

ƯỚC LƯỢNG TRẠNG THÁI SẠC CỦA PIN DỰA TRÊN THUẬT TOÁN VFFRLS KẾT HỢP MẠNG NEURAL

STATE OF CHARGE ESTIMATION OF BATTERY BASED ON VFFRLS ALGORITHM
COMBINED WITH NEURAL NETWORK

Nguyễn Kiên Trung¹,
Trần Đức Hiệp², Nguyễn Thị Điệp^{3,*}

DOI: <http://doi.org/10.57001/huinh5804.2024.364>

TÓM TẮT

Bài báo này đề xuất một phương pháp mới kết hợp giữa thuật toán VFFRLS và mạng Neural để ước lượng trạng thái sạc của pin. Thuật toán VFFRLS được sử dụng để nhận dạng trực tuyến các tham số của mô hình pin, với mục đích có thêm nhiều đầu vào hơn cho mạng Neural nhằm tăng độ chính xác ước lượng. Ngoài ra, các tham số này được đưa vào mạng Neural để đánh giá mức độ quan trọng của từng tham số. Đề xuất này có ưu điểm là cho biết mức độ quan trọng của từng tham số đầu vào, khối lượng tính toán giảm đi đáng kể mà kết quả dự đoán vẫn chính xác. Số liệu sử dụng trong bài báo thu thập từ quá trình xả thực tế của pin Lithium-ion. Kết quả mô phỏng và thực nghiệm đạt được sai số RMSE nhỏ hơn 0,29% và MAE nhỏ hơn 0,23%.

Từ khóa: Trạng thái sạc, mạng Neural, pin Lithium-ion, ước lượng SOC, VFFRLS.

ABSTRACT

This paper proposes a new method combining VFFRLS and Neural Network to estimate the state of charge of battery. The VFFRLS algorithm is used for online identification of the battery model's parameters, aiming to provide more inputs to the Neural Network to improve estimation accuracy. Additionally, these parameters are fed into the Neural Network to assess the importance of each parameter. The advantage of this proposed approach is that it shows the importance of each input characteristic, and has excellent accuracy in predicting the result despite the small computational volume. The data used in this work is collected from the actual discharge process of Lithium-ion batteries. Simulation and experiment results of the proposed method reach less than 0,29% and 0,23% in RMSE and MAE respectively.

Keywords: State of charge, Neural network, Lithium-ion battery, SOC estimation, VFFRLS.

¹Khoa Tự động hóa, Trường Điện - Điện tử, Đại học Bách khoa Hà Nội

²Khoa Điện, Trường Đại học Công nghiệp Hà Nội

³Khoa Điều khiển và Tự động hóa, Trường Đại học Điện lực

*Email: diepnt@epu.edu.vn

Ngày nhận bài: 14/8/2024

Ngày nhận bài sửa sau phản biện: 30/9/2024

Ngày chấp nhận đăng: 28/11/2024

1. GIỚI THIỆU

Ô nhiễm môi trường, sự nóng lên của trái đất là những vấn đề rất nghiêm trọng mà thế giới đang phải đối mặt. Ngành công nghiệp xe điện đang phát triển nhanh chóng để đáp ứng nhu cầu di chuyển của con người với lượng khí thải carbon thấp [1]. Một trong những vấn đề lớn của xe điện đó là vấn đề lưu trữ năng lượng [2]. Ngày nay, pin Lithium-ion đã trở thành lựa chọn chính để lưu trữ năng lượng cho xe điện vì nó có mật độ năng lượng cao, tuổi thọ dài, hiệu suất khi làm việc ở nhiệt độ cao tốt và khả năng tự phóng điện thấp. Bên cạnh đó pin Lithium-ion còn tồn tại một số nhược điểm như nhạy cảm với quá sạc, quá xả, có thể gây sự cố khi không được kiểm soát [3]. Do vậy, để tận dụng tối đa các ưu điểm và hạn chế tối thiểu các nhược điểm của pin Lithium-ion thì một hệ thống quản lý năng lượng (BMS - battery management system) cho pin là rất cần thiết [4, 5]. Trạng thái sạc (SOC - State of charge) là một trong những thông số rất quan trọng của hệ thống BMS, nó cho biết trạng thái, thời điểm sạc và khả năng làm việc của xe điện. Tuy nhiên, SOC là đại lượng khó có thể đo lường trực tiếp được nên chỉ có thể tiếp cận bằng việc ước lượng [6]. Ước lượng chính xác SOC cũng là một thách thức không hề nhỏ do nó bị ảnh hưởng bởi sự lão hóa, bởi sự thay đổi của nhiệt độ và chu kỳ sạc/xả [7].

Hiện nay có hai phương pháp chính để ước lượng SOC là dựa trên mô hình và không

dựa trên mô hình. Phương pháp dựa trên mô hình như Kalman Filter (KF) [8], Expanded Kalman filter (EKF) [9], Unscented Kalman filter (UKF) [10, 11]... là các phương pháp ước lượng vòng kín, có khả năng sửa lỗi, giảm thiểu nhiễu nhưng khối lượng tính toán khá lớn và chưa xét tới yếu tố nhiệt độ. Phương pháp không dựa trên mô hình như phương pháp đếm Coulomb [12], điện áp hở mạch [13], mạng Neural [14]... Các phương pháp này có đặc điểm chung là không có khả năng tự khắc phục lỗi, cần số lượng dữ liệu đào tạo lớn, nhưng bù lại kết quả là chính xác cao.

