

การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน
ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว
STATE OF HEALTH ESTIMATION FOR A LI-ION BATTERY
USING LSTM NEURAL NETWORK



ธนวิทย์ เต่าเอก
THANAWIT TAO-EK

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมไฟฟ้า

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2568

KMITL-2025-EN-M-027-056

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

STATE OF HEALTH ESTIMATION FOR A LI-ION BATTERY
USING LSTM NEURAL NETWORK



A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN ELECTRICAL ENGINEERING
SCHOOL OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2025

KMITL-2025-EN-M-027-056

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2025

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออนด้วย โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว
นักศึกษา	นายธนวิทย์ เต่าเอก
รหัสประจำตัว	62601060
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2568
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.สุพัฒน์ กิตติรัตน์สัจจา

บทคัดย่อ

การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน เป็นวิธีการเพื่อใช้ในการระบุว่แบตเตอรี่มีการเสื่อมสภาพลงจากสภาวะเริ่มต้นเพียงใด ข้อมูลนี้มีประโยชน์ในการตัดสินใจว่าเมื่อใดจำเป็นต้องเปลี่ยนแบตเตอรี่ใหม่ สามารถใช้เพื่อคำนวณอายุการใช้งานที่เหลืออยู่ได้ วิทยานิพนธ์เล่มนี้จะนำเสนอการประมาณสถานะสุขภาพของแบตเตอรี่ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวโดยใช้ข้อมูลที่ได้จากข้อมูลโพรไฟล์การอัดประจุ โดยประเมินประสิทธิภาพการประมาณสถานะสุขภาพของแบตเตอรี่ระหว่างการใช้ข้อมูลอินพุตที่แตกต่างกันได้แก่ กระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิและเวลา รวมถึงการใช้ชุดข้อมูลแบบหลายอินพุตไปยังโครงข่ายประสาทเทียม เงื่อนไขทั้งสองนี้ยังดำเนินการด้วยค่าสถานะประจุเริ่มต้นที่แตกต่างกันและอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบที่แตกต่างกัน ชุดข้อมูลสำหรับการเรียนรู้และทดสอบในวิทยานิพนธ์นี้ นำมาจากชุดข้อมูลเซลล์ 18650 “B0005” ที่รวบรวมโดย NASA ซึ่งได้นำมาชั่งตัวอย่างใหม่ให้เหลือ 20 จุดข้อมูลในแต่ละไซเคิล จากการประเมินด้วยค่า RMSE ของผลการประมาณ แสดงให้เห็นว่าการใช้กระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลาเป็นอินพุตให้โครงข่ายประสาทเทียมจะให้ผลลัพธ์ที่ดีที่สุดและอัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบที่สูงกว่ายังให้ผลลัพธ์ที่ดีกว่าด้วย เมื่อพิจารณาถึงเงื่อนไขที่ใกล้เคียงกับการใช้งานจริงที่มีการเริ่มอัดประจุแบตเตอรี่จาก SOC ที่ไม่ใช่ 0% ชุดข้อมูลจะถูกสร้างใหม่โดยการสุ่มค่าเริ่มต้นสถานะประจุสำหรับการเริ่มอัดประจุจากชุดข้อมูลเดิมเพื่อการเรียนรู้และการทดสอบ ในกรณีนี้ผลการประมาณค่า SOH แสดงการแกว่งให้เห็นบางส่วน และขนาดการแกว่งจะลดลงเมื่อมีอัตราส่วนระหว่างการเรียนรู้กับการทดสอบที่สูงขึ้น ผลลัพธ์ที่ดีที่สุดที่ได้จากอัตราส่วนระหว่างการเรียนรู้กับการทดสอบ 80:20 โดยมี RMS อยู่ที่ 0.0085 นอกจากนี้ชุดข้อมูลชุดที่สองที่ได้จากแบตเตอรี่ลิเทียมไอออนแบบปริซึมเซลล์ “C” ขนาด 15Ah ที่มี SOH 95% หลังจกผ่านการทดสอบ 138 รอบ ยังใช้เพื่อเรียนรู้และทดสอบเครือข่ายประสาทเทียมโครงสร้างแบบเดียวกันนี้ด้วย ในชุดข้อมูลนี้ไม่มีโพรไฟล์อุณหภูมิในระหว่างการอัดประจุ ผลการประมาณค่า SOH มีเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แนวโน้มเดียวในทางเดียวกันกับของแบตเตอรี่ “B0005” โดยที่ SOC ที่เริ่มอัดประจุแบบสุ่มจะให้ผลลัพธ์ที่มีการแกว่งสูงแต่ลดลงเมื่อมีอัตราส่วนระหว่างการเรียนรู้และการทดสอบที่สูงขึ้น ผลลัพธ์ที่ดีที่สุดที่ได้จากอัตราส่วนระหว่างการเรียนรู้และการทดสอบ 80:20 โดยมี RMS อยู่ที่ 0.0616 ซึ่งสูงกว่าของ “B0005” ค่า RMSE จะลดลงเล็กน้อยเมื่อใช้ช่วง SOC เริ่มต้นแบบสุ่มที่แคบลง โดยคาดว่าค่าประมาณค่า SOH จะแม่นยำขึ้นเมื่อชุดข้อมูลมีรอบการทดสอบมากขึ้น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis	State of Health Estimation for a Li-ion Battery using LSTM Neural Network
Student	Mr. Thanawit Tao-ek
Student ID.	62601060
Degree	Master of Engineering
Program	Electrical Engineering
Year	2025
Thesis Advisor	Assoc.Prof.Dr.Supat Kittiratsatcha

ABSTRACT

The state of health (SOH) estimation for a Li-ion battery is a method that determines how much the battery's health has deteriorated from its original state. This can be useful in deciding when a new battery replacement may be necessary and can be used to calculate the Remaining Useful Life (RUL). This thesis presents a state of health estimation using a Long Short-Term Memory neural network, having charge profile data as the inputs. In this thesis, the state of health estimation is evaluated using single or multiple inputs including current, voltage, temperature, and time for the neural network. The evaluations are also performed with different ratios of train-to-test set and different initial states of charge (SOC) at the starting of charging. The first dataset used in this thesis are taken from "B0005" 18650 cell collected by NASA and have been appropriately resampled for 20 data points for each cycle. From the evaluation with RMSE values of the estimation results, it is shown that using multiple inputs including current, voltage, temperature, and time for the neural network provides better results. The higher train-to-test ratio provides lower RMSE of SOH estimations. When considering close to practical use conditions where a battery may be charged from the SOC other than 0%, a randomly starting SOC data set is regenerated from the original data set for the training and test. In this case the SOH estimation shows some fluctuations, and the fluctuation is lower with higher train-to-test ratio. The best result obtained with 80:20 train-to-test ratio has RMS of 0.0085. In addition, the second dataset obtained from a 15Ah prismatic cell "C" lithium-ion battery having 95% SOH after 138 test cycle is also used to train and test for the same

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

structural neural network. In this dataset the temperature profile during charging is missing. The same trend of estimation results is obtained compared to those of the battery “B0005”, where randomly starting charging SOC gives higher fluctuation results that decreases with higher train-to-set ratio. The best result obtained with 80:20 train-to-test ration has RMS of 0.0616 which is higher than those of “B0005”. The RMSE is slightly decreased when using narrower random starting SOC window. The estimation is expected to be more accurate when the dataset contains more test cycles.



กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้ สำเร็จลุล่วงด้วยความกรุณาอย่างสูงจากท่านอาจารย์ที่ปรึกษา ดร.สมภพ ผลไม้ และรองศาสตราจารย์ ดร.สุวัฒน์ กิตติรัตนสัจจา ที่ได้เสียสละเวลาในการให้คำปรึกษา ชี้แนะแนวทางแก้ไขข้อบกพร่อง ตลอดจนการตรวจสอบความเรียบร้อยของวิทยานิพนธ์เล่มนี้ ข้าพเจ้าขอกราบขอบพระคุณทุกท่านเป็นอย่างสูง

ขอขอบพระคุณอาจารย์ คณะวิศวกรรมไฟฟ้า สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังทุกท่าน ที่ให้การอบรมสั่งสอน มอบวิชาความรู้ให้แก่ข้าพเจ้า และขอขอบคุณสมาชิกทุกท่านในห้องปฏิบัติการ PEARL LAB ที่ให้ความช่วยเหลือสนับสนุนเครื่องมือสิ่งของที่เกี่ยวข้องในงานวิจัยจนสำเร็จลุล่วงไปด้วยดี

สุดท้ายนี้ขอขอบพระคุณบิดา มารดา และครอบครัวซึ่งเป็นที่เคารพรักและเป็นกำลังใจตลอดมา ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้ มา ณ ที่นี้

ธนวิทย์ เต่าเอก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	III
กิตติกรรมประกาศ.....	V
สารบัญ.....	VI
สารบัญตาราง.....	IX
สารบัญรูป.....	X
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของวิทยานิพนธ์.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตของงานวิจัย.....	3
1.4 แผนการปฏิบัติงาน.....	4
1.5 ประโยชน์ที่รับจากการวิจัย.....	4
บทที่ 2 การประเมินสถานะสุขภาพ แบทเตอรีลิเทียมไอออน.....	5
2.1 แบทเตอรีลิเทียมไอออน.....	5
2.1.1 คุณสมบัติของแบทเตอรีลิเทียมไอออน.....	5
2.1.2 หลักการทำงานของแบทเตอรีลิเทียมไอออน.....	5
2.2 สถานะสุขภาพ.....	6
2.3 สถานะประจุ.....	8
2.4 ปัญญาประดิษฐ์.....	9
2.5 การเรียนรู้ของเครื่อง.....	10
2.5.1 การเรียนรู้แบบมีผู้สอน.....	10
2.5.2 การเรียนรู้แบบไม่มีผู้สอน.....	11
2.5.3 การเรียนรู้แบบเสริมแรง.....	11
2.6 โครงข่ายประสาทเทียม.....	12
2.6.1 โครงสร้างของโครงข่ายประสาทเทียม.....	15
2.6.2 การเรียนรู้เชิงลึก.....	15
2.6.3 โครงข่ายประสาทเทียมแบบเวียนซ้ำ.....	16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6.4	โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว.....	16
2.7	tensorflow.keras.....	19
บทที่ 3	การสร้างแบบจำลองสำหรับการประเมินสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน	23
3.1	ชุดข้อมูลแบตเตอรี่ (Data sets).....	23
3.1.1	ชุดข้อมูลแบตเตอรี่ B0005.....	23
3.1.2	ชุดข้อมูลแบตเตอรี่ C	27
3.2	การจัดเตรียมข้อมูล	29
3.2.1	ค่าสหสัมพันธ์	29
3.2.2	การชักตัวอย่างชุดข้อมูลแบตเตอรี่ B0005	31
3.2.3	การชักตัวอย่างชุดข้อมูลแบตเตอรี่ C.....	34
3.3	การสร้างแบบจำลอง	37
3.4	การประมวลผล	38
บทที่ 4	ผลการประเมินสถานะสุขภาพของแบตเตอรี่.....	46
4.1	ผลการประเมินสถานะสุขภาพจากชุดข้อมูลแบตเตอรี่ B0005	46
4.1.1	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่อตัวแปร อินพุตต่างชนิดกัน	46
4.1.2	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่อ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน	53
4.1.3	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม.....	56
4.1.4	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม เมื่อ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน	59
4.2	ผลการประเมินสถานะสุขภาพจากชุดข้อมูลแบตเตอรี่ C.....	62
4.2.1	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่อ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน	63
4.2.2	การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม เมื่อ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน	66
บทที่ 5	สรุปผลการทดสอบ และข้อเสนอแนะ.....	70
5.1	สรุปผลการทดสอบ.....	70
5.2	วิเคราะห์ปัญหา.....	71

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.3 ข้อเสนอแนะ	77
เอกสารอ้างอิง	78
ภาคผนวก ก ผลงานเกี่ยวกับวิทยานิพนธ์ที่ได้รับการตีพิมพ์เผยแพร่	81
ประวัติผู้เขียน	89



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
ตารางที่ 1.1	แผนการดำเนินโครงการ 4
ตารางที่ 3.1	ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างข้อมูลโพรไฟล์ประจุไฟฟ้าของชุดข้อมูล แบตเตอรี่ B0005..... 30
ตารางที่ 3.2	ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างข้อมูลโพรไฟล์ประจุไฟฟ้าของชุดข้อมูล แบตเตอรี่ C 30
ตารางที่ 4.1	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% เมื่อตัวแปรอินพุตต่างชนิดกัน..... 52
ตารางที่ 4.2	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน 56
ตารางที่ 4.3	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้นแบบสุ่ม เมื่อตัวแปรอินพุตต่างชนิดกัน..... 59
ตารางที่ 4.4	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน 62
ตารางที่ 4.5	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ C ที่ SOC เริ่มต้น 0% เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน 65
ตารางที่ 4.6	ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ C ที่ SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน 68
ตารางที่ 4.7	ค่าผิดพลาดสูงสุดของผลการประมาณสถานะสุขภาพข้อมูลแบตเตอรี่ C ที่ SOC เริ่มต้นแบบสุ่ม..... 69

สารบัญรูป

รูปที่		หน้า
รูปที่ 2.1	กระบวนการประจุไฟฟ้าและคายประจุไฟฟ้า.....	6
รูปที่ 2.2	ตัวอย่างการกำเนิดใหม่ของความจุ.....	8
รูปที่ 2.3	ลำดับชั้นของปัญญาประดิษฐ์.....	10
รูปที่ 2.4	รูปแบบการเรียนรู้ของเครื่อง.....	12
รูปที่ 2.5	โครงสร้างของโครงข่ายประสาทเทียม.....	13
รูปที่ 2.6	โครงสร้างของเพอร์เซปตรอน.....	13
รูปที่ 2.7	ประเภทของฟังก์ชันกระตุ้น.....	14
รูปที่ 2.8	โครงสร้างของ Deep Learning.....	15
รูปที่ 2.9	โครงสร้างของโครงข่ายประสาทเทียมแบบเวียนซ้ำ.....	16
รูปที่ 2.10	โครงสร้างพื้นฐานของเซลล์ประสาท LSTM.....	17
รูปที่ 2.11	รูปแบบของอินพุตและเอาต์พุตข้อมูลที่นำเข้าสู่โครงข่ายประสาทเทียม LSTM.....	18
รูปที่ 2.12	โปรแกรมสำหรับการเขียนภาษา Python.....	22
รูปที่ 3.1	กราฟข้อมูลกระแสไฟฟ้าของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า.....	24
รูปที่ 3.2	กราฟข้อมูลแรงดันไฟฟ้าของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า.....	25
รูปที่ 3.3	กราฟข้อมูลอุณหภูมิของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า.....	25
รูปที่ 3.4	กราฟข้อมูลความจุในแต่ละรอบการคายประจุของแบตเตอรี่ B0005.....	26
รูปที่ 3.5	สถานะสุขภาพของแบตเตอรี่ B0005.....	26
รูปที่ 3.6	กราฟข้อมูลกระแสไฟฟ้าของแบตเตอรี่ C ขณะประจุไฟฟ้า.....	27
รูปที่ 3.7	กราฟข้อมูลแรงดันไฟฟ้าของแบตเตอรี่ C ขณะประจุไฟฟ้า.....	28
รูปที่ 3.8	กราฟข้อมูลความจุในแต่ละรอบการคายประจุของแบตเตอรี่ C.....	28
รูปที่ 3.9	สถานะสุขภาพของแบตเตอรี่ C.....	29
รูปที่ 3.10	กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้น 0%.....	31
รูปที่ 3.11	กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้นแบบสุ่ม.....	32
รูปที่ 3.12	กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้น 0%.....	32
รูปที่ 3.13	กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้นแบบสุ่ม.....	33

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.14	กราฟข้อมูลอุณหภูมิ 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้น 0%.....	33
รูปที่ 3.15	กราฟข้อมูลอุณหภูมิ 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้นแบบสุ่ม.....	34
รูปที่ 3.16	กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นเริ่มต้น 0%	35
รูปที่ 3.17	กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นแบบสุ่ม.....	35
รูปที่ 3.18	กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นเริ่มต้น 0%	36
รูปที่ 3.19	กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นแบบสุ่ม.....	36
รูปที่ 3.20	แสดงตัวอย่างการจัดเรียงลำดับข้อมูลสำหรับการฝึกสอนแบบจำลอง LSTM แบบ many to one.....	37
รูปที่ 3.21	Library สำหรับการจัดเตรียมข้อมูลและการประมาณสถานะสุขภาพของแบตเตอรี่... 39	
รูปที่ 3.22	การนำเข้าข้อมูลในรูป DataFrame	40
รูปที่ 3.23	การปรับชุดข้อมูลให้เป็นปกติ ด้วยวิธี Min-Max scaling	40
รูปที่ 3.24	ชุดข้อมูลแบตเตอรี่ B0005 หลังจากปรับข้อมูล ด้วยวิธี Min-Max scaling.....	41
รูปที่ 3.25	ชุดข้อมูลแบตเตอรี่ C หลังจากปรับข้อมูล ด้วยวิธี Min-Max scaling	41
รูปที่ 3.26	การจัดโครงสร้างชุดข้อมูลอินพุตก่อนนำเข้าสู่แบบจำลอง	42
รูปที่ 3.27	การแบ่งชุดข้อมูลเป็นชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบ	42
รูปที่ 3.28	การสร้างแบบจำลองโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว	43
รูปที่ 3.29	Model summary และการสิ้นสุดการเรียนรู้ของแบบจำลองด้วยฟังก์ชัน EarlyStopping.....	44
รูปที่ 3.30	กราฟแสดงผลลัพธ์ในกระบวนการเรียนรู้ของแบบจำลอง.....	44
รูปที่ 3.31	ขั้นตอนการประมาณสถานะสุขภาพของแบตเตอรี่.....	45
รูปที่ 4.1	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า.....	47
รูปที่ 4.2	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย กระแสไฟฟ้า.....	47
รูปที่ 4.3	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย ค่าอุณหภูมิ.....	48

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.4	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า.....	48
รูปที่ 4.5	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า อุณหภูมิ	49
รูปที่ 4.6	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย กระแสไฟฟ้า อุณหภูมิ	49
รูปที่ 4.7	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า เวลา.....	50
รูปที่ 4.8	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า อุณหภูมิ เวลา	50
รูปที่ 4.9	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย กระแสไฟฟ้า อุณหภูมิ เวลา	51
รูปที่ 4.10	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ	51
รูปที่ 4.11	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 4 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา	52
รูปที่ 4.12	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50.....	54
รูปที่ 4.13	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40.....	54
รูปที่ 4.14	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30.....	55
รูปที่ 4.15	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20.....	55
รูปที่ 4.16	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา.....	57
รูปที่ 4.17	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า อุณหภูมิ เวลา.....	57
รูปที่ 4.18	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ	58
รูปที่ 4.19	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

	ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า.....	58
รูปที่ 4.20	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50.....	60
รูปที่ 4.21	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40.....	60
รูปที่ 4.22	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30.....	61
รูปที่ 4.23	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20.....	61
รูปที่ 4.24	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50.....	63
รูปที่ 4.25	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40.....	64
รูปที่ 4.26	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30.....	64
รูปที่ 4.27	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20.....	65
รูปที่ 4.28	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50.....	66
รูปที่ 4.29	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40.....	67
รูปที่ 4.30	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30.....	67
รูปที่ 4.31	ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20.....	68
รูปที่ 5.1	ชุดข้อมูลกระแสไฟฟ้าแบตเตอรี่ C	72
รูปที่ 5.2	กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นแบบสุ่ม.....	72
รูปที่ 5.3	ชุดข้อมูลแรงดันไฟฟ้าแบตเตอรี่ C	73
รูปที่ 5.4	กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C มีค่า SOC เริ่มต้นแบบสุ่ม.....	73
รูปที่ 5.5	ช่วงเวลาในการสุ่มจุดข้อมูลแรกของข้อมูลกระแสไฟฟ้า	74

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 5.6	ช่วงเวลาในการสุ่มจุดข้อมูลแรกของข้อมูลแรงดันไฟฟ้า.....	74
รูปที่ 5.7	ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-65% SOC	75
รูปที่ 5.8	ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-35% SOC	75
รูปที่ 5.9	ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-65% SOC	76
รูปที่ 5.10	ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-35% SOC	76



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของวิทยานิพนธ์

จากปัญหาสภาวะมลพิษทางอากาศที่เกิดขึ้นจากการกระทำของมนุษย์ เช่น การคมนาคม อุตสาหกรรม หรือกิจกรรมในภาคครัวเรือนที่ส่งผลให้เกิดการปล่อยก๊าซเรือนกระจก จึงได้มีการคิดค้นวิธีการต่างๆ เพื่อลดปัญหาการปล่อยก๊าซเรือนกระจก ในภาคส่วนของการคมนาคม ในหลายๆ ประเทศได้มีการคิดค้นและพัฒนายานยนต์ไฟฟ้าเพื่อมาทดแทนยานยนต์น้ำมัน ที่ใช้พลังงานเชื้อเพลิงเผาไหม้ซึ่งเป็นสาเหตุของก๊าซเรือนกระจก ยานยนต์ไฟฟ้าที่ใช้พลังงานจากแบตเตอรี่จะไม่ก่อให้เกิดปัญหาด้านมลพิษ แบตเตอรี่จึงเป็นส่วนสำคัญในการขับเคลื่อนของยานยนต์ไฟฟ้า โดยยานยนต์ไฟฟ้าในยุคปัจจุบันจะใช้แบตเตอรี่ลิเทียมไอออนเป็นแหล่งพลังงาน นอกจากยานยนต์ไฟฟ้าในปัจจุบัน แบตเตอรี่ลิเทียมไอออนถูกนำมาใช้อย่างแพร่หลายในการทำงานภายในชีวิตประจำวัน เช่น เครื่องใช้ไฟฟ้าในบ้าน สมาร์ทโฟน และเครื่องมือช่าง เนื่องจากมีความหนาแน่นของพลังงานสูง อัตราการคายประจุสูง การคายประจุภายในตัวเองต่ำ และมีน้ำหนักที่น้อยกว่าแบตเตอรี่ตะกั่วเมื่อเทียบกับความจุที่เท่ากัน อย่างไรก็ตาม การเสื่อมสภาพของแบตเตอรี่เป็นปัญหาที่เกิดขึ้นหลังจากกระบวนการผลิตแบตเตอรี่และเริ่มใช้งาน การประมาณสถานะสุขภาพ (SOH) [1] ของแบตเตอรี่อย่างแม่นยำเป็นสิ่งสำคัญสำหรับคาดการณ์ว่าอายุการใช้งานแบตเตอรี่จะสิ้นสุดเมื่อใด นอกจากนี้ความจุ (capacity) ของแบตเตอรี่จะลดลงหลังจากรอบการประจุไฟฟ้าและการคายประจุไฟฟ้าหลายๆ ครั้ง ซึ่งไม่ใช่การลดลงอย่างเป็นเชิงเส้นเนื่องจากการพบการเพิ่มขึ้นของค่าความจุอย่างผิดปกติในบางรอบการใช้งานที่เรียกว่า การกำเนิดใหม่ของความจุ (capacity regeneration) ดังนั้นหากต้องการประมาณสถานะสุขภาพของแบตเตอรี่ให้ได้อย่างแม่นยำ ควรนำเรื่องการกำเนิดใหม่ของความจุมาร่วมพิจารณาด้วยการหาอายุการใช้งาน (Remaining useful life : RUL) ที่เหลืออยู่ของแบตเตอรี่จะใช้วิธีการประมาณสถานะสุขภาพมีสามแนวทางที่นิยมใช้ [2] วิธีแรก ได้แก่

วิธีการวัดโดยตรง (Direct Measurement) วิธีการวัดโดยตรงต้องมีเครื่องมือเฉพาะสำหรับการวัดคุณสมบัติทางไฟฟ้าของแบตเตอรี่ ซึ่งเป็นวิธีที่แม่นยำและตรงไปตรงมาในการประมาณสถานะสุขภาพ โดยวิธีที่นิยมได้แก่

- การวัดค่าความต้านทานภายใน (Internal Resistance) อาศัยหลักการของแบตเตอรี่ที่เสื่อมสภาพจะมีความต้านทานภายในสูงขึ้น เนื่องจากปัจจัยต่าง ๆ เช่น การเสื่อมของแผ่นอิเล็กโทรด หรือการลดลงของอิเล็กโทรไลต์ หรืออาจจะใช้เทคนิคการวิเคราะห์อิมพีแดนซ์ของแบตเตอรี่ (Electrochemical Impedance Spectroscopy : EIS) ข้อดีของวิธีการนี้คือ มีความแม่นยำสูงและวิเคราะห์พฤติกรรมของแบตเตอรี่ได้ละเอียด ส่วน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อเสีย คือ ต้องใช้เครื่องมือเฉพาะทาง ซึ่งมีค่าใช้จ่ายสูงและใช้ระยะเวลาในการประมวลผลที่ซับซ้อน

- การนับประจุ (Coulomb Counting) วิธีนี้ใช้วัดกระแสไฟฟ้าที่ไหลเข้าและออกจากแบตเตอรี่เมื่อมีการประจุไฟฟ้าและคายประจุไฟฟ้า จากนั้นนำกระแสที่ได้มาคำนวณหาค่าความจุไฟฟ้า ข้อดีของวิธีการนี้คือ สามารถใช้ได้กับแบตเตอรี่ทุกประเภท แต่ข้อเสียคือ ต้องคายประจุไฟฟ้าจนหมดทุกรอบการวัดเพื่อให้ได้ค่าที่แม่นยำ

วิธีที่สองสร้างแบบจำลอง (Model-based method) เป็นวิธีที่ใช้แบบจำลองทางคณิตศาสตร์และฟิสิกส์ เพื่อประเมินสถานะสุขภาพของแบตเตอรี่ โดยวิธีที่นิยมได้แก่

- แบบจำลองเชิงประจักษ์ (Empirical Model) จะใช้สมการจากข้อมูลลักษณะเฉพาะของแบตเตอรี่ลิเทียมไอออนในการสร้างแบบจำลองการเสื่อมสภาพของแบตเตอรี่ โดยใช้เทคนิคการฟิตเส้นโค้ง (Curve Fitting) ข้อดีคือใช้งานง่ายและรวดเร็ว แต่ข้อเสียคือ ไม่สามารถใช้กับแบตเตอรี่ต่างชนิดกันได้
- แบบจำลองเชิงเคมีไฟฟ้า (Electrochemical Model) เป็นแบบจำลองที่ใช้สมการเคมีและฟิสิกส์ โดยจะพิจารณากระบวนการทางเคมีที่เกิดขึ้นภายในแบตเตอรี่ เช่น การเคลื่อนที่ของไอออน และปฏิกิริยาที่เกิดขึ้นระหว่างอิเล็กโทรดและอิเล็กโทรไลต์ ข้อดีคือสามารถจำลองการเสื่อมสภาพของแบตเตอรี่และประมาณสถานะสุขภาพได้อย่างแม่นยำ แต่ข้อเสียคือ มีความซับซ้อนและต้องใช้ต้นทุนในการคำนวณสูง
- แบบจำลองวงจรเทียบเท่า (Equivalent Circuit Model) หมายถึงวงจรเทียบเท่าของวงจรเทวินินที่ประกอบด้วยแหล่งจ่ายไฟฟ้า ความต้านทานและความจุ คุณลักษณะของเซลล์แบตเตอรี่สามารถจำลองการใช้ส่วนประกอบทางไฟฟ้า เช่น ตัวต้านทาน (Resistor) ตัวเก็บประจุ (Capacitor) และตัวเหนี่ยวนำ (Inductor) เพื่อจำลองพฤติกรรมของแบตเตอรี่จริงและนำไปใช้ในการประมาณสถานะสุขภาพ มีข้อดีคือ มีความแม่นยำสูงคำนวณง่าย แต่ข้อเสียคือ ไม่สามารถอธิบายกระบวนการทางเคมีได้

วิธีที่สามการขับเคลื่อนเชิงข้อมูล (Data driven method) [3] ในปัจจุบันนิยมอย่างมากในงานที่เกี่ยวข้องกับปัญญาประดิษฐ์ ซึ่งหมายถึงการใช้ข้อมูลจริงในการวิเคราะห์และตัดสินใจ แทนที่จะต้องพึ่งพาสสมมติฐานที่มนุษย์ตั้งขึ้นหรือเงื่อนไขที่กำหนดขึ้นเองแบบดั้งเดิม ระบบเรียนรู้การตัดสินใจได้แบบเรียลไทม์หากมีข้อมูลใหม่ แนวทางนี้ใช้ข้อมูลที่ถูเก็บรวบรวม วิเคราะห์ และประมวลผลเพื่อนำไปใช้ในการตัดสินใจเพื่อให้ได้ผลลัพธ์ที่แม่นยำ ข้อมูลที่ต้องมาจากแหล่งข้อมูลที่เชื่อถือได้ ซึ่งประโยชน์ของวิธีการขับเคลื่อนเชิงข้อมูล ยกตัวอย่างเช่น ช่วยลดต้นทุนในเรื่องค่าใช้จ่ายและเวลาที่ใช้ในการเก็บข้อมูลใหม่ เนื่องจากสามารถใช้ข้อมูลที่มีเพื่อทำนายแนวโน้มในอนาคตได้ซึ่ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบจำลองสามารถเรียนรู้และพัฒนาได้เองจากข้อมูลที่มี แต่ข้อเสียของวิธีการขับเคลื่อนเชิงข้อมูล เช่น ต้องใช้ข้อมูลที่ถูกต้องและมีคุณภาพหากข้อมูลมีข้อผิดพลาด การวิเคราะห์ก็จะผิดพลาดตามไปด้วยหรือข้อมูลมีน้อยเกินไปจนไม่สามารถนำมาใช้ในการวิเคราะห์ได้เพียงพอ ซึ่งการเก็บข้อมูลขนาดใหญ่ต้องใช้ต้นทุนสูงและใช้ระยะเวลามากสำหรับการเตรียมข้อมูลให้เหมาะสม

ในวิทยานิพนธ์นี้จึงเลือกวิธีการขับเคลื่อนเชิงข้อมูลด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) ถือเป็นเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence) ที่สามารถประมวลผลข้อมูลอย่างรวดเร็ว โดยใช้กระบวนการเรียนรู้จากข้อมูล สามารถวิเคราะห์ข้อมูลและมีกระบวนการตัดสินใจที่คล้ายกับมนุษย์ ได้รับการยอมรับและถูกใช้งานอย่างแพร่หลายในด้านต่างๆมาในการประมาณสถานะสุขภาพของแบตเตอรี่ซึ่งจะเป็นวิธีที่อาศัยชุดข้อมูลที่มีในอดีต เช่น ค่าความจุ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ ความต้านทาน และอื่นๆ โดยไม่ต้องใช้แบบจำลองทางคณิตศาสตร์หรือกลไกภายในของการเสื่อมสภาพของแบตเตอรี่ วิธีนี้ใช้งานง่าย มีความแม่นยำสูง และซับซ้อนน้อยกว่าการใช้แบบจำลองทางคณิตศาสตร์

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษาโครงข่ายประสาทเทียม (Artificial Neural Network)
2. เพื่อศึกษาวิธีประมาณสถานะสุขภาพของแบตเตอรี่ จากค่าความจุของแบตเตอรี่ โดยวิธีขับเคลื่อนเชิงข้อมูล (Data driven method) ผ่านโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM)
3. เพื่อสร้างแบบจำลองสำหรับการประมาณสถานะสุขภาพของแบตเตอรี่ ด้วยโปรแกรมภาษา Python และศึกษาชุดคำสั่งโปรแกรมที่เกี่ยวข้อง

1.3 ขอบเขตของงานวิจัย

1. ศึกษาการประมาณสถานะสุขภาพของแบตเตอรี่ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว
2. สร้างแบบจำลองเพื่อใช้ในการประมาณสถานะสุขภาพของแบตเตอรี่ด้วยโปรแกรมภาษา Python
3. แบบจำลองการประมาณสถานะสุขภาพของแบตเตอรี่ สามารถประมาณสถานะสุขภาพของโพรไฟล์ประจุไฟฟ้าของแบตเตอรี่ต่างรุ่นและต่างความจุได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.4 แผนการปฏิบัติงาน

ตารางที่ 1.1 แผนการดำเนินโครงการ

การดำเนินการ	พ.ศ. 2567					พ.ศ. 2568			
	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.
ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการประเมินสถานะสุขภาพ									
ศึกษาการสร้างแบบจำลองโครงข่ายประสาทเทียม ผ่านชุดคำสั่งและโปรแกรมที่เกี่ยวข้อง									
ศึกษาวิธีจัดการข้อมูลและเตรียมชุดข้อมูลให้เหมาะสมสำหรับการประเมินสถานะสุขภาพแบบเตอรี									
สร้างแบบจำลองในการประเมินสถานะสุขภาพด้วยโครงข่ายประสาทเทียม LSTM									
นำแบบจำลองที่ออกแบบ มาทดสอบด้วยชุดข้อมูลแบบเตอรีที่จัดเตรียมไว้									
สรุปผลการทดสอบ									
จัดทำรูปเล่มวิทยานิพนธ์									

1.5 ประโยชน์ที่ได้รับจากการวิจัย

1. องค์ความรู้เกี่ยวกับการประเมินสถานะสุขภาพของแบบเตอรี
2. องค์ความรู้เกี่ยวกับโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว
3. สามารถประเมินสถานะสุขภาพของแบบเตอรีชนิดลิเทียมไอออนด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ผ่านโปรแกรมภาษา Python
4. สามารถนำงานวิจัยไปพัฒนาต่อยอดในการประเมินสถานะสุขภาพของแบบเตอรีสำหรับยานยนต์ไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

