



پیاده‌سازی سیستم تطبیقی فازی-عصبی در مدل‌سازی و تخمین حالت شارژ باتری‌های لیتیوم-یون

محمد نصیری^۱، محمدحسین کاظمی^{۲*}

*نویسنده مسئول، دریافت: ۱۴۰۰/۰۲/۲۹، بازنگری: ۱۴۰۰/۰۶/۰۱، پذیرش: ۱۴۰۰/۰۶/۳۱

^۱ کارشناسی ارشد، مهندسی برق - کنترل، دانشگاه شاهد، تهران، ایران
^۲ دانشیار، دانشکده فنی و مهندسی، دانشگاه شاهد، تهران، ایران

چکیده

در این مقاله با بکارگیری یک شبکه عصبی فازی و براساس مدل فضای حالت باتری‌های لیتیوم-یون، حالت شارژ باتری تخمین زده می‌شود. داده‌های آزمایشگاهی نمونه‌برداری از باتری، عبارتند از سیگنال‌های ولتاژ و جریان پایانه‌های باتری که برای مدل‌سازی باتری مورد استفاده قرار می‌گیرند. با اجرای پنجره لغزان، پارامترهای مدل سیستم در پنجره‌های کاری مختلف براساس روش کمترین مربعات خطا شناسایی شده و با استفاده از یک شبکه عصبی فازی آموزش داده می‌شوند. سپس از تئوری فیلتر کالمن بهره برده و یک الگوریتم جهت تخمین حالت شارژ ارائه می‌شود. سه دسته داده عملی از اطلاعات ولتاژ و جریان باتری به صورت جداگانه جمع‌آوری شده و برای آموزش شبکه عصبی فازی، تعیین صحت عملکرد تخمین پیشنهادی و مدل آموزش یافته، بکار گرفته می‌شوند. برای هر سه دسته از داده‌ها، مقایسه تخمین به روش پیشنهادی و روش‌های فیلتر تطبیقی H_∞ ، EKF و SRUKF صورت پذیرفت که نتایج نشان می‌داد روش پیشنهادی در تمام حالات از شاخص خطای تخمین مناسب‌تری برخوردار می‌باشد.

کلمات کلیدی: حالت شارژ باتری، شبکه عصبی فازی، فیلتر کالمن

۱- مقدمه

دهد. در کاربردهایی که عموماً دوره‌های طولانی از استراحت، یعنی عدم شارژ و دشارژ باتری وجود دارد، روش ذکر شده پیشنهاد می‌گردد. در این حالت اندازه‌گیری ولتاژ مدار باز بیشتر برای تنظیم کردن روش‌های دیگر تخمین حالت شارژ به کار می‌رود [۳،۴]. این روش به صورت برون خط و تست آزمایشگاهی می‌باشد [۵].

روش دیگر تعیین حالت شارژ، شمارش آمپر ساعت می‌باشد که از جریان شارژ یا دشارژ برای اندازه‌گیری حالت شارژ باتری استفاده می‌کند چرا که شارژ و دشارژ بطور مستقیم به جریان باتری بستگی دارند. روش ذکر شده علاوه بر نیاز به دانستن شرایط اولیه حالت شارژ دارای دو مشکل اساسی است، نخست آنکه اندازه‌گیری نادرست جریان می‌تواند به خطای زیادی منجر گردد، بنابراین نیازمند حسگرهای دقیق اندازه‌گیری جریان می‌باشد. دوم اینکه تمام جریانی که باتری را تغذیه می‌کند برای شارژ مصرف نمی‌گردد، در نتیجه تلفات داخلی باتری باید

برای تخمین حالت شارژ باتری روش‌های مختلفی بیان شده است که هر کدام از این روش‌ها خصوصیات مربوط به خود را دارد. فعالیت‌ها و کارهای زیادی در این زمینه انجام گرفته است که آنها را می‌توان به دو دسته کلاسیک و هوشمند تقسیم کرد. روش کلاسیک شامل روش ولتاژ مدار باز و شمارش آمپر ساعت و روش فیلتر کالمن ... است و روش هوشمند را می‌توان شامل بکارگیری شبکه‌های فازی و عصبی و... دانست. حالت شارژ باتری به صورت کلی عبارت است از نسبت شارژ ذخیره شده در باتری، به کل شارژ قابل ذخیره در آن [۱،۲]. یکی از روش‌های ساده‌ای که در تعیین مقدار شارژ باتری استفاده می‌شود روش ولتاژ مدار باز می‌باشد. ولتاژ مدار باز باتری بصورت مستقیم به حالت شارژ آن بستگی دارد. این وابستگی می‌تواند رابطه‌ای بین مقدار حالت شارژ و ولتاژ پایانه‌های باتری را نشان

کنیم ولتاژ خروجی در لحظه فعلی به ولتاژ لحظه قبل و حالت شارژ لحظه فعلی و جریان لحظه فعلی وابسته است، می‌توان این وابستگی را به صورت زیر نشان داد.