Các phương pháp sử dụng mạng Neural hiện nay chỉ tập trung thay đổi cấu trúc mạng mà chưa xem xét ảnh hưởng của tính chất đầu vào tới chất lượng dự đoán của mạng. Vì vậy, bài báo này đề xuất một phương pháp ước lượng SOC mới kết hợp đánh giá mức độ quan trọng của tham số mô hình pin thu được từ thuật toán VFFRLS đối với mạng Neural. Từ đó giúp cho mô hình có những thông số đầu vào hữu ích, giảm thiểu khối lượng tính toán mà kết quả thu được có độ chính xác cao. Độ chính xác của phương pháp được xác minh bằng mô phỏng và thực nghiệm.

Bài báo có cấu trúc như sau: Phần 2 trình bày cơ sở lý thuyết xác định các tham số của mô hình pin bằng thuật toán VFFRLS. Phần 3 đề xuất cấu trúc mạng Neural để ước lượng SOC. Phần 4 trình bày các kết quả mô phỏng và thực nghiệm. Kết luận và đề xuất được trình bày ở phần 5.


2. XÁC ĐỊNH THAM SỐ MÔ HÌNH TRỰC TUYẾN BẰNG THUẬT TOÁN VFFRLS

Việc ước lượng SOC phụ thuộc vào mô hình chính xác của pin nên việc xác định chính xác các tham số của pin là rất quan trọng. Để có đầy đủ cơ sở dữ liệu về mô hình pin, trong phần này, một mô hình mạch tương đương của pin Lithium-ion được xây dựng. Sau đó, sử dụng thuật toán bình phương nhỏ nhất để quy (Recursive Least Squares-RLS) để xác định tham số của mô hình. Tuy nhiên, trong quá trình nhận dạng tham số dữ liệu đầu vào tăng dần theo mỗi chu kỳ nên phương pháp RLS được kết hợp với một biến hệ số quên (Varying Forgetting Factor-VFF) để giảm khối lượng dữ liệu tăng độ chính xác của thuật toán, nó được gọi là phương pháp bình phương tối thiểu đệ quy có hệ số quên thay đổi (Varying Forgetting Factor Recursive Least Squares - VFFRLS) [15].

2.1. Mô hình mạch tương đương của pin

Mô hình mạch tương đương điển hình của pin Lithium-ion được trình bày trên hình 1. Nguồn áp U_{OCV} đại diện cho điện áp của pin tại điểm cân bằng hay điện áp hở mạch của pin, nội trở của pin R_0 , mạch $R_1 - C_1$ đại

diện cho quá trình quá độ điện áp trên hai cực pin. Đầu vào của mô hình là dòng điện $i(t)$ sạc/xả của pin, đầu ra là điện áp trên hai cực pin (U_b) [16].



Hình 1. Mạch tương đương của pin [16]

Sử dụng mô hình Thevenin để phân tích mạch trong miền liên tục:

$$\begin{cases} sU_1(s) = \frac{I(s)}{C_1} - \frac{U_1(s)}{R_1 C_1} \\ U_b(s) = U_{OCV}(s) - U_1(s) - R_0 I(s) \end{cases} \quad (1)$$

Hiệu điện áp hai cực đầu ra và điện áp hở mạch như sau:

$$U_b(s) - U_{OCV}(s) = -I(s) \left(R_0 + \frac{R_1}{1 + R_1 C_1 s} \right) \quad (2)$$

Đặt $E_L = U_b - U_{OCV}$, hàm truyền có thể được viết như sau:

$$G(s) = \frac{E_L(s)}{I(s)} = -\frac{R_0 + R_1 + R_0 R_1 C_1 s}{1 + R_1 C_1 s} \quad (3)$$

Chuyển đổi hàm truyền sang miền gián đoạn bằng phương pháp Tustin. Thay $s = \frac{2}{T} \frac{1-z^{-1}}{1+z^{-1}}$ vào (3), hàm truyền trên miền gián đoạn được trình bày trong (4).

$$G(z^{-1}) = -\frac{\frac{R_0 T + R_1 T + 2R_0 R_1 C_1}{T + 2R_1 C_1} + \frac{R_0 T + R_1 T - 2R_0 R_1 C_1}{T + 2R_1 C_1} z^{-1}}{1 + \frac{T - 2R_1 C_1}{T + 2R_1 C_1} z^{-1}} \quad (4)$$

Đặt: $a_1 = -\frac{T - 2R_1 C_1}{T + 2R_1 C_1}$; $a_2 = -\frac{R_0 T + R_1 T + 2R_0 R_1 C_1}{T + 2R_1 C_1}$;

