \quad (12)$$

حل انتگرال (۱۱) در حالت کلی بصورت تحلیلی مشکل است. اما از آنجایی که $p(x_{k-1} | z_{1:k-1})$ بوسیله مجموع ذرات $\{x_{k-1}^{(i)}, w_{k-1}^{(i)}\}$ تخمین زده می‌شود تقریب $p(x_k | z_{1:k-1})$ به صورت زیر است:

$$p(x_k | z_{1:k-1}) = \sum_{i=1}^N w_{k-1}^{(i)} p(x_k | x_{k-1}^{(i)}, u_k) \quad (13)$$

آنگاه تابع چگالی احتمال پسین به صورت زیر تقریب زده می‌شود:

$$p(x_k | z_{1:k}) \propto p(z_k | x_k) \sum_{i=1}^N w_{k-1}^{(i)} p(x_k | x_{k-1}^{(i)}, u_k) \quad (14)$$

با توجه به اینکه نمونه‌برداری از پسین واقعی $p(x_k | z_{1:k})$ معمولاً غیرممکن است، از یک توزیع پیشنهادی باید نمونه‌برداری شود. وزن پر اهمیت ذرات به صورت زیر است:

$$w_k = \frac{p(x_k | z_{1:k})}{q(x_k | z_{1:k})} \quad (15)$$

که با جایگذاری $p(x_k | z_{1:k})$ وزن ذرات به صورت زیر محاسبه می‌شود:

$$(x+a)^n = \sum_{j=1}^N \binom{n}{k} w^{(j)} a^{n-k} \quad (16)$$

$$\tilde{w}_k^{(i)} = \frac{p(z_k | x_k^{(i)}) \sum_{j=1}^N w_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}{q(x_k | z_{1:k})}$$

انتخاب تابع توزیع پیشنهادی یکی از گام‌های مهم در طراحی فیلتر ذره‌ای حاشیه‌ای است. در فیلتر ذره‌ای حاشیه‌ای عمومی ترین تابع توزیع پیشنهادی، توزیع پیشین است:

$$q(x_k) = p(x_k | z_{1:k-1}) \quad (17)$$

که در این صورت وزن ذرات از رابطه زیر محاسبه می‌شود:

$$w_k^{(i)} = \frac{p(x_k^{(i)} | z_{1:k})}{q(x_k^{(i)})} = \frac{1}{\hat{c}_t} p(z_k | x_k^{(i)}) \frac{p(x_k^{(i)} | z_{1:k-1})}{q(x_k^{(i)})} \quad (18)$$

که \hat{c}_t به صورت زیر است:

$$\hat{c}_k = \sum_{i=1}^N p(z_k | x_k^{(i)}) \frac{p(x_k^{(i)} | z_{1:k-1})}{q(x_k^{(i)})}$$

در نتیجه وزن ذرات به صورت زیر محاسبه می‌شود:

$$w_k^{(i)} \propto p(z_k | x_k^{(i)}) \quad (19)$$

در این روش از آنجایی که آخرین اطلاعات اندازه‌گیری در فرآیند نمونه برداری مورد توجه قرار نمی‌گیرد، دقت پایین بوده و لازم است که تعداد ذرات زیاد باشند. برای حل این مشکل در برخی تحقیقات یک فیلتر مانند EKF در گام نمونه برداری وارد می‌شود. با این وجود، وارد کردن EKF در گام نمونه برداری حجم محاسبات را افزایش می‌دهد. در این مقاله، برای بهبود همزمان دقت و کاهش محاسبات در تخمین وضعیت شارژ باتری، یک روش تحت عنوان فیلتر ذره‌ای حاشیه‌ای کمکی پیشنهاد می‌گردد. در این روش به شیوه ساده‌تر و کم هزینه‌تر از نظر محاسباتی، اندازه‌گیری‌ها وارد فرآیند نمونه برداری شده است. برای این منظور از ایده مشابه فیلترهای ذره‌ای کمکی در فیلتر ذره‌ای حاشیه‌ای استفاده شده است. برای این منظور، تابع توزیع پسین (۱۴) بطور معادل به صورت زیر بازنویسی می‌شود:

$$p(x_k | z_{1:k}) = \sum_{i=1}^N \omega_{k-1}^{(i)} p(z_k | x_{k-1}^{(i)}) p(x_k | x_{k-1}^{(i)}, z_k) = \sum_{i=1}^N p(i | z_{1:k}) p(x_k | x_{k-1}^{(i)}, z_k) \quad (20)$$

که $p(i | z_{1:k})$ به فرم زیر است:

$$p(i | z_{1:k}) \propto \omega_{k-1}^{(i)} p(z_k | x_{k-1}^{(i)}) = \omega_{k-1}^{(i)} \int p(z_k | x_k) p(x_k | x_{k-1}^{(i)}, u_k) dx_k \quad (21)$$