การประมาณสถานะสุขภาพ แบตเตอรี่ลิเทียมไอออน

2.1 แบตเตอรี่ลิเทียมไอออน

แบตเตอรี่เป็นอุปกรณ์ที่ใช้ในการเก็บพลังงานไฟฟ้า เพื่อใช้ในการให้พลังงานไฟฟ้าแก่อุปกรณ์ไฟฟ้าและอิเล็กทรอนิกส์ ซึ่งแบตเตอรี่ถือเป็นอุปกรณ์ทางเคมีไฟฟ้าที่ใช้ปฏิกิริยาทางเคมีเพื่อขับเคลื่อนพลังงานไฟฟ้า ประกอบด้วยขั้วบวก (แคโทด) ขั้วลบ (แอโนด) และสารอิเล็กโทรไลต์

แบตเตอรี่แบ่งเป็น 2 ประเภท คือแบตเตอรี่ปฐมภูมิ (Primary battery) หมายถึงแบตเตอรี่ที่ผ่านการใช้งานจนพลังงานที่กักเก็บภายในแบตเตอรี่หมดลงแล้วจะไม่สามารถนำกลับมาใช้ใหม่ได้ เช่น แบตเตอรี่อัลคาไล (Alkaline Battery) แบตเตอรี่ลิเทียม (Lithium Battery) ที่ใช้ในอุปกรณ์ไฟฟ้า เช่น นาฬิกา รีโมทโทรทัศน์ ไฟฉาย ส่วนแบตเตอรี่ทุติยภูมิ (Secondary battery) หมายถึงแบตเตอรี่ที่ผ่านการใช้งานแล้วสามารถนำกลับมาใช้งานใหม่ได้ ด้วยการประจุไฟฟ้าให้แบตเตอรี่ใหม่ซึ่งทำให้สามารถใช้งานแบตเตอรี่ได้หลายรอบจนกว่าแบตเตอรี่จะเสื่อมสภาพ เช่น แบตเตอรี่ลิเทียม-ไอออน (Li-ion) แบตเตอรี่ลิเทียม-โพลิเมอร์ (LiPo) แบตเตอรี่ตะกั่ว-กรด (Lead-acid) ที่ใช้ในอุปกรณ์ไฟฟ้า เช่น โทรศัพท์มือถือ ยานยนต์ไฟฟ้า คอมพิวเตอร์โน้ตบุ๊ก

2.1.1 คุณสมบัติของแบตเตอรี่ลิเทียมไอออน

แบตเตอรี่ลิเทียมไอออนเป็นแบตเตอรี่ที่นิยมนำมาใช้กับยานยนต์ไฟฟ้าในยุคปัจจุบัน และอุปกรณ์อิเล็กทรอนิกส์ชนิดอื่น ๆ อย่างแพร่หลาย ซึ่งมีข้อดีประกอบด้วย [4]

- ความหนาแน่นพลังงานสูง มีความสามารถในการเก็บพลังงานสูง
- มีขนาดเล็กและน้ำหนักเบาเมื่อเทียบกับแบตเตอรี่ชนิดอื่น ๆ
- มีอัตราการคายประจุในตัวเองต่ำ

อย่างไรก็ตามแบตเตอรี่ลิเทียมไอออนก็ยังมีข้อด้อยประกอบด้วย

- มีการเสื่อมอายุตามธรรมชาติของแบตเตอรี่แม้จะไม่ได้ใช้งาน
- มีความไวต่อความร้อนสูง ซึ่งหากใช้งานในอุณหภูมิสูงเกินไปอาจทำให้เกิดการเสื่อมสภาพเร็วขึ้น
- ลิเทียมเป็นธาตุที่ติดไฟ แบบแบตเตอรี่ต้องมีวงจรป้องกันการเกิดการลัดวงจร และควบคุมแรงดันให้อยู่ในระดับปลอดภัย
- ต้นทุนการผลิตที่สูงเมื่อเทียบกับแบตเตอรี่ประเภทอื่น

2.1.2 หลักการทำงานของแบตเตอรี่ลิเทียมไอออน

แบตเตอรี่ลิเทียมไอออนอาศัยปฏิกิริยาทางไฟฟ้าเคมีแบบกลับ ระหว่างลิเทียมไอออนกับวัสดุอิเล็กโทรด ปฏิกิริยาเหล่านี้เกิดขึ้นในอิเล็กโทรดบวก (แคโทด) และอิเล็กโทรดลบ (แอโนด) แคโทดมัก

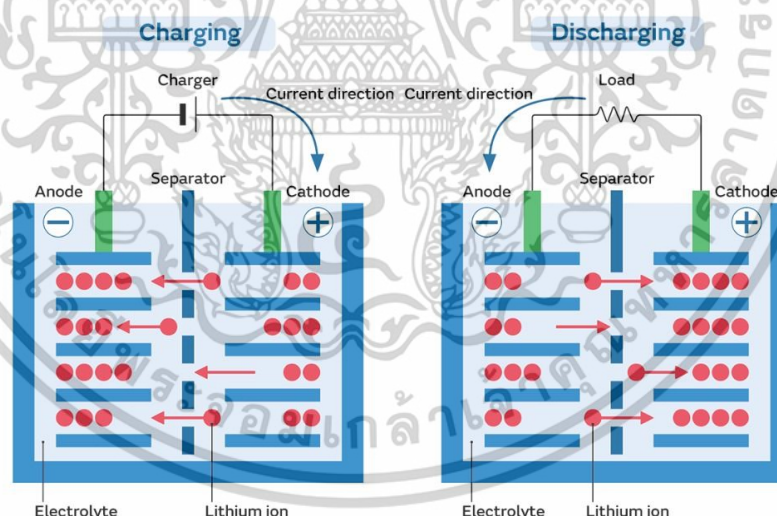
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทำจากสารประกอบที่มีลิเทียมเป็นส่วนประกอบ เช่น ลิเทียมโคบอลต์ออกไซด์ (LiCoO_2) หรือลิเทียมไอออนฟอสเฟต (LiFePO_4) ขณะที่แอโนดมักทำจากกราไฟต์ ในส่วนสารอิเล็กโทรไลต์ ซึ่งเป็นเกลือลิเทียมในตัวทำละลายอินทรีย์ ช่วยในการไหลของไอออน ในขณะที่ตัวคั่น (separator) มักทำจากวัสดุที่มีรูพรุนสามารถให้ไอออนเคลื่อนที่ผ่านได้ และเป็นตัวป้องกันไม่ให้ขั้วบวก (แคโทด) และขั้วลบ (แอโนด) สัมผัสกันโดยตรง ซึ่งจะช่วยป้องกันการลัดวงจร

กระบวนการประจุไฟฟ้าและคายประจุไฟฟ้าในแบตเตอรี่ลิเทียมไอออนเกิดขึ้นจากการเคลื่อนตัวของไอออนลิเทียมจากขั้วหนึ่งไปยังอีกขั้วหนึ่ง

ในขณะที่แบตเตอรี่กำลังประจุไฟฟ้า ไอออนลิเทียมจะถูกผลักจากขั้วบวก ผ่านอิเล็กโทรไลต์ไปยังขั้วลบ โดยอาศัยแหล่งพลังงานไฟฟ้าภายนอก เมื่อไอออนเหล่านี้ไปถึงขั้วลบ ไอออนเหล่านี้จะรวมตัวกับอิเล็กตรอนที่มีอยู่ ซึ่งก็คือการกักเก็บพลังงาน

การคายประจุไฟฟ้าในแบตเตอรี่จะเกิดกระบวนการย้อนกลับ อุปกรณ์ไฟฟ้าจะดึงพลังงานทำให้ไอออนลิเทียมที่ขั้วลบสูญเสียอิเล็กตรอน และเปลี่ยนเป็นลิเทียมไอออน จากนั้นไอออนเหล่านี้จะเคลื่อนที่กลับผ่านอิเล็กโทรไลต์ เคลื่อนตัวไปทางขั้วบวก การเคลื่อนที่ของอิเล็กตรอนผ่านวงจรภายนอก (อุปกรณ์ไฟฟ้า) จะทำให้เกิดกระแสไฟฟ้าที่ใช้งานได้ ซึ่งเป็นการจ่ายพลังงานให้กับอุปกรณ์ที่เชื่อมต่อกับแบตเตอรี่ [5]



รูปที่ 2.1 กระบวนการประจุไฟฟ้าและคายประจุไฟฟ้า

2.2 สถานะสุขภาพ

สถานะสุขภาพ (State-of-health : SOH) ของแบตเตอรี่หมายถึงตัวบ่งชี้การเสื่อมสภาพของแบตเตอรี่โดยแสดงผ่านค่าความจุ (capacity) ที่ลดลงของแบตเตอรี่ซึ่งผ่านการใช้งานเปรียบเทียบกับความจุแบตเตอรี่ใหม่ [6] โดยค่าสถานะสุขภาพของแบตเตอรี่ที่ลดลงอาจเกิดได้จากเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลายปัจจัย เช่น จำนวนรอบการประจุไฟฟ้าและคายประจุไฟฟ้า (Charge-Discharge Cycle) หรือเรียกสั้นๆว่ารอบการใช้งาน รอบการใช้งานที่เพิ่มขึ้นจะส่งผลให้แบตเตอรี่มีความจุลดลง การใช้งานแบตเตอรี่ในสถานะอุณหภูมิที่สูงเกินไปก็เป็นการเร่งการเสื่อมสภาพ เนื่องจากจากอุณหภูมิมีผลต่อปฏิกิริยาเคมีภายในเซลล์แบตเตอรี่

การประมาณสถานะสุขภาพของแบตเตอรี่เป็นวิธีการที่ใช้คาดการณ์อายุการใช้งานของแบตเตอรี่ว่าแบตเตอรี่มีการเสื่อมสภาพลดลงกี่เปอร์เซ็นต์เมื่อเทียบกับจากเดิม ทำให้สามารถวางแผนการใช้งานและการดูแลจัดการแบตเตอรี่ได้อย่างเหมาะสม เพิ่มความปลอดภัยในการใช้งานและเป็นตัวช่วยในการตัดสินใจสำหรับการเปลี่ยนแบตเตอรี่ใหม่ การประมาณสถานะสุขภาพของแบตเตอรี่เป็นอัตราส่วนระหว่างความจุสูงสุดของแบตเตอรี่ในรอบการใช้งานกับความจุสูงสุดของแบตเตอรี่ใหม่ดังสมการที่ 2.1

$$SOH_k (\%) = \frac{C_k}{C_0} \times 100 \quad (2.1)$$

โดยที่ C_k คือ ค่าความจุในรอบที่ k ของแบตเตอรี่
 C_0 คือ ค่าความจุเริ่มต้นของแบตเตอรี่

การกำเนิดใหม่ของความจุ (capacity regeneration) เป็นปรากฏการณ์ที่แบตเตอรี่สามารถฟื้นคืนความสามารถในการเก็บประจุไฟฟ้าบางส่วนหลังจากที่เคยสูญเสียไป โดยทั่วไปแล้ว แบตเตอรี่ที่ผ่านการใช้งานไปสักระยะหนึ่งจะมีแนวโน้มที่ความจุไฟฟ้าจะลดลงเนื่องจากปัจจัยทางเคมีและกายภาพ แต่ในบางกรณีเมื่อแบตเตอรี่ได้รับการพัก หรือผ่านกระบวนการประจุไฟฟ้าและคายประจุไฟฟ้าอย่างเหมาะสม อาจทำให้ความจุเพิ่มขึ้นในรอบการใช้งานรอบถัดไป การกำเนิดใหม่ของความจุอาจเกิดได้จากหลายปัจจัยเช่น การฟื้นตัวของโครงสร้างอิเล็กโทรดในแบตเตอรี่ลิเทียมไอออน ขั้วบวก (แคโทด) และขั้วลบ (แอโนด) ทำงานโดยการรับและปล่อยไอออนลิเทียมระหว่างการประจุไฟฟ้าและคายประจุไฟฟ้า เมื่อผ่านรอบการใช้งานไปช่วงเวลาหนึ่ง อิเล็กโทรดอาจเกิดการเสื่อมสภาพเนื่องจากการสะสมของปฏิกิริยาเคมี เมื่อหยุดการใช้ใช้งานแบตเตอรี่อาจช่วยให้โครงสร้างของอิเล็กโทรดคืนตัวบางส่วน ทำให้การเคลื่อนที่ของไอออนลิเทียมดีขึ้นและฟื้นคืนความสามารถในการเก็บประจุไฟฟ้า อีกปัจจัยหนึ่งคือ การฟื้นตัวของอิเล็กโทรไลต์ อิเล็กโทรไลต์ในแบตเตอรี่ลิเทียมไอออนเป็นตัวกลางที่ช่วยให้ไอออนลิเทียมเคลื่อนที่ระหว่างขั้วไฟฟ้า เมื่อแบตเตอรี่ผ่านใช้งานไประยะเวลาหนึ่ง อาจเกิดกระบวนการเสื่อมสภาพของอิเล็กโทรไลต์ ซึ่งเป็นสาเหตุหนึ่งที่ทำให้แบตเตอรี่สูญเสียความจุ เช่น การสลายตัวของเกลือลิเทียม การสลายตัวของตัวทำละลายในอิเล็กโทรไลต์ เมื่ออิเล็กโทรไลต์เสื่อมสภาพ ค่าความต้านทานภายในของแบตเตอรี่จะเพิ่มขึ้น ทำให้เกิดการสูญเสียพลังงานในรูปของความร้อน

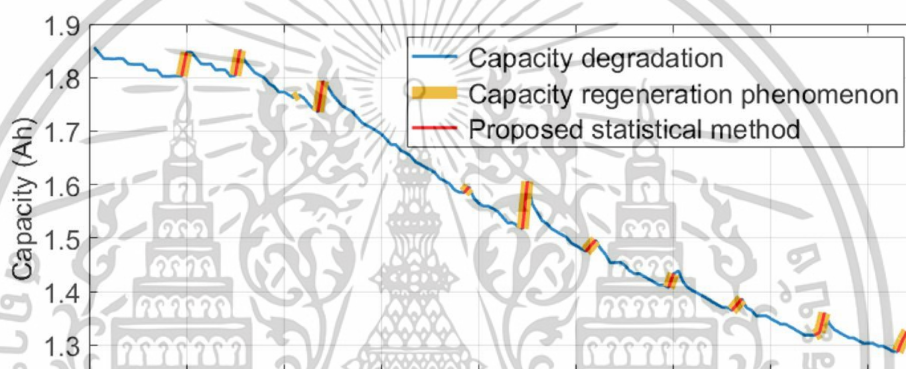
ส่งผลให้ความสามารถในการจ่ายกระแสลดลง แม้ว่าสภาพของอิเล็กโทรไลต์จะเป็น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กระบวนการที่ไม่สามารถย้อนกลับได้ทั้งหมด แต่ก็มีบางกรณีที่สามารถช่วยให้แบตเตอรี่ฟื้นคืนความสามารถในการเก็บประจุได้ การใช้แบตเตอรี่ภายใต้แรงดันและอุณหภูมิที่เหมาะสมสามารถช่วยให้สารประกอบที่ตกค้างถูกใช้ไป ทำให้อิเล็กโทรไลต์กลับมามีประสิทธิภาพที่ดีขึ้น ก็ส่งผลให้ความจุของแบตเตอรี่เพิ่มขึ้นเช่นกัน

การกำเนิดใหม่ของความจุนี้ไม่ได้หมายถึงการฟื้นฟูแบตเตอรี่ เนื่องจากแบตเตอรี่อาจฟื้นคืนความจุได้เพียงระยะเวลาสั้นๆ และเกิดขึ้นในบางรอบการใช้งาน ก่อนที่จะกลับไปเสื่อมสภาพเช่นเดิม และการกำเนิดใหม่ของความจุนี้ยากต่อการตรวจสอบและคาดการณ์ เนื่องจากเป็นการเกิดขึ้นในลักษณะที่ไม่สามารถกำหนดได้ ในบางช่วงของการใช้งานแบตเตอรี่ ซึ่งส่งผลให้การประมาณสถานะสุขภาพเกิดความผิดพลาดและไม่แม่นยำ



รูปที่ 2.2 ตัวอย่างการกำเนิดใหม่ของความจุ [7]

2.3 สถานะประจุ

สถานะประจุ (State-of-charge : SOC) ของแบตเตอรี่หมายถึงระดับพลังงานที่เหลืออยู่ในแบตเตอรี่ที่แสดงในรูปของเปอร์เซ็นต์ ซึ่งเป็นอัตราส่วนของความจุที่เหลืออยู่ต่อความจุที่แบตเตอรี่จะเก็บกักพลังงานได้ ถ้าสถานะประจุ 100 เปอร์เซ็นต์นั้นหมายถึงแบตเตอรี่มีความจุพลังงานเต็ม เมื่อใช้งานแบตเตอรี่จนค่าสถานะประจุเหลือ 30 เปอร์เซ็นต์ นั้นหมายถึงแบตเตอรี่มีความจุลดลงเหลือเพียง 30 เปอร์เซ็นต์ของความจุเมื่อแบตเตอรี่เต็ม ในปัจจุบันการวิเคราะห์สถานะประจุของแบตเตอรี่ถูกนำมาใช้ในอุปกรณ์ไฟฟ้ารวมถึงยานยนต์ไฟฟ้า เพื่อช่วยเพิ่มประสิทธิภาพในการใช้งาน ใช้คำนวณระยะเวลาที่เหลือในการใช้งาน ซึ่งช่วยให้ผู้ขับขี่วางแผนการเดินทางได้ดีขึ้นและยืดอายุแบตเตอรี่ ซึ่งการใช้งานแบตเตอรี่ควรใช้งานให้อยู่ระหว่าง 20 เปอร์เซ็นต์ ถึง 80 เปอร์เซ็นต์ของ SOC [8] เพราะระดับประจุนั้นสอดคล้องกับจำนวนของลิเทียมไอออนที่เคลื่อนที่ได้ในชั้นแกรไฟต์และลิเทียมโคบอลต์ออกไซด์ของเซลล์ การมีไอออนมากเกินไปในชั้นใดชั้นหนึ่งในภายหลังอาจทำให้แบตเตอรี่เกิดความเครียดและเมื่อเวลาผ่านไป จะส่งผลต่อสุขภาพของแบตเตอรี่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การนับคูลอมบ์ (Coulomb counting) เป็นวิธีที่ใช้กันอย่างแพร่หลายในการประมาณสถานะประจุ โดยวิธีนี้จะคำนวณความสามารถในการเก็บประจุของแบตเตอรี่จากการเปลี่ยนแปลงของประจุที่เหลืออยู่ ซึ่งพิจารณาจากกระแสไฟฟ้าที่ไหลเข้าและออกจากเซลล์แบตเตอรี่ [9]


$$SOC(t) = SOC(t_0) + \frac{1}{C_{cap}} \int_{t_0}^t I(t) dt \quad (2.2)$$

โดยที่	$SOC(t_0)$	คือ SOC เริ่มต้น
	$I(t)$	คือ กระแสไฟฟ้าขณะอัดประจุหรือคายประจุให้แบตเตอรี่
	C_{cap}	คือ ความจุที่พิกัดแบตเตอรี่

2.4 ปัญญาประดิษฐ์

ปัญญาประดิษฐ์ (Artificial Intelligence: AI) เป็นศาสตร์ที่เกี่ยวข้องกับการศึกษาวิจัยพัฒนาระบบคอมพิวเตอร์ที่มุ่งเน้นให้คอมพิวเตอร์สามารถทำงานเลียนแบบการคิดของมนุษย์ได้ [10] โดย AI สามารถ เรียนรู้ (Learning) คิววิเคราะห์ (Reasoning) และ ตัดสินใจ (Decision Making) ได้ด้วยตัวเอง ปัญญาประดิษฐ์ได้ถูกบัญญัติขึ้นครั้งแรกในปี ค.ศ. 1950 ระบุในเอกสารของ Alan Turing ในบทความ "Computing Machinery and Intelligence" ได้บัญญัติคำว่าปัญญาประดิษฐ์ขึ้นเป็นครั้งแรกและนำเสนอเป็นแนวคิดทางทฤษฎีและปรัชญาว่าเครื่องจักรสามารถคิดเองได้หรือไม่ ในปัจจุบันระบบปัญญาประดิษฐ์ใช้เทคโนโลยีที่หลากหลาย ในการทำงานด้านข้อมูลเฉพาะจะแตกต่างกันไปแต่หลักการยังคงเหมือนเดิม โดยจะแปลงข้อมูลทุกประเภท เช่น ข้อความ รูปภาพ วิดีโอ และเสียง ให้เป็นตัวแทนเป็นตัวเลข และระบุรูปแบบและความสัมพันธ์ระหว่างข้อมูลเหล่านั้นทางคณิตศาสตร์ ดังนั้น เทคโนโลยีปัญญาประดิษฐ์จึงจำเป็นต้องมีการเรียนรู้ โดยจะต้องสัมผัสกับชุดข้อมูลที่มีอยู่จำนวนมากเพื่อเรียนรู้ ซึ่งคล้ายกับที่มนุษย์เรียนรู้จากประสบการณ์ความรู้ที่มีอยู่ ซึ่งในปัจจุบันปัญญาประดิษฐ์ถูกพัฒนาต่อยอดไปใช้ในงานด้านต่างๆที่หลากหลายและเป็นพื้นฐานของเทคโนโลยีที่เกี่ยวข้อง เช่น การเรียนรู้ของเครื่อง (Machine learning) โครงข่ายประสาทเทียม (Artificial neural network : ANN) และ การเรียนรู้เชิงลึก (Deep learning)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 ลำดับชั้นของปัญญาประดิษฐ์

2.5 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง (Machine learning) ถูกจัดว่าเป็นส่วนหนึ่งของปัญญาประดิษฐ์ที่เน้นให้คอมพิวเตอร์สามารถเรียนรู้จากข้อมูลได้โดยไม่ต้องเขียนคำสั่งกำหนดล่วงหน้า [11] การเรียนรู้ของเครื่องนั้นจะมีหลักการคล้ายกับมนุษย์ที่จำเป็นต้องเรียนรู้จากประสบการณ์ ด้วยการป้อนชุดข้อมูลพื้นฐาน และชุดคำสั่งเพื่อให้คอมพิวเตอร์เรียนรู้ และจำแนกแยกแยะข้อมูลในรูปแบบต่างๆ และเพื่อให้ได้ผลลัพธ์ที่แม่นยำมากขึ้น ผู้พัฒนาจึงต้องมีการป้อนชุดข้อมูลใหม่ๆ และต้องฝึกฝนระบบอย่างสม่ำเสมอ เพื่อให้เกิดการพัฒนาการของระบบ ทำให้ระบบคิดได้ด้วยตัวเองในเวลาต่อมา การเรียนรู้ของเครื่องจะแบ่งออกเป็น 3 ประเภทตามรูปแบบการเรียนรู้ [12]

2.5.1 การเรียนรู้แบบมีผู้สอน

การเรียนรู้แบบมีผู้สอน (Supervised Learning) ทำได้โดยการป้อนชุดข้อมูลให้คอมพิวเตอร์ใช้ในการฝึกฝนนั้นเรียกว่า ข้อมูลชุดเรียนรู้ (Training Data / Training Set) จากนั้นต้องแยกประเภทของข้อมูลที่จะนำมาฝึกฝนว่าเป็นข้อมูลชนิดอะไร โดยการกำกับข้อมูลว่าเป็น Labels หรือ Class โดยการแยกข้อมูลสามารถแยกได้เป็น 2 ประเภทดังต่อไปนี้

- การจำแนกประเภท (Classification) เป็นวิธีการเรียนรู้ที่ให้แบบจำลองจำแนกข้อมูลตามที่ Labels กำหนดให้ และให้คำตอบซึ่งเป็นคำตอบที่อยู่ในหมวดหมู่ชัดเจน หรือเป็นกลุ่ม และเป็นค่าที่ไม่ต่อเนื่อง เช่น การกำหนดเพศว่าเป็นผู้ชายหรือผู้หญิง หรือการทำนายว่าพรุ้งนี้ฝนจะตกหรือไม่ตก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- การวิเคราะห์ค่าต่อเนื่อง (Regression) เป็นวิธีการเรียนรู้ที่ให้แบบจำลอง คาดการณ์ค่าตัวเลขที่ต่อเนื่อง หรือหาแนวโน้มของข้อมูล ค่าตอบที่ได้จะไม่เป็น Labels หรือ Class เช่น การคาดการณ์ราคาน้ำมันในอนาคต หรือการคาดการณ์อัตราการเติบโตของมนุษย์

เมื่อชุดข้อมูลที่ใช้ในการเรียนรู้ Machine Learning ผ่านอัลกอริทึมสำหรับสร้างแบบจำลองที่ใช้ในการคาดการณ์ผลลัพธ์แล้ว หลังจากนั้นจะทำการทดสอบประสิทธิภาพของแบบจำลองด้วยการนำชุดข้อมูลใหม่หรือข้อมูลชุดทดสอบ (Test Set) เพื่อดูผลลัพธ์ว่าแบบจำลองสามารถคาดการณ์ผลลัพธ์ได้อย่างถูกต้อง

2.5.2 การเรียนรู้แบบไม่มีผู้สอน

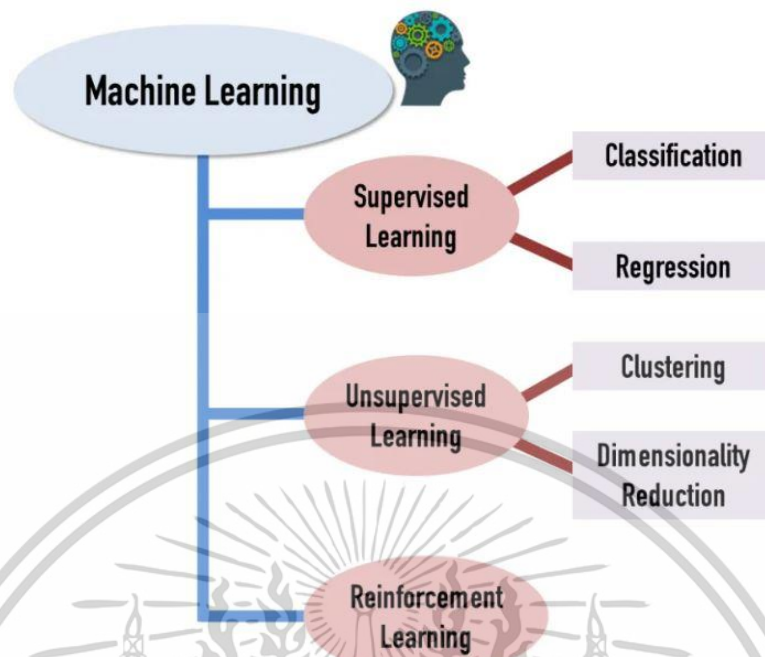
การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นการให้แบบจำลองเรียนรู้ข้อมูลที่ไม่มีป้ายกำกับกับข้อมูล (Labels) ซึ่งหมายความว่า ชุดข้อมูลที่ใช้จะไม่มีคำตอบที่ชัดเจน แบบจำลองต้องค้นหารูปแบบหรือโครงสร้างของข้อมูลเองโดยไม่มีตัวอย่างของคำตอบที่ถูกต้อง ซึ่งวิธีการนี้จะเน้นไปที่การวิเคราะห์ข้อมูล สามารถแยกได้เป็น 2 ประเภทดังต่อไปนี้

- การจัดกลุ่มข้อมูล (Clustering) เป็นกระบวนการจัดข้อมูลออกเป็นกลุ่มตามความคล้ายคลึงกันซึ่งจะมีลักษณะเฉพาะของตัวเอง โดยที่ข้อมูลภายในกลุ่มจะมีคุณสมบัติที่คล้ายกันมากกว่าข้อมูลที่อยู่ในกลุ่มอื่น เช่น แบ่งกลุ่มลูกค้าตามพฤติกรรมการซื้อ
- การลดมิติของข้อมูล (Dimensionality Reduction) คือ กระบวนการลดจำนวนตัวแปรที่ใช้ในข้อมูลโดยไม่ทำให้ข้อมูลสูญเสียความสำคัญ ทำให้แบบจำลองเรียนรู้ได้เร็วขึ้นและป้องกันการเรียนข้อมูลที่ผิดพลาดมากเกินไป

2.5.3 การเรียนรู้แบบเสริมแรง

การเรียนรู้แบบเสริมแรง (Reinforcement Learning) เป็นการให้แบบจำลองเรียนรู้จากระบบการป้อนกลับ ถ้าเปรียบเทียบให้เห็นภาพก็เหมือนกับการฝึกฝนสัตว์เลี้ยง ยกตัวอย่างการฝึกลูกสุนัขให้จับมือผู้ฝึกนั้นมึวิธีการอย่างไร เริ่มแรกให้ผู้ฝึกยื่นมือมาที่ลูกสุนัข ถ้าลูกสุนัขไม่จับมือผู้ฝึกตอบผู้ฝึกก็จะไม่มอบอาหารให้ แต่เมื่อใดที่ลูกสุนัขจับมือผู้ฝึกก็จะได้รับอาหาร การได้รับรางวัลนี้และเรียนรู้ที่จะจดจำรูปแบบซึ่งนำไปสู่ผลลัพธ์ แนวคิดนี้ถูกนำมาใช้ในการออกแบบของการเรียนรู้แบบเสริมแรง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.4 รูปแบบการเรียนรู้ของเครื่อง

2.6 โครงข่ายประสาทเทียม

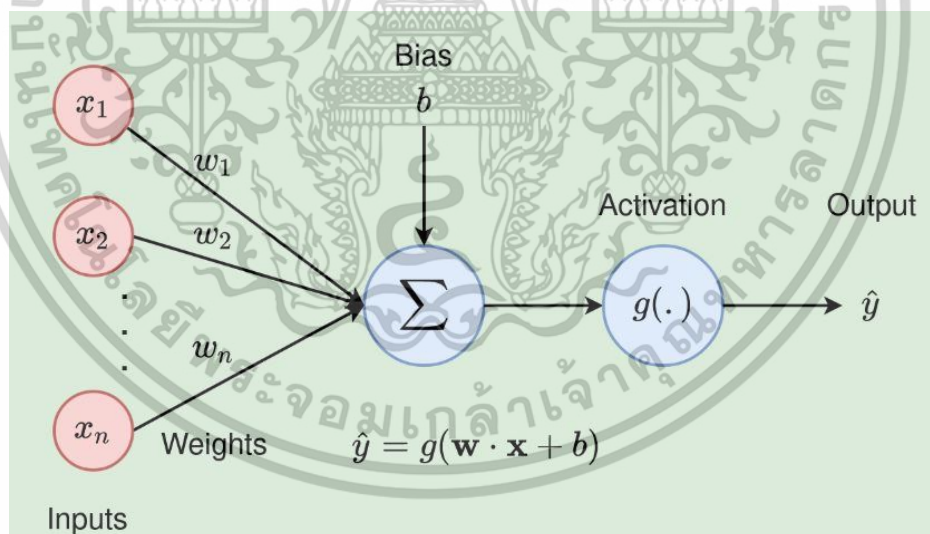
โครงข่ายประสาทเทียม (Artificial neural network : ANN) เป็นการพัฒนาขีดความสามารถของคอมพิวเตอร์ที่เป็นลักษณะการทำงานตามคำสั่งอย่างตรงไปตรงมา ไม่มีประสิทธิภาพในการแสดงความคิดเห็น วิเคราะห์ข้อมูล วิพากษ์วิจารณ์ข้อมูลได้ การพัฒนาขีดจำกัดนี้จะเหมือนการสร้างโปรแกรมคอมพิวเตอร์ที่ใช้แบบจำลองทางคณิตศาสตร์ ที่มีลักษณะการประมวลผลโดยจำลองความสามารถสมองมนุษย์ สามารถหาความสัมพันธ์ของข้อมูลนำเข้า (input) และข้อมูลส่งออก (output) โดยไม่จำเป็นต้องทราบความสัมพันธ์ทางคณิตศาสตร์ของข้อมูล โดยโครงข่ายประสาทเทียมมีการส่งผ่านสัญญาณคล้ายประสาทในสมองของมนุษย์ กล่าวคือมีความสามารถในการรวบรวมความรู้ผ่านกระบวนการเรียนรู้ (learning process) และความรู้เหล่านั้นจะถูกจัดเก็บอยู่ในรูปแบบค่าน้ำหนัก (weight) ซึ่งสามารถปรับเปลี่ยนค่าได้เมื่อได้รับการเรียนรู้ในสิ่งใหม่ การประมวลผลต่างๆจะเกิดในหน่วยประมวลผลย่อยเรียกว่า โหนด (node) เป็นการจำลองลักษณะการทำงานมาจากเซลล์ส่งสัญญาณระหว่างโหนดที่เชื่อมต่อกันเหมือนใยประสาทในระบบประสาทของมนุษย์ และภายในโหนดจะมีฟังก์ชันการส่งสัญญาณส่งออกที่เรียกว่า ฟังก์ชันกระตุ้น (activation function) ซึ่งสามารถส่งสัญญาณไปยังเซลล์ประสาทอื่นๆที่เชื่อมต่อกันได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.5 โครงสร้างของโครงข่ายประสาทเทียม [13]

ในการอธิบายการทำงานของโครงข่ายประสาทเทียมที่มีความซับซ้อนน้อยที่สุด จะอธิบายด้วยจำนวนเซลล์ประสาทเพียงเซลล์เดียวใน Hidden layer ซึ่งจะเรียกว่า เพอร์เซปตรอน (Perceptron) [14]