$a_3 = -\frac{R_0 T + R_1 T - 2R_0 R_1 C_1}{T + 2R_1 C_1}$

Phương trình (3) và (4) được viết lại trong (5) sau khi gián đoạn hóa, với $k = 1, 2, 3 \dots$

$$E_L(k) = a_1 E_L(k - 1) + a_2 I(k) + a_3 I(k - 1) \quad (5)$$

Giá trị điện áp hở mạch OCV bị tác động đáng kể bởi SOC khi làm việc trong điều kiện nhiệt độ (Tem) và độ lão hóa của pin (H), mối quan hệ đó được mô tả trong phương trình (6).

$$\frac{dU_{OCV}}{dt} = \frac{\partial U_{OCV}}{\partial SOC} \frac{\partial SOC}{\partial t} + \frac{\partial U_{OCV}}{\partial Tem} \frac{\partial Tem}{\partial t} + \frac{\partial U_{OCV}}{\partial H} \frac{\partial H}{\partial t} \quad (6)$$

Vì thời gian trích mẫu nhỏ hơn nhiều so với thời gian xả hết hoặc sạc đầy pin nên trong một chu kỳ trích mẫu có thể coi giá trị dung lượng còn lại (SOC) không đổi hay $\partial SOC/\partial t \approx 0$. Tốc độ thay đổi nhiệt độ hầu như là không đổi trong khoảng thời gian trích mẫu nhỏ nên $\partial Tem/\partial t \approx 0$. Trong một thời gian ngắn thì độ lão hóa của pin không đáng kể, coi $\partial H/\partial t \approx 0$. Từ đó, phương trình (6) được viết lại như sau:

$$\frac{dU_{OCV}}{dt} = \frac{U_{OCV}(k) - U_{OCV}(k-1)}{T} \approx 0 \quad (7)$$

Hay:

$$U_{OCV}(k) \approx U_{OCV}(k-1) \quad (8)$$

Từ phương trình (5) và (8), điện áp trên hai cực của pin được xác định như trong (9).

$$U_b(k) = (1 - a_1)U_{OCV}(k) + a_1U_b(k-1) + a_2I(k) + a_3I(k-1) = \phi(k)\theta(k) \quad (9)$$

Trong đó:

$$\phi(k) = [1, U_b(k-1), I(k), I(k-1)]$$

$$\text{và } \theta(k) = [(1 - a_1)U_{OCV}(k), a_1, a_2, a_3]^T.$$

2.2. Phương pháp trực tuyến xác định tham số mô hình pin VFFRLS

Sau khi thiết lập được mô hình pin như trên mục 2.1, các tham số mô hình được xác định bằng thuật toán bình phương đệ quy nhỏ nhất (RLS) kết hợp với hệ số quên (VFF) để tăng độ chính xác, phương pháp này còn được gọi là phương pháp bình phương tối thiểu đệ quy có hệ số quên thay đổi VFFRLS [15]. Phương pháp xác định tham số mô hình được thực hiện như dưới đây.

Giá trị đầu ra ước tính của mô hình:

$$y_k = \phi_n(k)\theta_n(k) + e(k) \quad (10)$$

Sai lệch giữa giá trị đầu ra của mô hình và đầu ra thực tế:

$$e(k) = U_b(k) - \phi_n(k)\hat{\theta}_n(k-1) \quad (11)$$

Hệ số khuếch đại $K(k)$ của VFF:

$$K(k) = \frac{P_n(k-1)\phi_n^T(k)}{\lambda_n(k-1) + \phi_n^T(k)P_n(k-1)\phi_n(k)} \quad (12)$$

Cập nhật vector tham số của mô hình:

$$\hat{\theta}_n(k) = \hat{\theta}_n^-(k) + K(k)e(k) \quad (13)$$

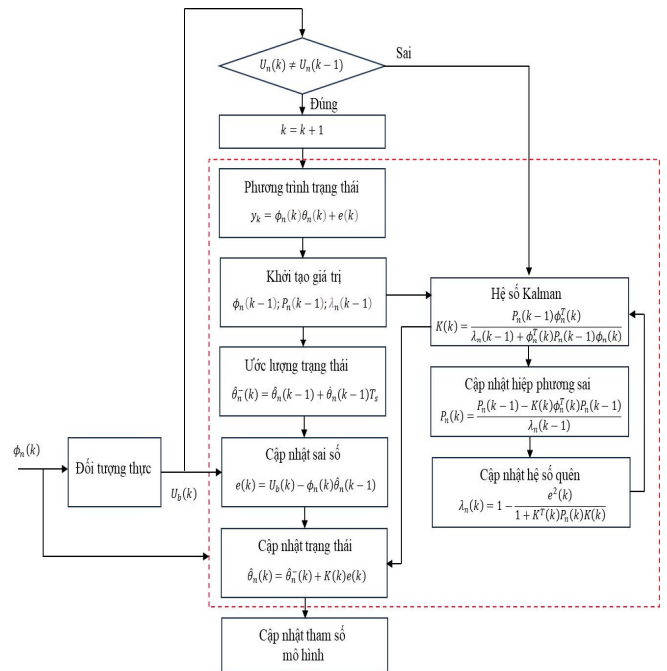
Cập nhật hiệp phương sai của giá trị ước lượng và thực tế:

$$P_n(k) = \frac{P_n(k-1) - K(k)\phi_n^T(k)P_n(k-1)}{\lambda_n(k-1)} \quad (14)$$

Cập nhật hệ số quên $\lambda_n(k)$ VFF:

$$\lambda_n(k) = 1 - \frac{e^2(k)}{1 + K^T(k)P_n(k)K(k)} \quad (15)$$

Trong đó, $\hat{\theta}(k)$ là ước lượng của vector $\theta(k)$, $e(k)$ là sai số của điện áp pin, $K(k)$ là hệ số khuếch đại VFF, $P(k)$ là ma trận hiệp phương sai; λ là trọng số VFF.