$$v_{i,k} = av_{i,k-1} + bz_k + di_k \quad (2)$$

پارامترهای a ، b ، و d با تغییر حالت شارژ تغییر می‌کنند و تابعی از آن می‌باشند که با استفاده از سیگنال‌های اندازه‌گیری می‌توان آنها را از روش کمترین مربعات خطا در پنجره‌هایی از حالت شارژ ثابت محاسبه کرد. این پارامترها در نهایت توسط یک شبکه انفیس و به ازای بازه کل تغییرات حالت شارژ تعیین می‌شوند. برای توصیف سیستم در فضای حالت لازم است که در ابتدا متغیرهای حالت مشخص شوند. فرض کنید $x_k \triangleq [v_{i,k-1} \ z_k]^T$ بردار متغیر حالت باشد که شامل ولتاژ پایانه باتری در لحظه قبل، $v_{i,k-1}$ ، و حالت شارژ در زمان فعلی، z_k ، می‌باشد. در این صورت مدل خطی زیر را می‌توان برای توصیف باتری در نظر گرفت [۲۴].

$$x_{k+1} = \begin{bmatrix} v_{i,k} \\ z_{k+1} \end{bmatrix} = \begin{bmatrix} a & b \\ 0 & 1 \end{bmatrix} x_k + \begin{bmatrix} d \\ \frac{\eta_i \Delta t}{C_i} \end{bmatrix} i_k + \begin{bmatrix} \omega_1(k) \\ \omega_2(k) \end{bmatrix} \quad (3)$$

$$y_k = v_{i,k} = [a \ b] x_k + di_k + v_k$$

که $\omega(k) = [\omega_1(k) \ \omega_2(k)]^T$ و v_k به ترتیب نویزهای فرآیند و اندازه‌گیر به فرم سفید با توزیع گوسی و میانگین صفر و مستقل از یکدیگر هستند. حال معادله کلی فضای حالت به صورت زیر درمی‌آید.

$$x_{k+1} = A_k x_k + B_k u_k + \omega_k \quad (4)$$

$$y_k = C_k x_k + D_k u_k + v_k$$

که؛

$$A_k \triangleq \begin{bmatrix} a & b \\ 0 & 1 \end{bmatrix}, B_k \triangleq \begin{bmatrix} d \\ \frac{\eta_i \Delta t}{C_i} \end{bmatrix}, C_k \triangleq [a \ b], D_k \triangleq d \quad (5)$$

با تعیین پارامترهای a ، b ، و d می‌توان مدل فضای حالت (۴) را تشکیل داد و یک تخمینگر مناسب برای متغیرهای حالت طراحی نمود، یعنی حالت شارژ را تخمین زد.

۳- شبکه فازی عصبی و تخمین پارامترها

جهت شناسایی مدل، فرآیند شارژ پالسی مورد استفاده قرار گرفته است طوری که باتری از وضعیت کامل دشارژ به وضعیت شارژ کامل برسد. شکل (۱) داده‌های اندازه‌گیری شده که از [۱۳] اقتباس شده‌اند را نشان می‌دهد. جهت نمایش واضح‌تر، شکل (۲) مقادیر داده‌ها را در یک بازه زمانی ۵۰ ثانیه نشان می‌دهد. جریان شارژ، سیگنالی متناوب شامل پالس مثبت جریان، دوره استراحت و پالس منفی جریان می‌باشد. دوره تناوب سیگنال جریان برابر ۲۵ ثانیه انتخاب شده است. بنابراین پارامترهای a ، b ، و d را می‌توان در هر دوره تناوب و با روش کمترین مربعات خطا و با استفاده از مدل رگرسیون زیر که از معادله (۲) نتیجه می‌شود، بدست آورد.

$$v_{i,k} = [v_{i,k-1} \ z_k \ i_k] \begin{bmatrix} a \\ b \\ d \end{bmatrix} \quad (6)$$

محاسبه کردند. مشکل نخست با استفاده از صرف هزینه برای تهیه تجهیزات اندازه‌گیری دقیق جریان قابل انجام است، در صورتی که برای مشکل دوم روش‌های محاسباتی بسیاری پیشنهاد و توسعه یافته‌اند [۵،۶].

