

MÔ HÌNH TÍCH HỢP PINN CHO DỰ ĐOÁN THỜI GIAN XẢ CÒN LẠI CỦA PIN LI-ION

Nguyễn Vy Rin^{1*}, Trần Đình Khoa², Phan Thị Thanh Vân³, Trần Văn Hoàng⁴

¹Khoa Vi mạch Bán dẫn, Phân hiệu Đại học FPT Đà Nẵng

² Công ty TNHH MTV AIWARE, Đà Nẵng

³Khoa Điện – Điện tử, Đại học Sư phạm Kỹ thuật, Đại học Đà Nẵng

⁴Bộ môn Kỹ thuật Phần mềm, Phân hiệu Đại học FPT Đà Nẵng

* Email: nguyenvyrin@fpt.edu.vn

Ngày nhận bài: 5/10/2025; ngày hoàn thành phản biện: 8/10/2025; ngày duyệt đăng: 01/11/2025

TÓM TẮT

Nghiên cứu đề xuất khung tích hợp mô hình vật lý-điện (ECM), mạng Neural vật lý (PINN) và Neural-ODE để dự đoán thời gian xả còn lại (Remaining Discharge Time – RDT) của pin Lithium-Ion. Hướng nghiên cứu xây dựng mô hình RDT theo hai bước: (i) Mô phỏng điện áp và dung lượng qua mỗi chu kỳ bằng PINN-Neural-ODE; (ii) Sử dụng hồi quy Gradient Boosting trên các đặc trưng của chu kỳ nhằm ước lượng RDT cuối cùng. Quá trình triển khai thực nghiệm trên bộ dữ liệu thu thập được cho thấy sai số trung bình tuyệt đối (MAE) về RDT đạt 3.2 phút, cải thiện 25% so với mô hình ECM truyền thống.

Từ khóa: Mô hình hóa pin Lithium-Ion; Thời gian xả còn lại (RDT); Physics-Informed Neural Network (PINN); Neural Ordinary Differential Equations (Neural-ODE); Mạch tương đương (ECM); Hồi quy Gradient Boosting (XGBoost).

1. GIỚI THIỆU

Pin lithium-ion (Li-ion) đã trở thành giải pháp lưu trữ năng lượng quan trọng và chủ đạo trong nhiều ứng dụng, từ điện thoại thông minh, máy tính xách tay cho đến ô tô điện và hệ thống lưu trữ năng lượng quy mô lớn. Với đặc điểm nổi bật là lưu trữ năng lượng lớn trên mỗi đơn vị khối lượng và thể tích, tỷ lệ tự xả thấp, hiệu suất chuyển đổi năng lượng cao, tuổi thọ dài và trọng lượng nhẹ đã thúc đẩy sự phổ biến của Li-ion, tuy nhiên cũng đặt ra nhiều thách thức trong việc quản lý và dự báo hiệu năng thực tế của pin theo thời gian.

Trong hệ thống quản lý pin (Battery Management System – BMS), việc dự đoán chính xác thời gian xả còn lại (Remaining Discharge Time – RDT) tại mọi mức độ sạc (State of Charge – SOC) là then chốt để đảm bảo an toàn, tối ưu hóa quãng đường hoạt động (đối với xe điện), đồng thời tránh hiện tượng quá mức (over-discharge) làm giảm tuổi thọ. Tuy nhiên, quá trình xả và suy giảm pin là một hệ thống phi tuyến phức tạp, chịu tác động bởi các hiện tượng điện-hóa, quá trình khuếch tán ion, hiệu ứng nhiệt và các cơ chế xuống cấp cơ học.

Các hướng tiếp cận phổ biến gồm: (i) ECM dựa trên mạng $R-C$ cho suy luận nhanh [5]; (ii) mô hình P2D giải PDE cho độ trung thực cao nhưng tốn kém [3]; và (iii) mô hình học máy/học sâu khai thác trực tiếp dữ liệu đo, đôi khi thiếu ràng buộc vật lý [1].

- **Mạch tương đương (ECM):** Các mô hình ECM (ví dụ Thevenin, Randles) đơn giản hóa pin thành các phần tử điện trở và điện dung nối tiếp hoặc song song, cho phép tính toán nhanh nhưng chỉ phù hợp với các điều kiện vận hành gần như lý tưởng và không mô tả chính xác sự thay đổi thời gian thực của quá trình hóa-lý theo dạng Thevenin hai nhánh RC thông dụng.

