

การพัฒนาแบบจำลองด้วยการเรียนรู้ของเครื่องเพื่อประมาณค่าความต้านทานภายในแบตเตอรี่ ในยานยนต์ไฟฟ้า

Development of a Machine Learning Model for Estimating the Internal Resistance of Batteries in Electric Vehicles

ภูษิต สร้อยประดิษฐ์¹ และ นิธิกร จันทรหัตถ์^{1*}

¹ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
Nitikorn_j@rmutt.ac.th^{1*}

บทคัดย่อ

การประเมินค่าความต้านทานภายในของแบตเตอรี่มีความสำคัญต่อการยกระดับความปลอดภัยและประสิทธิภาพของระบบกักเก็บพลังงาน โดยช่วยตรวจสอบสภาพการทำงานและการเสื่อมสภาพได้รวดเร็ว อย่างไรก็ตาม วิธีวัดแบบดั้งเดิมยังมีข้อจำกัดด้านความล่าช้าและต้องใช้เครื่องมือในการวัด งานวิจัยนี้จึงพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อประมาณค่าความต้านทานภายในจากข้อมูลแรงดัน และกระแสไฟฟ้า ผลการทดลองพบว่าแบบจำลองให้ค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่า 4 % และมีค่าสัมประสิทธิ์สหสัมพันธ์กำลังสองมากกว่า 0.95 แสดงถึงความแม่นยำและความสอดคล้องอย่างมีนัยสำคัญ จึงมีศักยภาพสูงในการนำไปประยุกต์ใช้กับระบบตรวจสอบแบตเตอรี่

คำสำคัญ: ค่าความต้านทานภายใน แบตเตอรี่ ระบบกักเก็บพลังงาน และยานยนต์ไฟฟ้า

Abstract

Estimating a battery's internal resistance is essential for improving the safety and efficiency of energy storage systems, as it facilitates the swift identification of operational conditions and deterioration. Nonetheless, traditional measurement techniques are constrained by latency and the requirement for specialized apparatus. This research constructs a machine learning model to assess internal resistance utilizing voltage and current data. Experimental results demonstrate that the model attains a mean absolute percentage error below 4% and a coefficient of determination (R^2) of 0.95, signifying good accuracy and robust correlation. The results indicate the model's significant potential for use in battery monitoring systems.

Keywords: Internal resistance, battery, energy storage systems and electric vehicles

1. บทนำ

ในปัจจุบัน ระบบกักเก็บพลังงานและยานยนต์ไฟฟ้ามีบทบาทสำคัญในการส่งเสริมการใช้พลังงานสะอาดและลดการปล่อยก๊าซเรือนกระจก ซึ่งแบตเตอรี่ลิเทียมไอออนถือเป็นหัวใจหลักของระบบเหล่านี้ โดยค่าความต้านทานภายในเป็นตัวชี้วัดสำคัญที่สะท้อนสมรรถนะและความปลอดภัยของแบตเตอรี่ การประเมินค่าความต้านทานภายในอย่างแม่นยำจึงมีความจำเป็น เพื่อใช้ในการติดตามสภาพของแบตเตอรี่และป้องกันความเสียหายจากความผิดปกติ เช่น การลัดวงจรภายใน