Hình 2. Sơ đồ thuật toán xác định tham số mô hình pin

Từ (11) và (15) thấy rằng, khi hệ thống thay đổi đột ngột, giá trị đầu ra mô hình sẽ gia tăng sai số so với giá trị đo, khi đó $\lambda_n(k)$ sẽ giảm, nói cách khác, trọng số của các giá trị ước lượng cũ sẽ giảm, trọng số của chu kỳ đo mới (khi hệ thống vừa thay đổi) sẽ tăng và kết quả cập nhật tham số sẽ đáp ứng nhanh với thay đổi của hệ thống. Còn khi động học của hệ chậm lại, hay hệ đã đạt đến điểm làm việc mới, lúc này sai lệch ước lượng giảm và $\lambda_n(k)$ tăng tiệm cận với 1, khi này thuật toán trở về dạng của RLS thông thường, đảm bảo sự ổn định trong quá trình ước lượng.

Hình 2 là sơ đồ thuật toán xác định giá trị tham số của mô hình. Các giá trị ban đầu $\theta_n(k)$, P_n , K được đặt trước với một giá trị hợp lý, sau đó $\theta_n(k)$ có thể được điều chỉnh phù hợp với vector của các giá trị đo lường $\Phi_n(k)$ bằng vòng lặp cập nhật hệ số quên $\lambda_n(k)$. Sau khi xác định được tham số mô hình pin Lithium-ion, việc tiếp theo là ước lượng các thông số quan trọng của pin mà không thể đo lường trực tiếp được - đó chính là SOC của pin. Phần tiếp theo trình bày phương pháp ước lượng giá trị SOC của pin.

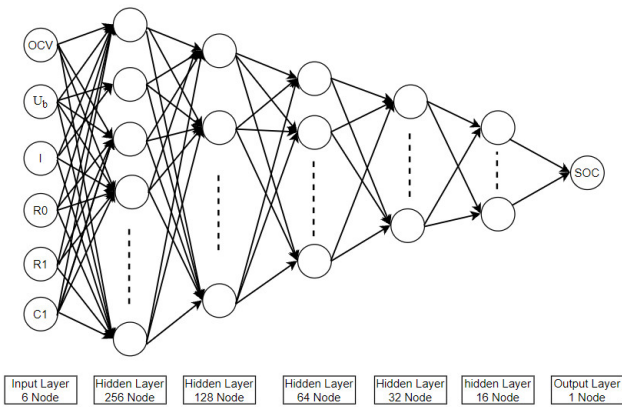
3. SỬ DỤNG MẠNG NEURAL ƯỚNG LƯỢNG SOC

Dựa vào lượng dữ liệu đo đạc thực tế trong quá trình xả thuận trở của pin lithium-ion, cấu trúc mạng Neural được đề xuất như trên hình 3. Vector đầu vào mạng là

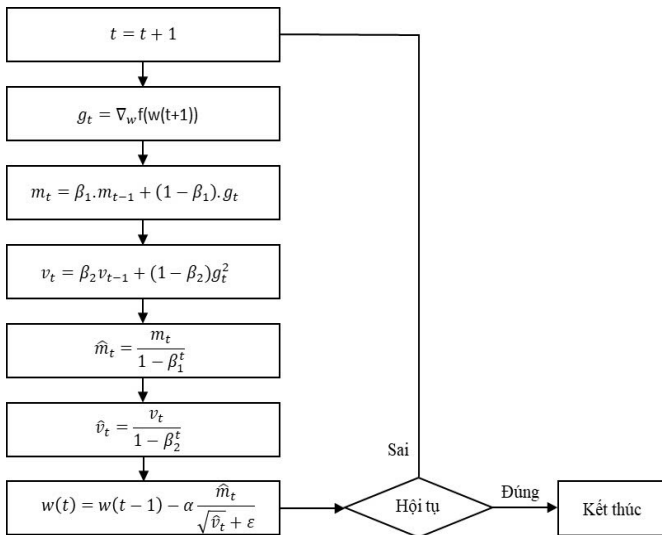
$X = [OCV, U_b, I, R_0, R_1, C_1]$. Mạng bao gồm một lớp input ban đầu, năm lớp Hidden (hàm Relu) để tính toán các trọng số và một lớp Output cuối cùng (hàm Sigmoid) để dự đoán SOC. Giá trị SOC chính xác dùng để tham chiếu mạng là giá trị được tính theo phương pháp đếm Coulomb như trong (16).

$$SOC(k) = SOC(0) - \frac{T}{C_n} \int_0^k (\eta I(t) - S_d) dt \quad (16)$$

Trong đó: SOC(0) là giá trị SOC ban đầu, I(t) là cường độ dòng điện tại thời điểm t, T là chu kỳ trích mẫu đo, C_n là dung lượng danh định của pin, η là hiệu suất và S_d là tốc độ tự xả.