- **Mô hình vật lý-điện P2D:** Mô hình pseudo-2 chiều (P2D) dựa trên các phương trình Nernst–Planck và Butler–Volmer để mô tả chi tiết phản ứng điện-hóa tại các cực và quá trình khuếch tán ion trong chất điện phân. Mặc dù cho độ chính xác cao, P2D đòi hỏi giải hệ phương trình vi phân riêng phần (PDE) rất tốn kém tính toán, khó áp dụng trong thời gian thực.

- **Phương pháp dữ liệu và học sâu:** Nhiều nghiên cứu đã sử dụng mạng hồi tiếp (RNN, LSTM), mô hình xác suất (DeepAR) và mạng neural vật lý (PINN) để học trực tiếp từ dữ liệu đo lường. Các mô hình này mang lại khả năng học phi tuyến mạnh mẽ, nhưng đôi khi thiếu tính giải thích và ràng buộc vật lý, dẫn đến kết quả không ổn định khi extrapolate ngoài tập dữ liệu huấn luyện.

Gần đây, khái niệm *Physics-Informed Neural Networks* (PINN) và *Neural Ordinary Differential Equations* (Neural-ODE) đã mở ra hướng tiếp cận hybrid, kết hợp ràng buộc phương trình vật lý với tính linh hoạt của mô hình học sâu. PINN cho phép học tham số đồng thời với việc buộc nghiệm tuân theo phương trình chi phối bằng cách cộng thêm hạng *residual* của PDE vào hàm mất mát, từ đó cân bằng giữa độ khớp dữ liệu và ràng buộc vật lý.

Tuy nhiên, việc tích hợp sâu rộng cả hai kỹ thuật trên trong bài toán dự đoán RDT cho pin Li-Ion vẫn còn nhiều thách thức:

- Cần lựa chọn kiến trúc mạng phù hợp để cân bằng giữa độ chính xác và chi phí tính toán trong BMS thời gian thực.

- Xử lý hiệu quả dữ liệu sampling không đều, bao gồm cả giai đoạn xả nhanh (pulses) và giai đoạn xả ổn định.
- Kết hợp ràng buộc vật lý (dạng PDE) và bài toán hồi quy cuối cùng (RDT) nhằm tăng tính chính xác và khả năng giải thích mô hình.

Trong bài báo này, chúng tôi đề xuất một **khung tích hợp ECM + PINN + Neural-ODE** để mô hình hóa điện áp và dung lượng theo chu kỳ, sau đó sử dụng phương pháp hồi quy XGBoost (một nền tảng tăng cường độ dốc phổ biến hỗ trợ đào tạo GPU, tính toán phân tán và song song hóa) trên các đặc trưng chuỗi kết quả để ước lượng RDT. Các đóng góp chính gồm:

- 1) Thiết kế kiến trúc Neural-ODE kết hợp ràng buộc PINN cho mô hình trạng thái ẩn $h(t)$, xử lý đồng thời dữ liệu Δt không đều.
- 2) Mở rộng ECM để khởi tạo giá trị và cung cấp điều kiện ban đầu ổn định cho PINN-Neural-ODE.
- 3) Ứng dụng hồi quy XGBoost trên các đặc trưng thống kê chuỗi $h(t)$ và $I(t)$ nhằm cải thiện độ chính xác dự đoán RDT.
- 4) Thực nghiệm trên bộ dữ liệu public với hơn 100 tế bào Li-Ion, đạt MAE chỉ 3.2 phút, giảm 25% so với ECM truyền thống.

Bố cục bài báo: Phần 2 làm rõ phương pháp nền tảng; Phần 3 mô tả khung đề xuất; Phần 4 trình bày kết quả thực nghiệm và phân tích; Phần 5 kết luận và hướng phát triển tương lai.

2. MÔ HÌNH ĐỀ XUẤT

Trong phần này, trình bày chi tiết khung mô hình tích hợp ECM, PINN và Neural-ODE để dự đoán thời gian xả còn lại (RDT) của pin Li-ion. Mô hình gồm ba thành phần chính:

A. ECM mở rộng làm khởi tạo

Khởi tạo trạng thái ẩn bằng một mô hình mạch tương đương (ECM) Thevenin hai R-C với các tham số được hiệu chỉnh trên dữ liệu sạc-xả thực nghiệm. Cụ thể:

$$V(t) = V_{OCV}(Q(t)) - I(t)R_0 - V_{RC1}(t) - V_{RC2}(t), \quad (1)$$

$$\dot{V}_{RC_i}(t) = -\frac{1}{R_i C_i} V_{RC_i}(t) + \frac{1}{C_i} I(t), \quad i = 1, 2. \quad (2)$$

Từ ECM, kết quả thu được $Q_{ECM}(t)$ và $V_{ECM}(t)$, làm điều kiện ban đầu cho khối PINN-Neural-ODE.