วิธีการวัดค่าความต้านทานภายในแบบดั้งเดิม เช่น การวัดด้วยกระแสกระตุ้นหรือการวิเคราะห์ด้วยแบบจำลองทางไฟฟ้า ยังมีข้อจำกัดหลายด้าน เช่น ความแม่นยำต่ำ การตอบสนองที่ล่าช้า และความยุ่งยากในการนำไปใช้ในระบบจริง โดยเฉพาะในระบบขนาดใหญ่การวัดค่าความต้านทานภายใน (Internal Resistance: IR) ของแบตเตอรี่ลิเทียมไอออนมีหลายวิธีแบบดั้งเดิมที่ใช้งานอย่างแพร่หลาย ซึ่งแต่ละวิธีมีข้อดีและข้อจำกัดเฉพาะตัว แม้ว่าจะมีความสำคัญในการประเมินสมรรถนะและสุขภาพของแบตเตอรี่ แต่ก็เผชิญกับปัญหาด้านความสะดวกและประสิทธิภาพในการใช้งานจริงหนึ่งในวิธีที่แม่นยำที่สุดคือ Electrochemical Impedance Spectroscopy (EIS) ซึ่งเป็นเทคนิคเชิงความถี่ที่ให้ข้อมูลเชิงลึกเกี่ยวกับอิมพีแดนซ์ของแบตเตอรี่ในช่วงความถี่ต่าง ๆ โดยแม้จะมีความแม่นยำสูง แต่การวัดด้วย EIS ใช้เวลานานและไม่เหมาะกับการประเมินแบบเรียลไทม์ อย่างไรก็ตามมีความพยายามพัฒนา EIS ให้เร็วขึ้นด้วยเทคนิคอย่าง Fast-Fourier Transform และ Pseudo-random Sequences [1] อีกวิธีหนึ่งคือ DC Internal Resistance (DCIR) ซึ่งอาศัยการวัดแรงดันตกคร่อมหลังจากจ่ายกระแสแบบขั้นบันได (Step Current) มักใช้ในการทดสอบคุณภาพและวงจรของแบตเตอรี่ วิธีนี้ใช้งานง่ายแต่ไม่สามารถสะท้อนการเปลี่ยนแปลงของ IR ระหว่างการทำงานได้ดี ส่วน Pulse Testing เป็นเทคนิคที่ใช้พัลส์กระแสสั้น ๆ เพื่อประมาณค่า IR แบบไดนามิกจากการเปลี่ยนแปลงแรงดัน แม้ว่าจะใช้ได้ผลในบางกรณี แต่ก็ยังคงต้องให้แบตเตอรี่อยู่ในสถานะนิ่ง ทำให้ไม่เหมาะกับการประยุกต์ในระบบที่ทำงานต่อเนื่องหรือแบบเรียลไทม์ข้อจำกัดของวิธีดั้งเดิมเหล่านี้คือมักต้องถอดโหลออกจากแบตเตอรี่ก่อนการวัด จึงไม่สามารถใช้ในสภาพแวดล้อม in-operando ได้ นอกจากนี้ยังมีต้นทุนสูงและกระบวนการซับซ้อน ทำให้เกิดแนวโน้มในการค้นคว้าวิธีทางเลือกใหม่ เช่น การฉีดสัญญาณแบบ Binary Sequence เป็นช่วง ๆ (Discrete-Interval-Binary-Sequence Injection) ซึ่งสามารถวัดค่า IR ได้แบบเรียลไทม์ [2] แม้จะมีการพัฒนาวิธีวัดเหล่านี้อย่างต่อเนื่อง แต่การติดตามค่าความต้านทานภายในแบบเรียลไทม์ยังคงเป็นความท้าทายสำคัญ จึงจำเป็นต้องวิจัยวิธีที่มีความแม่นยำ ใช้งานได้ง่าย และเหมาะสมกับระบบแบตเตอรี่ที่ทำงานอย่างต่อเนื่องเพื่อแก้ไขข้อจำกัดของวิธีการวัดค่าความต้านทานภายในแบบดั้งเดิม

งานวิจัยนี้จึงนำเสนอแนวทางใหม่โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง เพื่อสร้างแบบจำลองที่สามารถประมาณค่าความต้านทานภายในได้จากข้อมูลแรงดันและกระแสไฟฟ้าที่ได้จากการทำงานจริงของแบตเตอรี่ แนวทางนี้ช่วยให้สามารถประเมินค่าความต้านทานภายในได้อย่างต่อเนื่อง รวดเร็ว และไม่รบกวนการทำงานของระบบ โดยเฉพาะอย่างยิ่งในระบบขนาดใหญ่หรือระบบที่ใช้ใช้งานจริง ซึ่งไม่สามารถหยุดเพื่อตรวจวัดได้โดยสะดวก ทั้งนี้ยังเปิดโอกาสให้ระบบจัดการแบตเตอรี่สามารถ

นำข้อมูลที่ได้ไปใช้ในการวินิจฉัย ตรวจสอบความผิดปกติ และบริหารจัดการสมรรถนะของแบตเตอรี่ได้อย่างมีประสิทธิภาพมากยิ่งขึ้น