در بعضی از روش‌ها، حالت شارژ به عنوان یک متغیر حالت از معادله دینامیکی مستقیماً توسط فیلتر کالمن تعمیم یافته (EKF^1) [۱۰-۱۲،۲۷] و $SPKF^2$ [۱۱] و یا رویترگر لونبرگر [۱۲] و فیلتر H_{∞} [۱۶-۱۳] محاسبه می‌شود. برخی از محققین شبکه عصبی مصنوعی را در تخمین حالت شارژ مورد استفاده قرار داده‌اند [۱۷-۲۱]. آنها شبکه را بصورت برون خط برای تقریب رابطه بین حالت شارژ به عنوان متغیر خروجی و سایر پارامترها به عنوان متغیرهای ورودی آموزش داده و جهت تخمین حالت شارژ بکار گرفته‌اند. این روش بسیار حساس به ساختار شبکه و نحوه آموزش می‌باشد. فیلتر کالمن یکی از تخمین‌گرهای کلاسیک است که برای تخمین حالت‌های داخلی یک سیستم دینامیکی مورد استفاده قرار می‌گیرد. در برخی از تحقیقات از این فیلتر جهت تخمین ولتاژ مدار باز و یا دیگر کمیت‌های باتری که وابسته به حالت شارژ هستند استفاده شده است [۲۳،۲۲،۱۶]. اما در برخی از کارهای اخیر، حالت شارژ نیز به عنوان یکی از متغیرهای حالت تعریف شده و توسط فیلترهای کالمن مختلف مستقیماً تخمین زده می‌شود [۲۴-۲۷]. در اکثر این کارها از مدارهای معادل غیرخطی و یا معادلات دیفرانسیل شیمیایی استفاده شده است که سبب می‌شود انرژی زیادی صرف شناسایی پارامتر و یا الگوریتم‌های پیچیده تخمین شود. یکی دیگر از روش‌های تخمین حالت شارژ، استفاده از فیلتر H^{∞} تطبیقی می‌باشد [۱۳-۱۶]. در این فیلتر سعی می‌شود ماکزیمم انرژی خطا در بدست آوردن تخمین به حداقل برسد.


نوآوری این مقاله، ارائه یک روش جدید برای مدل‌سازی و تخمین حالت شارژ در فضای حالت است که بخش مدل‌سازی آن مبتنی بر روش ارائه شده در [۱۳] و بهبود آن با بکارگیری شبکه انفیس^۳ جهت تعیین پارامترهای مدل می‌باشد و نیازی به تست‌های عملی جداگانه برای اندازه‌گیری ولتاژ مدار و دیگر پارامترهای مرتبط با حالت شارژ ندارد [۸-۱۰،۱۲،۲۱-۱۸]. روش پیشنهادی در این مقاله به روی داده‌های آزمایشی یک باتری لیتیوم-یون برگرفته از مرجع [۱۳]، پیاده‌سازی گردیده است که نتایج آن نشان دهنده کارایی روش پیشنهادی نسبت به روش‌های دیگر، [۲۸،۲۴،۱۳]، می‌باشد.

۲- مدل‌سازی

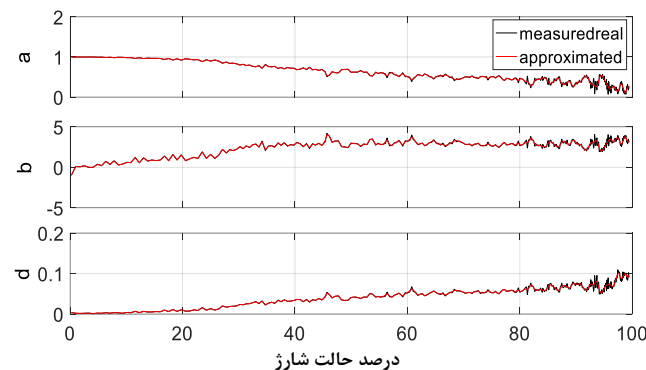
همانطور که در بخش مقدمه بیان شد، قسمت مدل‌سازی سیستم برگرفته از مرجع [۱۳] می‌باشد که بطور مختصر در این بخش بیان می‌گردد. حالت شارژ یک باتری عبارتست از نسبت شارژ انباشته شده به کل ظرفیت شارژ، بنابراین می‌توان آنرا تحت یک کمیت بدون دیمانسیون از انتگرال جریان علامت‌دار باتری همراه با یک ضریب نرمالایز کننده در بازه صفر و یک درآورد [۵،۶]. این انتگرال با یک تقریب عددی با رابطه تفاضلی زیر معادل خواهد شد [۲،۱].

$$z_{k+1} = z_k - \left(\frac{\eta_i \Delta t}{C_i} \right) i_k \quad (1)$$


که z_k حالت شارژ، i_k جریان علامت‌دار باتری (مثبت برای دشارژ) در زمان نمونه‌برداری k ، Δt بازه زمان نمونه‌برداری، η_i راندمان کلمب^۴ ($\eta_i < 1$) برای شارژ و $\eta_i = 1$ برای دشارژ) و C_i ماکزیمم ظرفیت قابل دسترس است که ممکن است تحت تأثیر دما و عمر باتری قرار گیرد. حالت شارژ تعریف شده در معادله (۱) را می‌توان به عنوان یک متغیر حالت در نظر گرفت [۲۸،۲۴]. اگر فرض



شکل ۲- داده‌های آزمایشگاهی ولتاژ و جریان باتری باز شده در یک بازه زمانی ۵۰ ثانیه‌ای جهت نمایش بهتر