برای نمونه برداری از (۲۱)، در ابتدا از تابع توزیع $p(i | z_{1:k})$ بوسیله نمونه برداری از i می‌توان نمونه برداری کرد که i بعنوان متغیر کمکی^۱ از $p(i | z_{1:k})$ دانسته می‌شود. سپس می‌توان x_k را از $p(x_k | x_{k-1}^{(i)}, z_k)$ نمونه برداری کرد. از آنجایی (۲۱) را به صورت تحلیلی نمی‌توان ارزیابی کرد، $p(i | z_{1:k})$ به صورت زیر تقریب زده می‌شود:

$$\hat{p}(i | z_{1:k}) \propto \omega_{k-1}^{(i)} p(z_k | \mu_k^{(i)}) \quad (22)$$

که

$$\mu_k^{[i]} = E(x_k | x_{k-1}^{(i)}) \quad (23)$$

^۱ Auxiliary variable

۱. برای $i=1, \dots, N$ محاسبه $\lambda_{k-1}^{(i)}, \mu_k^{(i)}$

$$\mu_k^{(i)} = E(x_k | x_{k-1}^{(i)}, u_k)$$

$$\hat{\lambda}_{k-1}^{(i)} = \omega_{k-1}^{(i)} p(z_k | \mu_k^{(i)})$$

$$\lambda_{k-1}^{(i)} = \frac{\hat{\lambda}_{k-1}^{(i)}}{\sum_{i=1}^N \hat{\lambda}_{k-1}^{(i)}}$$

۲. برای $i=1, \dots, N$ ، نمونه برداری از تابع توزیع

پیشنهادی

$$q(x_k | z_{1:k}) \sim \sum_{i=1}^N \lambda_{k-1}^{(i)} p(x_k | x_{k-1}^{(i)}, u_k)$$

۱. برای $i=1, \dots, N$ محاسبه وزن پراهمیت

$$\tilde{w}_k^{(i)} = \frac{p(z_k | x_k^{(i)}) \sum_{j=1}^N w_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}{\sum_{j=1}^N \lambda_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}$$

۳. نرمال‌سازی وزن‌ها

$$w_k^{(i)} = \frac{\tilde{w}_k^{(i)}}{\sum_{j=1}^N \tilde{w}_k^{(j)}}$$

شکل ۲- شبه کد تخمین وضعیت شارژ باتری با فیلتر ذره‌ای حاشیه‌ای کمکی

با توجه به اینکه نمونه برداری از $p(x_k | x_{k-1}^{(i)}, \bar{z}_k)$ همیشه بسادگی ممکن نیست، در عوض از $p(x_k | x_{k-1}^{(i)})$ نمونه برداری شده است. بنابراین تابع توزیع پیشنهادی فیلتر ذره‌ای کمکی^۱ به صورت زیر است:

$$q(x_k | \bar{z}_{1:k}) \propto \sum_{i=1}^N \hat{p}(i | \bar{z}_{1:k}) p(x_k | x_{k-1}^{(i)}) \quad (24)$$

شبه کد فیلتر ذره‌ای حاشیه‌ای کمکی در شکل (۲) بطور خلاصه نشان داده شده است. تخمین حالت به صورت زیر است:

$$\hat{x}_k = \sum_{i=1}^N \hat{w}_k^{(i)} x_k^{(i)}$$

که وزن نرمال شده به صورت زیر محاسبه می‌شود:

$$\hat{w}_k^{(i)} = \frac{w_k^{(i)}}{\sum_{i=1}^N w_k^{(i)}}$$

وقتی تعداد ذرات بینهایت باشد حالت تخمین زده شده \hat{x}_k به مقدار واقعی حالت x_k میل خواهد کرد. با وجود این، با گذشت زمان تعداد کمی از ذرات وزن بزرگی دارند و وزن بیشتر ذرات ناچیز است. این مشکل به عنوان تباهدگی ذرات معروف است. در نتیجه آن هزینه محاسبات زیادی صرف نمونه‌هایی می‌شود که وزن ناچیزی دارند. برای حل این مشکل نمونه برداری مجدد انجام می‌شود. مشهورترین الگوریتم‌های نمونه برداری مجدد عبارت از چند جمله‌ای، طبقه طبقه شده^۲، سیستماتیک^۳ و باقیمانده (PR)^۴ هستند [۹۸-۲۸]. در میان الگوریتم‌های نمونه برداری مجدد، روش نمونه برداری مجدد^۵ RSR، مرسوم‌ترین الگوریتم می‌باشد. این الگوریتم با توجه به وزن ذرات تصمیم می‌گیرد که چه تعداد کپی از هر ذره بسازد. این روش در بسیاری از تحقیقات استفاده شده است [۲۸]. اگر چه نمونه برداری مجدد RSR مسئله تباهدگی را کاهش می‌دهد، مشکل دیگری بنام فقر نمونه به همراه دارد و موجب از دست دادن تنوع میان ذرات می‌شود. به دلیل تکرار بیش از حد ذرات با وزن بالا و کنار گذاشتن بسیاری از ذرات کم وزن، تعداد ذرات یکسان به طور قابل توجهی افزایش می‌یابد و تنوع ذرات کاهش می‌یابد و در نتیجه کواریانس نمونه‌ها و دقت تخمین کاهش می‌یابد. بنابراین برای افزایش دقت تخمین تنوع میان ذرات بسیار مهم است. در این مقاله از عملگرهای ژنتیک و الگوریتم M-H برای افزایش تنوع میان ذرات استفاده شده است.