2. งานวิจัยที่เกี่ยวข้อง

2.1 การใช้ Machine Learning ประเมิน SoH

ความก้าวหน้าของเทคนิคการเรียนรู้ของเครื่อง (Machine Learning: ML) ในช่วงหลังได้เข้ามามีบทบาทสำคัญในการประมาณค่าพารามิเตอร์ภายในของแบตเตอรี่ เช่น สถานะสุขภาพของแบตเตอรี่ (State of Health: SoH), สถานะการชาร์จ (State of Charge: SoC) และค่าความต้านทานภายใน โดยแนวทางแบบ data-driven นี้สามารถให้ผลการทำนายที่แม่นยำโดยไม่ต้องอาศัยการวัดแบบรุกล้ำ (non-invasive) จึงเหมาะสมอย่างยิ่งสำหรับการนำไปใช้งานร่วมกับระบบจัดการแบตเตอรี่ (Battery Management System: BMS)

ตารางที่ 1 วิธีการและเทคนิคที่ใช้ในงานวิจัยด้านการทำนายค่าความต้านทานภายใน

งานวิจัย	วิธีการ / เทคนิค	ข้อมูลนำเข้า	จุดเด่น	ข้อจำกัด
M.A.A Khan (2022)	EIS + SVR	Voltage Current Temp	ความแม่นยำสูง ($R^2 > 0.95$)	ใช้ EIS ต้องมีอุปกรณ์เฉพาะ
H.A. Khalid (2022)	RF Regression	V, I, SoC, Cycle index	ไม่ต้องหยุดโหลด, ใช้ข้อมูลที่มีอยู่แล้ว	สมรรถนะลดลงที่ SoC ต่ำ
R. Balan (2022)	ANN (MLP)	V, I, T, Time	ประเมิน IR ได้แม่นยำระหว่างชาร์จ	ต้องการข้อมูล training จำนวนมาก
B. Bakkaloglu (2022)	Linear Regression	Avg. Current, ΔV	เรียบง่าย, ฝังในไมโครคอนโทรลเลอร์ได้	ความแม่นยำต่ำเมื่อโหลดไม่คงที่
Proposed methods	SVR, RF, MLP, LSTM, NARX	V, I, T	ใช้กับ BMS จริงได้, แม่นยำ	ทดสอบด้วยการจำลอง


ในการประเมิน SoH นักวิจัยได้นำเทคนิค ML อย่าง Neural Networks และ Decision Trees มาใช้วิเคราะห์จากข้อมูลประวัติการชาร์จและดิสชาร์จ ซึ่งให้ผลแม่นยำสูงและใช้ทรัพยากรในการประมวลผลน้อยกว่าวิธีเชิงฟิสิกส์แบบเดิม [3] สำหรับการประมาณความจุของแบตเตอรี่ (Capacity Estimation) มีการใช้แบบจำลองการถดถอย (Regression Models) และเทคนิคจับคู่โค้งแรงดันไฟฟ้า (Curve-Matching) โดยอาศัยข้อมูลจากกราฟแรงดันและรอบการใช้งาน ซึ่งช่วยให้สามารถติดตามความจุได้แบบเรียลไทม์ เพิ่มความน่าเชื่อถือของระบบแบตเตอรี่ [4] ในด้านการทำนายค่าความต้านทานภายใน (IR) ได้มีการประยุกต์ใช้โมเดลอย่าง Support Vector Regression (SVR), Random Forest และ Artificial Neural Network ซึ่งอาศัยตัวแปรนำเข้า เช่น แรงดันไฟฟ้า กระแส และอุณหภูมิ โดยผลการทำนายที่แม่นยำของ IR มีความสำคัญต่อการเพิ่มประสิทธิภาพและยืดอายุการใช้งานของแบตเตอรี่ [5]

แม้ว่าการใช้ ML จะให้ประโยชน์อย่างมากในงานวิเคราะห์แบตเตอรี่ แต่ยังคงมีความท้าทาย เช่น ความต้องการชุดข้อมูลขนาดใหญ่ และปัญหา overfitting ที่อาจเกิดขึ้นในโมเดลที่ซับซ้อน ดังนั้น การพัฒนาเทคนิคการ

เรียนรู้ที่มีความยืดหยุ่นและเหมาะสมกับสภาพข้อมูลจริงจะเป็นกุญแจสำคัญในการยกระดับเทคโนโลยีจัดการแบตเตอรี่ต่อไป