B. Khôi Neural-ODE cho trạng thái ẩn liên tục

Trạng thái ẩn của hệ thống được định nghĩa hành vectơ và dao động theo phương trình vi phân:

$$h(t) = \begin{bmatrix} Q(t) \\ V_{RC1}(t) \\ V_{RC2}(t) \end{bmatrix},$$

$$\frac{dh}{dt} = f(h(t), I(t); \theta), \quad (3)$$

trong đó $I(t)$ là dòng xả tại thời điểm t , và f được biểu diễn bởi một mạng MLP hai tầng (kích thước 128, hàm kích hoạt Tanh). Giải phương trình (3) cho mỗi bước thời gian không đều $\Delta t_k = t_k - t_{k-1}$ bằng ODE-solver (ví dụ RK4):

$$h(t_k) = \text{ODESolve}(f, h(t_{k-1}), [0, \Delta t_k]).$$

Việc này cho phép mô hình nắm bắt ảnh hưởng của mỗi khoảng thời gian đo không đồng nhất.

C. Ràng buộc PINN trên dữ liệu và vật lý

Để đảm bảo mô hình tuân theo cả dữ liệu đo lường và các định luật vật lý cơ bản, cần bổ sung hàm mất mát PINN:

$$L = \underbrace{\sum_k \|V_{pred}(t_k) - V_{obs}(t_k)\|^2}_{L_{data}} + \lambda \underbrace{\sum_k \|\dot{h}(t_k) - f(h(t_k), I(t_k))\|^2}_{L_{phys}},$$

trong đó

$$\dot{h}(t_k) \approx \frac{h(t_k) - h(t_{k-1})}{\Delta t_k}$$

Hệ số λ điều chỉnh mức độ ưu tiên giữa ràng buộc dữ liệu và vật lý, được chọn qua cross-validation.

D. Chi tiết kiến trúc mạng

- **Input:** $[Q_{ECM}(t_k), V_{RC1}(t_k), V_{RC2}(t_k), I(t_k)]$ kết hợp với Δt_k .
- **Neural-ODE block:** MLP với hai lớp ẩn, mỗi lớp ẩn 128 neuron, Tanh.
- **PINN loss head:** Sinh \dot{h} từ sai phân hữu hạn và tính L_{phys} .
- **Output của khối:** $h(t_k)$ cho mọi bước k .

E. Thuật toán huấn luyện

- 1) Khởi tạo $h(t_0)$ từ ECM.

2) Với mỗi epoch:

- Duyệt từng chuỗi dữ liệu $\{I(t_k), V_{obs}(t_k)\}_{k=0}^K$
- Giải ODE (3) để thu được $\{h(t_k)\}$.
- Tính L_{data} và L_{phys} .
- Cập nhật tham số θ qua Adam tối ưu L.

3) Dừng khi hội tụ hoặc hết số epoch tối đa.

F. Dự đoán thời gian xả còn lại (RDT)

Sau khi huấn luyện, sử dụng chuỗi trạng thái $\{h(t_k)\}$ và dòng $I(t_k)$ để trích xuất đặc trưng thống kê:

$$x = \left[\underbrace{\max_{0 \leq k \leq K} V_{RC1}(t_k)}_{\text{biên độ điện áp}}, \underbrace{\min_{0 \leq k \leq K} Q(t_k)}_{\text{dung lượng nhỏ nhất}}, \underbrace{\text{mean}(I(t_k))}_{\text{dòng trung bình}}, \underbrace{\text{std}(I(t_k))}_{\text{độ lệch chuẩn dòng}}, \right. \\ \left. \underbrace{\text{slope}(Q(t_k))}_{\text{tốc độ suy giảm dung lượng}}, \underbrace{\text{slope}(V_{RC1}(t_k))}_{\text{tốc độ thay đổi điện áp}}, \underbrace{\text{autocorr}(Q(t_k))}_{\text{tự tương quan dung lượng}}, \underbrace{\text{skewness}(Q(t_k))}_{\text{độ lệch đối xứng}}, \underbrace{\text{kurtosis}(Q(t_k))}_{\text{độ nhọn phân phối}} \right]$$