¹ Auxiliary

² Stratified resampling

³ Systematic resampling

⁴ Residual resampling

⁵ Residual systematic resampling

افزایش تنوع میان ذرات با عملگرهای ژنتیک و الگوریتم M-H

در حالت کلی، یک خاصیت فیلتر ذره‌ای و در نتیجه فیلتر ذره‌ای حاشیه‌ای این است که تنوع میان ذرات از بین می‌رود. در نتیجه با گذشت زمان، تعداد ذرات مجزا و در نتیجه کواریانس نمونه‌ها کاهش می‌یابد. در این مقاله از عملگرهای الگوریتم ژنتیک و الگوریتم M-H برای افزایش تنوع میان ذرات فیلتر ذره‌ای حاشیه‌ای کمکی استفاده شده است. الگوریتم M-H یک روش زنجیره‌ای مارکوف مونت کارلو (MCMC^۱) برای بدست آوردن دنباله‌ای از نمونه‌های تصادفی از توزیع احتمالی است که نمونه برداری مستقیم از آن دشوار است [۴۰]. الگوریتم M-H یک توزیع شرطی به عنوان تابع توزیع پیشنهادی برای ایجاد زنجیره مارکوف با توزیع نامتغیر به کار می‌برد. در روش پیشنهادی، نمونه برداری مجدد روی بخشی از ذرات که دارای وزن کمی هستند انجام می‌شود. در این روش ذرات به صورت ذرات با وزن ناچیز و ذرات با وزن قابل توجه دسته بندی می‌شوند. ذرات با وزن کم با ذرات با وزن زیاد و گام M-H اصلاح می‌شوند. برای این منظور، فرض کنید مجموعه ذرات نمونه برداری شده از تابع توزیع پیشنهادی $q(x_k | \bar{z}_{1:k})$ به صورت $\{x_k^{(i)}, \tilde{w}_k^{(i)}\}_{i=1}^N$ باشند. حال ذرات را بر اساس وزن آنها مرتب می‌شوند و مجموعه جدید وزن W بدست آورده می‌شود. آنگاه مجموعه ذرات $\{x_k^{(i)}, \tilde{w}_k^{(i)}\}_{i=1}^N$ دسته بندی می‌شوند. برای این منظور وزن هر ذره با یک مقدار آستانه بالا ω_H و یک مقدار آستانه پایین ω_L مقایسه می‌شود. ذراتی که وزن آنها بین این دو آستانه است، بعنوان ذرات با وزن متوسط در نظر گرفته می‌شوند و نمونه برداری مجدد نمی‌گردند. فرض کنید تعداد ذرات با وزن بزرگتر از ω_H و کمتر از ω_L بترتیب بوسیله N_H و N_L مشخص شوند. در این صورت مجموع وزن ذراتی که نمونه برداری مجدد می‌شوند، عبارت از $S_{HL} = \sum_{i=1}^{N_H+N_L} w_k^{(i)}$ است که در آن i به گونه‌ای انتخاب می‌شود که شرایط $w_k^{(i)} > \omega_H$ یا $w_k^{(i)} < \omega_L$ برقرار باشد.

بعد از جداسازی ذرات، از عملگر ترکیب الگوریتم ژنتیک برای بهبود ذرات با وزن کم استفاده می‌شود. تاکنون عملگرهای ترکیب زیادی برای الگوریتم ژنتیک در مقالات ارایه شده است که در این مقاله از اپراتور تقاطع حسابی^۲ برای اصلاح ذرات با وزن کم استفاده شده است. برای این منظور، فرض کنید $x_{H,k}^{(i)}$ و $x_{L,k}^{(i)}$ بترتیب ذرات از C_H و C_L را ارایه دهند و ذرات با وزن کم اصلاح شده باشند. یک ذره با وزن بالا $x_{H,k}^{(i)}$ بطور تصادفی از مجموعه C_H انتخاب می‌شود، آنگاه ذره $x_{L,k}^{(i)}$ که در مجموعه با ذرات کم C_L است با $x_{H,k}^{(i)}$ ترکیب می‌شود. در این صورت با استفاده از عملگر ترکیب ذرات کم وزن اصلاح شده به صورت زیر حاصل می‌شود:

$$x_{C,k}^{(i)} = \alpha x_{L,k}^{(i)} + (1-\alpha)x_{H,k}^{(i)}$$

که در آن $i=1, \dots, N_L$ و $j=1, \dots, N_H$ است. N_L و N_H بترتیب تعداد ذراتی است که C_H و C_L شامل می‌شوند. برای هر $x_{L,k}^{(i)}$ بصورت تصادفی از N_H انتخاب می‌شود. $\alpha \in [0,1]$ پارامتری است که نشان می‌دهد چگونه اطلاعات از $x_{H,k}^{(i)}$ انتقال می‌یابد. α بزرگتر به معنی انتقال اطلاعات بیشتر از $x_{H,k}^{(i)}$ به $x_{L,k}^{(i)}$ است. برای $\alpha=1$ $x_k^{(i)} = x_k^{(i)}$ است و هیچ ترکیبی اتفاق نخواهد افتاد. وزن ذرات اصلاح شده به صورت زیر است:

$$\tilde{w}_k^{(i)} = \frac{p(z_k | x_k^{(i)}) \sum_{j=1}^N w_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}{\sum_{j=1}^N \lambda_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}$$