Hình 3. Cấu trúc mạng Neural để xuất



Hình 4. Thuật toán Adam

Thuật toán tối ưu Adam được lựa chọn cho sử dụng cho mô hình. Thuật toán Adam là sự kết hợp của hai phương pháp RMSprop và Momentum. Nó sử dụng gradient bình phương để điều chỉnh tốc độ học tập như RMSprop (biến v_t) và tận dụng đường trung bình động của gradient (biến m_0) tương tự như Momentum để thuật toán hội tụ nhanh hơn. Lưu đồ thuật toán được trình bày trên hình 4. Trong đó, các tham số: α là tốc độ học; β_1 là tham số cho bước

động lượng; β_2 là tham số cho bước RMSprop; $f(w) = Y_a - Y$ là hàm lỗi; $w(0)$ là trọng số ban đầu; g_t là đạo hàm của hàm lỗi; $m_0 = 0$ là momen thứ nhất thời điểm đầu tiên; $v_0 = 0$ là momen thứ hai ở thời điểm đầu tiên; t là bước cập nhật.

Hiệu suất của mô hình được đánh giá theo tiêu chí RMSE (Root Mean Square Error) và MAE (Mean Absolute Error), được định nghĩa trong các phương trình (17) và (18).

$$RMSE = 100 * \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (\%) \quad (17)$$

$$MAE = 100 * \frac{\sum_{i=1}^n e_i}{n} \quad (18)$$

Trong đó, e là độ chênh lệch giá trị thực tế và dự đoán và n là số phần tử trong tập dữ liệu. RMSE cho biết mức độ ổn định của mô hình, MAE cho biết độ chính xác của ước lượng. Với trọng số của mạng tốt, SOC sẽ được ước tính online khi đưa các tham số vào mạng Neural.

Phương pháp đánh giá Kernel Shap được sử dụng để đánh giá mức độ quan trọng của các thông số đầu vào [17]. Cuối cùng, dựa vào tính năng đầu vào đang xét và giá trị cần dự đoán: mô hình g được đề xuất như một mô hình hồi quy tuyến tính có trọng số, giá trị Shapley chính là các trọng số trong mô hình. Tính toán mức độ quan trọng của các tham số đầu vào trên toàn bộ tập dữ liệu bằng cách tính giá trị trung bình tuyệt đối của giá trị Shapley như sau [18]:

$$I_j = \frac{\sum_{i=1}^M |\phi_j^i|}{M} \quad (19)$$

Trong đó, M là số lượng mẫu; j là tham số đang xét; i là chỉ số của phần tử trong tập đang xét; I_j là giá trị mức độ quan trọng; ϕ_j là giá trị Shapley (trung bình có trọng số của các tham số trên toàn bộ mô hình) [17].

Biểu thức tính giá trị Shapley cho một thông số đầu vào được biểu diễn như trong (20).

$$\phi_i = \frac{1}{|N|!} \sum_{S \subseteq N \setminus \{i\}} |S|! (|N| - |S| - 1)! [f_{(S \cup \{i\})} - f_{(S)}] \quad (20)$$


Trong đó, N là tập hợp tất cả các tham số; S là tập con của N; $f(s)$ là giá trị dự đoán của mô hình khi sử dụng tham số đầu vào là S.

4. KẾT QUẢ MÔ PHỎNG VÀ THỰC NGHIỆM

Việc thực nghiệm được thực hiện như sau: Bước 1: Xác định tham số mạch tương đương của pin theo thời gian thực (nhận dạng trực tuyến) bằng thuật toán VFFRLS. Việc xác định thông số này được thực hiện bằng cách chỉ cần

đo dòng điện và điện áp của pin trong quá trình hoạt động. Bước 2: Tham số thu được của mô hình pin tại mỗi bước thời gian được đưa vào mô hình mạng Neural để ước lượng giá trị SOC.

Tế bào pin Lithium Lishen 18650 được chọn làm đối tượng chính để thực nghiệm. Một mô hình thực nghiệm được xây dựng trong phòng thí nghiệm như trên hình 5.



Hình 5. Mô hình thực nghiệm


4.1. Thu thập tham số mạch trong quá trình xả với điện trở không đổi

Để thu thập tham số của mạch, thực hiện quá trình xả với điện trở không đổi, điều kiện làm việc được thiết lập như trên bảng 1. Kết quả đo dòng điện sạc và điện áp giữa hai điện cực của pin được thể hiện trên hình 6. Quá trình xả bắt đầu tại thời điểm 100s, điện áp trên hai điện cực của pin tối đa là 4V, kết thúc quá trình xả tại thời điểm 5500s điện áp trên hai điện cực của pin là 1,5V.