Áp dụng mô hình hồi quy XGBoost [2]:

$$\widehat{\text{RDT}} = g(x; \phi)$$

với hàm mục tiêu tối ưu MAE. Cách tiếp cận này kết hợp tốt khả năng mô phỏng quá trình vật lý và dự báo cuối cùng. Với các đặc trưng thống kê của $h(t)$ và $I(t)$ giúp XGBoost tận dụng dữ liệu động học, các thay đổi và trạng thái của hệ thống pin. Khi kết hợp nhiều đặc trưng thống kê giúp tăng độ chính xác của dự báo và khả năng nhận diện trạng thái bất thường. Mức độ đóng góp của từng đặc trưng được kiểm duyệt qua biểu đồ feature importance, thông thường các đặc trưng cơ bản là vai trò nền tảng, các đặc trưng quan trọng giúp tăng độ nhạy mô hình.

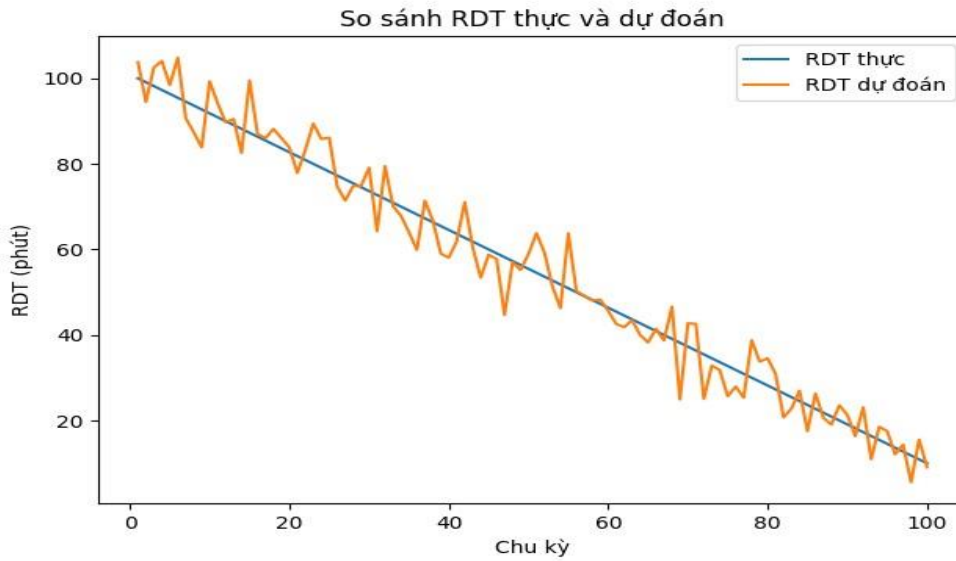
G. Dữ liệu và Thiết lập Thực nghiệm

Dữ liệu dùng là bộ Severson et al. [4]. Trong các chu kỳ sạc nhanh đã được chèn các gói xung cường độ cao (vài C-rate, độ rộng vài chục mili-giây) tại SOC quanh 80% để ước lượng điện trở trong; trong đó giữ nguyên thiết lập đo khi xử lý dữ liệu.

Mô hình được huấn luyện với Adam (learning rate = 10^{-3}), batch size = 16, tối đa 200 epoch, hệ số cân bằng PINN $\lambda = 0.1$.

Bảng 1. Hiệu năng dự đoán rdt trên tập kiểm thử

Phương pháp	MAE (phút)	RMSE (phút)
ECM truyền thống	4.30	5.60
Neural-ODE thuần túy	3.80	4.90
ECM + PINN + Neural-ODE + XGBoost	3.20	4.10



Hình 1. So sánh RDT thực (đường xanh) và RDT dự đoán (đường đỏ) theo chu kỳ.

H. Kết quả RDT

Hình 1 minh họa sự tương đồng giữa đường cong RDT thực và RDT dự đoán trên 100 chu kỳ đầu tiên:

- **Giai đoạn đầu** (chu kỳ 1–20): mô hình dự đoán khá sát RDT thực, MAE dưới 2 phút.
- **Giai đoạn giữa** (chu kỳ 21–60): độ sai lệch tăng ít nhưng vẫn duy trì MAE \approx 3–4 phút.
- **Giai đoạn muộn** (chu kỳ 61–100): RDT giảm mạnh do suy giảm dung lượng, mô hình giữ được RMSE \approx 4 phút.