¹ Markov chain Monte Carlo

² Arithmetic Crossover

۱. برای $i=1, \dots, N$ ، محاسبه $\lambda_{k-1}^{(i)}$ ، $\mu_k^{(i)}$

$$\mu_k^{(i)} = E(x_k | x_{k-1}^{(i)}, u_k)$$

$$\hat{\lambda}_{k-1}^{(i)} = \omega_{k-1}^{(i)} p(z_k | \mu_k^{(i)})$$

$$\lambda_{k-1}^{(i)} = \frac{\hat{\lambda}_{k-1}^{(i)}}{\sum_{i=1}^N \hat{\lambda}_{k-1}^{(i)}}$$

۲. برای $i=1, \dots, N$ ، نمونه برداری از تابع توزیع پیشنهادی

$$q(x_k | z_{1:k}) \sim \sum_{i=1}^N \lambda_{k-1}^{(i)} p(x_k | x_{k-1}^{(i)})$$

۳. دسته بندی ذرات $\{x_k^i, \tilde{w}_k^i\}_{i=1}^N$ به N_L و N_H

۱،۳ برای $i=1, \dots, N_L$

۲،۳ تولید تصادفی یک عدد تصادفی $u \sim U_{[0,1]}$

۳،۳ محاسبه احتمال قبولی

$$\gamma = \min \left\{ 1, \frac{w}{w'} \right\}$$

۴،۳ قبول یا رد حرکت نمونه

If $u \leq \gamma$

قبول حرکت با احتمال γ به صورت زیر:

$$x_k^{(i)} = x_k^{\prime(i)}$$

Else

رد حرکت با احتمال $1-\gamma$ به صورت زیر:

$$x_k^{(i)} = x_k^{(i)}$$

۴. برای $i=1, \dots, N$ ، محاسبه وزن پراهمیت ذرات

$$\tilde{w}_k^{(i)} = \frac{p(z_k | x_k^{(i)}) \sum_{j=1}^N w_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}{\sum_{j=1}^N \lambda_{k-1}^{(j)} p(x_k^{(i)} | x_{k-1}^{(j)}, u_k)}$$

۱،۴ نرمال سازی وزن ها

$$w_k^{(i)} = \frac{\tilde{w}_k^{(i)}}{\sum_{j=1}^N \tilde{w}_k^{(j)}}$$

شکل ۳- شبه کد فیلتر ذره‌ای حاشیه ای کمکی بهبود یافته

حال از الگوریتم MH برای قبول یا رد ذره بهبود یافته استفاده می‌شود. این الگوریتم دارای گام‌های زیر است:

۱. نمونه برداری $u \sim U_{[0,1]}$

۲. محاسبه احتمال قبولی

$$\gamma = \min \left\{ 1, \frac{w_k}{w'_k} \right\}$$

۳. قبول یا رد حرکت نمونه

If $u \leq \gamma$

قبول حرکت با احتمال γ به صورت زیر:

$$x_k^{(i)} = x'_k{}^{(i)}$$

Else

رد حرکت با احتمال $1 - \gamma$ به صورت زیر:

$$x_k^{(i)} = x_k^{(i)}$$

end if

شبه کد الگوریتم نهایی تخمین وضعیت شارژ باتری با استفاده از فیلتر ذره‌ای حاشیه‌ای کمکی بهبود یافته در شکل (۳) نشان داده شده است.

جدول ۱- مشخصات اصلی باتری


مدل	ولتاژ نامی	ظرفیت نامی	ولتاژ برش بالا و پایین
INR ۱۸۶۵۰-۲۰R	۳/۶V	۱/۳Ah	۴/۲۷-۲/۰V

۵- نتایج


در این بخش، عملکرد تخمین وضعیت شارژ باتری مبتنی بر تخمینگرهای EPF، UPF و روش پیشنهادی مورد ارزیابی قرار گرفته‌اند. داده‌های استفاده شده برای ارزیابی عملکرد روش پیشنهادی، داده‌های تست آزمایشگاهی در دانشگاه ویسکانسین-مدیسون^۱ است. این داده‌های آزمایشگاهی برای کلیه محققین قابل استفاده است و جزء معروفترین داده‌ها در حوزه تخمین وضعیت شارژ باتری است [۴۱]. در ابتدا مجموعه تست FUDS به عنوان یک مجموعه تست استاندارد برای ارزیابی موثر بودن روش پیشنهادی استفاده شده است. شماتیک تست باتری در شکل (۴) نشان داده شده است. باتری مورد آزمایش در این مقاله باتری مدل INR 18650-20R با جریان نامی ۱/۳ آمپر و ولتاژ نامی ۳/۶ ولت است. مشخصات اصلی باتری در جدول (۱) آورده شده است. جریان ورودی باتری و ولتاژ ترمینال به عنوان خروجی به ترتیب در شکل‌های (۵) و (۶) نشان داده شده است. شکل (۷) نتایج بدست آمده از روشهای مختلف را نشان می‌دهد. نتایج شامل مقدار واقعی وضعیت شارژ و مقدار تخمین زده شده آنها با استفاده از UPF [۳۲]، UPF [۳۵] و

^۱ University of Wisconsin-Madison


روش پیشنهادی است. همانطور که از شکل (۸) مشاهده می‌شود روش پیشنهادی با دقت بالاتری SOC را نسبت به سایر روشها تخمین می‌زند. این بدان دلیل است که SOC تخمین زده شده توسط روش پیشنهادی به مقدار واقعی SOC نزدیکتر است.