شکل ۳- مقایسه مقادیر پارامترهای a ، b ، d و تقریب آنها توسط شبکه انفیسی





شکل ۴- خطای بین خروجی مدل و سیگنال اندازه‌گیری شده تحت داده‌های اعتبار سنجی

برای اطمینان بهتر از نحوه عملکرد شبکه انفیسی یکسری داده که از اواسط شارژ باتری به بعد، حالت شارژ ۶۵٪، گرفته شده (داده‌های ۶۵٪) مورد آزمایش قرار داده می‌شود. کلا در این مقاله سه دسته داده از اطلاعات ولتاژ و جریان باتری به صورت جداگانه برای آموزش شبکه، تعیین صحت عملکرد فیلتر کالمن و مدل آموزش یافته، بکار گرفته شد (داده‌های آموزش، داده‌های اعتبارسنجی و داده‌های

از آنجا که در هر دوره تناوب شارژ پالسی، درصد کمی شارژ صورت می‌گیرد (کمتر از ۵ درصد)، می‌توان فرض کرد که در هر دوره تناوب مقدار حالت شارژ ثابت است و در نتیجه می‌توان پارامترها را برحسب حالت شارژ و از روش کمترین مربعات خطا تخمین زد.

حال برای مشخص کردن پارامترها برحسب مقادیر مختلف حالت شارژ، از شبکه انفیسی استفاده می‌شود. شبکه انفیسی می‌تواند برازش منحنی را به خوبی تقریب بزند. همانطور که می‌دانیم برای آموزش شبکه انفیسی [۲۹] باید ورودی و خروجی شبکه مشخص شود در اینجا ورودی شبکه انفیسی حالت شارژ و خروجی شبکه انفیسی پارامترهای a ، b ، d می‌باشند که نمونه‌های آن از روش کمترین مربعات خطا بدست آمده‌اند. سه شبکه جهت تخمین هر یک از پارامترها بکار گرفته شده است. این شبکه‌ها ابتدا آموزش و سپس آزمایش می‌شوند. مشخصات شبکه انفیسی طراحی شده از این قرار هستند: در لایه اول از توابع عضویت ناقوسی، که هر تابع دارای سه پارامتر غیرخطی است استفاده شده است. در لایه دوم ۱۰۰ گره ثابت قرار دارد که حاصل ضرب سیگنال ورودی را در خروجی ظاهر می‌نماید. در لایه سوم نیز ۱۰۰ گره ثابت قرار دارد که عمل نرمالیزه کردن سیگنال حاصل از لایه دوم را بر عهده دارد. در لایه ۴ قواعد اگر- آنگاه فازی، بر پایه سیستم فازی تاکاگی و سوگنو استفاده می‌گردد. الگوریتم یادگیری هیبرید است که از تلفیق روش گردایان نزولی و تخمین حداقل مربعات اتخاذ می‌شود.

با تنظیم پارامترهای شبکه و پس از آموزش آن، شکل (۳) مقایسه پاسخ شبکه انفیسی را با مقادیر واقعی بدست آمده از اندازه‌گیری نشان می‌دهد. همانطور که در این شکل دیده می‌شود پاسخ شبکه از تقریب بسیار خوبی برخوردار است. حال مدل خطی فضای حالت سیستم (۳)، پارامترهای خود را از شبکه انفیسی دریافت می‌دارد و آماده برای مراحل بعدی می‌باشد. شکل (۴) خطای خروجی (ولتاژ پایانه باتری) بین مدل بدست آمده و خروجی اندازه‌گیری شده را تحت داده‌های اعتبارسنجی نشان می‌دهد.



شکل ۱- داده‌های کامل آزمایشگاهی ولتاژ و جریان باتری در فرآیند شارژ کامل جهت شناسایی پارامترها

می‌باشند [۲۲]. بنابراین الگوریتم تخمین حالت شارژ را مبتنی بر فیلتر کالمن و بکارگیری شبکه انفیس می‌توان بصورت زیر ارائه داد.

قدم اول: مقدار دهی شرایط اولیه حالت x_0 و ماتریس‌های کوواریانس P ، R و Q .

قدم دوم: محاسبه پارامترهای a_k ، b_k و d_k از شبکه انفیس و مدل باتری
(۵) از (A_k, B_k, C_k, D_k) .

قدم سوم: بروز رسانی زمانی تخمین حالت و کوواریانس خطا

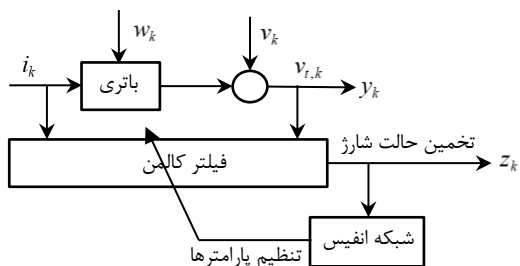
$$\begin{aligned} \hat{x}_k^- &= A_{k-1}\hat{x}_{k-1} + B_{k-1}u_{k-1} \\ P_k^- &= A_{k-1}P_{k-1}A_{k-1}^T + Q \end{aligned} \quad (7)$$