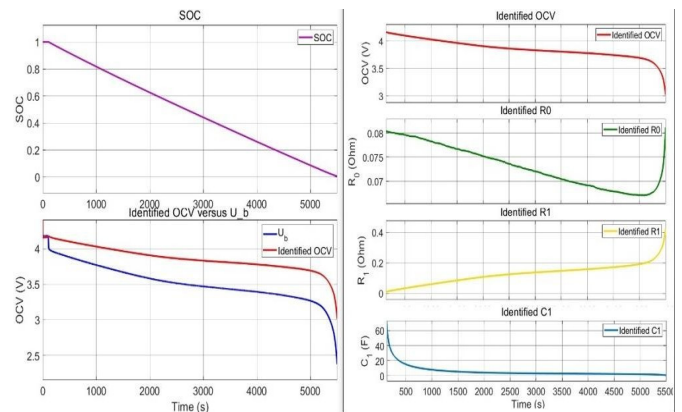
Kết quả đo dòng điện sạc và điện áp giữa hai điện cực của pin được đưa vào thuật toán VFFRLS. Các tham số mô hình pin được ước lượng theo thuật toán VFFRLS được trình bày trên hình 7. Trong quá trình xả này, OCV của pin có hình dạng là điện áp đầu cuối và lớn hơn giá trị điện áp đầu cuối (U_b). Mặt khác, nội trở của pin (R_0) khoảng 80mΩ khi SOC bằng 100%, nội trở giảm tuyến tính xuống bằng 65mΩ khi giá trị SOC giảm xuống còn 10%. Trong 10% SOC cuối cùng, nội trở lại tăng nhanh lên bằng 80mΩ. Xu hướng này tăng giảm này cũng phù hợp với thông tin biểu dữ liệu của pin. Tương tự như vậy, các tham số như R_1 , C_1 được ước lượng và có kết quả như trên hình 9.

Bảng 1. Thông số quá trình xả pin

Thông số	Giá trị
Tổng thời gian xả	5500s
Trở xả	2Ω
Điện áp ban đầu (SOC = 100%)	4,18V
Điện áp kết thúc chu trình	3,0V
Thời gian kết nối với tải	100s




Hình 6. Cấu hình tải trong quá trình xả




Hình 7. Giá trị tham số ước lượng được

4.2. Kết quả ước lượng SOC

Từ dữ liệu các tham số của mạch đã được thu thập được ở trên được đưa vào mạng Neural để ước lượng SOC. Lấy ngẫu nhiên 90% để huấn luyện (trong đó, 80% huấn luyện, 20% xác thực để tránh overfitting) và 10% dùng để kiểm tra. Với kích thước Batch_Size là 256, mô hình mạng để xuất huấn luyện 10 lần lấy kết quả tốt nhất. Kết quả dự đoán SOC với đầy đủ các tính năng đầu vào ($[OCV, U_b, I, R_0, R_1, C_1]$) được biểu diễn trên hình 8. Hình 8a là đồ thị biểu diễn SOC dự đoán và chính xác, hình 8b là tỷ lệ % sai lệch của SOC. Kết quả, RMSE bằng 0,29% và MAE bằng 0,23%. Như vậy, kết quả dự đoán SOC có độ chính xác cao khi kết hợp thuật toán VEERLS và mạng Neural.




a) SOC dự đoán và SOC chính xác



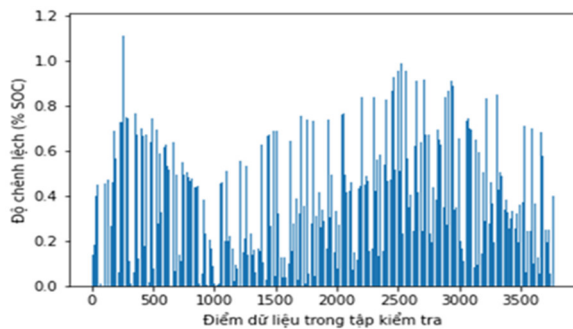
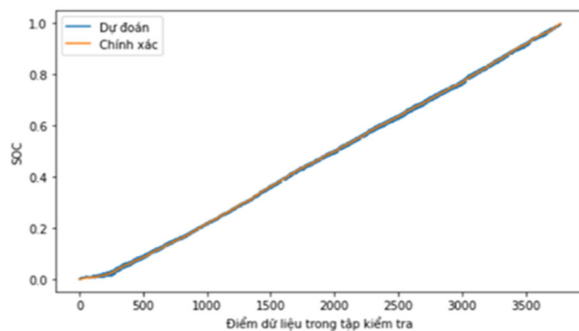
b) Sai lệch dự đoán SOC

Hình 8. Kết quả dự đoán SOC với đầu vào [OCV, U_b , I, R_0 , R_1 , C_1]





Hình 9. Biểu đồ mức độ quan trọng của các tham số đầu vào



Để xem xét các đầu vào nào ảnh hưởng tới giá trị dự đoán của mạng như thế nào, sử dụng phương pháp Kernel SHAP [17] vào mạng Neural, kết quả thu được như trong đồ thị hình 9. Kết quả cho thấy, R_1 ảnh hưởng nhiều nhất, R_0 ảnh hưởng ít nhất tới mô hình dự đoán. Từ kết quả này, các trường hợp khác nhau được chia ra để kiểm chứng và đánh giá tính đúng đắn của thuật toán.