شکل ۴- تست باتری لیتیوم یون




شکل ۶- ولتاژ ترمینال خروجی باتری



شکل ۵- جریان ورودی




شکل ۷- نتایج تخمین SOC




شکل ۸- زوم شده شکل (۷)

برای ارزیابی دقیق‌تر و بهتر، جذر میانگین مربعات خطا (RMSE) مربوط به SOC با استفاده از تخمینگرهای مختلف مورد ارزیابی قرار گرفته است. نتایج در شکل (۹) نشان داده شده است. شکل (۹) مقدار RMSE را در طول زمان نشان می‌دهد. مقدار RMSE با ۵۰ بار تکرار در شرایط یکسان بدست آمده است. RMSE از روش مونت کارلو با ۵۰ بار اجرا بدست آمده است. همانطور که مشاهده می‌شود RMSE روش پیشنهادی کمتر از سایر روش‌ها است و RMSE روش EPF از سایر الگوریتم‌ها بدتر است.



شکل ۹- RMSE در طول زمان مربوط به SOC




شکل ۱۰- RMSE مربوط به SOC

عملکرد روش پیشنهادی با تعداد ذرات مختلف و مقایسه آن با روشهای UPF [۳۲]، UPF [۳۵] و CPF [۳۶] از نظر زمان ، حجم محاسبات و دقت در جدول (۲) نشان داده شده است. مشاهده می‌شود وابستگی عملکرد سایر روشها به تعداد ذرات بیشتر از روش پیشنهادی است. این موضوع بدان علت است در روش پیشنهادی، نمونه برداری مجدد روی بخشی از ذرات که دارای وزن کمی هستند انجام می‌شود. در این روش ذرات به صورت ذرات با وزن ناچیز و ذرات با وزن قابل توجه دسته بندی می‌شوند. ذرات با وزن کم با ذرات با وزن زیاد با اعمال عملگرهای ژنتیک و الگوریتم M-H اصلاح می‌شوند. این باعث سبب می‌شود که در روش پیشنهادی تنوع میان ذرات حفظ شود و ذرات نمونه برداری مجدد شده بطور مجانبی نمونه‌ها را از تابع چگالی احتمال پسین حالت واقعی تقریب بزنند. به عبارت دیگر، روش پیشنهادی می‌تواند از فقر نمونه‌ها جلوگیری کند و در نتیجه نیاز به تعداد ذرات زیاد نمی‌باشد. امتیاز الگوریتم جدید این است که روش پیشنهادی برای بدست آوردن دقت تخمین یکسان با فیلتر ذره‌ای به ذرات به مراتب کمتری نیاز دارد. جدول (۲) مقایسه روشها را از نظر حجم محاسبات نشان می‌دهد.

جدول ۲- مقایسه فیلترها با تعداد ذرات مختلف از نظر دقت و حجم محاسبات


تعداد ذرات	روش	زمان پردازش	RMSE
50	Proposed Method	31	0/007
	CPF[36]	12/9	0/087
	UPF[35]	14	0/09
	EPF[32]	12	0/023
30	Proposed Method	16	0/0081
	CPF[36]	8/5	0/016
	UPF[35]	9	0/017
	EPF[32]	7	0/039
10	Proposed Method	8	0/0083
	CPF[36]	5/5	0/026
	UPF[35]	6	0/028
	EPF[32]	4	0/045




شکل ۱۱- پروفایل جریان ورودی HPPC

برای ارزیابی بیشتر عملکرد روش پیشنهادی در تخمین SOC تست HPPC به عنوان یک پروفایل جریان پیچیده دیگر مورد استفاده قرار گرفته است. تست HPPC از آزمایش‌های معروف برای ارزیابی عملکرد الگوریتم‌های تخمین وضعیت شارژ باتری است. پروفایل مربوطه به جریان در تست HPPC در شکل (۱۱) نشان داده شده است.