قدم چهارم: محاسبه بهره کالمن

$$G_k = P_k^- C_k^T (C_k P_k^- C_k^T + R)^{-1} \quad (8)$$

قدم پنجم: بروز رسانی اندازه‌گیری تخمین حالت و کوواریانس خطا


$$\begin{aligned} \hat{x}_k &= \hat{x}_k^- + G_k [y_k - (C_k \hat{x}_k^- + D_k u_k)] \\ P_k &= (I - G_k C_k) P_k^- \end{aligned} \quad (9)$$



شکل ۶- بلوک دیاگرام مفهومی الگوریتم تخمین حالت شارژ پیشنهادی


۵- نتایج پیاده‌سازی

برای بررسی صحت عملکرد تخمین‌گر ابتدا باتری کاملاً دشارژ می‌شود تا اطمینان حاصل شود که حالت شارژ اولیه باتری برابر صفر است. سپس با استفاده از روش شارژ بازتابی، باتری تا حالت شارژ کامل، شارژ می‌شود. اطلاعات فرآیند شارژ با نرخ نمونه برداری ۵۰ میلی ثانیه در رایانه ذخیره می‌شود و از روش شمارش آمپر ساعت، حالت شارژ بدست می‌آید. حال جهت تخمین حالت شارژ، الگوریتم پیشنهادی بکار گرفته می‌شود. شکل (۷) تخمین حالت شارژ را به همراه مقدار محاسبه شده نشان می‌دهد. همانطور که در شکل مشخص است تخمین حالت شارژ توانسته است بخوبی مقدار واقعی را دنبال کند.



شکل ۷- تخمین حالت شارژ براساس داده‌های اصلی

شکل (۵) خطای خروجی بین مدل بدست آمده و خروجی اندازه‌گیری شده را تحت این داده‌های ۶۵٪ نشان می‌دهد. مقدار خطا در این حالت کمی بیشتر از حالت قبل است، حدود ۰/۲، اما هنوز در محدوده قابل قبول قرار دارد [۱۳].



شکل ۵- خطای بین خروجی مدل و سیگنال اندازه‌گیری شده تحت داده‌های ۶۵٪

۴- الگوریتم تخمین

با داشتن شبکه انفیس و با قرار دادن حالت شارژ به عنوان ورودی می‌توان در هر لحظه پارامترهای a ، b و d را محاسبه کرد. با دانستن این پارامترها و استفاده از آن در مدل فضای حالت می‌توان از یک تخمین‌گر کالمن ساده جهت تخمین حالت شارژ بهره برد. شکل (۶) بلوک دیاگرام مفهومی آنرا نشان می‌دهد. فیلتر کالمن ابزاری قوی و پرکاربرد است که بطور کلی در یک سیستم خطی می‌تواند یک تخمین بهینه از متغیرهای حالتی که بطور مستقیم قابل اندازه‌گیری نیستند ارائه دهد. هرچند که در سیستم‌های غیرخطی نظیر باتری‌ها نیز می‌توان بطور هوشمندانه از فیلتر کالمن استفاده نمود. برای توصیف بیشتر فیلتر کالمن می‌توان به مرجع [۱۵] مراجعه نمود. فیلتر کالمن سعی در کمینه کردن میانگین مربعات خطا دارد. خروجی فیلتر کالمن به شکل بازگشتی محاسبه می‌شود و بهنگام‌سازی حالت‌های جدید با استفاده از حالت قبلی و داده ورودی انجام می‌شود. بنابراین فقط کافیست که حالت تخمین زده شده قبلی در حافظه نگهداری شود و به همین دلیل این الگوریتم برای پیاده‌سازی دیجیتال مناسب است. فرمول‌بندی ریاضی این مسئله با استفاده از مفاهیم فضای حالت قابل بیان است. می‌توان یک مدل فضای حالت تعریف کرد و پارامترهای تخمین زده شده را حالت‌های این مدل در نظر گرفت. البته بایستی مدل برای فیلتر کالمن شناخته شده باشد. این شناخت به معنای دانستن پارامترهای مدل فضای حالت و آمارگان متغیرهای سیستم است. حالت‌های داخلی مدل توسط یک فرآیند تصادفی به‌عنوان ورودی تعیین می‌شوند. فیلتر کالمن با دانستن مدل سیستم، آمارگان متغیرهای آن و یک اندازه‌گیری مغشوش از سیگنال دریافتی قادر به تخمین حالت سیستم برحسب کمترین مربعات خطا است [۲۴، ۲۸، ۳۰]. مدل معرفی شده برای باتری، (۴)، یک مدل خطی ولی با پارامترهای متغیر است. فیلتر کالمنی که برای تخمین حالت‌های یک سیستم خطی متغیر با زمان منتج از خطی‌سازی یک سیستم غیرخطی، طراحی شده باشد می‌باشد، فیلتر کالمن تعمیم یافته (EKF) نامیده می‌شود. هر چند رفتار فیلتر EKF برای یک سیستم غیرخطی غیربهینه می‌باشد ولی در اکثر کاربردها پاسخ دقیقی از خود نشان می‌دهد [۳۱]. یکی از نکات کلیدی در طراحی فیلتر کالمن، انتخاب مناسب ماتریس‌های کوواریانس برای نویزهای اندازه‌گیر و فرآیند می‌باشد. ماتریس کوواریانس نویز اندازه‌گیر (R) مستقیماً از داده‌های باتری قابل تعیین می‌باشد. واریانس‌ها را می‌توان براحتی از توان دوم جذر میانگین مربعات (rms) اندازه‌گیری‌های نویزی و ولتاژ پایانه باتری محاسبه نمود. فرض می‌شود که نویزها مستقل هستند و دارای توزیع گوسی