3. ระเบียบวิธีวิจัย

ในงานวิจัยนี้ กระบวนการดำเนินการเริ่มจากการเตรียมข้อมูลโดยเก็บรวบรวมข้อมูลจากเซลล์แบตเตอรี่ชนิดลิเทียมไอออนฟอสเฟต (LFP) พร้อมประมวลผลข้อมูลดิบให้มีความเหมาะสมต่อการวิเคราะห์ โดยคำนวณค่าที่เกี่ยวข้องจากแรงดันไฟฟ้าและกระแสไฟฟ้า เช่น ทำการปรับสเกลข้อมูลให้อยู่ในช่วง $[0,1]$ เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของแบบจำลอง จากนั้นแบ่งชุดข้อมูลออกเป็นข้อมูลฝึกและข้อมูลทดสอบในสัดส่วน 70 ต่อ 30 พร้อมดำเนินการคัดกรองและลบข้อมูลที่มีค่าผิดปกติหรือข้อมูลสูญหายเพื่อรักษาคุณภาพของข้อมูล ขั้นตอนต่อมาทำการกำหนดการทดสอบโดยเลือกใช้วิธีการเรียนรู้ของเครื่องหลายรูปแบบ ได้แก่ การถดถอยเชิงเส้น การถดถอยแบบเวกเตอร์สนับสนุน การถดถอยแบบป่าสุ่ม และการรับรู้หลายชั้น ทั้งนี้ ประสิทธิภาพของแต่ละแบบจำลองจะได้รับการประเมินโดยใช้ตัวชี้วัดมาตรฐาน ได้แก่ งานวิจัยนี้ใช้ตัวชี้วัดมาตรฐานทางสถิติและการเรียนรู้ของเครื่อง ได้แก่ ค่าความคลาดเคลื่อนเฉลี่ย (Mean Absolute Error: MAE) ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RM Error: MAPE) จะนำไปสู่การเลือกแบบจำลองที่เหมาะสมที่สุดสำหรับการพยากรณ์และการวิเคราะห์ในงานวิจัยเพื่อเปรียบเทียบประสิทธิภาพและคัดเลือกวิธีการที่เหมาะสมที่สุดสำหรับการวิเคราะห์ในงานวิจัยนี้แต่ในตัวโปรแกรมจะยังมีข้อจำกัดที่เราไม่สามารถแก้ไขเองได้อยู่จะเป็นการที่ MATLAB นั้นยังไม่สามารถนำข้อมูลที่มีทั้งหมดที่เก็บมาได้มาใช้จริงได้จึงต้องเอาการปรับลดข้อมูลก่อนที่จะเริ่มการฝึกโมเดลจึงต้องปรับเปลี่ยนวิธีในการทำข้อมูลของการฝึกโมเดล เพื่อให้งานวิจัยนี้มีความแม่นยำที่สุด




รูปที่ 1 กระบวนการวิจัย


3.1 การเตรียมข้อมูล

กระบวนการเตรียมข้อมูลสำหรับการสร้างแบบจำลองแบตเตอรี่ลิเทียมไอออนฟอสเฟต (LFP) มีความสำคัญอย่างยิ่งต่อความแม่นยำ

และความน่าเชื่อถือของโมเดลการพยากรณ์ งานวิจัยนี้ใช้ชุดข้อมูลที่เก็บจากการทดลองในการจำลองด้วยโปรแกรม Automotive Simulation Model โดยทดสอบเซลล์ LFP ขนาด 80 Ah ในหลายสภาวะการชาร์จและดิสชาร์จ ข้อมูลที่ได้ประกอบด้วยพารามิเตอร์หลัก ได้แก่ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ สถานะการชาร์จ (SoC) และค่าความต้านทานภายใน โดยกราฟพื้นผิวสามมิติแสดงความสัมพันธ์ระหว่างสถานะประจุ (SoC) และอุณหภูมิต่อค่าความต้านทานภายในของแบตเตอรี่ พบว่าความต้านทานมีค่าสูงสุดเมื่อ SoC อยู่ในช่วงประมาณ 50–90% และอุณหภูมิอยู่ราว 20–40°C ขณะที่ในช่วง SoC ต่ำหรือสูงมาก รวมถึงอุณหภูมิที่ต่ำหรือสูงเกินไป ค่าความต้านทานภายในจะลดลงอย่างชัดเจน ดังแสดงในรูปที่ 2 และโครงสร้างและการจัดเรียงเซลล์ภายในแบตเตอรี่ที่แสดงในรูปที่ 3 โดยมีข้อมูลมิติ ขนาด และจำนวนเซลล์ในแต่ละทิศทาง เพื่อใช้คำนวณคุณสมบัติเชิงกายภาพ เช่น มวล 178 kg และพื้นที่ผิวรวม 1.495 m² ของแบตเตอรี่แพ็คเกจ พร้อมทั้งระบุตำแหน่งการไหลของกระแสรวม ผ่านการเรียงลำดับเซลล์ ซึ่งช่วยในการจำลองวงจรสมมูลของแบตเตอรี่สำหรับวิเคราะห์ค่าความต้านทานระหว่างการชาร์จและการคายประจุได้แม่นยำ