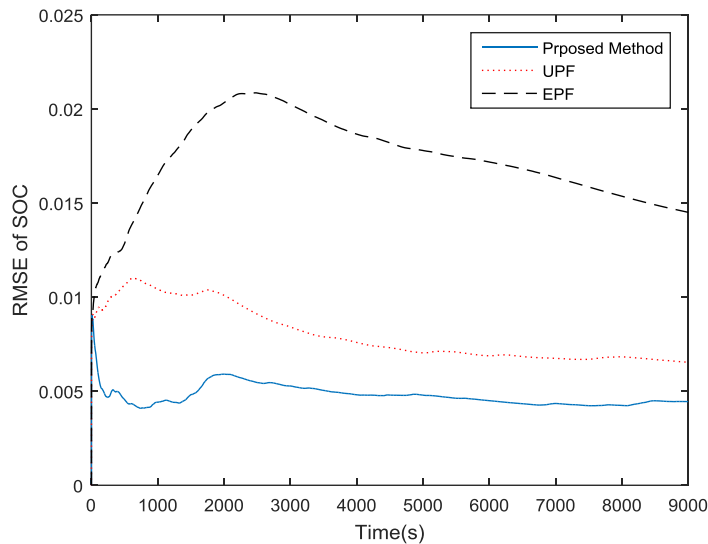
عملکرد روش پیشنهادی برای تخمین وضعیت شارژ باتری با تخمینگرهای EPF و UPF مورد ارزیابی قرار گرفته است. شکل‌های (۱۲) تا (۱۴) نتایج بدست آمده از روش‌های مختلف را در تست HPPC نشان می‌دهد. شکل‌های (۱۲) تا (۱۳) نتایج شامل مقدار واقعی وضعیت شارژ و مقدار تخمین زده شده آن با استفاده از روش پیشنهادی، EPF و UPF است. نتایج نشان می‌دهند که روش پیشنهادی از دقت بالاتری نسبت به سایر روش‌ها برخوردار است. شکل (۱۳) نشان می‌دهد که در روش پیشنهادی مقدار واقعی به مقدار تخمین زده شده نزدیک و به خوبی آن را دنبال کرده و همگرا است. در شکل ۱۴ مقدار RMSE در طول زمان مربوط به SOC در تست HPPC برای روش‌های مختلف نشان داده شده است. همانطور که مشاهده می‌شود همانند سایر آزمایشها در این حالت هم RMSE روش پیشنهادی از سایر روش‌ها کوچکتر و همگرایی آن بیشتر است.



شکل ۱۲- مقایسه تخمین SOC در تست HPPC




شکل ۱۳- زوم شده شکل (۱۲)




شکل ۱۴- RMSE در طول زمان مربوط به SOC در تست HPPC


در نهایت عملکرد روش پیشنهادی، با EPF و UPF در حالت شارژ شدن مقایسه شده است. پروفایل مربوطه به جریان در این تست در شکل (۱۵) نشان داده شده است. شکل (۱۶) تا (۱۷) تخمین وضعیت شارژ باتری را نشان می‌دهند. برای واضح شدن نتایج بخشی از شکل (۱۶) در شکل (۱۷) بزرگنمایی شده است. مقدار RMSE بدست آمده از روشهای مختلف در طول زمان در شکل (۱۸) نشان داده شده است. از این شکل دیده می‌شود که RMSE مربوط به روش پیشنهادی در تست‌ها همگرایی بیشتر و مقدار آن کمتر از سایر روش‌ها است.



شکل ۱۶- مقایسه تخمین SOC در تست HPPC



شکل ۱۷- زوم شده شکل (۱۶)



شکل ۱۸- RMSE در طول زمان مربوط به SOC

۶- نتیجه گیری

در این مقاله، تخمین وضعیت شارژ باتری لیتیوم یون بر اساس فیلتر ذره‌ای حاشیه‌ای کمکی بهبود یافته ارائه شده است. در روش پیشنهادی از عملگرهای ژنتیک و الگوریتم M-H برای بهبود عملکرد فیلتر ذره‌ای حاشیه‌ای کمکی در تخمین وضعیت شارژ باتری لیتیوم-یون استفاده شده است. استفاده از عملگرهای ژنتیک و الگوریتم M-H سبب افزایش تنوع میان ذرات می‌شود و در نتیجه باعث می‌شود ذرات نمونه برداری مجدد شده بطور مجانبی نمونه‌ها را از تابع چگالی احتمال پسین حالت واقعی تقریب بزنند و سازگاری تخمین‌ها افزایش یابد. تخمین وضعیت شارژ باتری مبتنی بر روش پیشنهادی با سایر تخمینگرها با استفاده از داده‌های آزمایش‌های معروف HPPC و FUDS در حالت شارژ و دشارژ باتری مورد ارزیابی قرار گرفته است. نتایج نشان می‌دهند عملکرد فیلتر پیشنهادی در تخمین وضعیت شارژ باتری بهتر از عملکرد سایر روش‌ها است. بعلاوه، وابستگی عملکرد روش پیشنهادی به تعداد ذرات کمتر از سایر روش‌ها است. جذر میانگین مربعات خطا در روش پیشنهادی با ذرات مختلف نزدیک ۰/۰۰۷ است در حالی که در سایر روش‌ها با کاهش ذرات، جذر میانگین مربعات خطا افزایش می‌یابد. در نتیجه روش پیشنهادی برای بدست آوردن دقت تخمین یکسان با فیلتر ذره‌ای به ذرات به مراتب کمتری نیاز دارد و حجم محاسبات آن پایین است. اگر چه روش پیشنهادی تخمین وضعیت شارژ باتری را بهبود داده است، اما هنوز امکان بهبود بیشتری وجود دارد. با توجه به اینکه در این پژوهش پارامترهای الگوریتم ژنتیک به صورت سعی و خطا تنظیم شده‌اند، تنظیم تطبیقی پارامترهای الگوریتم ژنتیک می‌تواند از کارهای آتی این پژوهش باشد. بعلاوه، هرچه مدل سیستم باتری دقیق‌تر باشد، دقت تخمین وضعیت شارژ بهتر خواهد بود. بنابراین، در ادامه در کارهای آینده سعی خواهد شد روش پیشنهادی در مرتبه بالا و تطبیقی استفاده شود. همچنین سعی خواهد شد با روش‌هایی، بار محاسباتی روش پیشنهادی کاهش داده شود.