รูปที่ 2.6 โครงสร้างของเพอร์เซปตรอน

รูปที่ 2.6 กระบวนการทำงานจะเริ่มจากการรับค่าอินพุตเข้ามา จากนั้นจะมีการคูณด้วยค่าน้ำหนัก (Weights) คือค่าที่บอกว่าจะให้อินพุตมีอิทธิพลต่อผลลัพธ์มากแค่ไหน ถ้าค่าสูงหมายถึงอินพุตมีผลกระทบมากต่อการตัดสินใจของโครงข่าย นอกจากนี้ยังมีการเพิ่มค่า bias ซึ่งมีหน้าที่ช่วยให้โครงข่ายมีความยืดหยุ่นมากขึ้น และช่วยในการเรียนรู้ข้อมูลที่ซับซ้อนขึ้นได้ หลังจากนั้นจะส่งไปเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาติให้นำไปเผยแพร่ในวงจำกัดการค่าน้ำหนักที่ปรับค่าได้ และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ประมวลผลและตัดสินใจโดยฟังก์ชันกระตุ้น (activation function) ซึ่งจะใช้สมการคณิตศาสตร์โดยมีพื้นฐานจากสมการเส้นตรง

$$y = g\left(\sum_{i=1}^n (w_i \cdot x_i) + b\right) \quad (2.3)$$

โดย y คือ ผลลัพธ์ที่ได้จากฟังก์ชันกระตุ้น ถูกใช้งาน g คือ ฟังก์ชันกระตุ้น w คือ ค่าน้ำหนัก ส่วน b คือ bias เพื่อช่วยปรับค่าให้เหมาะสม เมื่อผลลัพธ์ที่ได้ผ่านการประมวลผลและตัดสินใจโดยฟังก์ชันกระตุ้น ซึ่งจะใช้เกณฑ์การตัดสินใจที่นิยมคือ ฟังก์ชันขั้นบันได (Step Function) โดยพิจารณาจากผลรวมของอินพุตที่ถูกรวมกับค่าน้ำหนักและค่า bias ถ้าผลรวมของฟังก์ชันมากกว่าเกณฑ์ก็จะเปิดการใช้งานฟังก์ชัน แต่ถ้ามีค่าน้อยกว่าเกณฑ์ก็จะปิดการทำงานของฟังก์ชัน

$$g(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.4)$$

ฟังก์ชันกระตุ้นที่ใช้ในการประมวลผลสำหรับโครงข่ายประสาทเทียมมีหลายประเภท ซึ่งมีคุณลักษณะเด่นที่แตกต่างกัน ดังนั้นการเลือกฟังก์ชันที่เหมาะสมมีความสำคัญต่อประสิทธิภาพของโครงข่ายประสาทเทียมโดยควรพิจารณาจากลักษณะของข้อมูลและเลือกใช้อย่างเหมาะสม



รูปที่ 2.7 ประเภทของฟังก์ชันกระตุ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6.1 โครงสร้างของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมประกอบไปด้วยเซลล์ประสาทเทียม หรือโหนดจำนวนมากเชื่อมต่อกัน ซึ่งการเชื่อมต่อจะแบ่งเป็นกลุ่มย่อยเรียกว่า ชั้น (layer) ซึ่งจะแบ่งเป็น 3 ส่วน [15] ได้แก่

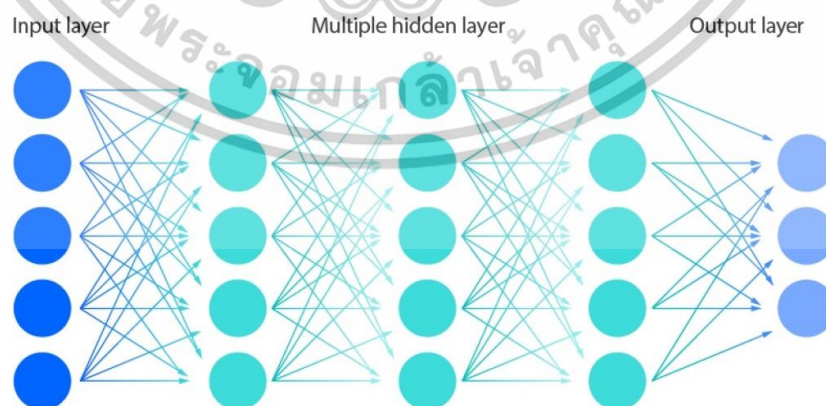
ชั้นรับข้อมูลป้อนเข้า (input layer) จะรับข้อมูลเข้าสู่โครงข่าย แต่ละโหนดจะแทนค่าของตัวแปรอิสระ (Independent Variable) หรือคุณลักษณะ (Feature) ของข้อมูล รับข้อมูลเข้ามาเป็นค่าตัวเลขที่สามารถจัดเก็บในรูปแบบของเวกเตอร์หรือเมทริกซ์ จำนวนโหนดในชั้นนี้จะเท่ากับจำนวนข้อมูลนำเข้า

ชั้นแอบแฝง (hidden layer) ส่วนของโครงข่ายที่มีการประมวลผลและเรียนรู้ข้อมูล โดยปกติจะมีหลายชั้น แต่ละชั้นมีหลายโหนดที่เชื่อมต่อกันเป็นเครือข่าย ชั้นที่มีโหนดกลางที่คำนวณค่าระหว่างชั้นรับข้อมูลป้อนเข้าและชั้นส่งข้อมูลออก แต่ละชั้นมีจำนวนโหนดที่แตกต่างกันไป และมีฟังก์ชันกระตุ้นที่ใช้ในการคำนวณผลลัพธ์ของแต่ละโหนด

ชั้นส่งข้อมูลออก (output layer) เป็นผลลัพธ์ที่ได้จาก ชั้นแอบแฝงชั้นสุดท้ายซึ่งเป็นการแสดงผลลัพธ์ที่ต้องการ ซึ่งผลลัพธ์ที่ได้สามารถให้คำตอบเป็นได้ทั้งตัวเลข หรือ Labels ขึ้นอยู่กับข้อมูลที่ป้อนให้โครงข่าย

2.6.2 การเรียนรู้เชิงลึก

การเรียนรู้เชิงลึก (Deep learning) เป็นโครงข่ายประสาทเทียมแบบหลายชั้นซึ่งคล้ายกับตาข่ายของเซลล์ประสาทที่เชื่อมต่อกันซึ่งอยู่ภายในสมอง เป็นส่วนหนึ่งของโครงข่ายประสาทเทียมที่มีโครงสร้างแบบหลายชั้นซ่อนอยู่ (Multiple Hidden Layers) ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบข้อมูลที่ซับซ้อนได้ดีขึ้นเนื่องจากอัลกอริทึมของ Deep Learning จะซับซ้อนกว่าและเหมาะสมกับงานที่มีข้อมูลจำนวนมาก




รูปที่ 2.8 โครงสร้างของ Deep Learning

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6.3 โครงข่ายประสาทเทียมแบบเวียนซ้ำ

โครงข่ายประสาทเทียมแบบเวียนซ้ำ (Recurrent neural network : RNN) [16] เป็นโครงข่ายประสาทเทียมที่นำผลลัพธ์ที่ได้จากการคาดการณ์ นำกลับมาใช้เป็นข้อมูลอินพุตสำหรับการประมวลผลผลลัพธ์ข้อมูลในลำดับถัดไปด้วย ซึ่งจะเหมาะสมกับข้อมูลที่มีลักษณะเป็นแบบอนุกรมเวลา (Time series) แต่อย่างไรก็ตามโครงข่ายประสาทเทียมแบบเวียนซ้ำก็ยังมีข้อด้อยสำคัญนั่นคือปัญหาเกรเดียนต์หายไป (Vanishing gradients) ซึ่งจะหมายถึงอัตราการเปลี่ยนแปลงที่หายไป ของฟังก์ชันความผิดพลาด (Loss function) ในระหว่างขั้นตอนการเรียนรู้ของแบบจำลอง ต่อค่าพารามิเตอร์ของแบบจำลอง เช่น ค่าน้ำหนัก (weight) และ bias ซึ่งเป็นพารามิเตอร์ที่ถูกปรับระหว่างกระบวนการเรียนรู้แบบจำลอง เพื่อให้แบบจำลองสามารถทำนายผลลัพธ์ได้แม่นยำ ปัญหาเกรเดียนต์ซึ่งเกิดได้จากการคำนวณแบบวนรอบของข้อมูลที่มีลำดับความสัมพันธ์ระยะยาว ซึ่งจะส่งผลให้เกรเดียนต์ลดลงจนเกือบเป็นศูนย์ ทำให้แบบจำลองไม่สามารถปรับค่าน้ำหนัก และ bias ที่เหมาะสมต่อไปได้ จนกระทั่งหยุดกระบวนการเรียนรู้และผลลัพธ์ที่ได้เกิดความคลาดเคลื่อน




รูปที่ 2.9 โครงสร้างของโครงข่ายประสาทเทียมแบบเวียนซ้ำ

2.6.4 โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว

โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) ถูกจัดเป็นโครงข่ายประสาทเทียมแบบเวียนซ้ำประเภทหนึ่งซึ่งถูกพัฒนาเพื่อแก้ปัญหาในการเรียนรู้ข้อมูลที่มีลำดับความสัมพันธ์ระยะยาวได้อย่างมีประสิทธิภาพ LSTM แก้ปัญหานี้ได้ด้วยการใช้ cell state ที่เป็นการเก็บข้อมูลระยะยาวและมีการควบคุมข้อมูลในแต่ละขั้นตอนผ่านฟังก์ชันที่ทำหน้าที่เหมือนประตู (Gate) มี 3 ส่วนได้แก่ Forget Gate Input Gate และ Output Gate ซึ่งทำงานร่วมกันเพื่อควบคุมการไหลของข้อมูลเข้าและออกจากเซลล์ [17-18]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.10 โครงสร้างพื้นฐานของเซลล์ประสาท LSTM

Forget Gate (f_t) มีบทบาทสำคัญในการลบข้อมูลสถานะของเซลล์ก่อนหน้าและสร้างพื้นที่สำหรับข้อมูลใหม่ให้พร้อมสำหรับการรวมอินพุต (x_t) ข้อมูลใหม่เข้ากับเอาต์พุตของสถานะเซลล์ก่อนหน้า (h_{t-1}) โดยคำนึงถึง weight (W_f) และ bias (b_f) ซึ่งผลลัพธ์จะเป็นตัวกำหนดว่าข้อมูลก่อนหน้านี้นี้ควรถูกลบออกหรือเก็บรักษาไว้ ผ่านฟังก์ชัน sigmoid (σ) เพื่อใช้ในการตัดสินใจ Forget Gate แสดงดังสมการที่ (2.5)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.5)$$

Input Gate (i_t) คือ มีหน้าที่รับข้อมูลอินพุตที่เข้ามาใหม่แล้วทำการบันทึกหรือเขียนข้อมูลลงไปในแต่ละโนด ซึ่งจะแบ่งออกเป็น 2 ส่วน คือ ส่วนแรกเป็นส่วนของการอัปเดตข้อมูลเพื่อควบคุมข้อมูลเข้าและออกจากเซลล์โดยใช้ฟังก์ชัน sigmoid (σ) เพื่อพิจารณาว่าควรรวมอินพุตใหม่ไว้ในสถานะเซลล์หรือไม่ ส่วนที่สองถ้า Input Gate เลือกอัปเดตข้อมูล เข้าสถานะเซลล์ ฟังก์ชัน tanh จะทำการสร้าง Candidate value (C_t) หรือหน่วยความจำใหม่ขึ้น Input Gate แสดงดังสมการที่ (2.6) และ (2.7)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.6)$$

$$C_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.7)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อมีการอัปเดตข้อมูลจากสถานะเซลล์จากเซลล์ก่อนหน้า ($C_{(t-1)}$) ไปเป็นสถานะเซลล์ใหม่ (C_t) จะถูกรวมด้วย Forget Gate จากก่อนหน้านี้ จากนั้นจะเพิ่มค่า Candidate value เข้าไปด้วยซึ่งจะได้สถานะเซลล์ใหม่ดังสมการที่ (2.8)

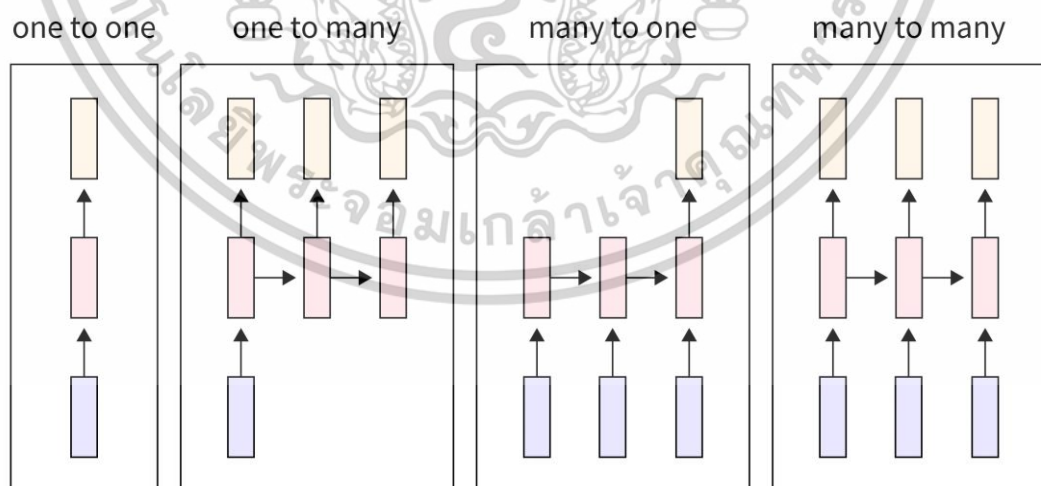
$$C_t = f_t \times C_{(t-1)} + i_t \times C_t \quad (2.8)$$

Output Gate (O_t) ทำหน้าที่เตรียมส่งออกข้อมูลโดยฟังก์ชัน sigmoid (σ) จะเป็นตัวเลือกว่าข้อมูลใดควรถูกส่งออกไปเป็นเอาต์พุต จากนั้นนำค่าที่ได้จากสถานะเซลล์ไปเข้าฟังก์ชัน tanh โดยค่าที่ได้จะมีค่าเป็น 1 หรือ -1 และเมื่อนำกลับมารวมกับค่าเอาต์พุตที่ได้จากฟังก์ชัน sigmoid จะได้ค่า Hidden State (h_t) เพื่อนำไปใช้ในสถานะเซลล์ถัดไป ดังแสดงในสมการที่ (2.9) และ (2.10)

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.9)$$

$$h_t = O_t \times \tanh(C_t) \quad (2.10)$$

นอกจากนี้รูปแบบของอินพุตข้อมูลที่น่าเข้าสู่โครงสร้างของ LSTM และเอาต์พุตที่ได้ยังถูกกำหนดเป็นรูปแบบต่างๆ [19] ได้ดังรูปที่ 2.11



รูปที่ 2.11 รูปแบบของอินพุตและเอาต์พุตข้อมูลที่น่าเข้าสู่โครงข่ายประสาทเทียม LSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.11 สามารถอธิบายรูปแบบของอินพุตและเอาต์พุตได้ดังนี้

- One to One เป็นโครงสร้างที่ง่ายที่สุดมี อินพุต 1 ค่า และให้ เอาต์พุต 1 ค่า ทำงานคล้ายกับโครงข่ายประสาทเทียมแบบดั้งเดิม อินพุตและเอาต์พุตมีขนาดคงที่ ยกตัวอย่างเช่น ข้อมูลอินพุตคือรูปภาพสัตว์ชนิดหนึ่ง ให้แบบจำลองจำแนกว่าเป็นภาพแมวหรือสุนัข
- One to Many เป็นโครงสร้างที่มีอินพุต 1 ค่า แต่เอาต์พุตมากกว่า 1ค่า ซึ่งเป็นลำดับของข้อมูล ยกตัวอย่างเช่น ให้แบบจำลองสร้างคำอธิบายจากภาพที่ใส่เข้าไป หลังจากนั้นประมวลผลและสร้างคำตอบขึ้นทีละคำ ได้ผลลัพธ์เป็น 3 คำตอบคือ แมว ปีน กำแพง
- Many to One เป็นโครงสร้างที่มีอินพุตมากกว่า 1 ค่า แต่เอาต์พุตมี 1ค่า ใช้ในกรณีที่ต้องการสรุปหรือประมวลผลข้อมูลจากหลายอินพุตให้ออกมาเป็นผลลัพธ์เดียว ยกตัวอย่างเช่น ป้อนข้อความหลายคำ แล้วให้โมเดลบอกว่าเป็นข้อความเชิงบวกหรือเชิงลบ
- Many to Many เป็นโครงสร้างที่มี อินพุตและเอาต์พุตมากกว่า 1 ค่า ยกตัวอย่างเช่น โปรแกรมแปลภาษาโดยป้อนประโยคในภาษาอังกฤษ แล้วให้แบบจำลองแปลเป็นภาษาไทย

2.7 tensorflow.keras

Guido Van Rossum โปรแกรมเมอร์ชาวเนเธอร์แลนด์เป็นผู้สร้างภาษา Python โดยเขาเริ่มต้นในปี 1989 และในปี 1994 Python 1.0 ได้รับการนำออกมาเผยแพร่ พร้อมฟังก์ชันใหม่เพื่อประมวลผลรายการข้อมูลได้อย่างง่ายดาย เช่น Map, Filter และ Reduce ซึ่งในปัจจุบันภาษาโปรแกรม Python เป็นภาษาการเขียนโปรแกรมระดับสูง ที่ใช้อย่างแพร่หลายในเว็บแอปพลิเคชัน ได้รับความนิยมอย่างมากในปัจจุบัน เนื่องจากใช้ไวยากรณ์ที่ใกล้เคียงกับภาษาอังกฤษ ซึ่งทำให้ผู้เริ่มต้นสามารถเรียนรู้และใช้งานได้เร็ว เช่น การประกาศตัวแปร การใช้งานเงื่อนไข ทำให้เหมาะสมสำหรับทั้งผู้เริ่มต้นและผู้พัฒนามืออาชีพในการเขียนโปรแกรม Python มีไลบรารี และ เครื่องมือเสริม ที่หลากหลาย ซึ่งสามารถใช้ได้ฟรี เช่น NumPy, Pandas, TensorFlow และอื่นๆ อีกมากมาย ช่วยให้งานพัฒนาโปรแกรมทำได้ง่ายและรวดเร็ว และมีแหล่งข้อมูลที่เป็นประโยชน์มากมายบนอินเทอร์เน็ต สามารถเรียนรู้ Python ด้วยตนเองด้วยการค้นหาวิดีโอ บทแนะนำสอนการใช้งาน เอกสารประกอบ และคู่มือนักพัฒนาได้อย่างง่ายดาย [20]

การประยุกต์ใช้ Python ร่วมกับโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (LSTM) เป็นหนึ่งในแนวทางที่ได้รับความนิยมอย่างมาก โดยการสร้างแบบจำลองที่สามารถประมวลผลข้อมูลที่มีลำดับเวลา (sequential data) หรือการคาดการณ์ข้อมูลจากชุดข้อมูลที่มีการพึ่งพาข้อมูลก่อนหน้า เนื่องจาก Python มี ไลบรารี และเครื่องมือเสริมที่สนับสนุนการคำนวณในด้าน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ต่างๆ ใน Python มีหลายไลบรารีที่นิยมใช้สำหรับการคำนวณและสร้างแบบจำลอง LSTM โดยในวิทยานิพนธ์เล่มนี้ได้แนะนำเสนอการใช้ tensorflow.keras

tensorflow เป็นเฟรมเวิร์กการเรียนรู้เชิงลึก (Deep Learning Framework) ที่พัฒนาโดย Google ซึ่งรองรับการคำนวณทางคณิตศาสตร์และการเรียนรู้ รองรับหลายภาษาการเขียนโปรแกรม เช่น Python, C++, JavaScript, Java

keras เป็น high-level API ที่ใช้สร้างและฝึกฝนโมเดล Neural Networks ซึ่งออกแบบให้ใช้งานง่าย มีเครื่องมือที่พร้อมใช้ สำหรับการสร้าง Layer, Activation Functions, Optimizers, Loss Functions และอื่นๆ ซึ่งทำให้สามารถสร้างแบบจำลองโครงข่ายประสาทเทียมได้ง่ายและรวดเร็ว

ตั้งแต่ tensorflow 2.0 ขึ้นไป keras ได้ถูกรวมเข้ากับ tensorflow เป็นส่วนเดียวกันเรียกว่า tensorflow.keras ถือเป็น API ที่อยู่ภายใน tensorflow และเป็นส่วนหนึ่งของไลบรารี tensorflow ซึ่งทำให้ทั้งสองสามารถทำงานร่วมกันได้อย่างง่ายดาย ผู้ใช้สามารถเลือกใช้ keras ในการสร้างโมเดลอย่างรวดเร็วหรือใช้ tensorflow ในการทำงานที่ซับซ้อนขึ้นตามความต้องการ

ขั้นตอนในการใช้ Python ร่วมกับ LSTM

- เตรียมข้อมูล (Data Preparation) การจัดเตรียมข้อมูล เช่น การทำให้ข้อมูลอยู่ในรูปแบบที่สามารถนำเข้า LSTM ได้ด้วยกระบวนการต่างๆ เช่น Data Cleaning หรือการทำความสะอาดข้อมูลอย่างละเอียด ซึ่งหมายถึงกระบวนการในการจัดการข้อมูลดิบ (raw data) ที่มีปัญหาหรือข้อผิดพลาด เช่น ข้อมูลที่ขาดหาย ข้อมูลที่ซ้ำซ้อน รวมถึงการทำให้ข้อมูลมีคุณภาพ รวมถึงการลบข้อมูลที่ไม่จำเป็น เพื่อให้ข้อมูลมีความสมบูรณ์ ถูกต้อง และพร้อมสำหรับการวิเคราะห์หรือการใช้ในแบบจำลอง อีกวิธีที่นิยมทำควบคู่กันคือ การปรับชุดข้อมูลให้เป็นปกติ (Normalization) จะดำเนินการด้วยวิธี Min-Max scaling คือการปรับฐานของชุดข้อมูลทั้งหมดให้อยู่ในช่วง 0-1 เพื่อช่วยลดเวลาในการเรียนรู้ของแบบจำลอง เพราะแบบจำลองจะมีการประมวลผลที่ซับซ้อนมากขึ้น หากตัวแปรแต่ละตัวนั้นมีช่วงของข้อมูลที่แตกต่างกันมาก เมื่อข้อมูลถูกปรับให้เป็นค่าที่เหมาะสม จะช่วยเพิ่มประสิทธิภาพให้แบบจำลอง แสดงดังสมการที่ 2.11

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \times 100 \quad (2.11)$$

โดย X_{nor} คือ ข้อมูลหลังจากการปรับฐาน X คือ ข้อมูลที่เลือกเพื่อทำการปรับฐาน X_{min} X_{max} คือ ข้อมูลที่มีค่าน้อยที่สุดและมากที่สุดในช่วงข้อมูลตามลำดับโดยเป็นข้อมูลชนิดเดียวกัน

- สร้างแบบจำลอง LSTM ในการเรียนรู้ข้อมูลและคาดการณ์ผลลัพธ์ที่ต้องการ โดยใช้ไลบรารี TensorFlow.keras

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ประเมินผลลัพธ์ด้วยการใช้ Root Mean Squared Error (RMSE) เป็นตัวชี้วัดที่ใช้เพื่อประเมินความแม่นยำของแบบจำลองเชิงทำนาย โดยจะวัดค่าเฉลี่ยของข้อผิดพลาดระหว่างค่าที่คาดการณ์และค่าจริงในชุดข้อมูล คุณลักษณะสำคัญของ RMSE คือความอ่อนไหวต่อข้อผิดพลาดขนาดใหญ่ เนื่องจากจะยกกำลังสองของความแตกต่างของผลลัพธ์ก่อนทำการเฉลี่ย ซึ่งจะขยายผลกระทบของความเบี่ยงเบนที่สำคัญ ดังแสดงในสมการที่ 2.12 นอกจากนี้ยังมีวิธีการประเมินผลลัพธ์ด้วยวิธีอื่นอยู่อีก เช่น Mean Absolute Percentage Error (MAPE) ซึ่งวัดค่าผิดพลาดระหว่างค่าที่คาดการณ์และค่าจริง และแสดงข้อผิดพลาดเฉลี่ยในรูปของเปอร์เซ็นต์ ซึ่งเหมาะสำหรับการเปรียบเทียบข้อผิดพลาดระหว่างชุดข้อมูลที่แตกต่างกัน ดังแสดงในสมการที่ 2.13

$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (C - C_k)^2} \quad (2.12)$$

$$MAPE(\%) = \frac{100}{K} \sum_{k=1}^K \left(\frac{|C - C_k|}{C} \right) \quad (2.13)$$

โดย C คือ ค่าจริง C_k คือ ค่าความจุคาดการณ์ K คือ จำนวนรอบของชุดข้อมูล

โปรแกรมสำหรับเขียน Python เรียกว่า IDE (Integrated Development Environment) หรือ Code Editor เป็นโปรแกรมที่ช่วยให้การเขียนโค้ดและพัฒนาโปรแกรมเป็นเรื่องง่ายขึ้น มีเครื่องมือครบวงจรสำหรับการพัฒนา Python เช่น ตัวแก้ไขโค้ด (Code Editor) ดีบั๊กเกอร์ (Debugger) ใช้ตรวจสอบข้อผิดพลาดของโค้ดคอมไพเลอร์/อินเตอร์พรีเตอร์ (Compiler/Interpreter) ใช้แปลงโค้ดให้คอมพิวเตอร์เข้าใจ ตัวจัดการแพ็คเกจ (Package Manager) ใช้ติดตั้งไลบรารีหรือโมดูลเสริม การรองรับเวอร์ชวลเอนไวรอนเมนต์ (Virtual Environment) ในปัจจุบันมีโปรแกรมสำหรับเขียนภาษา Python ออกมาให้ นักพัฒนาซอฟต์แวร์ หรือบุคคลทั่วไปใช้หลายโปรแกรม ซึ่งมีทั้งแบบฟรีและคิดค่าใช้จ่าย ยกตัวอย่างเช่น

- VS CODE (Visual Studio Code) ใช้งานได้ฟรีและไม่กินทรัพยากรเครื่องคอมพิวเตอร์ รองรับส่วนเสริม (Extensions) มากมาย เช่น Python, Jupyter, Git สามารถรองรับหลายภาษาที่ไม่ใช่แค่ Python และยังมี AI ช่วยแนะนำโค้ด (Copilot, IntelliCode)
- Jupyter Notebook เป็นเครื่องมือสำหรับเขียนและรันโค้ด Python ในรูปแบบของ "โน้ตบุ๊ก" ซึ่งช่วยให้เขียนโค้ดและแสดงผลได้ในทันที เหมาะสำหรับ Data Science, Machine Learning และงานวิเคราะห์ข้อมูล สามารถรันโค้ดทีละส่วนโดยไม่ต้องรันใหม่

ทั้งโปรแกรม เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Google Colab มีข้อดีคือ ใช้งานได้ฟรี ใช้งานง่ายโดยไม่ต้องติดตั้ง เหมาะกับ Data Science, Machine Learning, AI รองรับบริการรันโค้ดที่ละเซลล์ ทำให้ทดลองโค้ดได้ง่าย
- PyCharm เป็น Integrated Development Environment (IDE) หรือ เครื่องมือพัฒนาโปรแกรมสำหรับการเขียนและพัฒนาโปรแกรมในภาษา Python โดยเฉพาะ โดย PyCharm ได้รับความนิยมอย่างมากในหมู่ผู้พัฒนาซอฟต์แวร์ที่ใช้ Python เนื่องจากมีเครื่องมือที่ช่วยให้การเขียนโปรแกรมเป็นไปได้ง่ายและสะดวกมากขึ้น



รูปที่ 2.12 โปรแกรมสำหรับการเขียนภาษา Python

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

การสร้างแบบจำลองสำหรับการประมาณสถานะสุขภาพของ แบตเตอรี่ลิเทียมไอออน

การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน ในวิทยานิพนธ์นี้ถูกนำเสนอด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว โดยวิธีการขับเคลื่อนเชิงข้อมูล ในวิทยานิพนธ์นี้จะใช้ดำเนินการด้วยภาษาโปรแกรม Python ผ่านโปรแกรม Pycharm Community Editor ทั้งหมด โดยใช้ไลบรารี tensorflow.keras เป็นเครื่องมือในการสร้างแบบจำลองเพื่อวิเคราะห์ เรียนรู้ และประมาณผลลัพธ์ที่ต้องการได้อย่างแม่นยำ การตรวจสอบประสิทธิภาพของแบบจำลองถูกประเมินด้วยค่า RMSE ในส่วนของชุดข้อมูลของแบตเตอรี่ที่จะนำมาใช้ในการทดสอบจะแบ่งเป็น 2 ชุดข้อมูล โดยชุดข้อมูลแรกจะใช้ชุดข้อมูลแบตเตอรี่ B0005 เพื่อออกแบบและสร้างแบบจำลองให้มีความเหมาะสมในการประมาณสถานะสุขภาพ ส่วนชุดข้อมูลที่สองจะเป็นชุดข้อมูลแบตเตอรี่ลิเทียมไอออนที่มีความแตกต่างจากชุดข้อมูลแรก โดยมีรุ่น ข้อมูลโพรไฟล์ประจุไฟฟ้าและค่าความจุแตกต่างกันเพื่อใช้ทดสอบและประเมินประสิทธิภาพของแบบจำลองในกรณีที่มีการเปลี่ยนแปลงชุดข้อมูลของแบตเตอรี่ แบบจำลองยังสามารถประมาณสถานะสุขภาพได้แม่นยำหรือไม่ โดยในวิทยานิพนธ์เล่มนี้จะกำหนดชื่อชุดข้อมูลแบตเตอรี่ชุดที่สองนี้ว่าแบตเตอรี่ C

3.1 ชุดข้อมูลแบตเตอรี่ (Data sets)

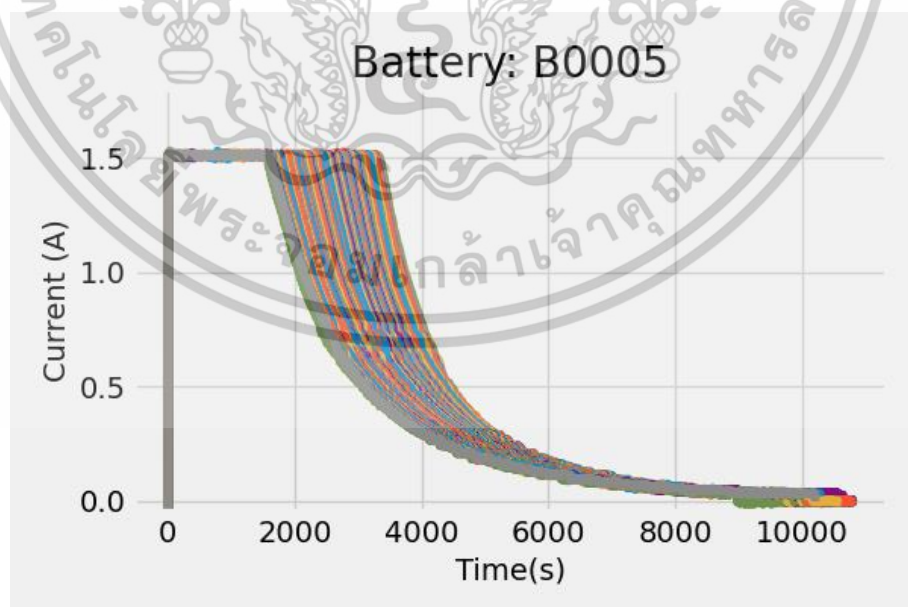
3.1.1 ชุดข้อมูลแบตเตอรี่ B0005

ชุดข้อมูลแบตเตอรี่ลิเทียมไอออนได้นำข้อมูลมาจาก NASA Prognostics Center of Excellence Data Repository [21] ซึ่งชุดข้อมูลนี้ประกอบด้วยเซลล์ลิเทียมไอออน 18650 จำนวน 34 เซลล์ ถูกจัดแบ่งเป็น 3 กลุ่มข้อมูลแยกตามอุณหภูมิแวดล้อมของการทดสอบที่แตกต่างกัน คือ 4°C 24°C และ 43°C ในบทความนี้จะเลือกใช้ชุดข้อมูลภายใต้อุณหภูมิแวดล้อมที่ 24°C โดยประกอบด้วยชุดข้อมูลเซลล์แบตเตอรี่ 4 เซลล์ คือ B0005 B0006 B0017 B0018 เมื่อพิจารณาจำนวนรอบของการใช้งาน ข้อมูลแบตเตอรี่ B0005 B0006 และ B0017 มีจำนวนข้อมูลที่ถูกเก็บไว้มากกว่า 160 รอบการใช้งาน ในวิทยานิพนธ์นี้ได้นำข้อมูล B0005 ซึ่งมีจำนวนรอบของการคายประจุไฟฟ้าเป็นจำนวน 167 รอบ และมีข้อมูลของค่าความจุอยู่ในช่วง 100 เปอร์เซ็นต์ ถึง 70 เปอร์เซ็นต์ มาใช้ในการทดสอบ