รูปที่ 2 กราฟพื้นผิวของความต้านทานภายในแบตเตอรี่เทียบกับสถานะประจุและอุณหภูมิ



รูปที่ 3 วงจรสมมูลของแบตเตอรี่พร้อมค่าความต้านทานระหว่างการชาร์จและการคายประจุ


รูปที่ 4 เป็นวงจรสมมูลของแบตเตอรี่แพ็คเกจ ซึ่งใช้แทนพฤติกรรมทางไฟฟ้าของชุดแบตเตอรี่ในระหว่างการชาร์จและการคายประจุ โดยประกอบด้วยแหล่งแรงดันไฟฟ้าเชิงอุดม ต่ออนุกรมกับความต้านทานภายใน และองค์ประกอบ R-C ที่แทนพลวัตของเซลล์ ข้อมูลค่าความ

ต้านทานถูกระบุแยกตามสภาวะการทำงาน ได้แก่ ความต้านทานระหว่างการคายประจุ 0.0007 โอห์ม และ 0.0003 โอห์ม และความต้านทานระหว่างการชาร์จ 0.0007 โอห์ม และ 0.0003 โอห์ม ซึ่งช่วยให้การจำลองสามารถสะท้อนการสูญเสียพลังงานและประสิทธิภาพการทำงานของแบตเตอรี่ได้อย่างแม่นยำ



รูปที่ 4 โครงสร้างและการจัดเรียงเซลล์ของชุดแบตเตอรี่สำหรับการวิเคราะห์

3.2 การสร้างและฝึกโมเดล



รูปที่ 5 ขั้นตอนการพัฒนาแบบจำลอง LSTM สำหรับประมาณค่าความต้านทานภายในของแบตเตอรี่จากข้อมูลแรงดันและกระแส

โมเดลที่ใช้ประกอบด้วย Linear Regression ซึ่งทำหน้าที่เป็น baseline สำหรับเปรียบเทียบประสิทธิภาพ โดยให้มุมมองที่เรียบง่ายเกี่ยวกับความสัมพันธ์ระหว่างตัวแปร [6] Support Vector Regression ซึ่งใช้ kernel แบบ RBF เพื่อจับความสัมพันธ์แบบไม่เป็นเชิงเส้น ซึ่งเหมาะกับพฤติกรรมของแบตเตอรี่ที่มีความซับซ้อน Random Forest Regression ซึ่งเป็นวิธีแบบ ensemble ที่ใช้ต้นไม้ตัดสินใจหลายต้น และมีจุดเด่นในด้านการวิเคราะห์ความสำคัญของฟีเจอร์ เพิ่มความสามารถในการอธิบายผลลัพธ์ [7] และ Multilayer Perceptron ซึ่งเป็นโครงข่ายประสาทเทียมแบบ feedforward มีสามชั้นซ่อนและฝึกด้วยตัวปรับ

ค่าพารามิเตอร์แบบ Adam ทำให้สามารถจำแนกรูปแบบข้อมูลแบบเตอร์ที่ซับซ้อนได้อย่างมีประสิทธิภาพ แม้ว่าโมเดลที่เลือกจะมีความสามารถในการทำนายที่ดี แต่ก็ยังมีบางจุดที่ต้องพัฒนาเพิ่มเติม โดยเฉพาะการใช้เทคนิค deep learning เช่น ซึ่งเหมาะกับข้อมูลที่มีลำดับต่อเนื่องและสามารถจับรูปแบบที่ซับซ้อนในพฤติกรรมของแบตเตอรี่ได้ดียิ่งขึ้น ซึ่งเป็นทิศทางที่น่าสนใจในการต่อยอดงานวิจัย