- [1] M.Hassan, S.Saha, Md.E.Haque, S.Islam, A.Mahmud, N.Mendis, “A comprehensive review of battery state of charge estimation techniques,” *Sustainable Energy Technologies and Assessments*, vol.54, 2022
- [2] R.P.Narasipuram, S.A.Mopidevi, “ Technological overview & design considerations for developing electric vehicle charging stations,” *Journal of Energy Storage*, vol.43, 2021.
- [3] W.A.Choi, “Study on State of Charge and State of Health Estimation in Consideration of Lithium-Ion Battery Aging,” *Sustainability*, vol.12, no.24, 2020.
- [4] S.Iniyan, S.Jebaraj, L.Suganthi, AA.Samuel, “Energy models for renewable energy utilization and to replace fossil fuels,” *Methodology*, vol.67, pp.28-37, 2020.
- [5] Q.Yu, C.Wan, J.Li, L.E, X.Zhang, Y.Huang, and T.Liu, “Open circuit voltage model fusion method for state of charge estimation of Lithium-Ion Batteries,” *Energies*, vol.14, no.7, 2021.
- [6] W.Choi, “A study on state of charge and state of health estimation in consideration of Lithium-Ion battery aging,” *Sustainability*, vol.12, no.24, 2020
- [7] B.Zine, H.Bia, A.Benmouna, M.Becherif, and M.Iqbal, “Experimentally validated coulomb counting method for Battery State-of-Charge estimation under variable current profiles,” *Energies*, vol.15, no.21, 2022.
- [8] Y.Xiong, Y.Zhu, H.Xing, S.Lin, J.Xiao, C.Zhang, “An improved state of charge estimation of lithium-ion battery based on a dual input model,” *Energy Sources, Part A*, vol.45, no.1, 2023.
- [9] X. Bian, L.Liu, J.Yan, Z.Zou, R. Zhao, “An open circuit voltage-based model for state-of-health estimation of lithium-ion batteries Model development and validation,” *Journal of Power Sources*, vol.448, 2020
- [10] A.K.Birjandi, M.F. Alavi, M.Salem, M.E.H.Assad, N. Prabakaran, “Modeling carbon dioxide emission of countries in southeast of Asia by applying artificial neural network,” *International Journal of Low-Carbon Technologies*, 17, 321–326, 2022.
- [11] G.Javid, D.O.Abdeslam, M. Basset, “Adaptive online state of charge estimation of EVs Lithium-Ion batteries with deep recurrent neural networks,” *Energies*, vol.14, 2021.
- [12] M.H.A.Jamlouie, “Accuracy improvement of SOC estimation in lithium-ion batteries by ANFIS vs. ANN modeling of nonlinear cell characteristics,” *Journal of Energy Storage*, vol.6, pp.95–104, 2021.
- [13] R.Xiong, J.Cao, Q.Yu, H.He, “Critical review on the battery state of charge estimation methods for electric vehicles,” *IEEE Access*, vol.6, pp.1832–1843, 2018.
- [14] Y.Zeng, Y.Li, and T.Yang, “State of charge estimation for Lithium-Ion Battery based on unscented Kalman Filter and long short-term memory neural network,” *Batteries*, vol.9, no.7 2023.
- [15] Y.Tian, R.Lai, X.Li, J.Tian, “State-of-charge estimation for lithium-ion batteries based on attentional sequence-to-sequence architecture,” *Journal of Energy Storage*, vol. 62, 2023.
- [16] O.H.Junior, G.R.Sylvestrin, H.F.Scherer, “Experimental validation of state of charge estimation by extended Kalman filter and modified coulomb counting,” *IEEE Latin America Transactions*, vol.20, no.11, 2022.
- [17] P.Shrivastava, T.K.Soon, M.Y. I.Idris, S.Mekhilef, S.B.R.S.Adnan, “Combined state of charge and state of energy estimation of Lithium-Ion battery using dual forgetting factor-based adaptive extended Kalman filter for electric vehicle applications”, *IEEE Transactions on Vehicular Technology*, vol.20, no.2, 2021.
- [18] Y.Wei, L.Ling, “State-of-Charge Estimation for Lithium-Ion Batteries Based on Temperature-Based Fractional-Order Model and Dual Fractional-Order Kalman Filter,” *IEEE Access*, vol.10, 2022.