جدول ۱ - مقایسه شاخص‌های میانگین و جذر میانگین مربعات درصد خطای تخمین با روش‌های مختلف وبا داده‌های متفاوت

تست	درصد میانگین خطا			پیشنهادی
	AHF	SRUKF	EKF	
اصلی	0.01	0.02	0.75	1
اعتبارسنجی	0.53	0.84	1.25	1.7
داده‌های ۶۵٪	1.09	1.17	1.86	2.04

تست	درصد جذر میانگین مربعات خطا (rms)			پیشنهادی
	AHF	SRUKF	EKF	
اصلی	1.59	2.29	1.57	2.03
اعتبارسنجی	2.92	3.35	3.03	3.05
داده‌های ۶۵٪	2.42	2.23	4.22	4.25


۶- نتیجه‌گیری

در این مقاله تخمین‌گر حالت شارژ باتری براساس مدل فضای حالت طراحی و پیاده‌سازی گردید. سیگنال‌های ولتاژ و جریان از پایانه‌های باتری نمونه‌برداری و برای شناسایی باتری مورد استفاده قرار گرفتند. با بکارگیری یک شبکه فازی عصبی پارامترهای مدل بصورت تابعی از حالت شارژ تعیین و با استفاده از فیلتر کالمن یک الگوریتم برای تخمین حالت شارژ ارائه گردید. با استفاده از داده‌های آزمایش عملی اخذ شده از مرجع [۱۳]، سه دسته داده از اطلاعات ولتاژ و جریان باتری به صورت جداگانه برای آموزش شبکه، تعیین صحت عملکرد فیلتر کالمن و مدل آموزش یافته، بکار گرفته شد (داده‌های آموزش، داده‌های اعتبارسنجی و داده‌های ۶۵٪). برای هر سه دسته از داده‌ها، مقایسه تخمین به روش پیشنهادی و روش‌های فیلتر تطبیقی H_∞ ، EKF و SRUKF صورت پذیرفت که نتایج نشان می‌داد روش پیشنهادی در تمام حالات از شاخص خطای تخمین مناسب‌تری برخوردار می‌باشد.

۶- مراجع


- [1] H. He, R. Xiong, X. Zhang, F. Sun, and J. Fan, "State-of-charge estimation of the Lithium-Ion battery using an adaptive extended Kalman filter based on an improved Thevenin model," *IEEE Trans. Veh. Technol.*, vol. 60, no. 4, pp. 1461-1469, 2011.
- [2] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs Part 2. Modeling and identification," *J. Power Sources*, vol. 134, no. 2, pp. 262-276, 2004.
- [3] S.-J. Huang, B.-G. Huang, and F.-S. Pai, "An approach to measurements of electrical characteristics of lithium-ion battery with open-circuit voltage function," *IET Power Electron.*, vol. 5, no. 9, pp. 1968-1975, 2012.
- [4] L. Pei, R. Lu, and C. Zhu, "Relaxation model of the open-circuit voltage for state-of-charge estimation in lithium-ion batteries," *IET Electr. Syst. Transp.*, vol. 3, no. 4, pp. 112-117, 2013.
- [5] V. Pop, H. J. Bergveld, P. H. L. Notten, and P. P. L. Regtien, "State-of-the-art of battery state-of-charge determination," *Meas. Sci. Technol.*, vol. 16, no. 12, pp. R93-R110, 2005.
- [6] S. Piller, M. Perrin, and A. Jossen, "Methods for state-of-charge determination and their applications," *J. Power Sources*, vol. 96, no. 1, pp. 113-120, 2001.
- [7] S. X. Chen, H. B. Gooi, N. Xia, and M. Q. Wang, "Modeling of lithium-ion battery for online energy management systems," *IET Electr. Syst. Transp.*, vol. 2, no. 4, pp. 202-210, 2012.
- [8] Z. Chen, Y. Fu, and C. ChrisMi, "State of charge estimation of Lithium-Ion batteries in electric drive vehicles using extended Kalman filtering," *IEEE Trans. Veh. Technol.*, vol. 62, no. 3, pp. 1020-1030, 2013.
- [9] J. Kim, S. Lee, and B. H. Cho, "Complementary cooperation algorithm based on DEKF combined with pattern recognition for SOC/capacity

برای روشن‌تر شدن درستی تخمین‌گر طراحی شده و ارزیابی عملکرد آن، دسته دیگری از داده‌ها مورد آزمایش قرار می‌گیرد. برای این کار ابتدا باتری را یک بار دیگر کاملاً دشارژ کرده و سپس توسط مدار شارژر با استفاده از اعمال سیگنال جریان مجدداً آنرا شارژ می‌کنیم. در حین عمل شارژ، داده‌ها (جریان و ولتاژ باتری) با نرخ ۵۰ میلی ثانیه نمونه‌برداری می‌شوند. سپس حالت شارژ باتری با استفاده از الگوریتم پیشنهادی تخمین زده می‌شود. شکل (۸) نتیجه تخمین را در این حالت نشان می‌دهد.