3.3 เมทริกซ์ที่ใช้ประเมินผล

การประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่อง ในการวินิจฉัยแบตเตอรี่นั้นขึ้นอยู่กับเมทริกซ์หลักหลายตัวที่ช่วยความแม่นยำในการพยากรณ์ โดยเมทริกซ์ที่ใช้บ่อย ได้แก่ ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE), ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบร้อยละ (MAPE), ค่ารากของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าสัมประสิทธิ์การกำหนด (R^2) ซึ่งล้วนมีความสำคัญต่อการประเมินประสิทธิภาพของโมเดลที่ใช้ในการพยากรณ์สถานะสุขภาพของแบตเตอรี่ SoH และอายุการใช้งานที่เหลืออยู่ (Remaining Useful Life: RUL)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$


$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

เมื่อ y_i คือ ค่าจริง $\hat{y}_i$ คือ ค่าที่โมเดลทำนาย และ n คือ จำนวนข้อมูลทั้งหมด

4. ผลการทดสอบ


ในการประเมินประสิทธิภาพของแบบจำลองที่พัฒนาขึ้น ได้ทำการทดสอบและเปรียบเทียบผลการทำนายค่าความต้านทานภายในของแบตเตอรี่ภายใต้สภาวะการทำงานที่แตกต่างกัน โดยใช้ตัวชี้วัดด้านความแม่นยำ เช่น ค่า MAE และ RMSE จากผลการเปรียบเทียบในรูปที่ 6 และตารางที่ 2 พบว่าแบบจำลอง LSTM ให้ค่าความคลาดเคลื่อนต่ำที่สุดทั้งในแง่ค่า MAE และ RMSE แสดงถึงความสามารถในการทำนายค่าความต้านทานภายในแบตเตอรี่ได้อย่างแม่นยำและเสถียรกว่าแบบจำลองอื่น ๆ ขณะที่แบบจำลอง Linear, Poly และ Tree มีค่าความคลาดเคลื่อนสูงกว่า LSTM อย่างชัดเจน ส่วนแบบจำลอง MLP และ NARX แม้จะมีความแม่นยำในระดับปานกลางแต่ยังด้อยกว่า LSTM ผลลัพธ์นี้ชี้ให้เห็นว่า LSTM เป็นแนวทางที่มีศักยภาพสูงสำหรับการประเมินค่าความต้านทานภายในแบตเตอรี่ โดยเฉพาะในงานที่ต้องการความแม่นยำและความน่าเชื่อถือในการพยากรณ์ โดยผลการจำลองแต่ละโมเดลแสดงในรูปที่ 7



รูปที่ 6 เปรียบเทียบค่า MAE และ RMSE ของแบบจำลองต่าง ๆ สำหรับการนำค่าความต้านทานภายในแบตเตอรี่

ตารางที่ 2 สมรรถนะของโมเดลในการประมาณค่าความต้านทานภายใน

โมเดล	MAE	MAPE (%)	R ²
Linear	0.0156	9.42	0.842
Decision Tree	0.0104	6.80	0.901
MLP	0.0058	10.65	0.961
LSTM	0.0063	4.12	0.952
NARX	0.0069	4.57	0.946



รูปที่ 7 กราฟเปรียบเทียบค่าจริงและค่าทำนายของแบบจำลองต่าง ๆ สำหรับการประมาณค่าความต้านทานภายในแบตเตอรี่

รูปที่ 7 ผลการทดลองแสดงให้เห็นว่าโมเดล LSTM มีความสามารถในการทำนายที่ใกล้เคียงค่าจริงมากกว่าโมเดลอื่น โดยค่าที่ทำนายมีการกระจายตัวน้อยและเกาะเส้นค่าจริงได้ดีกว่า ทำให้เห็นถึงศักยภาพของ LSTM ในการเรียนรู้ความสัมพันธ์เชิงเวลา (temporal dependency) ของข้อมูลได้อย่างมีประสิทธิภาพ อีกทั้งยังลดความคลาดเคลื่อนและความแปรปรวนในการพยากรณ์