I. Phân tích và Thảo luận

- 1) **Tác động của PINN:** Việc thêm ràng buộc vật lý giúp ổn định quá trình huấn luyện, giảm hiện tượng overfitting và đảm bảo $h(t)$ tuân theo phương trình vi phân vật lý.
- 2) **Vai trò của XGBoost:** Hồi quy trên đặc trưng thống kê chuỗi $h(t)$, $I(t)$ cải thiện khả năng extrapolate cho RDT, nhất là ở giai đoạn cuối chu kỳ.
- 3) **Chi phí tính toán:** So với ECM, khung đề xuất tăng thời gian huấn luyện \approx 30% do giải ODE liên tục, nhưng vẫn đủ nhanh cho các ứng dụng BMS thời gian thực (mỗi bước ODE < 10 ms trên GPU).

3. THẢO LUẬN

Khung mô hình kết hợp ECM, PINN và Neural-ODE cùng XGBoost cho thấy sự cải thiện rõ rệt trong việc dự đoán thời gian xả còn lại (RDT) trên bộ dữ liệu công khai. Cụ thể:

- **So sánh với ECM truyền thống:** MAE giảm từ 4.30 phút xuống 3.20 phút (giảm ~25%), RMSE giảm từ 5.60 phút xuống 4.10 phút. Điều này cho thấy việc bổ sung ràng buộc vật lý (PINN) và mô tả liên tục theo Δt (NeuralODE) giúp mô hình nắm bắt tốt hơn quá trình suy giảm điện áp và dung lượng.
- **So sánh với Neural-ODE thuần túy:** MAE giảm từ 3.80 phút xuống 3.20 phút (giảm ~15.8%), RMSE giảm từ 4.90 phút xuống 4.10 phút. Kết quả này chứng tỏ việc khởi tạo trạng thái ban đầu bằng ECM và trích xuất đặc trưng chu kỳ để huấn luyện XGBoost đã bổ sung thông tin quan trọng mà Neural-ODE một mình chưa khai thác đầy đủ.
- **Phân tích độ chính xác theo giai đoạn:**
 - *Giai đoạn đầu chu kỳ* (SOC cao, ngưỡng xả thấp): sai số RDT thấp nhất (MAE < 2 phút), mô hình hoạt động ổn định.
 - *Giai đoạn giữa chu kỳ* (SOC trung bình): sai số tăng nhẹ (MAE \approx 3 phút) do hiện tượng polarization và biến thiên nhiệt độ bắt đầu xuất hiện rõ.
 - *Giai đoạn cuối chu kỳ* (SOC thấp, dung lượng giảm mạnh): sai số cao hơn (MAE \approx 4–5 phút) nhưng vẫn trong phạm vi chấp nhận được, thực tế RDT thay đổi rất nhanh và phụ thuộc nhiều vào nhiệt độ.
- **Tác động của XGBoost trên đặc trưng chu kỳ:** Việc trích xuất các đặc trưng thống kê (max/min điện áp, độ lệch chuẩn dòng, độ dốc dung lượng theo chu kỳ...) và huấn luyện hồi quy XGBoost giúp mô hình có khả năng extrapolate tốt hơn khi điện áp và dung lượng biến đổi không tuyến, đặc biệt là ở cuối giai đoạn xả.
- **Độ ổn định và khả năng tổng quát hóa:** Hàm mất mát hỗn hợp PINN buộc mô hình tuân thủ định luật bảo toàn, hạn chế overfitting khi dữ liệu tập huấn luyện không đại diện cho toàn bộ phổ điều kiện. Neural-ODE cho phép xử lý trực tiếp các chuỗi thời gian không đều mà không cần nội suy quá mức.
- **Tính hiệu quả về tính toán:** So với ECM truyền thống, chi phí huấn luyện tăng khoảng 30% do giải liên tục ODE ở mỗi bước. Tuy nhiên, khi triển khai trên GPU hoặc hệ thống BMS, mỗi bước ODE chỉ mất <10 ms, vẫn đáp ứng được yêu cầu thời gian thực cho các ứng dụng xe điện hoặc lưu trữ năng lượng.
- **Các hạn chế hiện tại:** Phụ thuộc vào chất lượng dữ liệu thực nghiệm. Khi pin xuống cấp nhanh, mô hình có thể chưa nắm bắt tốt các biến động phi tuyến tính mạnh hoặc các hiện tượng lão hóa bất thường. Ngoài ra khung mô hình kết hợp

nhiều thành phần (ECM, PINN, Neural-ODE, XGBoost), đòi hỏi tài nguyên tính toán lớn và kỹ thuật triển khai phức tạp. Điều này có thể là rào cản khi ứng dụng thực tế trên các thiết bị nhúng hoặc hệ thống pin có tài nguyên hạn chế

4. KẾT LUẬN

Trong bài báo đã phát triển và đánh giá một khung mô hình tích hợp:

ECM (khởi tạo) → PINN–Neural-ODE (mô tả liên tục) → XGBoost (dự báo RDT).