شکل ۸ - تخمین حالت شارژ با داده‌های اعتبارسنجی

در آزمایش بعدی از داده‌هایی که از اواسط شارژ از باتری، حالت شارژ ۶۵٪، گرفته شده بود (داده‌های ۶۵٪) جهت تخمین حالت شارژ استفاده شده است که نتیجه تخمین در شکل (۹) مشاهده می‌شود.



شکل ۹ - تخمین حالت شارژ وبا داده‌های ۶۵٪ اعتبارسنجی

برای مقایسه نتایج روش پیشنهادی با روش‌های موجود، الگوریتم پیشنهادی در مرجع [۱۳] مورد بررسی قرار گرفته است. در این مرجع فیلتر تطبیقی H_∞ (AHF^۵) پیشنهاد شده است و پارامترهای مدل سیستم را از تقریب چندجمله‌ای‌ها و کمترین مربعات خطا محاسبه می‌کند. همچنین نتایج تخمین حاصل از روش‌های EKF و SRUKF که در [۲۴، ۲۸] پیشنهاد شده‌اند نیز مورد مقایسه قرار گرفته‌اند. با توجه به اینکه در نمایش این مقایسه بصورت منحنی تفاوتها قابل تفکیک نیستند، در جدول (۱) شاخص‌های میانگین و جذر میانگین مربعات (rms) درصد خطای تخمین با روش‌های مختلف وبا داده‌های متفاوت جهت مقایسه نشان داده شده است. همانطور که این جدول نشان می‌دهد روش پیشنهادی توانسته است که از شاخص خطای مناسبی برخوردار شود.

محمد نصیری کارشناسی ارشد برق گرایش کنترل از دانشگاه شاهد، تهران، ایران، در سال ۱۳۹۶ است. علاقه‌مندی پژوهشی ایشان در موضوعات کنترل شارژ باتری‌ها، الگوریتم‌های هوشمند، شبکه‌های عصبی



می‌باشد. آدرس پست الکترونیکی ایشان عبارتست از:

m.nasiri75@gmail.com

محمدحسین کاظمی عضو هیئت علمی دانشگاه شاهد گرایش برق-کنترل است. ایشان فارغ التحصیل دکترای برق کنترل از دانشگاه امیر کبیر در سال ۱۳۸۰، کارشناسی ارشد کنترل از دانشگاه صنعتی



شریف، و کارشناسی الکترونیک از دانشگاه صنعتی خواجه نصیر می‌باشد. موضوعات پژوهشی مورد علاقه وی روباتیک، هوش مصنوعی و سیستم‌های قدرت است. آدرس پست الکترونیکی ایشان عبارتست از:

kazemi@shahed.ac.ir

¹ Extended Kalman Filter

² Sigma-Point Kalman Filter

³ Anfis

⁴ Columbic efficiency

⁵ Adaptive H_{∞} Filter

- estimation and SOH prediction," *IEEE Trans. Power Electron.*, vol. 27, no. 1, pp. 436–451, 2012.
- [10] R. Xiong, H. He, F. Sun, and K. Zhao, "Evaluation on state of charge estimation of batteries with adaptive extended Kalman filter by experiment approach," *IEEE Trans. Veh. Technol.*, vol. 62, no. 1, pp. 108–117, 2013.
- [11] G. L. Plett, "Sigma-point Kalman filtering for battery management systems of LiPB-based HEV battery packs Part 2: Simultaneous state and parameter estimation," vol. 161, no. 2, pp. 1369–1384, 2006, doi: 10.1016/j.jpowsour.2006.06.004.
- [12] H. Rahimi-Eichi, F. Baronti, and M.-Y. Chow, "Online adaptive parameter identification and state-of-charge coestimation for Lithium-Polymer battery cells," *IEEE Trans. Ind. Electron.*, vol. 61, no. 4, pp. 2053–2061, 2014.
- [13] M. Charkhgard and M. H. Zarif, "Design of adaptive H_{∞} filter for implementing on state-of-charge estimation based on battery state-of-charge-varying modelling," *IET Power Electron.*, vol. 8, no. 10, pp. 1825–1833, 2015, doi: 10.1049/iet-pel.2014.0523.
- [14] D. Labarre, E. Grivel, N. Christov, and M. Najim, "Dual H_{∞} algorithms for signal processing, application to speech enhancement," *IEEE Trans. Signal Process.*, vol. 55, no. 11, pp. 5195–5208, 2007.
- [15] D. Simon, *Optimal State Estimation: Kalman, H Infinity, and Nonlinear Approaches*, 1st ed. USA: John Wiley & Sons, INC, 2006.
- [16] F. Zhang, G. Liu, L. Fang, and H. Wang, "Estimation of battery state of charge with H_{∞} observer: applied to a robot for inspecting power transmission lines," *IEEE Trans. Ind. Electron.*, vol. 59, no. 2, pp. 1086–1095, 2012.
- [17] C. H. Cai, D. Du, and Z. Y. Liu, "Battery state-of-charge (SOC) estimation using adaptive neuro-fuzzy inference system (ANFIS)," in *Fuzzy Systems*, 2003, pp. 1068–1073.
- [18] C.-H. Cai, Dong-Du, Z.-Y. Liu, and H. Zhang, "Artificial neural network in estimation of battery state of-charge (SOC) with nonconventional input variables selected by correlation analysis," in *Machine Learning and Cybernetics*, 2002, pp. 1619–1625.
- [19] C. Cai, D. Du, Z. Liu, and J. Ge, "State-of-charge (SOC) estimation of high power Ni-MH rechargeable battery with artificial neural network," in *Neural Information Processing*, 2002, pp. 824–828.
- [20] J. Peng, Y. Chen, and R. Eberhart, "Battery pack state of charge estimator design using computational intelligence approaches," in *Battery Conference on Applications and Advances*, 2000, pp. 173–177.
- [21] T. Yamazaki, K. Sakurai, and K. Muramoto, "Estimation of the residual capacity of sealed lead-acid batteries by neural network," in *Telecommunications Energy Conference*, 1998, pp. 210–214.
- [22] B. S. Bhangu, P. Bentley, D. A. Stone, and C. M. Bingham, "Nonlinear observers for predicting state-of-charge and state-of-health of lead-acid batteries for hybrid-electric vehicles," *IEEE Trans. Veh. Technol.*, vol. 45, no. 3, pp. 783–794, 2005.
- [23] S. Pang, J. Farrell, J. Du, and M. Barth, "Battery state-of-charge estimation," in *American Control Conference*, 2001, pp. 1644–1649.
- [24] M. Charkhgard and M. Farrokhi, "State-of-charge estimation for Lithium-Ion batteries using neural networks and EKF," *IEEE Trans. Ind. Electron.*, vol. 57, no. 12, pp. 4178–4187, 2010.
- [25] Y. He, X. T. Liu, C. Bin Zhang, and Z. H. Chen, "A new model for State-of-Charge (SOC) estimation for high-power Li-ion batteries," *Appl. Energy*, vol. 101, pp. 808–814, 2013.
- [26] G. L. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: Part 3. State and parameter estimation," *J. Power Sources*, vol. 134, no. 2, pp. 277–292, 2004.
- [27] R. Van der Merwe and E. A. Wan, "The square-root unscented Kalman filter for state and parameter-estimation," in *Acoustics, Speech, and Signal Processing*, 2001.
- [28] H. Gholizade-narm and M. Charkhgard, "Lithium-ion battery state of charge estimation based on square-root unscented Kalman filter," *IET Power Electron.*, vol. 6, no. 9, pp. 1833–1841, 2013, doi: 10.1049/iet-pel.2012.0706.
- [29] J.-S. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system," *IEEE Trans. Syst. Man. Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [30] T. O. Ting, K. L. Man, C.-U. Lei, and C. Lu, "State-of-charge for battery management system via Kalman filter," *Eng. Lett.*, vol. 22, no. 2, p. EL_22_2_05, 2014.
- [31] S. Haykin, *Kalman Filtering and Neural Networks*, 1st ed. USA: John Wiley & Sons, INC, 2001.

Implementation of adaptive neuro-fuzzy inference system in modeling and estimating the state-of-charge of Lithium-Ion batteries

Mohammad Nasiri¹, Mohammad Hossein Kazemi^{*1}

¹ Electronic Engineering Department, Shahed University, Tehran, Iran

Abstract

In this paper, a neuro-fuzzy inference system based on the state-space modeling of Lithium-Ion batteries is used to estimate the state-of-charge (SOC). The battery terminal voltage and current as laboratory sampling data are used for battery modeling. The moving window based on least square error method is applied in different operating windows to identify the parameters of the system and then the identified parameters are used for training an adaptive neuro-fuzzy inference system. Then, by exploiting the Kalman filter theory, an algorithm is proposed for state-of-charge estimation. Three kind of practical data are gathered separately from battery terminal voltage and current for training of the neuro-fuzzy system, evaluating of trained model, and proposed estimation algorithm. Finally, the estimation results of the proposed algorithm are compared with some existing algorithms that show the effectiveness of the proposed.

Keywords: State-of-charge; Neuro-fuzzy inference system; Kalman filter.