b) [OCV, U_b , I, R_0 , C_1]




c) [U_b , I, R_1]



a) [OCV, U_b , I, R_1 , C_1]





d) $[U_b, I]$

Hình 10. Đồ thị dự đoán SOC với các đầu vào khác nhau

Từ kết quả đánh giá mức độ quan trọng của các tham số tới độ chính xác của kết quả dự đoán của mạng trên, tiến hành đánh giá tính đúng đắn của thuật toán dự đoán SOC trong các trường hợp khác nhau như dưới đây:

- Trường hợp 1: Loại bỏ thông số ít quan trọng nhất R_0 - sử dụng các tham số đầu vào $[OCV, U_b, I, R_1, C_1]$ để dự đoán SOC. Kết quả kiểm chứng như trên hình 10a, sai số RMSE bằng 0,31%, MAE bằng 0,25%. Như vậy, khi bỏ tính năng ít quan trọng nhất R_0 thì kết quả dự đoán không sai khác nhiều so với kết quả của mô hình.

- Trường hợp 2: Loại bỏ thông số quan trọng nhất R_1 - sử dụng các tham số đầu vào $[OCV, U_b, I, R_0, C_1]$ để dự đoán SOC. Kết quả kiểm chứng như trên hình 10b, RMSE bằng 0,38%, MAE là 0,32%. Như vậy, khi loại bỏ tính năng quan trọng nhất R_1 , kết quả dự đoán sai khác khá nhiều so với kết quả mô hình.

- Trường hợp 3: Sử dụng các tham số đầu vào $[U_b, I, R_1]$ để dự đoán SOC, loại bỏ ba tính năng ít quan trọng nhất (OCV, R_0, C_1) . Kết quả kiểm chứng thể hiện trên hình 10c, RMSE bằng 0,46% và MAE bằng 0,38%. Như vậy, khi bỏ ba tính năng ít quan trọng nhất (OCV, R_0, C_1) kết quả dự đoán vẫn tương đối chính xác.

- Trường hợp 4: Chỉ sử dụng các tham số đo được ban đầu $[U_b, I]$ để dự đoán SOC. Kết quả kiểm chứng như trên hình 10d, RMSE bằng 0,8%, MAE bằng 0,65%. Như vậy, khi chỉ sử dụng những tính năng đo được ban đầu, độ chính xác dự đoán của mô hình giảm đáng kể.

Kết quả giá trị RMSE và MAE được tổng hợp trong bảng 2. Từ bảng 2 có thể thấy rõ hiệu quả và tính đúng đắn của thuật toán đánh giá mức độ quan trọng của các tính năng đầu vào. Trong trường hợp đầy đủ các tính năng đầu vào $([OCV, U_b, I, R_0, R_1, C_1])$ mô hình dự đoán chính xác nhất. Khi bỏ đi đầu vào ít quan trọng nhất R_0 (đầu vào $[OCV, U_b, I, R_1, C_1]$) thì kết quả dự đoán của mô hình không sai khác nhiều. Khi bỏ đi đầu vào quan trọng nhất R_1 đầu vào $[OCV, U_b, I, R_0, C_1]$ thì kết quả dự đoán

của mô hình bị sai khác khá nhiều. Nếu chỉ sử dụng các tham số đo được ban đầu $[U_b, I]$ thì mô hình dự đoán rất kém. Trong trường hợp cần mô hình dự đoán với độ chính xác ở mức vừa phải có thể sử dụng tính năng đầu vào $[U_b, I, R_1]$ để giảm thiểu thời gian và khối lượng tính toán cho mô hình.

Bảng 2. Sai số điện áp đầu cuối

Trường hợp	$[OCV, U_b, I, R_0, R_1, C_1]$	$[OCV, U_b, I, R_1, C_1]$	$[OCV, U_b, I, R_0, C_1]$	$[U_b, I, R_1]$	$[U_b, I]$
RMSE	0,29%	0,31%	0,38%	0,46%	0,8%
MAE	0,23%	0,25%	0,32%	0,38%	0,65%

5. KẾT LUẬN

Bài báo đề xuất phương pháp kết hợp thuật toán VFFRLS và mạng Neural để ước lượng SOC. Kết quả cho thấy từ những thông số có thể đo được là điện áp và dòng điện pin có thể mô tả đặc tính động học của pin, đánh giá, sử dụng chúng làm những đầu vào mạng Neural. Kết quả được đánh giá theo sai số RMSE (0,29%) và MAE (0,23%) cho thấy tính hiệu quả của phương pháp. So với các phương pháp dùng mạng Neural khác thì khối lượng tính toán và thời gian thực hiện của phương pháp này được giảm đi đáng kể mà kết quả vẫn chính xác.

TÀI LIỆU THAM KHẢO

[1]. X. Chen, W. Shen, T. T. Vo, Z. Cao, A. Kapoor, "An overview of lithium-ion batteries for electric vehicles," in *2012 10th International Power & Energy Conference (IPEC)*, Ho Chi Minh City: IEEE, 230-235, 2012. doi: 10.1109/ASSCC.2012.6523269.