ชุดข้อมูลแบตเตอรี่ B0005 มีโพรไฟล์การดำเนินการ 3 รูปแบบคือการประจุไฟฟ้า การคายประจุไฟฟ้า และอิมพีแดนซ์ของแบตเตอรี่ โดยแบตเตอรี่ถูกประจุไฟฟ้าในโหมดกระแสคงที่แรงดันคงที่ (CCCV) ที่ 1.5.A 4.2 V โดยมีกระแสสิ้นสุดการประจุไฟฟ้า 20 mA ในส่วนการคายประจุไฟฟ้า เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จะเป็นแบบกระแสไฟฟ้าคงที่ (CC) 2 A โดยมีแรงดันไฟฟ้าสิ้นสุด 2.7 V โดยค่าความจุเริ่มต้น C_0 ของแบตเตอรี่นี้คือ 1.86 Ah ในวิทยานิพนธ์นี้ไม่ได้ใช้ข้อมูลของอิมพีแดนซ์เนื่องจากสถานะสุขภาพของแบตเตอรี่ประมาณจากค่าความจุปัจจุบันได้โดยตรง ส่วนค่าอิมพีแดนซ์สามารถใช้ประมาณสถานะกำลัง (State of Power) ได้โดยตรง แต่การประมาณสถานะสุขภาพจากค่าอิมพีแดนซ์ต้องกำหนดความสัมพันธ์หรือนิยามเพิ่มเติม ทั้งนี้ค่าอิมพีแดนซ์ไม่สามารถวัดได้โดยง่ายในสภาพการใช้งานจริงบนยานยนต์ไฟฟ้า

โดยข้อมูลที่ให้นำมาใช้เป็นอินพุตในการประมาณสถานะสุขภาพของแบตเตอรี่ จะใช้ข้อมูลจากโปรไฟล์การประจุไฟฟ้าซึ่งประกอบด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและค่าเวลา ตั้งแต่เริ่มต้นการประจุไฟฟ้าไปจนถึงสิ้นสุดการประจุไฟฟ้างดแสดงดังรูปที่ 3.1-3.3 ข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า และอุณหภูมิเทียบกับเวลาในแต่ละรอบการประจุไฟฟ้าของแบตเตอรี่ B0005 จะแสดงให้เห็นถึงช่วงเวลาที่ใช้ในการบันทึกข้อมูลซึ่งใช้เวลาประมาณ 10,000 วินาที ในส่วนข้อมูลความจุจะได้จากโปรไฟล์การคายประจุไฟฟ้า รูปที่ 3.4 แสดงการเสื่อมของความจุและรูปที่ 3.5 แสดงสถานะสุขภาพของแบตเตอรี่ B0005 ตั้งแต่รอบการใช้งานที่ 1 ถึง 167 จะเห็นได้ว่าความจุของแบตเตอรี่จะลดลงตามจำนวนรอบการประจุไฟฟ้าและการคายประจุไฟฟ้า ซึ่งนั่นบ่งบอกถึงแบตเตอรี่มีสถานะสุขภาพที่แย่งตามจำนวนรอบการใช้งาน และจากข้อมูลยังพบว่ามี การเพิ่มขึ้นของค่าความจุ (Capacity regeneration) ในบางรอบการใช้งาน แสดงถึงคุณลักษณะที่ไม่เป็นเชิงเส้นระหว่างสถานะสุขภาพกับรอบการใช้งาน ดังนั้นการประมาณสถานะสุขภาพของแบตเตอรี่ที่แม่นยำจะช่วยให้คาดการณ์อายุการใช้งานแบตเตอรี่ได้ว่าจะสิ้นสุดลงเมื่อใด

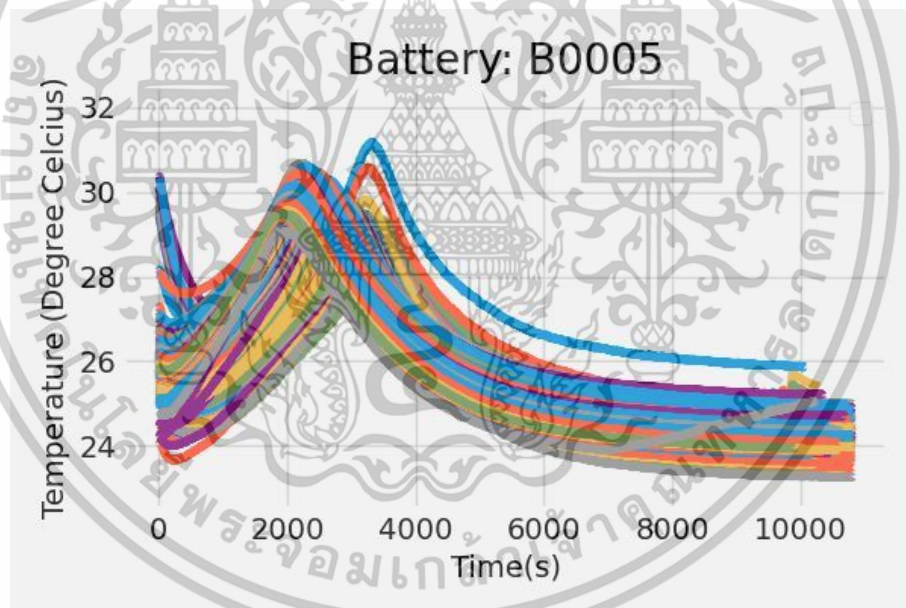


รูปที่ 3.1 กราฟข้อมูลกระแสไฟฟ้าของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.2 กราฟข้อมูลแรงดันไฟฟ้าของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า




รูปที่ 3.3 กราฟข้อมูลอุณหภูมิของแบตเตอรี่ B0005 ขณะประจุไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.4 กราฟข้อมูลความจุในแต่ละรอบการคายประจุของแบตเตอรี่ B0005



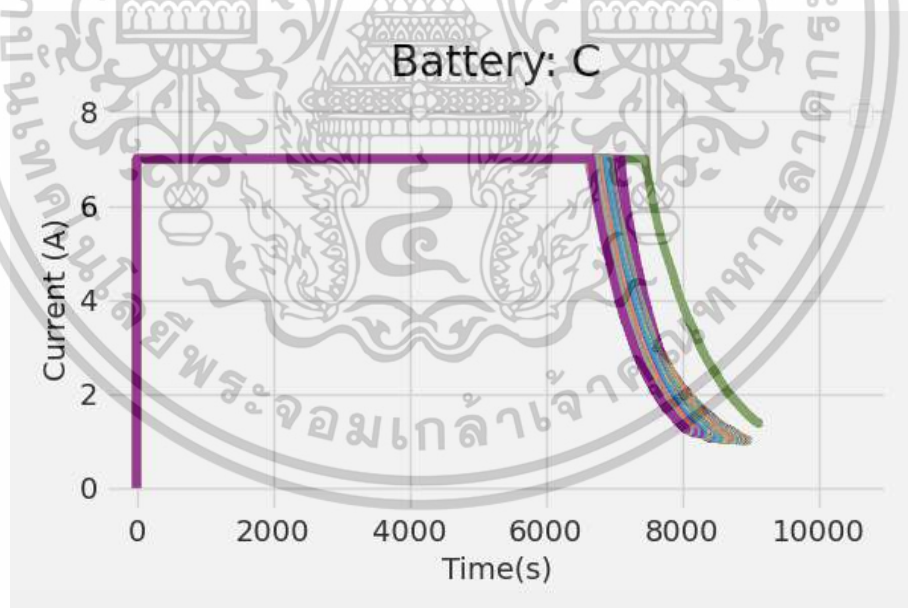
รูปที่ 3.5 สถานะสุขภาพของแบตเตอรี่ B0005

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.2 ชุดข้อมูลแบตเตอรี่ C

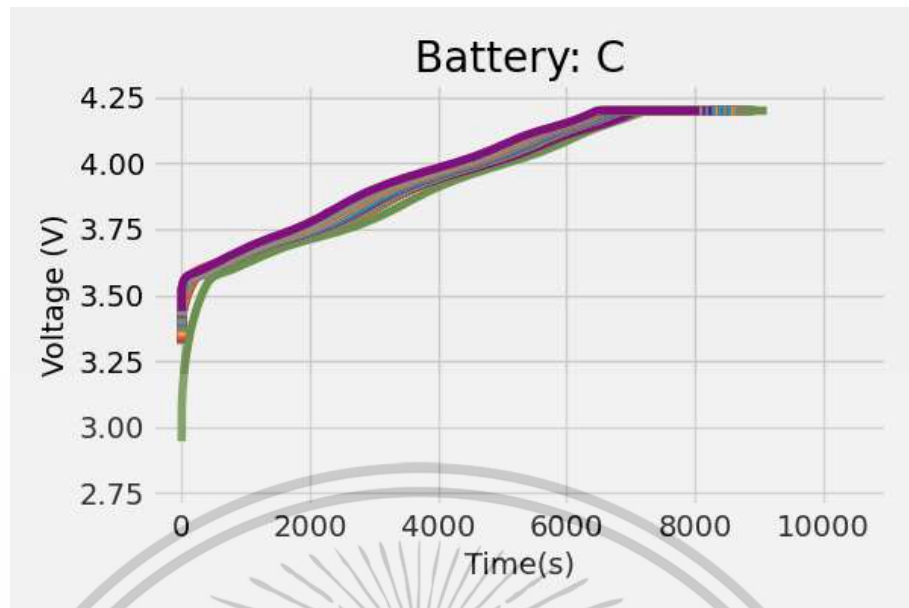
ชุดข้อมูลแบตเตอรี่ C เป็นชุดข้อมูลแบตเตอรี่ที่ได้จากโปรไฟล์การประจุไฟฟ้าจากแบตเตอรี่ชนิดลิเทียมไอออน จำนวน 1 เซลล์ ขนาดความจุ 15 Ah แรงดัน 4.2 V โดยแบตเตอรี่ถูกประจุไฟฟ้าในโหมดกระแสไฟฟ้าคงที่ 7 A จนมีแรงดัน 4.2 V ส่วนการคายประจุไฟฟ้าจะเป็นแบบกระแสไฟฟ้าคงที่ 7 A โดยมีแรงดันไฟฟ้าสิ้นสุด 3 V ชุดข้อมูลแบตเตอรี่ C ซึ่งจะประกอบด้วยโปรไฟล์ประจุไฟฟ้าและคายประจุไฟฟ้า โดยข้อมูลที่จะนำมาใช้เป็นอินพุตในการประมาณสถานะสุขภาพของแบตเตอรี่จะใช้ข้อมูลจากโปรไฟล์การประจุไฟฟ้าซึ่งประกอบด้วยข้อมูลแรงดันไฟฟ้า และกระแสไฟฟ้า แสดงดังรูปที่ 3.6 และ 3.7 จำนวนรอบของการคายประจุไฟฟ้าเป็นจำนวน 138 รอบ และมีข้อมูลของค่าความจุอยู่ในช่วงระหว่าง 100 เปอร์เซ็นต์ ถึง 95 เปอร์เซ็นต์ โดยจะมีอัตราส่วนการบันทึกข้อมูลในระหว่างการประจุและคายประจุอยู่ที่ 1 วินาทีต่อข้อมูล [22]

รูปที่ 3.8 แสดงการเสื่อมของความจุและรูปที่ 3.9 แสดงสถานะสุขภาพของแบตเตอรี่ C ตั้งแต่รอบการใช้งานที่ 1 ถึง 138 ซึ่งแสดงถึงคุณลักษณะของค่าความจุที่ลดลง ตามจำนวนรอบการประจุไฟฟ้าและการคายประจุไฟฟ้า เช่นเดียวกับกับแบตเตอรี่ B0005 แต่อัตราการเสื่อมสภาพของความจุต่อรอบการใช้งานของแบตเตอรี่ C นั้นมีค่าน้อยกว่าแบตเตอรี่ B0005 และจากข้อมูลค่าความจุของแบตเตอรี่ C ไม่พบการกำเนิดใหม่ของค่าความจุ




รูปที่ 3.6 กราฟข้อมูลกระแสไฟฟ้าของแบตเตอรี่ C ขณะประจุไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

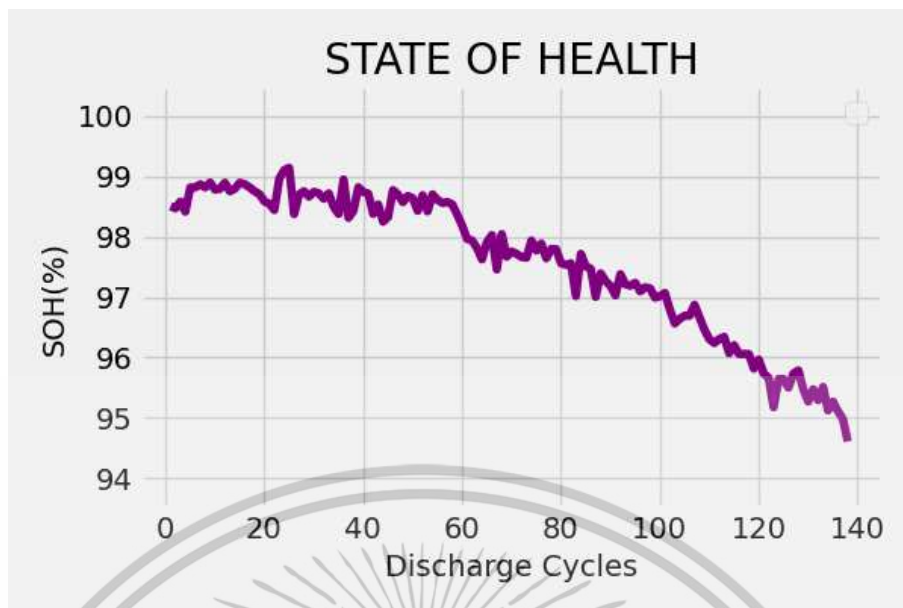


รูปที่ 3.7 กราฟข้อมูลแรงดันไฟฟ้าของแบตเตอรี่ C ขณะประจุไฟฟ้า



รูปที่ 3.8 กราฟข้อมูลความจุในแต่ละรอบการคายประจุของแบตเตอรี่ C

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.9 สถานะสุขภาพของแบตเตอรี่ C

3.2 การจัดเตรียมข้อมูล

การใช้โครงข่ายประสาทเทียมในการวิเคราะห์ หรือประมวลผลผลลัพธ์ จำเป็นต้องมีการจัดการข้อมูลที่ซ้ำซ้อนหรือเป็นข้อมูลที่มีค่าผิดพลาดออก (Data cleaning) และการลดจำนวนของข้อมูลก็จะช่วยลดเวลาในการเรียนรู้ของโครงข่ายประสาทเทียม เพื่อให้แน่ใจว่าข้อมูลที่จะนำมาใช้ในการวิเคราะห์เป็นข้อมูลที่ถูกต้องและมีคุณภาพ

3.2.1 ค่าสหสัมพันธ์

ค่าสหสัมพันธ์ (Correlation) [23] เป็นการศึกษาความสัมพันธ์ระหว่างข้อมูลหรือตัวแปรตั้งแต่ 2 ตัวแปรขึ้นไป ว่ามีความสัมพันธ์กันในระดับใด และมีความสัมพันธ์ในทิศทางใด เมื่อตัวแปรหนึ่งมีแนวโน้มเพิ่มขึ้นหรือลดลงเมื่ออีกตัวแปรหนึ่งเปลี่ยนแปลงหรือไม่ ซึ่งจะช่วยระบุว่าตัวแปรใดเกี่ยวข้องกันซึ่งสำคัญในการสร้างแบบจำลองหากตัวแปรสองตัวมีค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient) ที่สูงมาก อาจเลือกใช้เพียงตัวแปรเดียวเพื่อลดความซ้ำซ้อน และจะช่วยให้อุปกรณ์วิเคราะห์แนวโน้มของข้อมูลได้ง่ายยิ่งขึ้น ซึ่งค่าสัมประสิทธิ์สหสัมพันธ์จะเป็นตัวบ่งบอกความสัมพันธ์ของข้อมูล ถ้าหากค่าสัมประสิทธิ์มีค่าเป็น 0 จะหมายถึงไม่มีความสัมพันธ์ หากค่าสัมประสิทธิ์มีค่าเป็น 1 จะหมายถึงความสัมพันธ์เชิงบวกที่ตัวแปรทั้งสองมีการเพิ่มขึ้นในทิศทางเดียวกัน หรือค่าสัมประสิทธิ์มีค่าเป็น -1 จะหมายถึงความสัมพันธ์เชิงลบที่ตัวแปรหนึ่งเพิ่มขึ้นอีกตัวแปรหนึ่งจะลดลง ตารางที่ 3.1 จะแสดงค่าสัมประสิทธิ์สหสัมพันธ์ของชุดข้อมูลแบตเตอรี่ B0005 และ ตารางที่ 3.2 จะแสดงค่าสัมประสิทธิ์สหสัมพันธ์ของชุดข้อมูลแบตเตอรี่ C

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างข้อมูลโพรไฟล์ประจุไฟฟ้าของชุดข้อมูล แบตเตอรี่ B0005

ตัวแปร	รอบการประจุที่ 1	รอบการประจุที่ 50	รอบการประจุที่ 150
แรงดันไฟฟ้า-กระแสไฟฟ้า	-0.6299	-0.7309	-0.6487
แรงดันไฟฟ้า-อุณหภูมิ	-0.4931	-0.1030	0.0584
กระแสไฟฟ้า-อุณหภูมิ	0.7318	0.6625	0.6101

จากตารางที่ 3.1 แสดงความสัมพันธ์ของตัวแปรแรงดันไฟฟ้า กระแสไฟฟ้า และอุณหภูมิที่รอบการประจุที่ 1 50 และ 150 จากค่าสัมประสิทธิ์สหสัมพันธ์จะเห็นว่าระหว่างแรงดันไฟฟ้าและกระแสไฟฟ้ามีความสัมพันธ์เชิงลบที่มีค่าในช่วง -0.64 ถึง -0.73 ซึ่งสอดคล้องกับวิธีการประจุไฟฟ้าในโหมดกระแสคงที่แรงดันคงที่ (CCCV) โดยเฉพาะในช่วงที่เปลี่ยนจากการควบคุมกระแสเป็นการควบคุมแรงดัน ในขณะที่ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างแรงดันไฟฟ้าและอุณหภูมิของรอบการประจุที่ 1 50 และ 150 มีค่าแตกต่างกันและมีค่าใกล้ 0 นั้นหมายความว่าข้อมูลทั้งสองนี้ไม่มีความสัมพันธ์กัน ในส่วนค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างกระแสไฟฟ้าและอุณหภูมิจะเห็นว่ามีความสัมพันธ์เชิงบวก ที่สอดคล้องในเรื่องของการเพิ่มกระแสผ่านวงจร ซึ่งทำให้เกิดความร้อนและทำให้อุณหภูมิสูงขึ้น จากความสัมพันธ์ของตัวแปรทั้ง 3 ชนิดมีความสัมพันธ์ทั้งเชิงบวกและเชิงลบแต่ยังไม่สัมพันธ์กันมากจนเข้าใกล้ค่า 1 หรือ -1 ซึ่งอาจทำให้เกิดปัญหาเรื่องการมีข้อมูลซ้ำซ้อนกัน ดังนั้นตัวแปรเหล่านี้สามารถนำมาใช้เป็นข้อมูลอินพุตสำหรับการทำนายสถานะสุขภาพได้

ตารางที่ 3.2 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างข้อมูลโพรไฟล์ประจุไฟฟ้าของชุดข้อมูล แบตเตอรี่ C

ตัวแปร	รอบการประจุที่ 1	รอบการประจุที่ 50	รอบการประจุที่ 130
แรงดันไฟฟ้า-กระแสไฟฟ้า	-0.6020	-0.5339	-0.4989

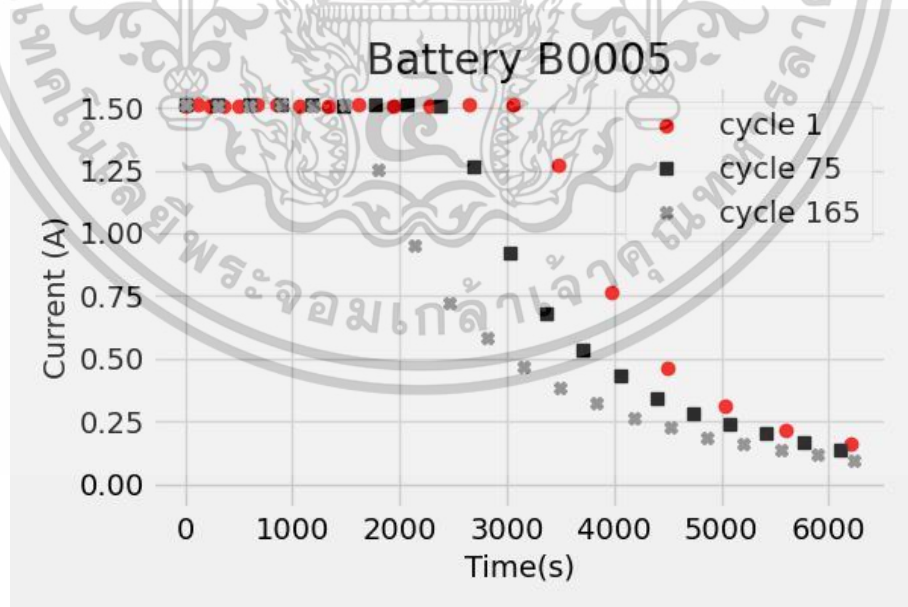
จากตารางที่ 3.2 แสดงความสัมพันธ์ของตัวแปรแรงดันไฟฟ้า และกระแสไฟฟ้า ที่รอบการประจุที่ 1 50 และ 130 จากค่าสัมประสิทธิ์สหสัมพันธ์จะเห็นว่าระหว่างแรงดันไฟฟ้าและกระแสไฟฟ้ามีความสัมพันธ์เชิงลบที่มีค่าในช่วง -0.49 ถึง -0.60 ซึ่งตัวแปรทั้งสองชนิดนี้สามารถนำมาใช้เป็นข้อมูลอินพุตสำหรับการทำนายสถานะสุขภาพได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.2 การชักตัวอย่างชุดข้อมูลแบตเตอรี่ B0005


ชุดข้อมูลแบตเตอรี่ B0005 ในวิทยานิพนธ์นี้จะถูกใช้เป็นชุดข้อมูลเพื่อสร้างแบบจำลองโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ในการประมาณสถานะสุขภาพแบตเตอรี่ โดยข้อมูลการประจุไฟฟ้านับเวลาเริ่มต้น 0 วินาที ณ ตำแหน่งการเริ่มประจุในโหมดกระแสคงที่ และลดไปจนถึงเวลาสุดท้ายที่ 6000 วินาที ซึ่งยังอยู่ในโหมดแรงดันคงที่ การเลือกชุดข้อมูล ณ ตำแหน่งการเริ่มประจุในโหมดกระแสคงที่นั้นมีความสัมพันธ์กับค่าแรงดันไฟฟ้าและอุณหภูมิของแบตเตอรี่ที่วัดได้ ณ ช่วงเวลาเดียวกัน หลังจากนั้นจะทำการชักตัวอย่างข้อมูลจากข้อมูลข้างต้นในแต่ละรอบการใช้งานแบบสม่ำเสมอจำนวน 20 จุดข้อมูล โดยรอบการประจุไฟฟ้าจะเริ่มต้นที่ 0% SOC เสมอ อย่างไรก็ตามในการใช้งานแบตเตอรี่ตามความเป็นจริงโดยพฤติกรรมแล้วมักจะเริ่มต้นการประจุไฟฟ้าในช่วงตั้งแต่ 90%-10% SOC [24] ดังนั้นในวิทยานิพนธ์นี้ โครงข่ายประสาทเทียมจะได้รับการเรียนรู้ด้วย SOC เริ่มต้นของการประจุไฟฟ้าที่แตกต่างกัน 2 รูปแบบ โดยรูปแบบแรก SOC เริ่มต้นที่ 0% และรูปแบบที่สอง SOC เริ่มต้นแบบสุ่ม เพื่อให้สอดคล้องกับพฤติกรรมการประจุไฟฟ้าตามการใช้งานแบตเตอรี่จริง รูปที่ 3.10 ถึง 3.15 จะแสดงตัวอย่างชุดข้อมูลที่ได้จากการชักตัวอย่าง 20 จุดข้อมูลในแต่ละรอบการประจุไฟฟ้า

- รอบการประจุที่ 1 จะแสดงด้วยจุดข้อมูลสีแดง
- รอบการประจุที่ 75 จะแสดงด้วยจุดข้อมูลสีดำ
- รอบการประจุที่ 165 จะแสดงด้วยจุดข้อมูลสีเทา

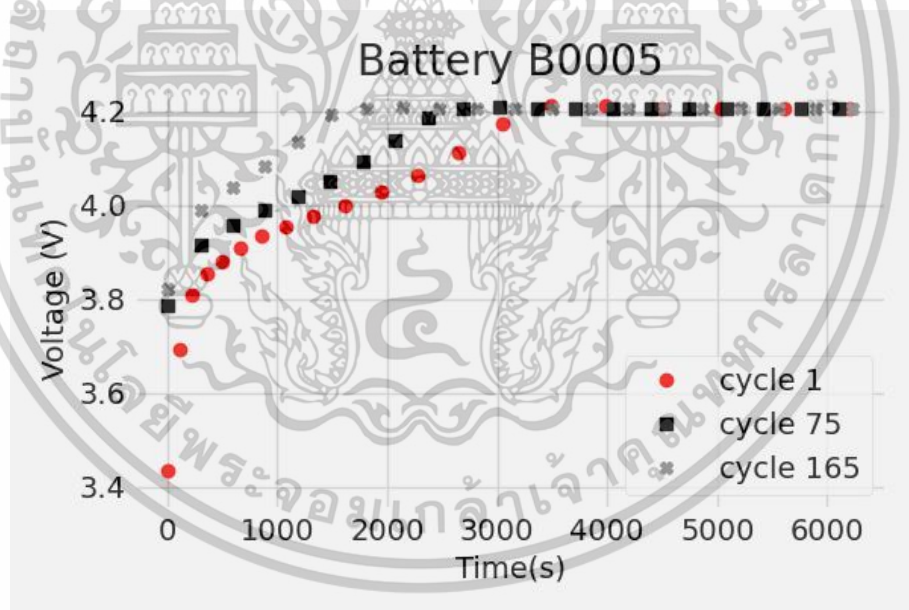


รูปที่ 3.10 กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้น 0%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

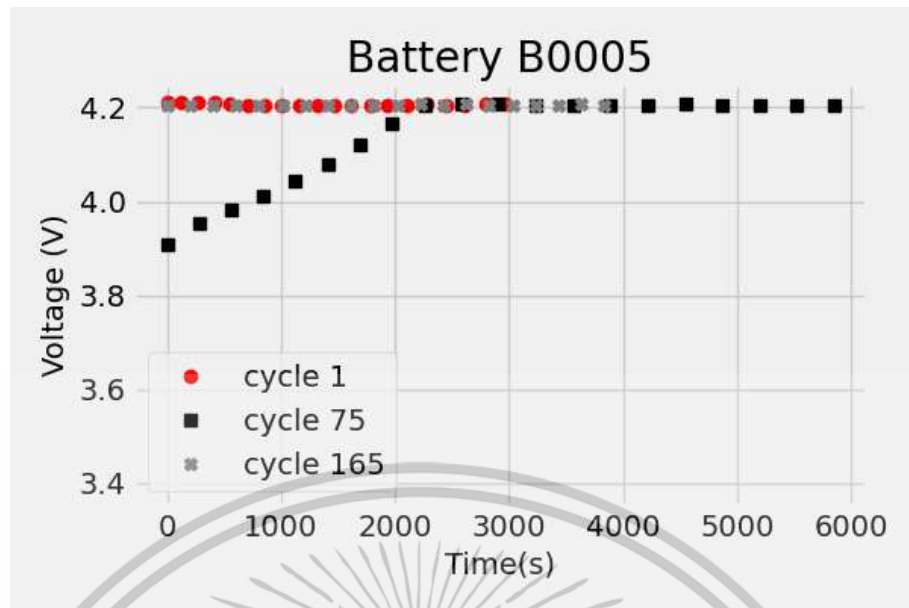


รูปที่ 3.11 กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005
มีค่า SOC เริ่มต้นแบบสุ่ม




รูปที่ 3.12 กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005
มีค่า SOC เริ่มต้น 0%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

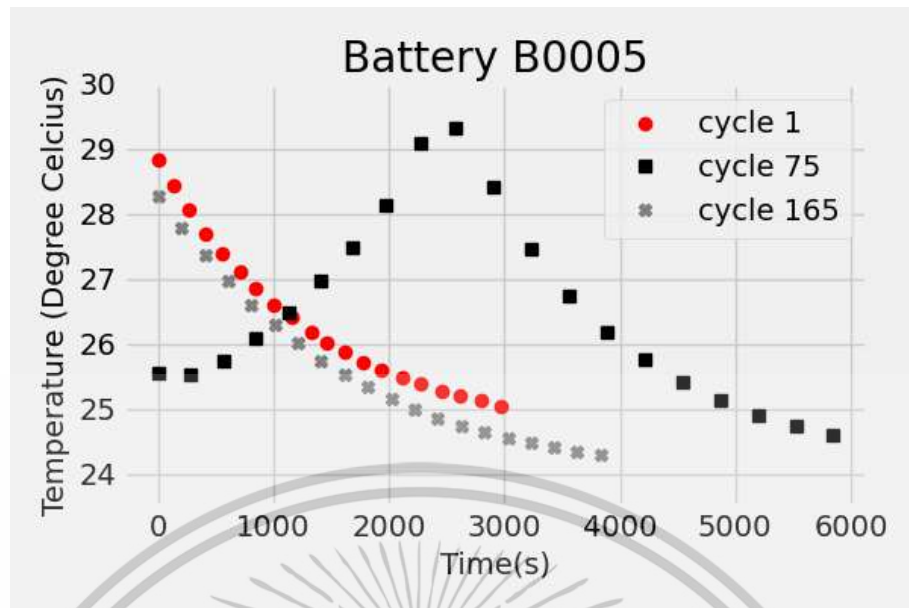


รูปที่ 3.13 กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005
มีค่า SOC เริ่มต้นแบบสุ่ม



รูปที่ 3.14 กราฟข้อมูลอุณหภูมิ 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005
มีค่า SOC เริ่มต้น 0%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



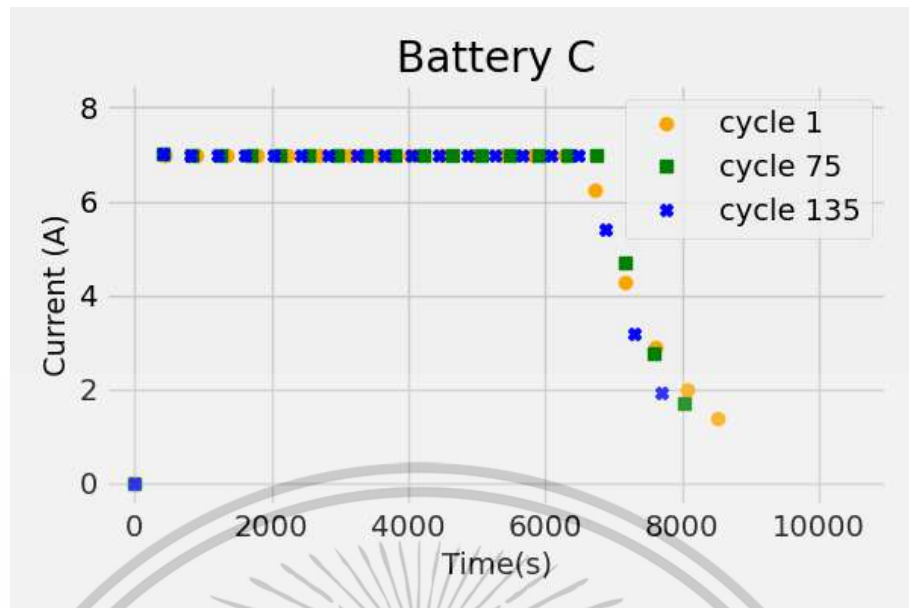
รูปที่ 3.15 กราฟข้อมูลอุณหภูมิ 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ B0005 มีค่า SOC เริ่มต้นแบบสุ่ม

3.2.3 การชักตัวอย่างชุดข้อมูลแบตเตอรี่ C

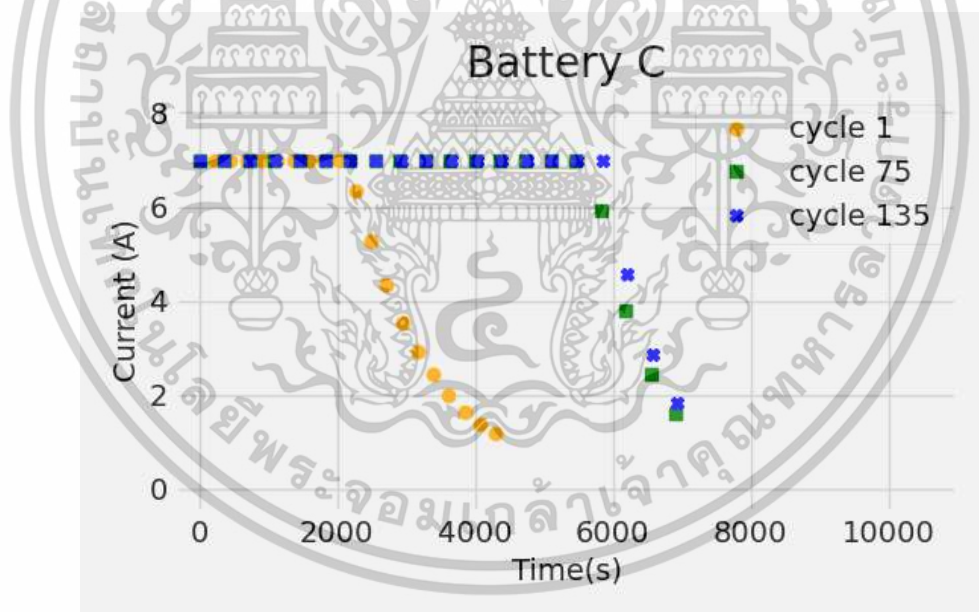
ดำเนินการชักตัวอย่างข้อมูลเป็น 2 ชุด โดยชุดข้อมูลแรกจะเริ่มต้นชักตัวอย่างข้อมูลที่เริ่มต้นด้วย SOC 0% ในแต่ละรอบการใช้งานแบบสุ่มจำนวน 20 จุดข้อมูลไปจนถึงข้อมูลสิ้นสุดการประจุ ชุดข้อมูลที่สองจะเป็นการชักตัวอย่างข้อมูลที่เริ่มต้นด้วย SOC เริ่มต้นแบบสุ่มในแต่ละรอบการใช้งานแบบสุ่มจำนวน 20 จุดข้อมูลไปจนถึงข้อมูลสิ้นสุดการประจุ รูปที่ 3.16 ถึง 3.19 จะแสดงตัวอย่างชุดข้อมูลที่ได้จากการชักตัวอย่าง 20 จุดข้อมูลในแต่ละรอบการประจุไฟฟ้า