5. สรุป

จากผลการศึกษา พบว่าเทคนิคการเรียนรู้ของเครื่องสามารถนำมาใช้ในการนำค่าความต้านทานภายในของแบตเตอรี่ลิเทียมไอออนได้อย่างแม่นยำ เมื่อใช้ร่วมกับข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า เก็บจากสภาพการใช้งานจริง ผลการทดลองชี้ให้เห็นว่าโมเดลประเภท LSTM ให้ผลลัพธ์ที่ดีที่สุดภายใต้ชุดข้อมูลที่ใช้ในการฝึกและทดสอบ ทั้งในแง่ของค่า MAE, MAPE และ R^2 ซึ่งสะท้อนถึงความสามารถของโมเดลในการเรียนรู้รูปแบบ

ข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ นอกจากนี้ วิธีการดังกล่าวยังช่วยลดข้อจำกัดของการวัดความต้านทานภายในแบบดั้งเดิมซึ่งมักต้องอาศัยอุปกรณ์เฉพาะและไม่เหมาะกับการใช้งานแบบเรียลไทม์จากศักยภาพของโมเดลที่พัฒนาขึ้น

งานวิจัยนี้ จึงสามารถนำไปต่อยอดโดยการฝังโมเดลเข้ากับระบบจัดการแบตเตอรี่สำหรับการใช้งานจริงในเวลาจริง นอกจากนี้ยังสามารถประยุกต์ใช้กับแบตเตอรี่ที่มีองค์ประกอบเคมีต่างชนิด เช่น NMC หรือ LCO เพื่อขยายขอบเขตของโมเดลให้รองรับระบบแบตเตอรี่ที่หลากหลายยิ่งขึ้น อีกทั้งยังสามารถพัฒนาในทิศทางของการเรียนรู้แบบถ่ายโอน หรือการเรียนรู้แบบออนไลน์ เพื่อให้สามารถปรับตัวกับข้อมูลใหม่ได้แบบต่อเนื่อง

กิตติกรรมประกาศ

บทความนี้ได้รับการสนับสนุนจาก มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

เอกสารอ้างอิง

- [1] M. A. A. Khan, H. A. Khalid, R. Balan, and B. Bakkaloglu, "A novel State of Charge and State of Health estimation technique for Lithium-ion cells using machine learning based Pseudo-Random Binary Sequence method," *J. Energy Storage*, vol. 55, p. 105472, Nov. 2022, doi: 10.1016/j.est.2022.105472.
- [2] R.-E. Tudoroiu, M. Zaheeruddin, S.-M. Radu, and N. Tudoroiu, "Real-Time Implementation of an Extended Kalman Filter and a PI Observer for State Estimation of Rechargeable Li-Ion Batteries in Hybrid Electric Vehicle Applications—A Case Study," *Batteries*, vol. 4, no. 2, 2018, doi: 10.3390/batteries4020019.
- [3] L. Qian, L. Xuan, and J. Chen, "Battery SOH estimation based on decision tree and improved support vector machine regression algorithm," *Front. Energy Res.*, vol. Volume 11-2023, 2023, doi: 10.3389/fenrg.2023.1218580.
- [4] S. Giazitzis, M. Sakwa, S. Leva, E. Ogliairi, S. Badha, and F. Rosetti, "A Case Study of a Tiny Machine Learning Application for Battery State-of-Charge Estimation," *Electronics*, vol. 13, no. 10, 2024, doi: 10.3390/electronics13101964.
- [5] M. Lin, C. Yan, W. Wang, G. Dong, J. Meng, and J. Wu, "A data-driven approach for estimating state-of-health of lithium-ion batteries considering internal resistance," *Energy*, vol. 277, p. 127675, Aug. 2023, doi: 10.1016/j.energy.2023.127675.
- [6] C. Nguyen Van and D. T. Quang, "Estimation of SoH and internal resistances of Lithium ion battery based on LSTM network," *Int. J. Electrochem. Sci.*, vol. 18, no. 6, p. 100166, June 2023, doi: 10.1016/j.ijoes.2023.100166.
- [7] G. Wang, Z. Lyu, and X. Li, "An Optimized Random Forest Regression Model for Li-Ion Battery Prognostics and Health Management," *Batteries*, vol. 9, no. 6, 2023, doi: 10.3390/batteries9060332.