[2]. Y. Yang, S. Bremner, C. Menictas, M. Kay, "Battery energy storage system size determination in renewable energy systems: A review," *Renewable and Sustainable Energy Reviews*, 91, 109-125, 2018. doi: 10.1016/j.rser.2018.03.047.

[3]. K. W. E. Cheng, B. P. Divakar, H. Wu, K. Ding, H. F. Ho, "Battery-Management System (BMS) and SOC Development for Electrical Vehicles," *IEEE Trans. Veh. Technol.*, 60, 1, 76-88, 2011. doi: 10.1109/TVT.2010.2089647.

[4]. Y. Xing, E. W. M. Ma, K. L. Tsui, M. Pecht, "Battery Management Systems in Electric and Hybrid Vehicles," *Energies*, 4, 11, 2011. doi: 10.3390/en4111840.

[5]. M. S. H. Lipu, et al., "Battery Management, Key Technologies, Methods, Issues, and Future Trends of Electric Vehicles: A Pathway toward Achieving Sustainable Development Goals," *Batteries*, 8, 9, 2022. doi: 10.3390/batteries8090119.

[6]. M. Al-Gabalawy, N. S. Hosny, J. A. Dawson, A. I. Omar, "State of charge estimation of a Li-ion battery based on extended Kalman filtering and sensor bias," *Int J Energy Res*, 45, 5, 6708-6726, 2021. doi: 10.1002/er.6265.

[7]. M. A. Hannan, M. S. H. Lipu, A. Hussain, A. Mohamed, "A review of lithium-ion battery state of charge estimation and management system in electric vehicle applications: Challenges and recommendations," *Renewable and Sustainable Energy Reviews*, 78, 834-854, 2017. doi: 10.1016/j.rser.2017.05.001.

[8]. T. O. Ting, K. L. Man, E. G. Lim, M. Leach, "Tuning of Kalman Filter Parameters via Genetic Algorithm for State-of-Charge Estimation in Battery Management System," *The Scientific World Journal*, 1-11, 2014. doi: 10.1155/2014/176052.

[9]. G. Plett, "Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs Part 1. Background," *Journal of Power Sources*, 2004. doi: 10.1016/S0378-7753(04)00359-3.

[10]. P. Zhang, C. Xie, S. Dong, "State of charge estimation of lithium battery based on Dual Adaptive Unscented Kalman Filter," in *2018 IEEE International Power Electronics and Application Conference and Exposition (PEAC)*, Shenzhen: IEEE, 1-6, 2018. doi: 10.1109/PEAC.2018.8590470.

[11]. Y. Chen, D. Huang, Q. Zhu, W. Liu, C. Liu, N. Xiong, "A New State of Charge Estimation Algorithm for Lithium-Ion Batteries Based on the Fractional Unscented Kalman Filter," *Energies*, 10, 9, 1313, 2017. doi: 10.3390/en10091313.

[12]. Y. Zheng, M. Ouyang, X. Han, L. Lu, J. Li, "Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles," *Journal of Power Sources*, 377, 161-188, 2018. doi: 10.1016/j.jpowsour.2017.11.094.

[13]. Y. Xing, W. He, M. Pecht, K. L. Tsui, "State of charge estimation of lithium-ion batteries using the open-circuit voltage at various ambient temperatures," *Applied Energy*, 113, 106-115, 2014. doi: 10.1016/j.apenergy.2013.07.008.

[14]. A. Affanni, A. Bellini, C. Conconi, G. Franceschini, E. Lorenzani, C. Tassoni, "EV battery state of charge: neural network based estimation," in *IEEE International Electric Machines and Drives Conference, 2003. IEMDC'03.*, Madison, WI, USA: IEEE, 684-688, 2003. doi: 10.1109/IEMDC.2003.1210310.

[15]. N. T. Diep, N. K. Trung, "An online battery-state of charge estimation method using the varying forgetting factor recursive least square - unscented Kalman filter algorithm on electric vehicles," *International Journal of Electrical and Computer Engineering (IJECE)*, 14, 3, 2024. doi: 10.11591/ijece.v14i3.pp2541-2553.

[16]. R. Xiong, *Battery Management Algorithm for Electric Vehicles*. 2020. doi: 10.1007/978-981-15-0248-4.

[17]. S. M. Lundberg, S. I. Lee, "A unified approach to interpreting model predictions," in *Proceedings of the 31st International Conference on Neural Information Processing Systems*, in NIPS'17. Red Hook, NY, USA: Curran Associates Inc., 4768-4777, 2017.

[18]. C. Molnar, *Interpretable Machine Learning: A Guide For Making Black Box Models Explainable*. Munich, Germany: Independently published, 2022.

AUTHORS INFORMATION

Nguyen Kien Trung¹, Tran Duc Hiep², Nguyen Thi Diep³

¹School of Electrical and Electronic Engineering, Hanoi University of Science and Technology, Vietnam

²Faculty of Electrical Engineering, Hanoi University of Industry, Vietnam

³Faculty of Control and Automation, Electric Power University, Vietnam