- รอบการประจุที่ 1 จะแสดงด้วยจุดข้อมูลสีเหลือง
- รอบการประจุที่ 75 จะแสดงด้วยจุดข้อมูลสีเขียว
- รอบการประจุที่ 135 จะแสดงด้วยจุดข้อมูลสีน้ำเงิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.16 กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้น 0%

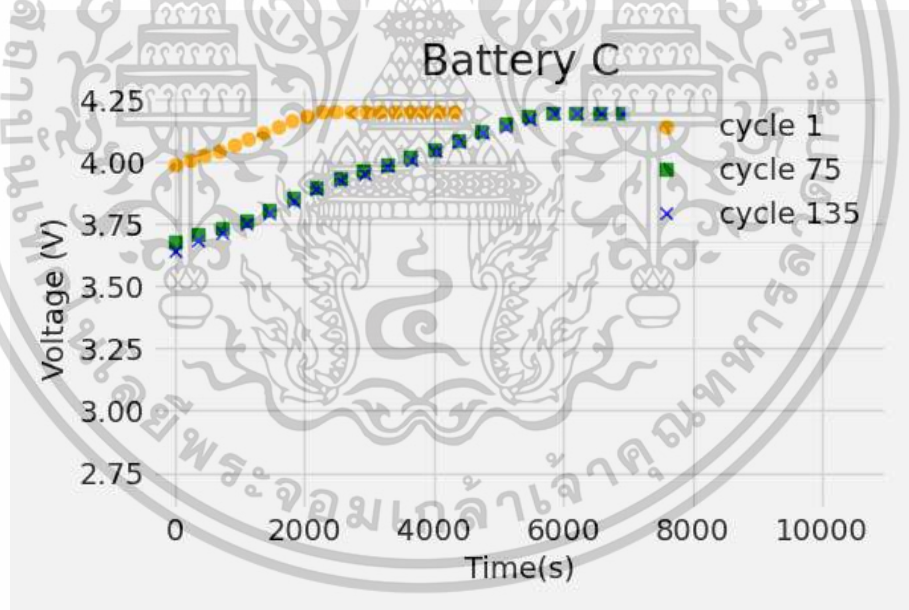


รูปที่ 3.17 กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้นแบบสุ่ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.18 กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้น 0%

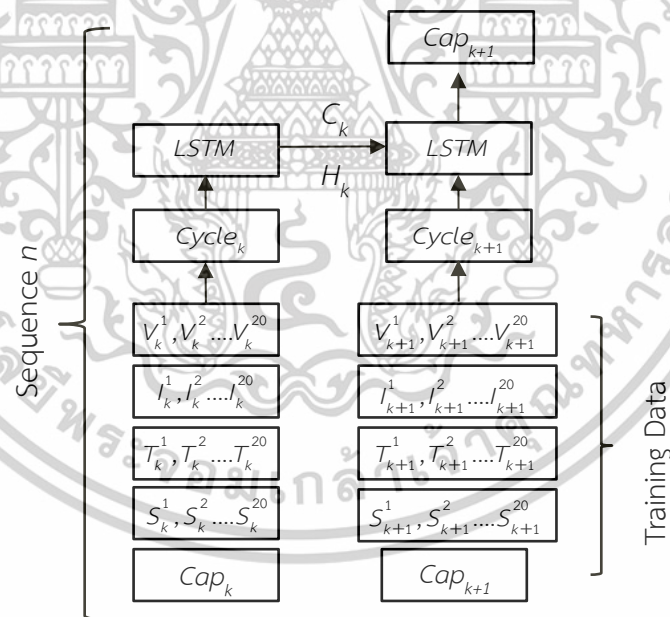


รูปที่ 3.19 กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้นแบบสุ่ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 การสร้างแบบจำลอง

การสร้างแบบจำลองโครงข่ายประสาทเทียมสำหรับการประมาณสถานะสุขภาพในวิทยานิพนธ์นี้ได้แนะนำการใช้โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (LSTM) ซึ่งเป็นโครงข่ายประเภทหนึ่งของโครงข่ายประสาทเทียมแบบเวียนซ้ำ (RNN) ที่สามารถเรียนรู้รูปแบบของข้อมูลตามลำดับเวลาได้อย่างมีประสิทธิภาพ โดยลักษณะของโครงข่ายที่นำมาใช้เป็นแบบหลายอินพุต (multi-channel) และมีโครงสร้างแบบ Many-to-One ซึ่งหมายถึงการนำเข้าข้อมูลหลายชุดในแต่ละช่วงเวลาและได้ผลลัพธ์ออกมาเป็นค่าหนึ่งค่า [25] การออกแบบโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวในวิทยานิพนธ์นี้มีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพของแบบจำลองให้สามารถรองรับอินพุตที่มีลักษณะแตกต่างกัน อินพุตของแบบจำลองประกอบด้วยข้อมูลโปรไฟล์ประจุไฟฟ้าของแบตเตอรี่ B0005 ที่มีความหลากหลายทั้งหมด 4 ประเภท คือ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลา แบบจำลองจะทำหน้าที่เรียนรู้รูปแบบความสัมพันธ์ระหว่างอินพุตทั้งสี่ประเภทนี้เพื่อทำนายค่าผลลัพธ์ ที่เป็นค่าความจุของแบตเตอรี่ ในการป้อนข้อมูลเข้าสู่แบบจำลองข้อมูลสำหรับการเรียนรู้จะถูกจัดเรียงในลักษณะลำดับ (Sequence) โดยในวิทยานิพนธ์เล่มนี้ได้เลือกใช้รูปแบบการนำเข้าของข้อมูลอินพุตสู่แบบจำลอง ในรูปที่ 3.20



รูปที่ 3.20 แสดงตัวอย่างการจัดเรียงลำดับข้อมูล
สำหรับการฝึกสอนแบบจำลอง LSTM แบบ many to one

$$Cycle_k, Cycle_{k+1} \rightarrow Cap_{k+1} \quad (3.1)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ $Cycle_k$ คือ ชุดข้อมูลเรียนรู้ของแบบจำลองในแต่ละรอบการประจุและคายประจุที่ประกอบด้วยอินพุตหลายตัวแปร $V_k^m, I_k^m, T_k^m, S_k^m$ และ Cap_k แทนข้อมูลที่ได้ทำการซักรวอย่างไว้ประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา และผลลัพธ์ค่าความจุตามลำดับ k คือ รอบการประจุและคายประจุของแบตเตอรี่ โดย k จะมีค่าเท่ากับ n ค่าของ m คือ ลำดับของชุดข้อมูลที่ได้จากการซักรวอย่างซึ่งจะเป็นจำนวนของชุดข้อมูลเรียงกันที่ 1 ถึง 20 โดยการนำเข้าข้อมูลจะพิจารณาข้อมูลจากรอบการประจุและคายประจุของแบตเตอรี่ที่มีลำดับต่อเนื่องกันจำนวน 2 รอบและจะเพิ่มลำดับของชุดข้อมูลตามรอบการประจุและคายประจุครั้งละ 1 รอบ

- Sequence 1 จะประกอบไปด้วย ชุดข้อมูลเรียนรู้ของรอบการประจุและคายประจุที่ 1 และ 2 เมื่อเข้าสู่แบบจำลอง ส่วนเอาต์พุต คือค่าความจุของรอบการคายประจุที่ 2 ในลำดับถัดมาจะทำการเพิ่มชุดข้อมูลของรอบถัดไป

- Sequence 2 จะประกอบไปด้วย ชุดข้อมูลเรียนรู้ของรอบการประจุและคายประจุที่ 2 และ 3 เมื่อเข้าสู่แบบจำลอง ส่วนเอาต์พุต คือค่าความจุของรอบการคายประจุที่ 3

- Sequence L-1 จะประกอบไปด้วย ชุดข้อมูลเรียนรู้ของรอบการประจุและคายประจุที่ L-1 และ L เมื่อเข้าสู่แบบจำลอง ส่วนเอาต์พุต คือค่าความจุของรอบการคายประจุที่ L

เมื่อกำหนดให้ L คือ จำนวนรอบประจุและคายประจุของชุดข้อมูลเรียนรู้ n แทนลำดับของ Sequence ซึ่งมีค่า $n = 1, 2, \dots, L-1$

ในการฝึกสอนแบบจำลองข้อมูล $Cycle_k$ จะถูกป้อนเข้าสู่หน่วยความจำแรกเพื่อวิเคราะห์ความสัมพันธ์ของอินพุตและเอาต์พุต เมื่อทำการอัปเดตหน่วยความจำ (cell state) จะได้ C_k และผลลัพธ์ (hidden state) h_k ต่อจากนั้นข้อมูล $Cycle_{k+1}$ จะถูกป้อนเข้าสู่หน่วยความจำลำดับถัดมา โดยจะอาศัยหน่วยความจำและผลลัพธ์จากข้อมูล $Cycle_k$ มาร่วมวิเคราะห์และหาผลลัพธ์เป้าหมายที่ต้องการคือ Cap_{k+1}

3.4 การประมวลผล

การประมวลผลสถานะสุขภาพของแบตเตอรี่ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ในวิทยานิพนธ์นี้ใช้การเขียนภาษาโปรแกรมด้วย Python โดยใช้ไลบรารี tensorflow.keras เป็นเครื่องมือในการสร้างแบบจำลอง ดำเนินการด้วยโปรแกรม Pycharm Community Editor บนหน่วยประมวลผลกลาง Intel i7-7700 ความเร็ว 2.80 GHz ขนาดหน่วยความจำ 12 GB

ขั้นตอนแรกต้องเริ่มจากการนำ Library ที่เกี่ยวข้องในการประมวลผลสถานะแบตเตอรี่ ซึ่งจะประกอบไปด้วย

- NumPy (Numerical Python) เป็นหลักสำหรับการคำนวณทางคณิตศาสตร์ และตัวเลขใน Python โดยมีจุดเด่นที่ อาร์เรย์ (Array) แบบหลายมิติ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Pandas เป็นไลบรารีสำหรับจัดการข้อมูลในรูปแบบตาราง (DataFrame) แบบ 2 มิติ ซึ่งคล้ายกับตารางในโปรแกรม Microsoft Excel
- matplotlib เป็นไลบรารีใน Python ที่ใช้สำหรับ การสร้างกราฟและการแสดงผลข้อมูล (Data Visualization)
- tensorflow.keras เป็น library หลักสำหรับสร้างแบบจำลอง LSTM โดยจะประกอบไปด้วยแบบจำลอง Sequential ซึ่งเป็นแบบจำลองพื้นฐานสำหรับการทำโครงข่าย Dense เป็นชั้น Layer สำคัญที่ทำให้ Neural Network สามารถเรียนรู้และปรับปรุงประสิทธิภาพได้ซึ่งมีหน้าที่เป็น Fully Connected Layer ที่เชื่อมโยงทุก Neuron ของ Layer ก่อนหน้าและ LSTM คือโครงสร้างแบบจำลองหน่วยความจำระยะสั้นแบบยาวที่จะนำมาใช้
- math เป็นไลบรารีที่นำมาเรียกใช้ฟังก์ชันคณิตศาสตร์
- EarlyStopping เป็นหนึ่งใน callbacks ของ keras ที่ใช้สำหรับหยุดการเรียนรู้ของแบบจำลองก่อนที่ epoch จะสิ้นสุดลง หากค่า Loss ของแบบจำลองไม่ลดลงตามจำนวนรอบการเรียนรู้ ช่วยป้องกัน overfitting และลดเวลาในการเรียนรู้ของแบบจำลอง
- load_model เป็นฟังก์ชันจาก tensorflow.keras ที่ใช้ในการเรียกคืนแบบจำลองที่เคยถูกบันทึกไว้กลับมาใช้งานใหม่ รวมถึงโครงสร้างแบบจำลอง ค่าน้ำหนัก หรือค่า bias ที่ถูกบันทึกไว้

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import tensorflow.keras
import math
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, LSTM
from tensorflow.keras.callbacks import EarlyStopping
from sklearn.preprocessing import MinMaxScaler
from sklearn.model_selection import train_test_split
from tensorflow.keras.callbacks import Callback
from tensorflow.keras.models import load_model
```

รูปที่ 3.21 Library สำหรับการจัดเตรียมข้อมูลและการประมาณสถานะสุขภาพของแบตเตอรี่

ขั้นตอนถัดไปคือการนำเข้าสู่ชุดข้อมูลที่จะนำมาใช้ในการสร้างแบบจำลองการประมาณสถานะสุขภาพทั้งหมดประกอบด้วยชุดข้อมูลชุดข้อมูลค่า SOC เริ่มต้น 0% หรือ SOC เริ่มต้นแบบสุ่มของเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบตเตอรี่ B0005 ซึ่งประกอบไปด้วยข้อมูลอินพุต คือ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลาและเอาต์พุต คือ ความจุ ซึ่งข้อมูลทั้งหมดได้ถูกจัดเตรียมไว้เป็นรูปแบบไฟล์ CSV (Comma-Separated Values) โดยนำเข้าข้อมูลให้อยู่ในรูปของ DataFrame

```
VB0005 = pd.read_csv('1.B0005 Data V 20.csv')
IB0005 = pd.read_csv('1.B0005 Data I 20.csv')
TB0005 = pd.read_csv('1.B0005 Data T 20.csv')
TimeB0005 = pd.read_csv('1.B0005 Data Time 20.csv')
capB0005 = pd.read_csv('capcut B0005.csv')
```

รูปที่ 3.22 การนำเข้าข้อมูลในรูป DataFrame

จากนั้นทำการปรับชุดข้อมูลให้เป็นปกติ (Normalization) จะดำเนินการด้วยวิธี Min-Max scaling เป็นการปรับฐานของชุดข้อมูลทั้งหมดให้อยู่ในช่วง 0-1 เพื่อให้ชุดข้อมูลเป็นฐานเดียวกันก่อนเข้าแบบจำลอง ในการปรับชุดข้อมูลให้เป็นปกตินี้ก็จะดำเนินการกับแบตเตอรี่ทั้ง 2 ชุดข้อมูล

```
VB0005Data_raw = VB0005
minV = VB0005.min().min() # df['Low'].min()
maxV = VB0005.max().max() # df['High'].max()
VB0005MinMax = (VB0005 - minV) / (maxV - minV)

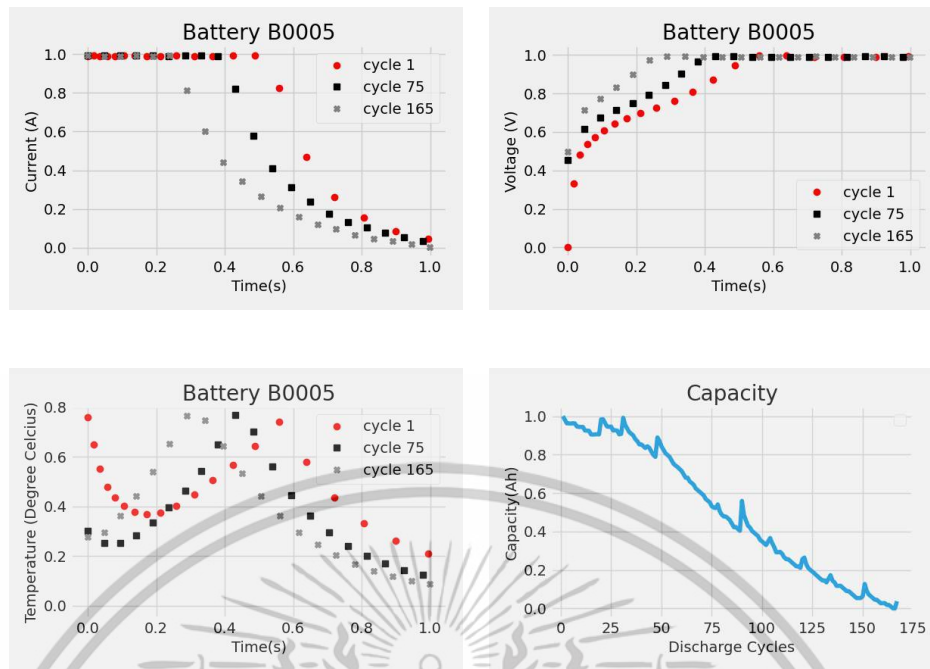
IB0005Data_raw = IB0005
minI = IB0005.min().min() # df['Low'].min()
maxI = IB0005.max().max() # df['High'].max()
IB0005MinMax = (IB0005 - minI) / (maxI - minI)

TB0005Data_raw = TB0005
minT = TB0005.min().min() # df['Low'].min()
maxT = TB0005.max().max() # df['High'].max()
TB0005MinMax = (TB0005 - minT) / (maxT - minT)

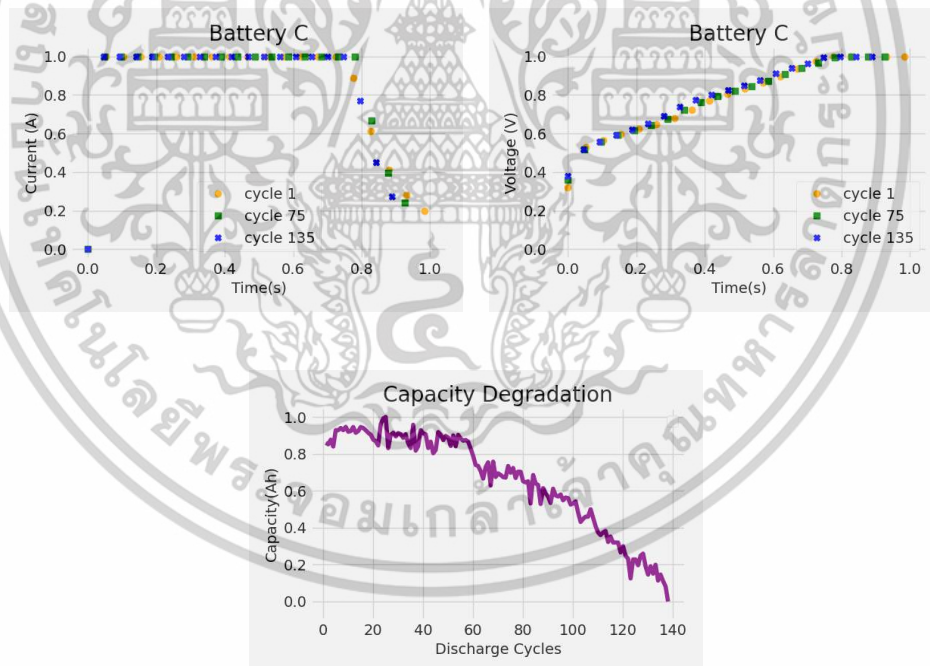
TimeB0005Data_raw = TimeB0005
minTime = TimeB0005.min().min() # df['Low'].min()
maxTime = TimeB0005.max().max() # df['High'].max()
TimeB0005MinMax = (TimeB0005 - minTime) / (maxTime - minTime)
```

รูปที่ 3.23 การปรับชุดข้อมูลให้เป็นปกติ ด้วยวิธี Min-Max scaling

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีกรนำไปใช้



รูปที่ 3.24 ชุดข้อมูลแบตเตอรี่ B0005 หลังจากปรับข้อมูล ด้วยวิธี Min-Max scaling



รูปที่ 3.25 ชุดข้อมูลแบตเตอรี่ C หลังจากปรับข้อมูล ด้วยวิธี Min-Max scaling

ขั้นตอนต่อมาคือการนำชุดข้อมูลที่ได้ทำการปรับฐานกลับเข้าสู่ DataFrame อีกครั้งก่อนเข้าสู่แบบจำลอง เพื่อทำการประมาณสถานะสุขภาพ โครงสร้างของแบบจำลองหน่วยความจำระยะสั้นแบบยาว ต้องใช้อินพุตในลักษณะอาร์เรย์ 3 มิติ ทำให้ต้องทำการปรับแต่งโครงสร้างของชุดข้อมูลให้อยู่เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในรูป shape = (sample, timesteps, features) โดยการจัดโครงสร้างของชุดข้อมูลจะใช้คำสั่ง pd.concat() สำหรับการเชื่อมต่อหลายๆ DataFrame หรือ Series ที่มีโครงสร้างข้อมูลเข้าด้วยกัน โดยสามารถกำหนดว่าให้เชื่อมต่อในทิศทางตามแถวหรือตามหลัก โครงสร้างของข้อมูลแบบเตอร์ B0005 หลังการจัดโครงสร้างแล้วจะได้เป็น 167 1 80 โดย sample หมายถึง จำนวนรอบการใช้งาน timesteps แทนชุดข้อมูลในแต่ละรอบการใช้งาน timesteps เท่ากับ 1 หมายถึง 1 ชุดข้อมูลในหนึ่งรอบการใช้งาน features คือจำนวนข้อมูลใน timesteps นั้นซึ่งประกอบไปด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและเวลาอย่างละ 20 ข้อมูล ดังแสดงดังรูปที่ที่ 3.26

```
xDataaB0005 = pd.concat([dataVB0005, dataIB0005, TB0005, dataTimeB0005], axis=1)
xDataB0005 = xDataaB0005.values.reshape((167, 1, 80)) #แปลงแถว
```

รูปที่ 3.26 การจัดโครงสร้างชุดข้อมูลก่อนนำเข้าสู่แบบจำลอง

ขั้นตอนต่อมาคือการแบ่งชุดข้อมูล ส่วนแรกจะเป็นชุดข้อมูลเรียนรู้ (Training set) ใช้ในการฝึกสอนให้แบบจำลอง ส่วนที่สองเป็นชุดข้อมูลสำหรับทดสอบ (Test set) คือชุดข้อมูลที่ใช้ในการทดสอบและประเมินผลลัพธ์ของแบบจำลอง รูปที่ 3.27 จะแสดงการแบ่งชุดข้อมูลเรียนรู้ต่อชุดข้อมูลทดสอบเป็นอัตราส่วน 70 ต่อ 30 และทำการเรียงข้อมูลให้เป็นลำดับด้วยการกำหนดข้อมูลสำหรับการเรียนรู้เป็น 2 รอบการประจุและคายประจุที่ติดกันโดยผลลัพธ์จะเป็นเอาต์พุตของชุดข้อมูลลำดับหลังและเปลี่ยนลำดับด้วยการเลื่อนข้อมูลของรอบการประจุและคายประจุไปครั้งละ 1 รอบ

```
train_ratio = 0.70
test_ratio = 0.30

XB0005_train, XB0005_test, yB0005_train,
yB0005_test = train_test_split(xDataB0005, yDataB0005, test_size=1 - train_ratio, shuffle = False)

1 usage
def reshape_to_sequence(XB0005_train, time_step):
    N = XB0005_train.shape[0] - time_step + 1
    xB0005_train = []
    for i in range(N):
        xB0005_train.append(XB0005_train[i:i+time_step, 0, :])
    return np.array(xB0005_train)

time_step = 2
XB0005_train = reshape_to_sequence(XB0005_train, time_step)
yB0005_train = yB0005_train[time_step-1:]
```

รูปที่ 3.27 การแบ่งชุดข้อมูลเป็นชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การสร้างแบบจำลองประมาณสถานะสุขภาพโดยการฝึกให้เรียนรู้ด้วยวิธีการขับเคลื่อนข้อมูล ต้องเริ่มจากการกำหนดค่า Hyperparameters ของแบบจำลองซึ่งกำหนดให้เป็นแบบ Hidden layer 1 ชั้น ประกอบด้วยเซลล์ประสาทหรือ Neuron จำนวน 200 Neuron โดยใช้ Adam Optimizer ซึ่งมีค่าอัตราเรียนรู้ (learning rate) ถูกตั้งค่าไว้ที่ 0.001 ในส่วน Activation function จะเป็น tanh และ Recurrent Activation function จะเป็น sigmoid เพื่อทำการปรับปรุงแบบจำลองให้มีความเหมาะสม ในส่วนการตั้งค่ารอบการสิ้นสุดในการเรียนรู้ของแบบจำลองในวิทยานิพนธ์ขอเสนอวิธีการใช้ฟังก์ชัน EarlyStopping [26] มาใช้ในการกำหนดเงื่อนไข เมื่อค่า training loss ของการเรียนรู้มีค่าไม่ลดลง 0.00001 ในช่วง 300 epoch ให้ทำการสิ้นสุดการเรียนรู้ หลังจากนั้นฟังก์ชัน EarlyStopping จะถูกตั้งคำสั่ง restore best weights ซึ่งเป็นพารามิเตอร์ที่ใช้ใน EarlyStopping โดยมีหน้าที่ในการกู้ค่าน้ำหนัก (weights) ของแบบจำลองให้กลับมาเป็นค่าที่ดีที่สุดที่เคยได้ระหว่างการเรียนรู้แทนที่จะเป็นค่าสุดท้ายก่อนสิ้นสุดการหยุดกระบวนการเรียนรู้ และสาเหตุที่ต้องตั้งค่าการสิ้นสุดของกระบวนการเรียนรู้ด้วย training loss ที่ไม่เปลี่ยนแปลงถึง 300 epoch เนื่องจากในบางกรณีที่แบบจำลองทำการเรียนรู้ข้อมูลอยู่นั้น ค่า training loss ไม่ลดลงเนื่องมาจากการกำหนดค่า hyperparameter ที่ยังไม่เหมาะสมหรือแบบจำลองเรียนรู้ค่าน้ำหนักที่ยังไม่ดีพอ แบบจำลองอาจสิ้นสุดการเรียนรู้ตามคำสั่งที่ให้ก่อนถึงเวลาที่เหมาะสม ทำให้ได้ผลลัพธ์ที่มีประสิทธิภาพที่ต่ำ และฟังก์ชัน EarlyStopping ก็สามารถแก้ปัญหา Overfitting ในการเรียนรู้ที่มากเกินไปได้ด้วยเช่นกัน ในส่วนของ training loss ถูกกำหนดด้วยฟังก์ชัน mean square error ซึ่งเป็น loss function สำเร็จรูปของ tensorflow.keras

หลังจากสิ้นสุดกระบวนการเรียนรู้ของแบบจำลองสามารถบันทึกแบบจำลอง LSTM ที่ผ่านกระบวนการเรียนรู้และปรับค่าน้ำหนักเก็บไว้ได้ด้วยคำสั่ง model.save เมื่อต้องการเรียกใช้แบบจำลอง LSTM ก็สามารถเรียกกลับด้วยคำสั่ง model_load ทำให้ไม่ต้องเรียนรู้ข้อมูลใหม่

```

model = Sequential()
model.add(LSTM(200, return_sequences=False, activation='tanh', \
              input_shape=(XB0005_train.shape[1], XB0005_train.shape[2])))

model.add(Dense(1))
model.compile(loss='mse', optimizer='adam')
es = EarlyStopping(monitor='loss', min_delta=0.00001, mode='min', \
                  verbose=1, patience=300, restore_best_weights=True)
history = model.fit(XB0005_train, yB0005_train, epochs=4000, \
                   batch_size=10, verbose=2, callbacks=[es])
model.summary()
model.save('D:/Python/result/B0005 SOC %/Soc 0% B0005 70 1.keras')

#model = load_model('D:/Python/result/B0005 SOC %/Soc 0% B0005 70 1.keras')
#model.summary()

```

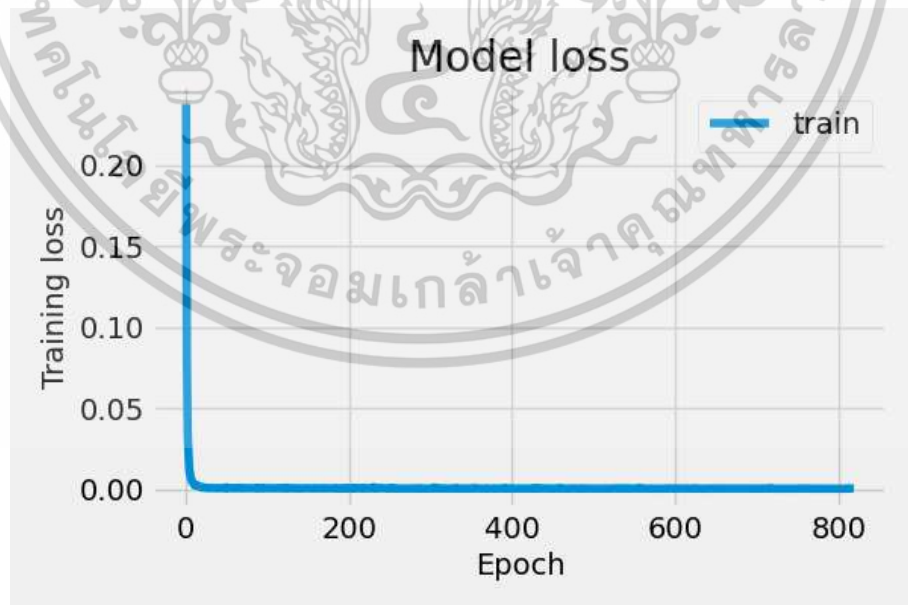
รูปที่ 3.28 การสร้างแบบจำลองโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Epoch 818/4000
12/12 - 0s - loss: 2.0232e-04 - 53ms/epoch - 4ms/step
Epoch 819/4000
12/12 - 0s - loss: 2.2307e-04 - 43ms/epoch - 4ms/step
Epoch 820/4000
Restoring model weights from the end of the best epoch: 520.
12/12 - 0s - loss: 2.0067e-04 - 59ms/epoch - 5ms/step
Epoch 820: early stopping
Model: "sequential"
-----
Layer (type)                Output Shape              Param #
-----
lstm (LSTM)                  (None, 200)               224800
dense (Dense)                 (None, 1)                  201
-----
Total params: 225001 (878.91 KB)
Trainable params: 225001 (878.91 KB)
Non-trainable params: 0 (0.00 Byte)
-----

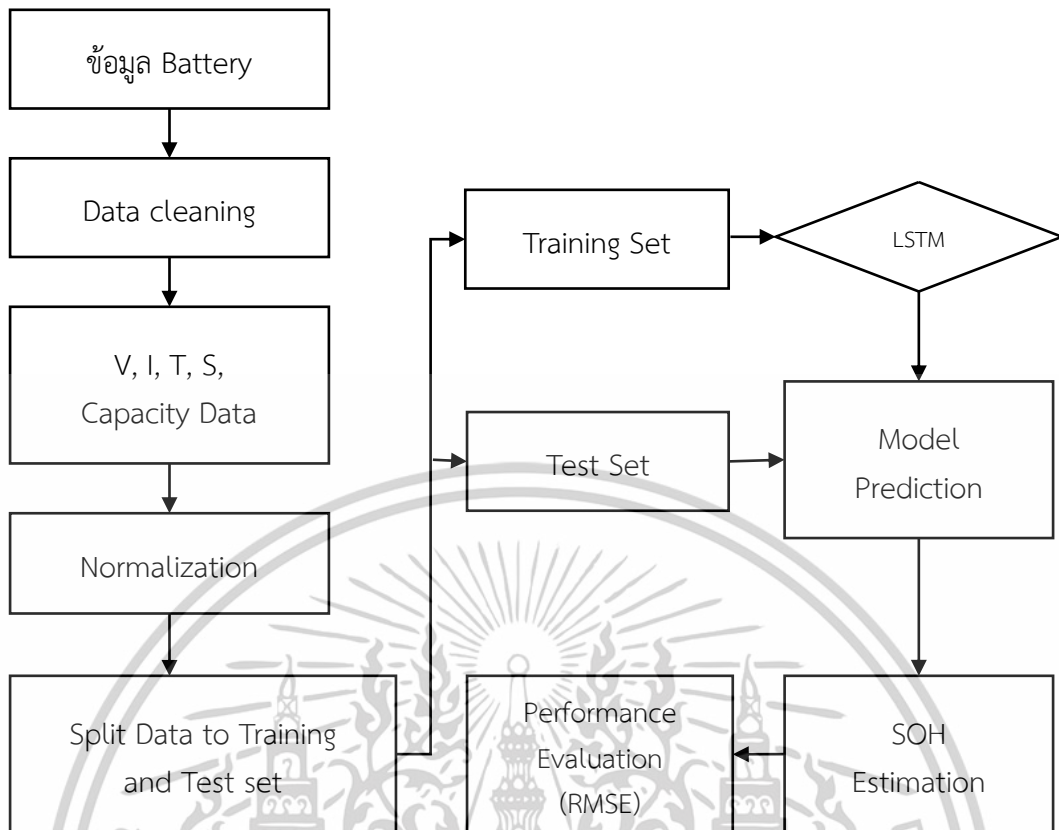
```

รูปที่ 3.29 Model summary และการสิ้นสุดการเรียนรู้ของแบบจำลองด้วยฟังก์ชัน EarlyStopping



รูปที่ 3.30 กราฟแสดงผลลัพธ์ในกระบวนการเรียนรู้ของแบบจำลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.31 ขั้นตอนการประมาณสถานะสุขภาพของแบตเตอรี่