- [19] M.Hossain, M. E. Haque, S. Saha, M.T Arif, AMT. Oo, "State of Charge Estimation of Li-ion Batteries Based on Adaptive Extended Kalman Filter," IEEE Power & Energy Society General Meeting, 2020.
- [20] E.L.G.Lutzemberger, L.Pugi, "State-of-charge estimation based on model-adaptive Kalman filters," Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2021.
- [21] Z.Huang, M. Best, J.Knowles; A.Fly, "Adaptive piecewise equivalent circuit model with SOC/SOH estimation based on extended Kalman filter," IEEE Transactions on Energy Conversion, vol.38, no.2, 2023.
- [22] X.Shu, Z.Chen, J.Shen, F.Guo, Y.Zhang, Y.Liu, "State of Charge Estimation for Lithium-Ion Battery Based on Hybrid Compensation Modeling and Adaptive H-Infinity Filter," IEEE Transactions on Transportation Electrification, vol.9, no.1, 2023.
- [23] K.Li, F.Zhou, X.Chen, W.Yang, J.Shen, Z.Song, "State-of-charge estimation combination algorithm for lithium-ion batteries with Frobenius-norm-based QR decomposition modified adaptive cubature Kalman filter and H-infinity filter based on electro-thermal model," Energy, vol.263, Part C, 2023.
- [24] H.Ben Sassi, F. Errahimi, N.Es-Sbai, "State of charge estimation by multi-innovation unscented Kalman filter for vehicular applications," Journal of Energy Storage, vol.32, 2020.
- [25] X.Lin, Y.Tang, J.Ren, Y.Wei, "State of charge estimation with the adaptive unscented Kalman filter based on an accurate equivalent circuit model," Journal of Energy Storage, vol.41, 2021.
- [26] L.Chen, X.Wu, AM.Lopes, L.Yin, P.Li, "Adaptive State-of-Charge estimation of lithium-ion batteries based on square-root unscented Kalman filter," Energy, vol.6, no.8, 2022.
- [27] N.Shi, Z.Chen, M.Niu, Z.He, Y.Wang, J. Cui, "State-of-charge estimation for the lithium-ion battery based on adaptive extended Kalman filter using improved parameter identification," Journal of Energy Storage, vol.45, 2022.
- [28] S.Hosseininasab, N.Momtaheni, S.Pischinger, M.Günther, L.Bauer, "State-of-charge estimation of Lithium-ion batteries using an adaptive dual unscented Kalman filter based on a reduced-order model," Journal of Energy Storage, vol.73, Part D, 2023.
- [29] F.Xia, Z.Wang, C.Zhang, "State of charge estimation of Lithium-ion batteries with particle filter algorithm," The 46th Annual Conference of the IEEE Industrial Electronics Society, 2020.
- [30] V.Sangwan, R.Kumar, A.K. Rathore, "State-of-Charge estimation of Li-ion battery at different temperatures using particle filter," The Journal of Engineering, vol.2019, no.18, pp.5320–5324, 2019.
- [31] Yuanhong Xu, Mingcong Deng, "Particle filter design for robust nonlinear control system of uncertain heat exchange process with sensor noise and communication time delay," Applied Sciences, vol.12, no.5, 2022.
- [32] R.Havangi, "Simultaneous Estimation of model parameters and state-of-charge of Lithium-Ion Batteries using Recursive least squares and Modified Particle Filter," Computational Intelligence in Electrical Engineering, vol. 12, no.1, 2021.
- [33] B.Xia, B.Xia, S.Guo, W.Wang, Y. Lai, H.Wang, M.Wang, W.Zheng, "A State of Charge Estimation Method Based on Adaptive Extended Kalman-Particle Filtering for Lithium-ion Batteries," Energies, vol.11, no.10, 2018.
- [34] Y.Wang, Z.Chen, "A framework for state-of-charge and remaining discharge time prediction using unscented particle filter," Applied Energy, vol.260, 2020.
- [35] F.Liu, J.Ma, W.Su, "Unscented Particle Filter for SOC Estimation Algorithm Based on a Dynamic Parameter Identification" Mathematical Problems in Engineering, vol.2019, 2019.
- [36] X.Wei, C.Jun, G.Yu, M.Jiachen, C.Jiaqing, "Unscented particle filter based state of energy estimation for LiFePO4 batteries using an online updated model," International Journal of Automotive Technology, vol.23, pp.503–510, 2022.

- [37] K.Zhang,J.Ma,X.Zhao,D. Zhang,Y.He,“State of charge estimation for Lithium battery Based on adaptively weighting cubature particle filter,” *IEEE Access*,vol.7,2019.
- [38] C.Kuptamete, N.Aunsri, “Review of resampling techniques in particle filtering framework,” *Measurement*, vol.193, 2022.
- [39] X.Zhang, L.Zhao,W.Zhong,F.Gu, “Performance Analysis of Resampling Algorithms of Parallel Distributed Particle Filters,” *IEEE Access*, vol.9, 2021.
- [40] H.A.Khidir, İ.Etikan, D.H.Kadir, N.H.Mahmood, R.Sabetvand, “Bayesian machine learning analysis with Markov Chain Monte Carlo techniques for assessing characteristics and risk factors of Covid-19 in Erbil City-Iraq 2020–2021,” *Alexandria Engineering Journal*,vol.78, pp.162-174, 2023.
- [41] <https://data.mendeley.com/datasets/wykht8y7tg/1>