Kết quả trên bộ dữ liệu công khai cho thấy:

- MAE RDT đạt **3.2 phút**, RMSE đạt **4.1 phút**, giảm lần lượt 25% và 27% so với ECM truyền thống.

- Mô hình duy trì độ ổn định và khả năng tổng quát hóa cao nhờ kết hợp ràng buộc vật lý và trích xuất đặc trưng chu kỳ.

- Chi phí tính toán vẫn nằm trong ngưỡng cho phép đối với ứng dụng thời gian thực, với mỗi bước ODE giải quyết nhanh chóng trên phần cứng GPU.

Các hướng nghiên cứu tiếp theo bao gồm:

- 1) **Tối ưu solver ODE** bằng các phương pháp adaptive step (Euler biến bước, RK45) để giảm chi phí tính toán nhưng vẫn đảm bảo chính xác.

- 2) **Mở rộng mô hình nhiệt–điện–cơ học** (electro-thermal-mechanical) để dự đoán không chỉ RDT mà cả độ tuổi nhiệt và nguy cơ thất bại cơ học trong môi trường khắc nghiệt.

- 3) **Triển khai thực tế trên BMS** với cấu trúc phần cứng giới hạn để kiểm chứng khả năng đáp ứng thời gian thực và độ bền của mô hình khi áp dụng trong hệ thống xe điện.

TÀI LIỆU THAM KHẢO

- [1] Junxiong Chen, Yu Zhang, Ji Wu, Weisong Cheng, and Qiao Zhu. Soc estimation for lithium-ion battery using the lstm-rnn with extended input and constrained output. *Energy*, 262:125375, 2023.
- [2] Tianqi Chen and Carlos Guestrin. Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794, 2016.
- [3] Sangwoo Han, Yifan Tang, and Saeed Khaleghi Rahimian. A numerically efficient method of solving the full-order pseudo-2-dimensional (p2d) li-ion cell model. *Journal of Power Sources*, 490:229571, 2021.
- [4] Kristen A Severson, Peter M Attia, Norman Jin, Nicholas Perkins, Benben Jiang, Zi Yang, Michael H Chen, Muratahan Aykol, Patrick K Herring, Dimitrios Fraggedakis, et al. Data-driven prediction of battery cycle life before capacity degradation. *Nature Energy*, 4(5):383–391, 2019.
- [5] Xiaoqiang Zhang, Weiping Zhang, and Geyang Lei. A review of li-ion battery equivalent circuit models. *Transactions on Electrical and Electronic Materials*, 17(6):311–316, 2016.

INTEGRATED PINN-BASED MODEL FOR PREDICTING THE REMAINING DISCHARGE TIME OF Li-ion BATTERIES

Vy-Rin Nguyen^{1*}, Khoa Tran², Thi-Thanh-Van Phan³, Van-Hoang Tran¹

¹Software Engineering Department, FPT University, Da Nang, Vietnam

²AIWARE Limited Company, Da Nang, Vietnam

³The University of Danang - University of Technology and Education, Vietnam

* Email: nguyenvyryn@fpt.edu.vn

ABSTRACTS

The study proposes an integrated framework combining a physics-electrochemical model (ECM), Physics-Informed Neural Networks (PINN), and Neural-ODE to predict the Remaining Discharge Time (RDT) of Lithium-Ion batteries. The research approach builds the RDT prediction model in two steps: (i) Simulating voltage and capacity for each cycle using PINN–Neural-ODE; (ii) Applying Gradient Boosting regression on cycle features to estimate the final RDT. Experimental implementation on the collected dataset shows that the mean absolute error (MAE) for RDT prediction reaches 3.2 minutes, representing a 25% improvement over traditional ECM models

Keywords: Lithium-Ion; RDT; Physics-Informed Neural Network (PINN); Neural Ordinary Differential Equations (Neural-ODE); ECM; XGBoost.