รูปที่ 3.31 แสดงลำดับขั้นตอนในการประมาณสถานะสุขภาพของแบตเตอรี่เริ่มต้นจากการคัดเลือกชุดข้อมูลของแบตเตอรี่ที่จะนำมาใช้ ขั้นตอนต่อมาตรวจสอบคุณภาพของข้อมูลและกำจัดข้อมูลที่ผิดพลาดและซ้ำซ้อนออก (Data cleaning) คัดเลือกชุดข้อมูลจากโปรไฟล์การประจุไฟฟ้าเพื่อใช้เป็นอินพุตของแบบจำลองประกอบด้วยชุดข้อมูลแรงดันไฟฟ้า (V) กระแสไฟฟ้า (I) อุณหภูมิ (T) เวลา (S) และเอาต์พุตคือค่าความจุ (Capacity) จากนั้นทำการชักตัวอย่างเป็นจำนวน 20 จุดข้อมูลในแต่ละตัวแปรตามรอบของการประจุไฟฟ้า โดยมีเงื่อนไขเพื่อใช้ในการประมาณสถานะสุขภาพของแบตเตอรี่ออกเป็น 2 วิธี ชุดข้อมูลแรกสำหรับ SOC เริ่มต้นที่ 0% และชุดข้อมูลที่สองสำหรับ SOC เริ่มต้นแบบสุ่มและทำการปรับชุดข้อมูลให้เป็นปกติปกติ (Normalization) ด้วยวิธี Min-Max scaling ขั้นตอนต่อมาทำการแบ่งชุดข้อมูลออกเป็นชุดข้อมูลเรียนรู้ (Training set) และชุดข้อมูลทดสอบ (Test set) จากนั้นนำชุดข้อมูลป้อนเข้าสู่โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวเพื่อสร้างแบบจำลองการประมาณสถานะสุขภาพของแบตเตอรี่ โดยชุดข้อมูลเรียนรู้ถูกใช้เป็นข้อมูลให้แบบจำลองเรียนรู้และจดจำ เมื่อได้โครงสร้างของแบบจำลอง นำชุดข้อมูลทดสอบป้อนเข้าสู่แบบจำลองเพื่อหาผลลัพธ์ (Model Prediction) ผลลัพธ์ของแบบจำลองก็คือผลการประมาณสถานะสุขภาพของแบตเตอรี่ (SOH Estimation) และตรวจสอบประสิทธิภาพของแบบจำลองด้วยค่า RMSE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการประเมินสถานะสุขภาพของแบตเตอรี่

ชุดข้อมูลและเงื่อนไขต่อไปนี้จะจัดทำขึ้นเพื่อเปรียบเทียบประสิทธิภาพการประเมินสถานะสุขภาพของแบตเตอรี่ผ่านโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว โดยจำลองตามพฤติกรรมการใช้งานแบตเตอรี่ของผู้ใช้งาน เริ่มต้นจากการประจุไฟฟ้าที่ค่า SOC เริ่มต้น 0% ลำดับต่อมาเป็นการประจุไฟฟ้ามีค่า SOC เริ่มต้นแบบสุ่ม โดยพิจารณาถึงการเลือกใช้ตัวแปรต่างชนิดกันและจำนวนข้อมูลเรียนรู้ต่อข้อมูลทดสอบว่าส่งผลต่อผลลัพธ์การประเมินสถานะสุขภาพเช่นใด โดยแบบจำลองจะเริ่มต้นจากการใช้ชุดข้อมูลแบตเตอรี่ B0005 ในการออกแบบและทดสอบผลลัพธ์ซึ่งข้อมูลที่ใช้เป็นอินพุตในการประเมินสถานะ มาจากข้อมูลโพรไฟล์ประจุไฟฟ้าของแบตเตอรี่ B0005 ซึ่งจะประกอบไปด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลาที่ใช้ ผ่านการชักตัวอย่าง 20 จุดข้อมูลจากชุดข้อมูลทั้งหมดเป็นจำนวน 167 รอบใช้งาน ในส่วนแบตเตอรี่ C จะเป็นการนำต้นแบบโครงสร้างแบบจำลองในการประเมินสถานะสุขภาพของแบตเตอรี่ B0005 มาประยุกต์ใช้เพื่อหาผลลัพธ์ของการประเมินสถานะสุขภาพ เพื่อทดสอบประสิทธิภาพของแบบจำลองในกรณีข้อมูลอินพุตเป็นแบตเตอรี่ต่างรุ่นกัน โดยข้อมูลอินพุตมาจากข้อมูลโพรไฟล์ประจุไฟฟ้าซึ่งประกอบไปด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้าและเวลาที่ใช้ ผ่านการชักตัวอย่าง 20 จุดข้อมูลจากชุดข้อมูลทั้งหมดเป็นจำนวน 138 รอบใช้งาน

4.1 ผลการประเมินสถานะสุขภาพจากชุดข้อมูลแบตเตอรี่ B0005


4.1.1 การประเมินสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่อตัวแปรอินพุตต่างชนิดกัน

การประเมินสถานะสุขภาพ ด้วยค่า SOC เริ่มต้น 0% จะใช้ข้อมูลอินพุตตั้งแต่เริ่มต้นกระบวนการประจุไฟฟ้าไปจนถึงสิ้นสุดการประจุไฟฟ้า โดยจะเปรียบเทียบผลลัพธ์ระหว่างตัวแปรอินพุตต่างชนิดกัน ขั้นตอนนี้จะเป็นการหาตัวแปรที่ส่งผลต่อการประเมินสถานะสุขภาพแบตเตอรี่ ว่าตัวแปรแต่ละชนิดส่งผลอย่างไรต่อผลลัพธ์ ชุดข้อมูลอินพุตจะเป็นชุดข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและเวลา ที่ชักข้อมูล 20 จุดข้อมูลด้วยค่า SOC เริ่มต้น 0%


การประเมินสถานะสุขภาพจะกำหนดค่า hyperparameters ให้โครงข่ายประสาทเทียมในการเรียนรู้เพื่อสร้างแบบจำลองเป็นโครงข่ายแบบ LSTM 1 ชั้น มี Hidden layer = 200 Neuron batch size เท่ากับ 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบเป็น 70 ต่อ 30 โดยเป็นชุดข้อมูลเรียนรู้ 117 รอบใช้งาน ชุดข้อมูลทดสอบ 50 รอบใช้งานและมีค่า SOC เริ่มต้น 0% โดยจะทำการทดสอบเงื่อนไขละ 3 ครั้ง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.1 ถึง 4.11 คือผลการประมาณสถานะสุขภาพแบตเตอรี่ด้วยตัวแปรอินพุตต่างชนิดกัน
เส้นสีน้ำเงินแสดงสถานะสุขภาพของแบตเตอรี่ของแบตเตอรี่ B0005 เส้นสีแดงแสดงผลการประมาณ
สถานะสุขภาพจากแบบจำลอง




รูปที่ 4.1 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า




รูปที่ 4.2 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%

ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย กระแสไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.3 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
ข้อมูลอินพุต 1 ตัวแปร ประกอบด้วย ค่าอุณหภูมิ




รูปที่ 4.4 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.5 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า อุณหภูมิ




รูปที่ 4.6 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
ข้อมูลอินพุต 2 ตัวแปร ประกอบด้วย กระแสไฟฟ้า อุณหภูมิ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.7 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า เวลา




รูปที่ 4.8 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า อุณหภูมิ เวลา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.9 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย กระแสไฟฟ้า อุณหภูมิ เวลา



รูปที่ 4.10 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 3 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.11 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% ข้อมูลอินพุต 4 ตัวแปร ประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา

ตารางที่ 4.1 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% เมื่อตัวแปรอินพุตต่างชนิดกัน

ข้อมูลอินพุต	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
แรงดันไฟฟ้า	0.0474	676	0.0456	1208	0.0815	1010
กระแสไฟฟ้า	0.0361	677	0.0432	649	0.0234	966
อุณหภูมิ	0.0408	714	0.0293	768	0.0574	677
แรงดันไฟฟ้า กระแสไฟฟ้า	0.0226	830	0.0285	772	0.0322	595
แรงดันไฟฟ้า อุณหภูมิ	0.0328	1040	0.0413	810	0.0347	862
กระแสไฟฟ้า อุณหภูมิ	0.0287	744	0.0297	1558	0.0252	977
แรงดันไฟฟ้า กระแสไฟฟ้า เวลา	0.0307	772	0.0304	943	0.0320	747
แรงดันไฟฟ้า อุณหภูมิ เวลา	0.0408	1067	0.0278	1639	0.0255	1590
กระแสไฟฟ้า อุณหภูมิ เวลา	0.0258	680	0.0228	1558	0.0233	1551
แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ	0.0402	1230	0.0202	988	0.0196	1646
แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา	0.0111	1658	0.0130	1487	0.0188	1763

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.1 แสดงผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% โดยอินพุตที่ใช้เป็นตัวแปรต่างชนิดกัน ซึ่งจะเห็นว่าแบบจำลองสามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพ ในกรณีที่ใช้ตัวแปรอินพุตเพียงชนิดเดียว ข้อมูลของค่ากระแสไฟฟ้าจะให้ผลลัพธ์ที่มีประสิทธิภาพสูงสุด แต่ถ้าเพิ่มความหลากหลายของตัวแปรอินพุตจะยิ่งเพิ่มประสิทธิภาพของแบบจำลอง โดยอินพุต 4 ชนิด ประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลา ให้ผลลัพธ์ที่มีค่า RMSE น้อยที่สุดมีค่า 0.111 แต่ความซับซ้อนในกระบวนการเรียนรู้ของแบบจำลองก็จะเพิ่มมากขึ้นเช่นกันโดยสามารถสังเกตได้จากจำนวนรอบของการเรียนรู้ (Epoch) ที่เพิ่มขึ้น นอกจากนี้แบบจำลองยังสามารถคาดการณ์การกำเนิดใหม่ของความจุได้อีกด้วย

4.1.2 การประมาณสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

ในการประมาณสถานะสุขภาพของแบตเตอรี่ การกำหนดอัตราส่วนระหว่างชุดข้อมูลการเรียนรู้ และชุดข้อมูลทดสอบนับเป็นปัจจัยสำคัญที่ต้องได้รับการประเมินอย่างละเอียดถี่ถ้วน โดยอัตราส่วนดังกล่าวควรพิจารณาจากขนาดและลักษณะเฉพาะของข้อมูล การแบ่งแยกข้อมูลออกเป็นชุดการเรียนรู้และชุดทดสอบถือเป็นขั้นตอนพื้นฐานที่ส่งผลโดยตรงต่อประสิทธิภาพและความน่าเชื่อถือของแบบจำลอง ดังนั้น การทดลองในขั้นต่อไปจึงมุ่งเน้นการหาอัตราส่วนที่เหมาะสมของชุดข้อมูลการเรียนรู้ เพื่อให้แบบจำลองสามารถทำนายผลลัพธ์บนชุดข้อมูลทดสอบได้อย่างมีประสิทธิภาพสูงสุด โดยต้องมั่นใจว่าปริมาณข้อมูลการเรียนรู้ไม่มากเกินไปจนส่งผลกระทบต่อความสามารถในการทำนายข้อมูลใหม่ (generalization ability) วัตถุประสงค์ของการทดสอบแบบจำลองนี้คือการวัดความสามารถในการทำนายข้อมูลที่ไม่เคยพบมาก่อน (unseen data) ซึ่งเป็นตัวชี้วัดสำคัญในการประเมินประสิทธิภาพของแบบจำลอง


การประมาณสถานะสุขภาพจะกำหนดค่า hyperparameters ให้โครงข่ายประสาทเทียมในการเรียนรู้เพื่อสร้างแบบจำลองเป็นโครงสร้างแบบ LSTM 1 ชั้น มี Hidden layer = 200 Neuron batch size เท่ากับ 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ ข้อมูลอินพุต 4 ชนิดที่ประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและเวลาจะให้ผลลัพธ์ที่แม่นยำที่สุดโดยอ้างอิงจากตารางที่ 4.1 โดยจะทำการทดสอบเงื่อนไขละ 3 ครั้ง

รูปที่ 4.12 ถึง 4.15 คือผลการประมาณสถานะสุขภาพแบตเตอรี่ด้วยอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน เส้นสีน้ำเงินแสดงสถานะสุขภาพของแบตเตอรี่ของแบตเตอรี่ B0005 เส้นสีแดงแสดงผลการประมาณสถานะสุขภาพจากแบบจำลอง โดยอัตราส่วนของชุดข้อมูล


- 50 ต่อ 50 เป็นชุดข้อมูลเรียนรู้ 84 รอบใช้งาน ชุดข้อมูลทดสอบ 83 รอบใช้งาน
- 60 ต่อ 40 เป็นชุดข้อมูลเรียนรู้ 100 รอบใช้งาน ชุดข้อมูลทดสอบ 67 รอบใช้งาน
- 70 ต่อ 30 เป็นชุดข้อมูลเรียนรู้ 117 รอบใช้งาน ชุดข้อมูลทดสอบ 50 รอบใช้งาน
- 80 ต่อ 20 เป็นชุดข้อมูลเรียนรู้ 134 รอบใช้งาน ชุดข้อมูลทดสอบ 33 รอบใช้งาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.12 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50




รูปที่ 4.13 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.14 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30



รูปที่ 4.15 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้น 0%
อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.2 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

อัตราส่วนข้อมูล	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
50:50	0.0801	736	0.0711	1231	0.0779	991
60:40	0.0278	1643	0.0365	1687	0.0423	1989
70:30	0.0130	1487	0.0111	1658	0.0188	1763
80:20	0.0071	800	0.0121	1352	0.0128	828

ตารางที่ 4.2 จากผลการประมาณสถานะสุขภาพแบตเตอรี่อัตราส่วนข้อมูลเรียนรู้ที่เพิ่มขึ้นมีผลทำให้ประสิทธิภาพของแบบจำลองสูงขึ้น เช่นเดียวกันกับอัตราส่วนข้อมูลทดสอบที่เพิ่มขึ้นก็ทำให้ประสิทธิภาพของแบบจำลองลดลงเช่นกัน อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20 เมื่อข้อมูลสำหรับเรียนรู้มีปริมาณมากเพียงพอสำหรับข้อมูลทดสอบ ก็จะทำให้ผลลัพธ์ที่มีความแม่นยำสูงในทางตรงกันข้ามที่อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50 เมื่อข้อมูลเรียนรู้มีปริมาณที่จำกัด แต่ข้อมูลทดสอบมีค่ามากเกินไป แบบจำลองสามารถประมาณสถานะได้แม่นยำในช่วงแรกเท่านั้นจากนั้นความแม่นยำก็จะลดลง

4.1.3 การประมาณสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม

การประมาณสถานะสุขภาพเมื่อ SOC เริ่มต้นแบบสุ่มเป็นการจำลองการใช้งานแบตเตอรี่ตามพฤติกรรมการประจุไฟฟ้าให้กับแบตเตอรี่ ไม่ว่าจะเป็นการใช้สมาร์ตโฟน หรือยานยนต์ไฟฟ้า จะเริ่มการประจุไฟฟ้าให้แบตเตอรี่ที่ผ่านการใช้งานอยู่ในช่วง SOC 90-10% และประจุไฟฟ้าไปจนแบตเตอรี่มีพลังงานเกือบเต็มความจุ โดยชุดข้อมูลอินพุตจะเป็นชุดข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและเวลา ที่ซึ่ข้อมูล 20 จุดข้อมูลที่ SOC เริ่มต้นแบบสุ่ม

การประมาณสถานะสุขภาพจะกำหนดค่า hyperparameters ให้โครงข่ายประสาทเทียมในการเรียนรู้เพื่อสร้างแบบจำลองเป็นโครงสร้างแบบ LSTM 1 ชั้น มี Hidden layer = 200 Neuron batch size เท่ากับ 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบเป็น 70 ต่อ 30 และมีค่า SOC เริ่มต้นแบบสุ่ม โดยจะทำการทดสอบเงื่อนไข 3 ครั้ง จากรูปที่ 4.16 ถึง 4.19 เส้นสีน้ำเงินแสดงสถานะสุขภาพของแบตเตอรี่ของแบตเตอรี่ B0005 เส้นสีแดงแสดงผลการประมาณสถานะสุขภาพจากแบบจำลอง


ตัวแปรอินพุตที่จะใช้ในการประมาณสถานะสุขภาพที่ SOC เริ่มต้นแบบสุ่ม จะอ้างอิงถึงตารางที่ 4.1 ซึ่งสามารถวิเคราะห์แนวโน้มของอินพุตที่ส่งผลต่อเอาต์พุต โดยจะเลือกใช้ชุดข้อมูลอินพุตที่ให้ค่าผิดพลาด RMSE น้อยที่สุด ซึ่งจะประกอบไปด้วย

- ชุดข้อมูลอินพุตแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา มีค่า RMSE น้อย 0.0143


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ชุดข้อมูลอินพุตแรงดันไฟฟ้า อุณหภูมิ เวลา มีค่า RMSE เฉลี่ย 0.0240
- ชุดข้อมูลอินพุตแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ มีค่า RMSE เฉลี่ย 0.0267
- ชุดข้อมูลอินพุตแรงดันไฟฟ้า กระแสไฟฟ้า มีค่า RMSE เฉลี่ย 0.0278




รูปที่ 4.16 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา




รูปที่ 4.17 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม

ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า อุณหภูมิ เวลา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.18 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ



รูปที่ 4.19 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุตประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.3 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้นแบบสุ่ม เมื่อตัวแปรอินพุตต่างชนิดกัน

ข้อมูลอินพุต	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลา	0.0198	2274	0.0191	1820	0.0157	1736
กระแสไฟฟ้า อุณหภูมิ เวลา	0.0189	1903	0.0212	2164	0.0245	1787
แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ	0.0417	1924	0.0610	3223	0.0511	3101
แรงดันไฟฟ้า กระแสไฟฟ้า	0.0648	3409	0.0570	2458	0.0708	2751


ตารางที่ 4.3 จากผลลัพธ์การประมาณสถานะสุขภาพของแบตเตอรี่ ที่ SOC เริ่มต้นแบบสุ่มแบบจำลองสามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพเมื่อใช้ตัวแปรอินพุตทั้ง 4 ชนิด คือ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลา ซึ่งมีค่าผิดพลาด RMSE น้อยกว่าอย่างเห็นได้ชัด จากรูปที่ 4.16 จะเห็นได้ว่าค่าที่คาดการณ์แม้จะมีความแม่นยำแต่มีการแกว่งของผลลัพธ์เกิดขึ้น ข้อสังเกตอีกประการคือ การใช้ข้อมูลอินพุตด้วยค่าเวลาสามารถช่วยลดการแกว่งของผลลัพธ์ได้

4.1.4 การประมาณสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

การประมาณสถานะสุขภาพจะกำหนดค่า hyperparameters ให้โครงข่ายประสาทเทียมในการเรียนรู้เพื่อสร้างแบบจำลองเป็นโครงสร้างแบบ LSTM 1 ชั้น มี Hidden layer = 200 Neuron batch size เท่ากับ 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ ข้อมูลอินพุต 4 ชนิดที่ประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิและเวลาจะให้ผลลัพธ์ที่แม่นยำที่สุดโดยอ้างอิงจากรูปที่ 4.3 โดยจะทำการทดสอบเงื่อนไขละ 3 ครั้ง




รูปที่ 4.20 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50




รูปที่ 4.21 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.22 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30



รูปที่ 4.23 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.4 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ B0005 ที่ SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

อัตราส่วนข้อมูล	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
50:50	0.0794	2276	0.0853	2217	0.0906	3234
60:40	0.0601	1410	0.0505	1231	0.0614	1985
70:30	0.0157	1736	0.0191	1820	0.0198	2274
80:20	0.0071	1201	0.0091	2000	0.0094	1827

ตารางที่ 4.4 จากผลลัพธ์การประมาณสถานะสุขภาพของแบตเตอรี่ ที่ SOC เริ่มต้นแบบสุ่ม เมื่อเปรียบเทียบอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบของอินพุต แบบจำลองสามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพมากที่สุดเมื่อมีอัตราส่วนข้อมูล 80:20 และรองลงมาเป็นอัตราส่วน 70:30 ซึ่งจะเห็นได้ว่าค่าที่คาดการณ์มีการแกว่งของผลลัพธ์เกิดขึ้น และการแกว่งของผลลัพธ์จะเพิ่มมากขึ้นเมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบลดลง จึงส่งผลต่อผลลัพธ์ที่คาดการณ์ทำให้มีประสิทธิภาพที่ลดลง

4.2 ผลการประมาณสถานะสุขภาพจากชุดข้อมูลแบตเตอรี่ C

จากผลการประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ทำให้สามารถออกแบบโครงสร้างแบบจำลองหน่วยความจำระยะสั้นแบบยาวที่สามารถใช้ในการประมาณสถานะสุขภาพของแบตเตอรี่ได้อย่างมีประสิทธิภาพ ทั้งในรูปแบบของ SOC เริ่มต้น 0% หรือ SOC เริ่มต้นแบบสุ่ม ทั้งนี้ความแม่นยำในการทำนายผลลัพธ์ก็ขึ้นอยู่กับหลายปัจจัยทั้งในด้านชนิดของตัวแปรที่ใช้ จำนวนข้อมูลที่เรียนรู้ หรือ จำนวนผลลัพธ์ของข้อมูลทดสอบ แต่อีกสิ่งหนึ่งที่น่าสนใจคือชุดข้อมูลแบตเตอรี่ B0005 ที่นำมาจาก NASA Prognostics Center of Excellence Data Repository ถูกสร้างขึ้นในปี 2008 ซึ่งแบตเตอรี่ที่นำมาใช้ทดสอบต้องถูกผลิตขึ้นก่อนหน้านั้น ความแตกต่างของเทคโนโลยีแบตเตอรี่ที่สังเกตได้อย่างชัดเจนคือ ค่าความจุที่ลดลงตามจำนวนรอบการประจุและคายประจุ เมื่อนำมาเปรียบเทียบกันจะเห็นได้ว่าแบตเตอรี่ B0005 เมื่อผ่านกระบวนการประจุและคายประจุ 167 รอบใช้งาน สถานะสุขภาพลดลงเหลือ 70% ในขณะที่แบตเตอรี่ C สถานะสุขภาพคงเหลือถึง 95% เมื่อผ่านจำนวนรอบการประจุและคายประจุที่ 138 รอบใช้งาน ซึ่งหมายความว่าแบตเตอรี่ในยุคปัจจุบันมีเทคโนโลยีในการผลิตแบตเตอรี่ที่สามารถเพิ่มอายุการใช้งานของแบตเตอรี่ได้มากยิ่งขึ้น


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2.1 การประมาณสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้น 0% เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

ในการทดสอบต่อไปนี้จะใช้โครงสร้างแบบจำลองที่ได้จากแบตเตอรี่ B0005 มาใช้ในการประมาณสถานะสุขภาพของแบตเตอรี่ C โดยการเปลี่ยนชุดข้อมูลเรียนรู้ของแบบจำลองเป็นชุดข้อมูลแบตเตอรี่ C ชุดข้อมูลอินพุตจะเป็นชุดข้อมูลโพรไฟล์ประจุไฟฟ้าประกอบด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า และเวลาที่ซีกข้อมูล 20 จุดข้อมูลด้วยค่า SOC เริ่มต้น 0%


การประมาณสถานะสุขภาพจะกำหนดค่า hyperparameters ให้โครงข่ายประสาทเทียมในการเรียนรู้เพื่อสร้างแบบจำลองเป็นโครงข่ายแบบ LSTM 1 ชั้น มี Hidden layer = 200 Neuron batch size เท่ากับ 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ ข้อมูลอินพุต 3 ชนิดที่ประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้าและเวลา โดยอัตราส่วนของชุดข้อมูล

- 50 ต่อ 50 เป็นชุดข้อมูลเรียนรู้ 69 รอบใช้งาน ชุดข้อมูลทดสอบ 69 รอบใช้งาน
- 60 ต่อ 40 เป็นชุดข้อมูลเรียนรู้ 83 รอบใช้งาน ชุดข้อมูลทดสอบ 55 รอบใช้งาน
- 70 ต่อ 30 เป็นชุดข้อมูลเรียนรู้ 97 รอบใช้งาน ชุดข้อมูลทดสอบ 41 รอบใช้งาน
- 80 ต่อ 20 เป็นชุดข้อมูลเรียนรู้ 110 รอบใช้งาน ชุดข้อมูลทดสอบ 28 รอบใช้งาน




รูปที่ 4.24 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0%
อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.25 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40



รูปที่ 4.26 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0% อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.27 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้น 0%
อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20

ตารางที่ 4.5 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ C ที่ SOC เริ่มต้น 0%
เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

อัตราส่วนของชุด ข้อมูลการเรียนรู้ต่อ การทดสอบ	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
50:50	0.1065	2946	0.1656	2594	0.1830	2825
60:40	0.0418	2791	0.0586	2857	0.0554	2984
70:30	0.0454	3340	0.0551	3958	0.0361	3202
80:20	0.0399	3623	0.0355	3323	0.0305	3094


ตารางที่ 4.5 จากผลการประมาณสถานะสุขภาพแบตเตอรี่ที่ SOC เริ่มต้น 0% แบบจำลองสามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพเมื่อข้อมูลอินพุตมีอัตราส่วนข้อมูลเรียนรู้อยู่ในช่วง 60-80 ในส่วนของอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50 แบบจำลองสามารถคาดการณ์ได้แม่นยำในช่วงแรกและความแม่นยำจะลดลงในรอบเมื่อข้อมูลทดสอบเพิ่มมากขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


4.2.2 การประมาณสถานะสุขภาพแบตเตอรี่ด้วยค่า SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

การทดสอบนี้เพื่อจำลองการประจุไฟฟ้าให้แบตเตอรี่ตามพฤติกรรมการใช้งานตามปกติด้วยค่า SOC เริ่มต้นแบบสุ่มมาใช้ในการประมาณสถานะสุขภาพของแบตเตอรี่ C โดย ชุดข้อมูลอินพุตจะเป็นชุดข้อมูลโพรไฟล์ประจุไฟฟ้าประกอบด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า และเวลา ที่ชักข้อมูล 20 จุดข้อมูลด้วยค่า SOC เริ่มต้นแบบสุ่ม


การประมาณสถานะจะกำหนดด้วยเงื่อนไขการทดสอบเดียวกัน คือ Hidden layer = 200 batch size = 10 ใช้ฟังก์ชัน EarlyStopping ในการสิ้นสุดการเรียนรู้ ข้อมูลอินพุต 3 ชนิดที่ประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้า และเวลา โดยจะทำการทดสอบเงื่อนไขละ 3 ครั้ง



รูปที่ 4.28 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม
อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 50:50




รูปที่ 4.29 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 60:40



รูปที่ 4.30 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.31 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ค่า SOC เริ่มต้นแบบสุ่ม อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20

ตารางที่ 4.6 ผลการประมาณสถานะสุขภาพชุดข้อมูลแบตเตอรี่ C ที่ SOC เริ่มต้นแบบสุ่ม เมื่ออัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบแตกต่างกัน

อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ	ครั้งที่ 1		ครั้งที่ 2		ครั้งที่ 3	
	RMSE	Epoch	RMSE	Epoch	RMSE	Epoch
50:50	0.1983	3327	0.2087	3299	0.1762	3361
60:40	0.1085	2793	0.1145	2520	0.1196	2239
70:30	0.0782	2884	0.0862	3190	0.0859	3271
80:20	0.0737	3705	0.0616	3825	0.0637	3679

ตารางที่ 4.6 จากผลการประมาณสถานะสุขภาพแบตเตอรี่ที่ SOC เริ่มต้นแบบสุ่ม การประมาณสถานะสุขภาพที่แม่นยำที่สุดต้องใช้ข้อมูลอินพุต ที่มีอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบถึง 80:20 โดยที่ค่า RMSE ที่น้อยที่สุดมีค่า 0.0616 ซึ่งถือว่ายังมีค่าผิดพลาดอยู่มาก เนื่องจากเกิดการแกว่งขึ้นของผลลัพธ์ โดยค่าความผิดพลาดสูงสุด (maximum point error) เมื่อพิจารณาจากค่าความจริงกับค่าความจุที่ได้จากการประมาณในแต่ละรอบใช้งานมีค่า 0.1485 Ah ซึ่งคิดเป็น 1.04% โดยตารางที่ 4.7 จะแสดงค่าความผิดพลาดสูงสุดในแต่ละรอบการทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.7 ค่าผิดพลาดสูงสุดของผลการประมาณสถานะสุขภาพข้อมูลแบบเตอร์รี C ที่ SOC เริ่มต้นแบบสุ่ม

อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ	ค่าความผิดพลาดสูงสุด	
	(Ah)	%
50:50	0.3429	2.39
60:40	0.2328	1.62
70:30	0.1784	1.24
80:20	0.1485	1.04

จากตารางที่ 4.7 พิจารณาจากผลลัพธ์การประมาณสถานะสุขภาพที่ให้ค่า RMSE น้อยที่สุดในแต่ละรอบการทดสอบ ค่าความผิดพลาดสูงสุดจากอัตราส่วนข้อมูลเรียนรู้ต่อการทดสอบ 50:50 มีค่าความผิดพลาดสูงสุดมากที่สุดถึง 2.39% ซึ่งแสดงรูปที่ 4.28 ค่าผิดพลาดที่เกิดขึ้นอาจเกิดขึ้นได้จากอัตราส่วนข้อมูลเรียนรู้ที่น้อยเกินไป เมื่อเปรียบเทียบกับอัตราส่วนข้อมูลเรียนรู้ต่อการทดสอบ 60:40 ที่มีผลลัพธ์ในบางรอบใช้งานสามารถประมาณสถานะได้แม่นยำ มีค่าความผิดพลาดสูงสุดที่ลดลงเหลือ 1.62% แต่เนื่องจากเกิดการแกว่งขึ้นของผลลัพธ์จึงทำให้ยังมีค่าผิดพลาดอยู่มากดังแสดงดังรูปที่ 4.29 เช่นเดียวกันกับผลการประมาณสถานะสุขภาพที่อัตราส่วนข้อมูลเรียนรู้ต่อการทดสอบ 70:30 มีค่าความผิดพลาดสูงสุด 1.24% และมีการแกว่งของผลลัพธ์ลดลง ดังแสดงดังรูปที่ 4.29

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สรุปผลการทดสอบ และข้อเสนอแนะ

5.1 สรุปผลการทดสอบ

วิทยานิพนธ์เล่มนี้นำเสนอวิธีการประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออนผ่านโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (LSTM) ด้วยวิธีขับเคลื่อนเชิงข้อมูล (Data-driven) ในวิทยานิพนธ์นี้จะใช้ภาษาโปรแกรม Python และ Library tensorflow.keras ในการสร้างแบบจำลองสถานะสุขภาพแบตเตอรี่ โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวเป็นแบบ 1 ชั้น ประกอบด้วยเซลล์ประสาท 200 เซลล์ (Hidden Layer 200) ทำการเรียนรู้และทดสอบข้อมูลด้วยชุดข้อมูลแบตเตอรี่ B0005 ซึ่งเป็นชุดข้อมูลจาก NASA และแบตเตอรี่ C ซึ่งเป็นชุดข้อมูลที่ได้จัดทำขึ้น จากผลการทดสอบโดยพิจารณาปัจจัยที่แตกต่างกัน ประกอบด้วย ประเภทของตัวแปรอินพุต อัตราส่วนข้อมูลการเรียนรู้ต่อข้อมูลทดสอบ เงื่อนไขค่า SOC (State of Charge) ที่เริ่มต้น 0% และแบบสุ่ม และการทดสอบกับแบตเตอรี่ที่ต่างรุ่นกัน

การประมาณสถานะสุขภาพของแบตเตอรี่ B0005 ที่ SOC เริ่มต้น 0% ตัวแปรอินพุตเดียวที่ให้ผลลัพธ์มีประสิทธิภาพสูงสุดคือ กระแสไฟฟ้า ซึ่งมีค่า RMSE ต่ำที่สุดเฉลี่ย 0.0342 ส่วนตัวแปรอินพุต 4 ชนิดประกอบด้วย แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลาจะให้ประสิทธิภาพสูงสุด ซึ่งมีค่า RMSE ต่ำที่สุดเฉลี่ย 0.0143 แต่จะใช้จำนวนรอบในการเรียนรู้ (Epoch) มากที่สุดเนื่องจากข้อมูลมีความซับซ้อนมากขึ้น ซึ่งบ่งบอกถึงเพิ่มความหลากหลายของชนิดข้อมูลสามารถเพิ่มประสิทธิภาพให้แบบจำลองได้ อัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20 ให้ผลลัพธ์แม่นยำที่สุดเนื่องจากข้อมูลสำหรับการเรียนรู้มีปริมาณเพียงพอ ในทางตรงกันข้ามอัตราส่วน 50:50 ให้ผลลัพธ์แม่นยำน้อยที่สุด เนื่องจากข้อมูลสำหรับการเรียนรู้ไม่เพียงพอให้แบบจำลองวิเคราะห์ความสัมพันธ์และมีความแม่นยำลดลงเมื่อมีข้อมูลทดสอบเพิ่มขึ้น ในส่วนของการกำเนิดใหม่ของความจุแบบจำลองยังสามารถคาดการณ์ได้อย่างถูกต้อง ในขณะที่ SOC เริ่มต้นแบบสุ่ม แบบจำลองสามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพซึ่งต้องใช้ตัวแปรอินพุต 4 ชนิด จึงจะให้ประสิทธิภาพสูงสุด แต่เกิดการแกว่งของผลลัพธ์ขึ้น โดยการเพิ่มอัตราส่วนข้อมูลการเรียนรู้สามารถช่วยลดการแกว่งของผลลัพธ์ได้

การประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ SOC เริ่มต้น 0% แบบจำลองสถานะสุขภาพที่มีต้นแบบจากแบตเตอรี่ B0005 สามารถนำมาใช้กับแบตเตอรี่ C ได้ แต่มีประสิทธิผลลดลงเล็กน้อย เนื่องจากข้อมูลแบตเตอรี่ B0005 แสดงการเสื่อมสภาพชัดเจน สถานะสุขภาพลดลงเหลือ 70% หลังผ่าน 167 รอบใช้งาน ส่วนแบตเตอรี่ C สถานะสุขภาพลดลงเพียง 95% หลังผ่าน 138 รอบใช้งาน ซึ่งผลการประมาณสถานะสุขภาพจากอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 70:30

และ 80:20 ให้ผลลัพธ์ที่แม่นยำมากที่สุด โดยอัตราส่วน 50:50 ให้ผลลัพธ์ที่แม่นยำอยู่ในช่วง 10 รอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำมาใช้เพื่อประโยชน์ทางการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ใช้งาน และความแม่นยำลดลงเมื่อข้อมูลทดสอบเพิ่มขึ้น ส่วน SOC เริ่มต้นแบบสุ่ม แบบจำลองสามารถประมาณสถานะได้ในอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบ 80:20 ให้ผลลัพธ์แม่นยำที่สุด แต่เกิดข้อผิดพลาดเนื่องจากการแกว่งของผลลัพธ์ ซึ่งอาจเกิดขึ้นได้จากหลายปัจจัยเช่น การเสื่อมสภาพของแบตเตอรี่ C ยังไม่แสดงการเสื่อมสภาพอย่างชัดเจนหลังจากผ่านรอบใช้งาน 138 รอบ สถานะสุขภาพยังมากกว่า 95% ซึ่งข้อมูลการเปลี่ยนแปลงของอินพุตและเอาต์พุตนี้อาจไม่เพียงพอให้แบบจำลองเรียนรู้ความสัมพันธ์ได้ หรือการเพิ่มความหลากหลายของข้อมูลอินพุตเช่น อุณหภูมิ เพื่อให้แบบจำลองเกิดการเรียนรู้ได้มากขึ้น จากแนวโน้มของเทคโนโลยีของแบตเตอรี่ที่มีอายุการใช้งานที่นานขึ้น อาจทำให้ต้องใช้ระยะเวลาในการเตรียมชุดข้อมูล (Dataset) ที่ยาวนานขึ้น สำหรับการใช้เทคนิคการขับเคลื่อนด้วยข้อมูล การประสมเทคนิคการประมาณเชิงโมเดลร่วมกับเทคนิคการขับเคลื่อนด้วยข้อมูลอาจช่วยลดระยะเวลาในการเตรียมชุดข้อมูลและเพิ่มความแม่นยำในการประมาณสถานะสุขภาพก็เป็นไปได้

จากผลการทดสอบทั้งหมดนี้แสดงให้เห็นว่า แบบจำลองหน่วยความจำระยะสั้นแบบยาวสามารถประมาณสถานะสุขภาพของแบตเตอรี่ได้อย่างมีประสิทธิภาพในกรณีที่ SOC เริ่มต้นเป็น 0 โดยเฉพาะเมื่อใช้ตัวแปรอินพุตครบถ้วนและอัตราส่วนข้อมูลการเรียนรู้ที่เหมาะสม อย่างไรก็ตามการนำไปใช้งานจริงควรพิจารณาปรับปรุงแบบจำลองเพื่อเพิ่มความเสถียรและลดความคลาดเคลื่อนในสถานะ SOC เริ่มต้นแบบสุ่ม ผลการทดสอบนี้สามารถเป็นแนวทางสำหรับการพัฒนา ระบบตรวจสอบสภาพแบตเตอรี่ในอุตสาหกรรมยานยนต์ไฟฟ้าและอุปกรณ์อิเล็กทรอนิกส์ เพื่อยืดอายุการใช้งานและเพิ่มความปลอดภัยได้


5.2 วิเคราะห์ปัญหา

ประเด็นที่อาจส่งผลให้ผลลัพธ์เกิดการแกว่ง และแบบจำลองไม่สามารถหาความสัมพันธ์ระหว่างข้อมูลได้ นั่นคือการเลือกช่วงเวลาสุ่ม ซึ่งชุดข้อมูลที่ได้จะสุ่มข้อมูลเริ่มต้น อยู่ในช่วง 0-5000 วินาที ในการสุ่มจุดข้อมูลเริ่มต้นในบางรอบการใช้งานอาจสุ่มจุดข้อมูลแรก เป็นจุดข้อมูลที่เข้าใกล้ 5000 วินาที ดังเช่นชุดข้อมูลในรูป 5.1 ในขณะที่รูปที่ 5.2 จะสังเกตเห็นว่าเส้นสีเหลือง คือชุดข้อมูล SOC เริ่มต้นแบบสุ่ม 20 จุดข้อมูล รอบการประจุไฟฟ้าที่ 1 จะมีช่วงของเวลาของข้อมูลน้อย ข้อมูลกระแสไฟฟ้าที่ได้เป็นช่วงที่การประจุไฟฟ้าใกล้เปลี่ยนจากสถานะกระแสคงที่เป็นแรงดันคงที่และทำการลดกระแสเมื่อแบตเตอรี่ใกล้เต็มและเมื่อเข้าสู่สถานะแรงดันคงที่ เมื่อเปรียบเทียบช่วงประจุไฟฟ้าที่กระแสต่ำ รอบการประจุไฟฟ้าที่ 1 จนถึงรอบที่ 135 การเปลี่ยนแปลงของข้อมูลก็ใช้เวลาแตกต่างกันเพียงเล็กน้อย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 5.1 ชุดข้อมูลกระแสแบตเตอรี่ C



รูปที่ 5.2 กราฟข้อมูลกระแสไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้นแบบสุ่ม

ชุดข้อมูลแรงดันรูปที่ 5.3 ก็เป็นลักษณะเช่นเดียวกันกับชุดข้อมูลกระแส ถ้าจุดเริ่มต้นในการสุ่มของแต่ละรอบการใช้งาน อยู่ที่ SOC เริ่มต้นเกิน 60% ชุดข้อมูลที่ได้ จะมีลักษณะเดียวกันกับชุดข้อมูลกระแสที่รอบการประจุที่ 1 รูปที่ 5.4 จะสังเกตได้ว่าเส้นสีเหลือง คือชุดข้อมูล SOC เริ่มต้นแบบสุ่ม 20 จุดข้อมูล ของรอบการประจุที่ 1 จะมีช่วงของเวลาของข้อมูลน้อย ซึ่งประมาณครึ่งหนึ่งของเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลจะอยู่ในช่วงแรงดันคงที่ ซึ่งจะเป็นค่าใกล้เคียงกันที่ 4.2V และถ้าสังเกตจุดข้อมูลแรงดัน จะพบว่าในรอบประจุไฟฟ้า รอบที่ 1 ถึง 135 ระยะเวลาและค่าแรงดันขณะประจุไฟฟ้าก่อนเข้าสู่สถานะแรงดันคงที่มีค่าแทบไม่แตกต่างกัน เนื่องจากค่าความจุที่ลดลงเล็กน้อย

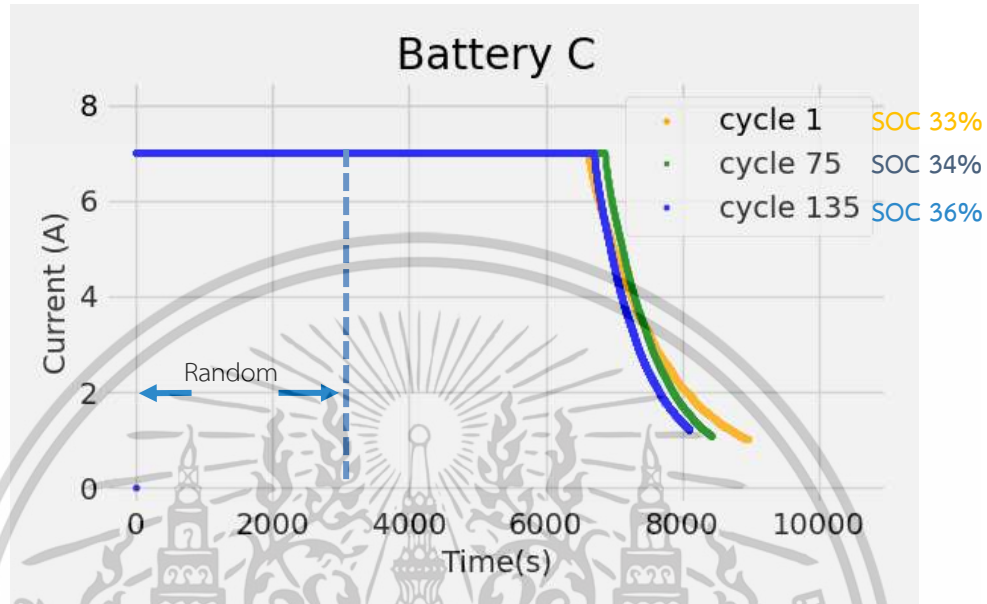


รูปที่ 5.3 ชุดข้อมูลแรงดันแบตเตอรี่ C


รูปที่ 5.4 กราฟข้อมูลแรงดันไฟฟ้า 20 จุดข้อมูลในแต่ละรอบการประจุของแบตเตอรี่ C
มีค่า SOC เริ่มต้นแบบสุ่ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทำการปรับช่วงเวลาในการสุ่มจุดข้อมูลแรกให้อยู่ในช่วง 0-2500 วินาที เพื่อให้ได้ชุดข้อมูลที่มีข้อมูลอยู่ในช่วงสถานะกระแสคงที่มากขึ้น ข้อมูลในแต่ละรอบการใช้งาน จะสุ่มจุดข้อมูลแรกอยู่ในช่วง 0-35% SOC




รูปที่ 5.5 ช่วงเวลาในการสุ่มจุดข้อมูลแรกของข้อมูลกระแสไฟฟ้า




รูปที่ 5.6 ช่วงเวลาในการสุ่มจุดข้อมูลแรกของข้อมูลแรงดันไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เงื่อนไขการทดสอบข้อมูลอินพุตประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้าและเวลา อัตราส่วนข้อมูลเรียนรู้ต่อข้อมูลทดสอบ 70:30 รูปที่ 5.7 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่ม ช่วง 0-65% SOC ผลลัพธ์มีค่า RMSE เท่ากับ 0.0782 ในขณะที่รูปที่ 5.8 จุดสุ่มข้อมูลจุดแรกช่วง 0-35% SOC ผลลัพธ์มีค่า RMSE เท่ากับ 0.0627 จากผลลัพธ์จะเห็นว่าผลการประมาณสถานะมีค่าแม่นยำมากขึ้นเล็กน้อย ซึ่งยังพบการแกว่งของข้อมูลในบางช่วง




รูปที่ 5.7 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-65% SOC




รูปที่ 5.8 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-35% SOC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เงื่อนไขการทดสอบข้อมูลอินพุตประกอบด้วยแรงดันไฟฟ้า กระแสไฟฟ้าและเวลา อัตราส่วน ข้อมูลเรียนรู้ต่อข้อมูลทดสอบ 80:20 รูปที่ 5.9 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่ม ช่วง 0-65% SOC ผลลัพธ์มีค่า RMSE เท่ากับ 0.0616 ในขณะที่รูปที่ 5.10 จุดสุ่มข้อมูลจุดแรกช่วง 0-35% SOC ผลลัพธ์มีค่า RMSE เท่ากับ 0.0525 จากผลลัพธ์จะเห็นว่า ผลการประมาณสถานะมีค่าแม่นยำมากขึ้นเล็กน้อย ซึ่งยังพบการแกว่งของข้อมูลในบางช่วง



รูปที่ 5.9 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-65% SOC



รูปที่ 5.10 ผลการประมาณสถานะสุขภาพ ที่ SOC เริ่มต้นแบบสุ่มช่วง 0-35% SOC

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการประมาณสถานะสุขภาพของแบตเตอรี่ C ที่ SOC เริ่มต้นแบบสุ่ม อัตราส่วนข้อมูลเรียนรู้ต่อข้อมูลทดสอบ 80:20 และ 70:30 ผลลัพธ์มีความแม่นยำขึ้นเล็กน้อยและยังเกิดการแกว่งของข้อมูลขึ้น ซึ่งแนวทางแก้ไขด้วยการลดช่วงจุดสุ่มข้อมูลจุดแรกของ SOC นี้จะช่วยเพิ่มความแม่นยำได้เล็กน้อย แต่ก็ยังไม่ใช่ทางแก้ปัญหาที่ให้ผลลัพธ์ที่ดีที่สุด การประมาณสถานะสุขภาพด้วยวิธีการขับเคลื่อนเชิงข้อมูลเพื่อให้แบบจำลองสามารถวิเคราะห์หาความสัมพันธ์ระหว่างตัวแปรอินพุตและเอาต์พุต การมีปริมาณของชุดข้อมูลที่เหมาะสมก็อาจเป็นสิ่งจำเป็นในการเพิ่มประสิทธิภาพประมาณสถานะสุขภาพ

5.3 ข้อเสนอแนะ

การประมาณสถานะสุขภาพของแบตเตอรี่ในวิทยานิพนธ์เล่มนี้มีข้อจำกัดจากการใช้ชุดข้อมูลแบตเตอรี่ที่ได้จากห้องปฏิบัติการ ในการประยุกต์ใช้งานเชิงเทคนิคและเชิงปฏิบัติ เพื่อการพัฒนาสู่ระบบตรวจสอบแบตเตอรี่แบบเรียลไทม์และการใช้งานในอุตสาหกรรมยานยนต์ไฟฟ้า ควรมีการทดสอบแบบจำลองกับแบตเตอรี่ที่ใช้งานจริงในสภาพแวดล้อมต่างๆ เช่น ในรถไฟฟ้หรือระบบกักเก็บพลังงานแสงอาทิตย์ เพื่อยืนยันถึงประสิทธิภาพของแบบจำลองภายใต้สภาวะที่ไม่แน่นอน

เอกสารอ้างอิง

- [1] Antong Xiao and Wenhong Liu. “Review of SOH prediction methods for lithium-ion batteries” **2024 7th Asia Conference on Energy and Electrical Engineering (ACEEE)**, pp. 285-289, 2024.
- [2] Lingzhi Su, Yan Xu and Zhaoyang Dong. “State-of-health estimation of lithium-ion batteries: A comprehensive literature review from cell to pack levels” **Energy Conversion and Economics**, pp. 224-242, 2024.
- [3] Quan Liu, Min Zheng and Peike Li. “A Review of Data-Driven SOH and RUL Estimation for Lithium-ion Batteries” **Proceedings of the 42nd Chinese Control Conference**, pp. 8769-8774, 2023.
- [4] Monolithai. “How does a lithium-ion battery work? Exploring technological advancements.” [Online]. Available : <https://www.monolithai.com/blog/how-does-a-lithium-ion-battery-work>
- [5] Murata. “Part 1: What are lithium-ion batteries? An expert describes their mechanism and characteristics..” [Online]. Available : <https://article.murata.com/en-global/article/basic-lithium-ion-battery-1>
- [6] Srikar Ravi, P.G.V. Koushik, V.Chetan Krishna Varma and S.Rajeswari. “Li-ion Batteries SoH Estimation Using LSTM” **2022 6th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS)**, 2022.
- [7] Jeff Dunn and Cong-Sheng Huang. “A P-value Approach for Real-time Identifying the Capacity Regeneration Phenomenon of Lithium-ion Batteries” **2023 IEEE 3rd International Conference on Industrial Electronics for Sustainable Energy Systems (IESES)**, 2023.
- [8] Gmssolar. “ค่า SoC และ SoH ของแบตเตอรี่คืออะไร พร้อมวิธีคำนวณ” [Online]. Available : <https://www.gmssolar.com/soc-soh-battery/>
- [9] Ghufron Fathoni, Sigit Agung Widayat, Paris Ali Topan, Abdul Jalil, Adha Imam Cahyadi and Oyas Wahyungoro. “Comparison of State-of-Charge (SOC) Estimation Performance Based on three Popular Methods: Coulomb Counting, Open Circuit Voltage, and Kalman Filter” **2017 2nd International Conference on Automation, Cognitive Science, Optics, Micro Electro-Mechanical System, and Information Technology (ICACOMIT)**, pp. 70-74, 2017.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [10] Amazon Web Services. “ปัญญาประดิษฐ์ (AI) คืออะไร.” [Online]. Available : <https://aws.amazon.com/th/what-is/artificial-intelligence/>
- [11] Cyber Elite. “Machine Learning เทคโนโลยีประโยชน์ครบจักรวาล.” [Online]. Available : <https://www.cyberelite.co.th/blog/machine-learning/>
- [12] หน.วิเคราะห์และพัฒนาระบบฯ กสทช.ฯ. “AI / ML / DL คืออะไร? ต่างกันอย่างไร?” [Online]. Available : <https://www.oncblog.navy.mi.th/dev-it/727/>
- [13] Chang Sim Vui, Gan Kim Soon, Chin Kim On, and Rayner Alfred. “A Review of Stock Market Prediction with Artificial Neural Network (ANN)” **2013 IEEE International Conference on Control System, Computing and Engineering**, pp. 447-482, 2013.
- [14] CSTOPICS. “Single-Layer Perceptrons.” [Online]. Available : <https://cstopics.com/books/artificial-intelligence/05-neural-networks/02-single-layer-perceptrons/>
- [15] ธนาวุฒิ ประกอบผล. “โครงข่ายประสาทเทียม Artificial Neural Networks” วารสารวิชาการ, ปีที่ 12 ฉบับที่ 24, หน้า 73-87, 2552.
- [16] Amazon Web Services. “RNN (นิเวศน์เน็ตเวิร์กแบบวนกลับ) คืออะไร.” [Online]. Available : <https://aws.amazon.com/th/what-is/recurrent-neural-network/>
- [17] Sirawich Smithsomboon. “สรุปความเข้าใจ RNN, LSTM, GRU (24/10/2020).” [Online]. Available : <https://sirawich99.medium.com/-rnn-lstm-gru-24-10-2020-95602afe3053>
- [18] JIANTAO QU, FENG LIU, YUXIANG MA, and JIAMING FAN. “A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery” **IEEE Access**, Volume: 7, pp. 87178-87191, 2019.
- [19] Cathrine Jeeva. “Introduction to Recurrent Neural Network (RNN).” [Online]. Available : <https://www.scaler.com/topics/deep-learning/rnn/#topic-challenge-container-463188>
- [20] Amazon Web Services. “Python คืออะไร.” [Online]. Available : <https://aws.amazon.com/th/what-is/python/>
- [21] B. Saha and K. Goebel, “Battery Data Set,” NASA Ames Prognostics Data Repository, (<https://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>), 2007.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [22] นมิดา แก้วสวัสดิ์, นฤมล ตลกุล, พีรตน์ รากแก่น, ภาวิณี กุลกิตต์วิริยะ. “การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียม” **ปริญญาพันธวิศวกรรมศาสตร์บัณฑิต**, ภาควิชาวิศวกรรมไฟฟ้า, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง, 2567.
- [23] มหาวิทยาลัยราชภัฏนครปฐม. “**บทที่ 8 สหสัมพันธ์และการวิเคราะห์การถดถอย.**” [Online]. Available : <http://pws.npru.ac.th/chalida/data/files/บทที่8สหสัมพันธ์และการถดถอย.pdf>
- [24] Thomas Franke and Josef F. Krems. “Understanding charging behaviour of electric vehicle users” **Transportation Research Part F Traffic Psychology and Behaviour**, pp. 75-89, 2013.
- [25] KYUNGNAM PARK, YOHWAN CHOI, WON JAE CHOI, HEE-YEON RYU and HONGSEOK KIM. “LSTM-Based Battery Remaining Useful Life Prediction With Multi-Channel Charging Profiles” **Transportation Research Part F Traffic Psychology and Behaviour, IEEE Access**, Volume: 8, pp. 20786-20798, 2020.
- [26] Suqin Yuan, Lei Feng and Tongliang Liu. “EARLYSTOPPING AGAINST LABEL NOISE WITHOUT VALIDATION DATA” **Published as a conference paper at ICLR 2024**, pp. 1-21, 2024.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




การประชุมวิชาการ ทางวิศวกรรมไฟฟ้า ครั้งที่ 47

THE 47th ELECTRICAL ENGINEERING CONFERENCE (EECON-47)

สมาคมวิชาการทางวิศวกรรมไฟฟ้า (ประเทศไทย)

ร่วมกับมหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์

วันที่ 13 - 15 พฤศจิกายน 2567 ณ โรงแรมเซ็นทาราและคอนเวนชันเซ็นเตอร์ อุดรธานี

CALL FOR PAPERS



การเผยแพร่บทความ

บทความที่ผ่านการพิจารณาได้รับการเผยแพร่ในหนังสือรวมเล่มผลงานวิจัย จากการประชุมวิชาการ(Proceeding)ของงาน EECON-47 บทความที่ผ่านการพิจารณา ผู้เขียนอย่างน้อย 1 คน ต้องลงทะเบียน และนำเสนอผลงานในที่ ประชุมวิชาการตามตารางเวลาที่กำหนด

การประชุมวิชาการทางวิศวกรรมไฟฟ้า

เป็นการประชุมวิชาการระดับชาติที่มีมาตรฐานทางวิชาการเป็นที่ยอมรับในระดับสากล มีวัตถุประสงค์เพื่อให้คณาจารย์ นิสิต นักศึกษา นักวิจัย รวมถึงวิศวกรและผู้ปฏิบัติงานในสาขาวิศวกรรมไฟฟ้า และสาขาวิศวกรรมด้านอื่น ๆ ที่เกี่ยวข้องจากสถาบันการศึกษา และหน่วยงานต่าง ๆ ทั้งจากส่วนภาครัฐและเอกชนได้ นำเสนอผลงานวิจัยรวมทั้งได้ มีโอกาสแลกเปลี่ยนความคิดเห็นทางด้านงานวิจัย และประสบการณ์ ระหว่างกัน การประชุมวิชาการทางวิศวกรรมไฟฟ้า

ดำเนินการโดยคณะกรรมการจัดการประชุมวิชาการทางวิศวกรรมไฟฟ้า ประกอบด้วย คณะกรรมการสภาวิชาการวิศวกรรมไฟฟ้า ผู้แทนจากสถาบันกรรมการสามัญ ผู้แทนจากสถาบันกรรมการสมทบ และคณะกรรมการดำเนินการจัดการประชุม จากสถาบันที่ได้รับเกียรติให้เป็นเจ้าภาพในแต่ละปี โดยการประชุมวิชาการทางวิศวกรรมไฟฟ้าจัดขึ้นทุกปีตั้งแต่ปี พ.ศ. 2521 เป็นต้นมา

ในปี พ.ศ. 2567 มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์ ได้รับเกียรติเป็นเจ้าภาพจัดการประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47 ซึ่งมหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์รับรองการก่อตั้ง20ปี

คณะกรรมการจัดงานประชุมวิชาการ

- กรรมการสภาวิชาการทางวิศวกรรมไฟฟ้าแห่งประเทศไทย**
- ศาสตราจารย์ ดร.โทสินทร์ จ้างงไทย
 - มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี
 - ศาสตราจารย์ ดร.ประยูกร อัครเอกฉนวน
 - มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
 - ศาสตราจารย์ ดร.อภิรัฐ ศิริธราวิฑิต
 - มหาวิทยาลัยขอนแก่น
 - รองศาสตราจารย์ ดร.ชัยวัฒน์ ธีตฤกษ์
 - สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
 - ผู้ช่วยศาสตราจารย์ ดร.อริคม กุศลบุตร
 - มหาวิทยาลัยเทคโนโลยีมหานคร
 - ผู้ช่วยศาสตราจารย์ ดร.สมชัย ศรีญวโรดม
 - มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
 - ผู้ช่วยศาสตราจารย์ เดชา วัลรัตน์
 - มหาวิทยาลัยมหิดล
 - ผู้ช่วยศาสตราจารย์ พิษัง เกฬาสาร
 - มหาวิทยาลัยศรีนครินทรวิโรฒ
 - อาจารย์ ธนวิญญู ชูสีภาวิทย์
 - มหาวิทยาลัยเชียงใหม่

สาขาบทความ

- ไฟฟ้ากำลัง (PW)
- ระบบควบคุมและการวัดคุม (CT)
- ไฟฟ้าสื่อสาร (CM)
- การประมวลผลสัญญาณ ดิจิตอล (DS)
- อิเล็กทรอนิกส์กำลัง (PE)
- วิศวกรรมอัจฉริยะ (SI)
- ไฟโตอิเล็กทรอนิกส์ (PH)
- งานวิจัยที่เกี่ยวข้องกับวิศวกรรมไฟฟ้า (GN)
- อิเล็กทรอนิกส์ (EL)
- คอมพิวเตอร์และเทคโนโลยีสารสนเทศ (CP)
- พลังงานทดแทน (RE)
- วิศวกรรมชีวการแพทย์ (BE)

กำหนดการส่งบทความ

26 กรกฎาคม 2567	26 สิงหาคม 2567	9 กันยายน 2567	11 ตุลาคม 2567
หมดเขตรับบทความ	แจ้งผลการพิจารณาบทความ	หมดเขตรับบทความฉบับสมบูรณ์	วันสุดท้ายของการลงทะเบียนของผู้นำเสนอบทความ

สถาบันกรรมการสามัญ

- จุฬาลงกรณ์มหาวิทยาลัย
- มหาวิทยาลัยกรุงเทพ
- มหาวิทยาลัยเกษตรศาสตร์
- มหาวิทยาลัยเกษตรศาสตร์
- มหาวิทยาลัยขอนแก่น
- มหาวิทยาลัยเชียงใหม่
- มหาวิทยาลัยเทคโนโลยีมหานคร
- มหาวิทยาลัยเอเซียอาคเนย์
- มหาวิทยาลัยสงขลานครินทร์
- มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี
- มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ
- มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
- ศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ
- สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

- มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
- มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
- มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์
- มหาวิทยาลัยพะเยา
- มหาวิทยาลัยรังสิต
- มหาวิทยาลัยอุบลราชธานี
- มหาวิทยาลัยศิลปากร
- มหาวิทยาลัยหอการค้าไทย
- มหาวิทยาลัยอีสเทิร์นเอเชีย
- มหาวิทยาลัยศรีปทุม
- มหาวิทยาลัยศรีนครินทรวิโรฒ
- มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ
- มหาวิทยาลัยเทคโนโลยีจิดจระหวง
- มหาวิทยาลัยสยาม
- มหาวิทยาลัยเทคโนโลยีสุรนารี
- มหาวิทยาลัยอัสสัมชัญ
- มหาวิทยาลัยธรรมศาสตร์
- มหาวิทยาลัยธุรกิจบัณฑิตย์
- มหาวิทยาลัยเนเรวอร์
- มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
- มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์
- มหาวิทยาลัยมหิดล

ติดต่อสอบถามข้อมูล

คณะวิศวกรรมศาสตร์
มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์

อาจารย์สุธี รุขพันธ์
โทร 081 - 199 - 5948

96 หมู่ 3 ถนน พุทรมณฑล สาย 5 ต.ศาลายา
อ.พุทธมณฑล จ.นครปฐม 73170



สถาบันกรรมการสมทบ

- มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย
- มหาวิทยาลัยราชภัฏนครปฐม
- มหาวิทยาลัยราชภัฏบ้านสมเด็จเจ้าพระยา
- สถาบันการอาชีวศึกษาภาคกลาง 1





Submission Link

eecon47.rmutr.ac.th

Email: eecon47@rmutr.ac.th หรือ Facebook: EECON47

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47
The 47th Electrical Engineering Conference (EECON-47)
วันที่ 13-15 พฤศจิกายน 2567 ณ โรงแรมเซ็นทาราและคอนเวนชันเซ็นเตอร์ จังหวัดอุดรธานี



การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว State of Health Estimation for a Li-ion Battery using LSTM Neural Network

ธนวิทย์ เต้าเอก* สมภพ ผลไม้ และ สุภัคน์ กิตติรัตนสังจา

สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
62601060@kmitl.ac.th* sompob.po@kmitl.ac.th supat.ki@kmitl.ac.th

บทคัดย่อ

การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน เป็นวิธีการเพื่อใช้ในการระบุว่าแบตเตอรี่มีการเสื่อมสภาพลงจากสภาวะเริ่มต้นเพียงใด ข้อมูลที่มีประโยชน์ในการตัดสินใจว่าเมื่อใดจำเป็นต้องเปลี่ยนแบตเตอรี่ใหม่ สามารถใช้เพื่อคำนวณอายุการใช้งานที่เหลืออยู่ได้ บทความนี้จะนำเสนอการประมาณสถานะสุขภาพของแบตเตอรี่ที่ได้จากข้อมูลโปรไฟล์การประจุไฟฟ้าด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ในบทความนี้จะเปรียบเทียบประสิทธิภาพการประมาณสถานะสุขภาพของแบตเตอรี่ระหว่างการใช้อำนาจของกระแสไฟฟ้าขณะประจุไฟฟ้าเพียงอย่างเดียว กับการใช้ข้อมูลร่วมกันระหว่างกระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลาที่ใช้เป็นหลายอินพุตไปยังโครงข่ายประสาทเทียม เงื่อนไขทั้งสองนี้ยังดำเนินการด้วยค่าสถานะประจุเริ่มต้นที่แตกต่างกันและอัตราส่วนของชุดข้อมูลการเรียนรู้ต่อการทดสอบที่แตกต่างกัน ชุดข้อมูลสำหรับการเรียนรู้และทดสอบในบทความนี้ นำมาจากชุดข้อมูลที่รวบรวมโดย NASA ซึ่งได้นำมาปรับแก้ตัวอย่างใหม่ให้เหมาะสม จากการศึกษาเบื้องต้นด้วยค่า MAPE และ RMSE ของผลการประมาณ แสดงให้เห็นว่าการใช้กระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลาเป็นอินพุตให้โครงข่ายประสาทเทียมจะให้ผลลัพธ์ที่ดีกว่า และยังคำนึงถึงสถานะประจุเริ่มต้นโดยการสุ่มเลือกจุดเริ่มต้นประจุไฟฟ้าจากชุดข้อมูลที่มี เพื่อนำมาเรียนรู้และทดสอบเพื่อให้สอดคล้องกับพฤติกรรมการใช้งานแบตเตอรี่ในยานยนต์ไฟฟ้าตามความเป็นจริง ซึ่งการเรียนรู้โดยใช้ค่าสถานะประจุเริ่มต้นแบบสุ่มจะให้ผลลัพธ์ที่ดีกว่าแบบสถานะประจุเริ่มต้นเป็นศูนย์เล็กน้อย และอัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบที่สูงกว่า ยังให้ผลลัพธ์ที่ดีกว่าด้วย

คำสำคัญ: แบตเตอรี่ลิเทียมไอออน สถานะประจุ สถานะสุขภาพ โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว

Abstract

The state of health (SOH) estimation for a Li-Ion battery is a method that determines how much the battery's health has deteriorated from its original state. This can be useful in deciding when a new battery replacement may be necessary and can be used to calculate the Remaining Useful Life (RUL). This paper presents a state of health estimation obtained from charge profile data using a Long Short-Term Memory neural network. In this paper, the state of health estimating performance is compared using a single input of charging current data with the combination of current, voltage, temperature, and time data used as inputs to the neural network. These two conditions are also performed with different initial states of charge (SOC) and

different ratios of train-to-test set. The training and testing datasets in this paper are taken from datasets collected by NASA and have been appropriately resampled from the evaluation with MAPE and RMSE values of the estimation results. It is shown that using current, voltage, temperature, and time as input to the network provides better results. It also considers SOC by randomly selecting the starting point of the charge from the available data set to learn and test to be consistent with the actual battery usage behavior in electric vehicles. At the same time, the randomized initial SOC is slightly better than the initial SOC of 0% and has a higher ratio of training to test information. It also gives better results.

Keywords: Li-Ion Battery, State of Charge, State of Health, Long Short-Term Memory Neural Network

1. บทนำ

ในปัจจุบันแบตเตอรี่ลิเทียมไอออน [1] ถูกนำมาใช้อย่างแพร่หลายในการใช้งานภายในชีวิตประจำวัน เช่น เครื่องใช้ไฟฟ้าในบ้าน สมาร์ทโฟน ยานยนต์ไฟฟ้า และเครื่องบินต่าง เนื่องจากมีความหนาแน่นของพลังงานสูง อัตราการคายประจุสูง และการคายประจุภายในตัวเองต่ำ อย่างไรก็ตาม การเสื่อมสภาพของแบตเตอรี่ถือเป็นปัญหาที่เกิดขึ้นหลังจากกระบวนการผลิตแบตเตอรี่และเริ่มใช้งาน การประมาณสถานะสุขภาพ (SOH) [2-3] ของแบตเตอรี่อย่างแม่นยำเป็นสิ่งสำคัญสำหรับคาดการณ์ว่าอายุการใช้งานแบตเตอรี่จะสิ้นสุดเมื่อใด นอกจากนี้ความจุ (capacity) ของแบตเตอรี่จะลดลงหลังจากการรอบการประจุไฟฟ้าและการคายประจุไฟฟ้าหลายครั้ง ซึ่งไม่ใช่การลดลงอย่างเป็นเชิงเส้นเนื่องจากการพบการเพิ่มขึ้นของค่าความจุอย่างผิดปกติในบางรอบเรียกว่าการกำเนิดใหม่ของความจุ (capacity regeneration) [4] ดังนั้นหากต้องการประมาณสถานะสุขภาพของแบตเตอรี่ให้ได้อย่างแม่นยำ จึงควรนำการกำเนิดใหม่ของความจุมาพิจารณาด้วย ในการหาอายุการใช้งาน หรือ RUL มีสองแนวทางที่นิยมใช้กันได้แก่วิธีสร้างแบบจำลอง (Model-based method) และวิธีการขับเคลื่อนเชิงข้อมูล (Data driven method) ทั้งนี้การสร้างแบบจำลองของการกำเนิดใหม่ของความจุนั้นทำได้ยากในทางปฏิบัติ ในบทความนี้จะเลือกใช้แนวทางวิธีการขับเคลื่อนเชิงข้อมูลด้วยโครงข่ายประสาทเทียม ในการประมาณสถานะสุขภาพของแบตเตอรี่ซึ่งจะเป็นวิธีที่อาศัยชุดข้อมูลที่มีในอดีต เช่น ค่าความจุ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ ความต้านทาน และอื่นๆ โดยไม่ต้องใช้แบบจำลองทางคณิตศาสตร์หรือกลไกภายในของการเสื่อมสภาพของแบตเตอรี่ วิธีนี้ใช้งานง่าย มีความแม่นยำสูง และซับซ้อนน้อยกว่าการใช้แบบจำลองทางคณิตศาสตร์ [5]

บทความนี้เสนอวิธีการประมาณสถานะสุขภาพของแบตเตอรี่ โดยใช้โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว [6] เนื่องจากชุด



*ผู้ประพันธ์บรรณกิจ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47
 The 47th Electrical Engineering Conference (EECON-47)
 วันที่ 13-15 พฤศจิกายน 2567 ณ โรงแรมเซ็นทาราและคอนเวนชันเซ็นเตอร์ จังหวัดอุดรธานี



ข้อมูลสำหรับการเรียนรู้และการทดสอบมีความสัมพันธ์ทางอนุกรมเวลา (Time-series) โดยศึกษาเปรียบเทียบความเที่ยงตรงของการประมาณสถานะสุขภาพของแบตเตอรี่ ระหว่างการใช้ข้อมูลกระแสไฟฟ้าขณะประจุไฟฟ้าเพียงอินพุตเดียว กับการใช้ข้อมูลกระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลาขณะประจุไฟฟ้ารวมกันเป็นอินพุตไปยังโครงข่ายประสาทเทียม เอ็นไอทีทั้งสองนี้ยังดำเนินการด้วยค่าสถานะประจุ (SOC) เริ่มต้นที่แตกต่างกัน และอัตราส่วนของชุดข้อมูลสำหรับการเรียนรู้ต่อข้อมูลการทดสอบที่แตกต่างกัน โดยในบทความนี้ใช้ชุดข้อมูลของแบตเตอรี่ลิเทียมไอออนที่ถูกรวบรวมไว้โดย NASA เนื่องจากเป็นชุดข้อมูลที่เปิดให้เข้าถึงได้โดยสาธารณะ และมีข้อมูลที่ใช้สำหรับการประมาณสถานะสุขภาพของแบตเตอรี่ครบถ้วน

2. ชุดข้อมูลแบตเตอรี่
2.1 แบตเตอรี่

ชุดข้อมูลแบตเตอรี่นำมาจาก NASA Prognostics Center of Excellence Data Repository [7] ซึ่งชุดข้อมูลนี้ประกอบด้วยเซลล์ลิเทียมไอออน 18650 จำนวน 34 เซลล์ ถูกจัดแบ่งเป็น 3 กลุ่มข้อมูลแยกตามอุณหภูมิแวดล้อมของการทดสอบที่แตกต่างกัน คือ 4°C 24°C และ 43°C ในบทความนี้จะเลือกใช้ชุดข้อมูลภายใต้อุณหภูมิแวดล้อมที่ 24°C โดยประกอบด้วยชุดข้อมูลเซลล์แบตเตอรี่ 4 เซลล์ คือ B0005 B0006 B0017 B0018 เมื่อพิจารณาจำนวนรอบของการใช้งาน ข้อมูลแบตเตอรี่ B0005 B0006 และ B0017 มีจำนวนข้อมูลที่เก็บไว้มากกว่า 160 รอบการใช้งาน ในบทความนี้ได้นำข้อมูล B0005 ซึ่งมีจำนวนรอบของการคายประจุไฟฟ้าทั้งหมดที่มากที่สุดจำนวน 168 รอบ และมีข้อมูลของค่าความจุในช่วง 100 เปอร์เซ็นต์ ถึง 70 เปอร์เซ็นต์ มาใช้ในการศึกษา


ข้อมูลแบตเตอรี่ B0005 มีโปรไฟล์การดำเนินการ 3 รูปแบบคือ การประจุไฟฟ้า การคายประจุไฟฟ้า และอิมพีแดนซ์ของแบตเตอรี่ โดยแบตเตอรี่ถูกประจุไฟฟ้าในโหมดกระแสคงที่ (CCCV) ที่ 1.5 A 4.2 V โดยมีกระแสสิ้นสุดการประจุไฟฟ้า 20 mA ในส่วนการคายประจุไฟฟ้าจะเป็นแบบกระแสไฟฟ้าคงที่ (CC) 2 A โดยมีแรงดันไฟฟ้าที่สิ้นสุด 2.7 V โดยค่าความจุเริ่มต้น C_0 ของแบตเตอรี่นี้คือ 1.86 Ah ในบทความนี้ไม่ได้ใช้ข้อมูลของอิมพีแดนซ์เนื่องจากสถานะสุขภาพของแบตเตอรี่ประมาณจากค่าความจุปัจจุบันได้โดยตรง ส่วนค่าอิมพีแดนซ์สามารถใช้ประมาณสถานะกำลัง (State of Power) ได้โดยตรง แต่การประมาณสถานะสุขภาพจากค่าอิมพีแดนซ์ต้องกำหนดความสัมพันธ์หรือนิยามเพิ่มเติม ทั้งนี้ค่าอิมพีแดนซ์ไม่สามารถวัดได้โดยง่ายในสภาวะการใช้งานจริงบนยานยนต์ไฟฟ้า โดยค่าสถานะสุขภาพ SOH ของแบตเตอรี่หาได้จากสมการที่ (1)

$$SOH(\%) = \frac{C_x}{C_0} \times 100 \quad (1)$$

C_x คือ ค่าความจุที่ได้ในแต่ละรอบของการคายประจุไฟฟ้า C_0 คือ ค่าความจุเริ่มต้น

รูปที่ 1 แสดงการเสื่อมของค่าความจุและสถานะสุขภาพของ B0005 ตั้งแต่รอบการใช้งานที่ 1 ถึง 168 จะเห็นได้ว่าความจุของแบตเตอรี่จะลดลงตามจำนวนรอบการประจุไฟฟ้าและการคายประจุไฟฟ้า ซึ่งนับบ่งบอกถึงแบตเตอรี่มีสถานะสุขภาพที่แย่ลงตามจำนวนรอบการใช้งาน และจากข้อมูลยังพบว่ามีค่าเพิ่มขึ้นของค่าความจุ (Capacity regeneration) ในบางรอบการใช้งาน แสดงถึงคุณลักษณะที่ไม่เป็นเชิงเส้นระหว่าง SOH กับ รอบการใช้งาน ดังนั้นการประมาณสถานะสุขภาพของแบตเตอรี่ที่


แม่นยำจะช่วยให้คาดการณ์อายุการใช้งานแบตเตอรี่ได้ว่าจะสิ้นสุดลงเมื่อใด




รูปที่ 1 ความจุและสถานะสุขภาพของแบตเตอรี่ B0005

2.2 โปรไฟล์การประจุไฟฟ้า


โปรไฟล์การประจุไฟฟ้าประกอบด้วยข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิกับค่าเวลา ตั้งแต่เริ่มต้นการประจุไฟฟ้าไปจนถึงการประจุไฟฟ้า โดยแสดงได้ดังรูปที่ 2-4



รูปที่ 2 กระแสไฟฟ้าของแบตเตอรี่วัดได้ในขณะประจุไฟฟ้า



รูปที่ 3 แรงดันไฟฟ้าของแบตเตอรี่วัดได้ในขณะประจุไฟฟ้า



รูปที่ 4 อุณหภูมิของแบตเตอรี่วัดได้ในขณะประจุไฟฟ้า

2.3 การเตรียมข้อมูล

การใช้โครงข่ายประสาทเทียมในการวิเคราะห์ หรือประมวลผลผลลัพธ์จำเป็นต้องมีการจัดการข้อมูลที่ซ้ำซ้อนหรือเป็นข้อมูลที่ซ้ำซ้อนมากเกินไป (Data cleaning) และการลดจำนวนของข้อมูลก็จะช่วยลดเวลาในการเรียนรู้ของโครงข่ายประสาทเทียม ในบทความนี้ได้เลือกข้อมูลการประจุไฟฟ้านับเวลาเริ่มต้น 0 วินาที ณ ตำแหน่งการเริ่มประจุในโหมดกระแสคงที่ และลดไปจนถึงเวลาสุดท้ายที่ 6000 วินาที (ซึ่งยังอยู่ในโหมดแรงดันคงที่) การเลือกชุดข้อมูล ณ ตำแหน่งการเริ่มประจุในโหมดกระแสคงที่นั้นมีความสัมพันธ์กับค่าแรงดันไฟฟ้าและอุณหภูมิของแบตเตอรี่ที่วัดได้ ณ ช่วงเวลาเดียวกัน หลังจากนั้นจะทำการชักตัวอย่างข้อมูลจากข้อมูลข้างต้นในแต่ละรอบการใช้งานแบบสุ่มจำนวน 20 จุดข้อมูล นอกจากนี้ชุดข้อมูลของ NASA รอบการประจุไฟฟ้าจะเริ่มต้นที่ 0% SOC




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47
 The 47th Electrical Engineering Conference (EECON-47)
 วันที่ 13-15 พฤศจิกายน 2567 ณ โรงแรมเซ็นทาราและคอนเวนชันเซ็นเตอร์ จังหวัดอุดรธานี

เสมอ อย่างไรก็ตามในการใช้งานแบตเตอรี่ตามความเป็นจริงโดยพฤติกรรมแล้วมักจะเริ่มต้นการประจุไฟฟ้าในช่วงตั้งแต่ 70%-10% [8] SOC ดังนั้นในบทความนี้ โครงข่ายประสาทเทียมจะได้รับการเรียนรู้ด้วย SOC เริ่มต้นของการประจุไฟฟ้าที่แตกต่างกันสองรูปแบบ โดยรูปแบบ SOC เริ่มต้นที่ 0% และรูปแบบที่สอง SOC เริ่มต้นแบบสุ่ม


รูปที่ 5-7 แสดงตัวอย่างชุดข้อมูลกระแสไฟฟ้า แรงดันไฟฟ้า และอุณหภูมิที่ได้จากการซึกตัวอย่างจำนวน 20 จุดข้อมูล โดยมีค่า SOC เริ่มต้นที่ 0% ดังรูป 5-7 (ก) และมีการสุ่มค่า SOC เริ่มต้นแบบสุ่ม ดังรูป 5-7 (ข) ตามลำดับ



รูปที่ 5 ข้อมูลกระแสไฟฟ้าที่ได้จากการซึกตัวอย่าง 20 จุดข้อมูลในแต่ละรอบการประจุ โดย (ก) มีค่า SOC เริ่มต้นที่ 0% (ข) มีค่า SOC เริ่มต้นแบบสุ่ม




รูปที่ 6 ข้อมูลแรงดันไฟฟ้าที่ได้จากการซึกตัวอย่าง 20 จุดข้อมูลในแต่ละรอบการประจุ โดย (ก) มีค่า SOC เริ่มต้นที่ 0% (ข) มีค่า SOC เริ่มต้นแบบสุ่ม



รูปที่ 7 ข้อมูลอุณหภูมิที่ได้จากการซึกตัวอย่าง 20 จุดข้อมูลในแต่ละรอบการประจุ โดย (ก) มีค่า SOC เริ่มต้นที่ 0% (ข) มีค่า SOC เริ่มต้นแบบสุ่ม

3. โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว
 3.1 โครงสร้างพื้นฐาน

โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว เหมาะสำหรับการประมวลผลตามลำดับและการทำงานเหตุการณ์ระยะยาว โครงสร้างพื้นฐานของเซลล์ประสาท LSTM [9] แสดงดังรูปที่ 8 โดยประกอบด้วยฟังก์ชันที่ทำหน้าที่เหมือนประตู (Gate) ที่มี 3 ส่วนได้แก่ Forget Gate Input Gate และ Output Gate ซึ่งทำงานร่วมกันเพื่อควบคุมการไหลของข้อมูลเข้าและออกจากเซลล์



รูปที่ 8 โครงสร้างพื้นฐานของเซลล์ประสาท LSTM

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] - b_f) \tag{2}$$

Forget Gate (f_t) มีบทบาทสำคัญในการลบข้อมูลสถานะของเซลล์ก่อนหน้าและสร้างพื้นที่สำหรับข้อมูลใหม่ให้พร้อมสำหรับการรวมอินพุต (x_t) ข้อมูลใหม่เข้ากับเอาต์พุตของสถานะเซลล์ก่อนหน้า (h_{t-1}) โดยคำนึงถึง weight (W_f) และ bias (b_f) ซึ่งผลลัพธ์จะเป็นตัวกำหนดว่าข้อมูลก่อนหน้านั้นควรถูกลบออกหรือเก็บรักษาไว้ ผ่านฟังก์ชัน sigmoid (σ) เพื่อใช้ในการตัดสินใจ Forget Gate แสดงดังสมการที่ (2)

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] - b_i) \tag{3}$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \tag{4}$$

Input Gate (i_t) คือ มีหน้าที่รับข้อมูลอินพุตที่เข้ามาใหม่แล้วทำการบันทึกหรือเขียนข้อมูลลงไปในแต่ละโนด ซึ่งจะแบ่งออกเป็น 2 ส่วน คือ ส่วนแรกเป็นส่วนของการอัปเดตข้อมูลเพื่อควบคุมข้อมูลเข้าและออกจากเซลล์โดยใช้ฟังก์ชัน sigmoid (σ) เพื่อพิจารณาว่าควรรวมอินพุตใหม่ไว้ในสถานะเซลล์หรือไม่ ส่วนที่สองถ้า Input Gate เลือกอัปเดตข้อมูลเข้าสถานะเซลล์ ฟังก์ชัน tanh จะทำการสร้าง Candidate value (\tilde{C}_t) ขึ้น Output Gate แสดงดังสมการที่ (3) และ (4)

$$C_t = f_t \cdot C_{(t-1)} + i_t \cdot \tilde{C}_t \tag{5}$$

เมื่อมีการอัปเดตข้อมูลจากสถานะเซลล์จากเซลล์ก่อนหน้า ($C_{(t-1)}$) ไปเป็นสถานะเซลล์ใหม่ (C_t) จะถูกรวมด้วย Forget Gate จากก่อนหน้านั้น จากนั้นจะเพิ่มค่า Candidate value เข้าไปด้วยซึ่งจะได้สถานะเซลล์ใหม่ดังสมการที่ (5)

$$O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \tag{6}$$

$$h_t = O_t \cdot \tanh(C_t) \tag{7}$$

Output Gate (O_t) ทำหน้าที่เตรียมส่งออกข้อมูลโดยฟังก์ชัน sigmoid (σ) จะเป็นตัวเลือกว่าข้อมูลใดควรถูกส่งออกไปเป็นเอาต์พุต จากนั้นนำค่าที่ได้จากสถานะเซลล์ไปเข้าฟังก์ชัน tanh โดยค่าที่ได้จะมีค่าเป็น 1 หรือ -1 และเมื่อนำกลับมารวมกับค่าเอาต์พุตที่ได้จากฟังก์ชัน sigmoid จะได้ค่า Hidden State (h_t) เพื่อนำไปใช้ในสถานะเซลล์ถัดไป ดังแสดงในสมการที่ (6) และ (7)

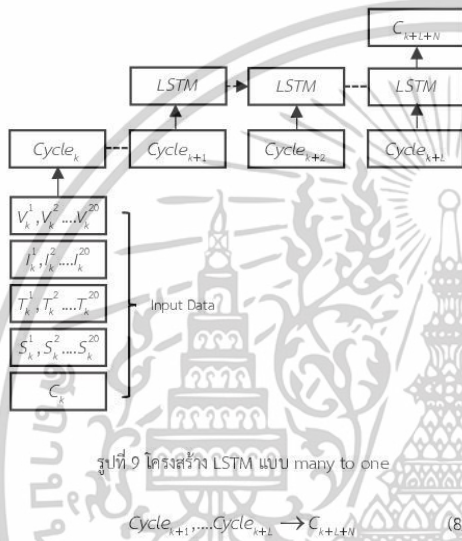


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



3.2 โครงสร้างแบบจำลอง

ในบทความนี้ใช้โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ชนิดหลายอินพุต (multi channels) โดยเสนอให้ใช้ประโยชน์จากโครงสร้างแบบ many to one เพื่อรองรับความหลากหลายของอินพุตสี่ประเภทที่แตกต่างกัน คือ แรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ และเวลา โดยมีผลลัพธ์เป็นค่าเดียวกันซึ่งก็คือค่าความจุ แสดงดังรูปที่ 9 และเอาต์พุตที่ได้จะแสดงดังสมการ (8) [10]



เมื่อ Cycle คือชุดข้อมูลที่ประกอบด้วยอินพุตหลายตัวแปร $V_k^m, I_k^m, T_k^m, S_k^m$ และ C_k แทนข้อมูลที่ทำการจัดตัวอย่างไว้ประกอบด้วยค่าแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลาและผลลัพธ์ค่าความจุตามลำดับ k คือ รอบการประจุไฟฟ้า L คือ จำนวนรอบของชุดข้อมูล N คือ ช่วงที่คาดการณ์ของผลลัพธ์

4. การประมาณสถานะสุขภาพของแบตเตอรี่
4.1 การปรับชุดข้อมูลให้เป็นปกติ (Normalization)

การปรับชุดข้อมูลให้เป็นปกติ จะดำเนินการด้วยวิธี Min-Max scaling คือการปรับฐานของชุดข้อมูลทั้งหมดให้อยู่ในช่วง 0-1 เพื่อช่วยลดเวลาในการเรียนรู้ของแบบจำลอง เพราะแบบจำลองจะมีการประมวลผลที่ซับซ้อนมากขึ้น หากตัวแปรแต่ละตัวนั้นมีช่วงของข้อมูลที่แตกต่างกันมาก เมื่อข้อมูลถูกปรับให้เป็นค่าที่เหมาะสม จะช่วยเพิ่มประสิทธิภาพให้แบบจำลอง แสดงดังสมการที่ (9)

$$X_{nor} = \frac{X - X_{min}}{X_{max} - X_{min}} \times 100 \quad (9)$$

โดย X_{nor} คือ ข้อมูลหลังจากการปรับฐาน X คือ ข้อมูลที่เลือกเพื่อทำการปรับฐาน X_{min}, X_{max} คือ ข้อมูลที่มีค่าน้อยที่สุดและมากที่สุดในชุดข้อมูลตามลำดับโดยเป็นข้อมูลชนิดเดียวกัน จากนั้นทำการแบ่งข้อมูลเพื่อให้

แบบจำลองเรียนรู้และจดจำรูปแบบ เรียกว่าชุดข้อมูลเรียนรู้ ชุดข้อมูลส่วนที่เหลือใช้ในการคาดการณ์ผลลัพธ์เรียกว่าชุดข้อมูลทดสอบ

4.2 การประมวลผล

การประมาณสถานะสุขภาพของแบตเตอรี่ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ในบทความนี้ใช้การเขียนภาษาโปรแกรมด้วย Python โดยใช้ไลบรารี keras เป็นเครื่องมือในการสร้างแบบจำลอง ดำเนินการด้วยโปรแกรม Pycharm Community Editor บนหน่วยประมวลผลกลาง Intel i7-7700 ความเร็ว 2.80 GHz ขนาดหน่วยความจำ 12 GB การเรียนรู้ของแบบจำลองใช้ Adam Optimizer ซึ่งมีอัตราเรียนรู้ (learning rate) ที่ 0.001 ทำการปรับปรุงแบบจำลองให้มีความเหมาะสม ในส่วนการตั้งค่ารอบการสิ้นสุดในการเรียนรู้ของแบบจำลอง ถูกตั้งค่าไว้ที่ 1600 epoch ซึ่งเป็นข้อมูลที่ได้จากการทดลองซ้ำ เมื่อมาจากการใช้ฟังก์ชัน early stop มาใช้ในการกำหนดเงื่อนไข เมื่อค่า loss ของการเรียนรู้มีค่าไม่ลดลงมากกว่า 50 epoch ให้ทำการสิ้นสุดการเรียนรู้ของแบบจำลอง ซึ่งจำนวนรอบการเรียนรู้ของแบบจำลองสิ้นสุดอยู่ระหว่าง 1300-1600 epoch โดยค่า loss ถูกกำหนดด้วยฟังก์ชัน mean square error ในส่วนของเอาต์พุตที่ได้จะถูกกำหนดด้วยฟังก์ชัน Activation tanh

การตรวจสอบประสิทธิภาพของแบบจำลองถูกประเมินด้วยค่า Root Mean Square Error (RMSE) และ Mean Absolute Percentage Error (MAPE) ดังสมการที่ (10) และ (11)

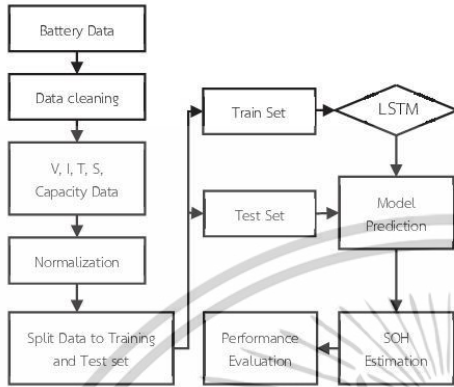
$$RMSE = \sqrt{\frac{1}{K} \sum_{k=1}^K (C - \hat{C}_k)^2} \quad (10)$$

$$MAPE (\%) = \frac{100}{K} \sum_{k=1}^K \left| \frac{C - \hat{C}_k}{C} \right| \quad (11)$$

โดย C คือ ค่าความจริง \hat{C}_k คือ ค่าความจุคาดการณ์ K คือ จำนวนรอบของชุดข้อมูล ลำดับขั้นตอนในการประมาณสถานะสุขภาพของแบตเตอรี่ แสดงดังรูปที่ 10 เริ่มต้นจากการคัดเลือกชุดข้อมูลของแบตเตอรี่ NASA ซึ่งก็คือชุดข้อมูลแบตเตอรี่ B0005 ลำดับต่อมาคือการเลือกข้อมูลจากโปรแกรมการประจุไฟฟ้า และคายประจุไฟฟ้า ซึ่งก็คือชุดข้อมูลแรงดันไฟฟ้า กระแสไฟฟ้า อุณหภูมิ เวลาและความจุ จากนั้นทำการจัดตัวอย่างเป็นจำนวน 20 จุดข้อมูลในแต่ละตัวแปรตามรอบของการประจุไฟฟ้า ซึ่งจะแบ่งเป็นชุดข้อมูลในการประมาณสถานะสุขภาพของแบตเตอรี่ออกเป็น 2 วิธี ชุดข้อมูลแรกสำหรับ SOC เริ่มต้นที่ 0% และชุดข้อมูลที่สองสำหรับ SOC เริ่มต้นแบบสุ่ม ลำดับต่อมาทำการปรับชุดข้อมูลให้เป็นปกติด้วยวิธี Min-Max scaling ทำการแบ่งชุดข้อมูลออกเป็นชุดข้อมูลเรียนรู้ และชุดข้อมูลทดสอบ ลำดับถัดไปเป็นขั้นตอนการใช้โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวในการสร้างแบบจำลองเพื่อประมาณสถานะสุขภาพของแบตเตอรี่ โดยชุดข้อมูลเรียนรู้ ถูกใช้เป็นข้อมูลให้แบบจำลองเรียนรู้และจดจำ ชุดข้อมูลทดสอบถูกใช้ในการหาผลลัพธ์ของแบบจำลอง ผลลัพธ์ของแบบจำลองก็คือผลการประมาณสถานะสุขภาพของแบตเตอรี่ โดยแบบจำลองจะถูกตรวจสอบประสิทธิภาพของผลลัพธ์ด้วยวิธีการหา RMSE และ MAPE



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 10 ขั้นตอนการประมาณสถานะสุขภาพของแบตเตอรี่

4.3 ผลการประมาณสถานะสุขภาพของแบตเตอรี่

ชุดข้อมูลและเงื่อนไขต่อไปนี้ จัดทำขึ้นเพื่อเปรียบเทียบประสิทธิภาพการประมาณสถานะสุขภาพของแบตเตอรี่ผ่านโครงข่ายประสาทเทียม หน่วยความจำระยะสั้นแบบยาว ซึ่งมีรายละเอียดดังนี้

- กรณีที่ 1) SOC เริ่มต้น 0% ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 80 ต่อ 20
- กรณีที่ 2) SOC เริ่มต้น 0% ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลา อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 80 ต่อ 20
- กรณีที่ 3) SOC เริ่มต้น 0% ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลา อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 70 ต่อ 30
- กรณีที่ 4) SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 80 ต่อ 20
- กรณีที่ 5) SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลา อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 80 ต่อ 20
- กรณีที่ 6) SOC เริ่มต้นแบบสุ่ม ข้อมูลอินพุต ประกอบด้วยค่ากระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลา อัตราส่วนข้อมูลในการเรียนรู้ต่อการทดสอบคือ 70 ต่อ 30

การประมาณสถานะสุขภาพที่ได้จากชุดข้อมูลแบตเตอรี่ ถูกแสดงด้วยเส้นสีน้ำเงิน ในขณะที่การประมาณสถานะสุขภาพจากแบบจำลองถูกแสดงด้วยเส้นสีแดง

รูปที่ 11 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 135 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้เกิดความคลาดเคลื่อนตั้งแต่การเริ่มต้นการประมาณ


รูปที่ 12 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 135 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้มีความแม่นยำในช่วงแรกและเกิดความคลาดเคลื่อนตั้งแต่รอบใช้งานที่ 150

รูปที่ 13 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 119 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้มีความแม่นยำในช่วงแรก และเกิดความคลาดเคลื่อนตั้งแต่รอบใช้งานที่ 135


รูปที่ 14 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 135 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้เกิดความคลาดเคลื่อนและการแกว่งของผลการประมาณ

รูปที่ 15 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 135 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้มีความแม่นยำ แต่พบการแกว่งของผลการประมาณ


รูปที่ 16 แสดง SOH ของแบตเตอรี่จากแบบจำลองที่รอบใช้งาน 119 ถึง 168 เมื่อเปรียบเทียบกับ SOH ที่ได้จากชุดข้อมูล ผลที่ได้มีความแม่นยำ แต่พบการแกว่งของผลการประมาณ




รูปที่ 11 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 1



รูปที่ 12 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 2



รูปที่ 13 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 3




รูปที่ 14 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 4




เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47
 The 47th Electrical Engineering Conference (EECON-47)
 วันที่ 13-15 พฤศจิกายน 2567 ณ โรงแรมเซ็นทาราและคอนเวนชันเซ็นเตอร์ จังหวัดอุดรธานี



รูปที่ 15 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 5



รูปที่ 16 ผลการประมาณสถานะสุขภาพของแบตเตอรี่ในกรณีที่ 6

ตารางที่ 1 ตารางเปรียบเทียบประสิทธิภาพ ผลการประมาณสถานะสุขภาพของแบตเตอรี่

กรณี	MAPE	RMSE	กรณี	MAPE	RMSE
1	1.2584	0.0179	4	1.2274	0.0188
2	0.7729	0.0115	5	0.6298	0.0106
3	1.0191	0.0164	6	0.8236	0.0133

จากผลการทดสอบ ประการแรกการใช้ชุดข้อมูลกระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลาเป็นอินพุตของแบบจำลองจะให้ผลลัพธ์ในการประมาณสถานะสุขภาพที่แม่นยำกว่าการใช้ชุดข้อมูลกระแสไฟฟ้าเพียงอย่างเดียว ประการที่สอง SOC เริ่มต้น 0% และ SOC เริ่มต้นแบบสุ่ม สามารถประมาณสถานะสุขภาพได้อย่างมีประสิทธิภาพใกล้เคียงกับสถานะสุขภาพที่ได้จากข้อมูลแบตเตอรี่ ประการที่สามอัตราส่วนข้อมูลในการเรียนรู้คืออัตราทดสอบ 80 ต่อ 20 ให้ผลลัพธ์ที่แม่นยำกว่า ประการสุดท้ายแบบจำลองสามารถคาดการณ์การกำเนิดใหม่ของความจุได้

5. สรุป

การประมาณสถานะสุขภาพของแบตเตอรี่ โดยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว ประการแรกเกี่ยวข้องกับจำนวนอินพุต ผลการทดสอบพบว่าการใช้อินพุตเพียงชนิดเดียวคือ ค่ากระแสไฟฟ้า ส่งผลให้การประมาณค่าสถานะสุขภาพ SOH มีความแม่นยำน้อยกว่าการใช้อินพุต 4 ชนิด ซึ่งประกอบด้วยกระแสไฟฟ้า แรงดันไฟฟ้า อุณหภูมิ และเวลา ประการที่สองชุดข้อมูล SOC เริ่มต้นที่ 0% และชุดข้อมูล SOC เริ่มต้นแบบสุ่ม ผลการทำนายจากทั้งสองวิธีมีความสอดคล้องและให้ผลลัพธ์ที่แม่นยำ ซึ่งชุดข้อมูล SOC เริ่มต้นแบบสุ่มให้ผลลัพธ์ที่ดีกว่าเล็กน้อย แต่มีความเหมาะสมมากกว่าสำหรับการคาดการณ์เมื่อใช้งานตามพฤติกรรมการใช้จริง ประการที่สามการลดจำนวนรอบที่ใช้สำหรับการเรียนรู้และเพิ่มจำนวนผลลัพธ์ที่คาดการณ์จากชุดทดสอบ ทำให้ความแม่นยำในการคาดการณ์ลดลง ประการสุดท้ายการกำเนิดใหม่ของความจุอาจทำให้เกิดความคลาดเคลื่อนระหว่างการประมาณ ซึ่งแบบจำลอง

สามารถคาดการณ์การกำเนิดใหม่ของความจุได้ใกล้เคียงกับชุดข้อมูลจากแบตเตอรี่ที่มี

เอกสารอ้างอิง

- [1] Y. Li, "Electrochemical Impedance Spectroscopy Analysis of Lithium Ion Battery Based on Equivalent Circuit Model," 2020 2nd International Conference on Applied Machine Learning (ICAML), Changsha, China, 2020, pp. 282-285.
- [2] S. Zhang, "A new method for lithium-ion battery's SOH estimation and RUL prediction," 2018 13th IEEE Conference on Industrial Electronics and Applications (CIEA), Wuhan, China, 2018, pp. 2693-2697.
- [3] S. Ravi, P.G.V. Koushik, V.Chetan Krishna Varma and S. Rajeswari, "Li-ion Batteries SoH Estimation Using LSTM," 2022 6th International Conference on Computation System and Information Technology for Sustainable Solutions (CSITSS), Bangalore, India, 2022, pp. 1-6.
- [4] Y. Cui and Y. Chen, "Prognostics of Lithium-Ion Batteries Based on Capacity Regeneration Analysis and Long Short-Term Memory Network," IEEE Transactions on Instrumentation and Measurement, vol. 71, pp. 1-13, 2022.
- [5] O. Liu, M. Zheng and P. Li, "A Review of Data-Driven SOH and RUL Estimation for Lithium-Ion Batteries," 2023 42nd Chinese Control Conference (CCC), Tianjin, China, 2023, pp. 8769-8774.
- [6] B. Kasniya, T. Kanumuri, V. Shrivastava and Y. Kuwal, "Lithium-Ion Battery's SOH Estimation Using Machine Learning with Multi-Channel Charging Profiles," 2023 International Conference on Computer, Electronics & Electrical Engineering & their Applications (IC2E3), Srinagar Garhwal, India, 2023, pp. 1-5.
- [7] B. Saha and K. Goebel, "Battery Data Set," NASA Ames Prognostics Data Repository, (<http://www.nasa.gov/intelligent-systems-division/discovery-and-systems-health/pcoe/pcoe-data-set-repository/>), NASA Ames Research Center, Moffett Field, CA, 2007.
- [8] T. Franke and J. Krems, "Understanding charging behaviour of electric vehicle users," Transportation Research Part F Traffic Psychology and Behaviour, vol. 21, pp. 75-89, 2013.
- [9] J. Qu, F. Liu, Y. Ma and J. Fan, "A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lithium-Ion Battery," IEEE Access, vol.7, pp. 87178-87191, 2019.
- [10] K. Park, Y. Choi, W. Jae Choi, H. Yeon Ryu and H. KIM, "LSTM-based Battery Remaining Useful Life Prediction with Multi-Channel Charging Profiles," IEEE Access, vol.8, pp. 20786-20798, 2020.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ-นามสกุล นายธนวิทย์ เต่าเอก
วัน เดือน ปีเกิด 31 สิงหาคม 2534
ที่อยู่ บ้านเลขที่ 588/170 หมู่บ้านเอเรสท์ แพรกษา ซอย 30 หมู่ 2 ตำบล
แพรกษาใหม่ อำเภอเมืองสมุทรปราการ จังหวัดสมุทรปราการ
รหัสไปรษณีย์ 10280

ประวัติการศึกษา:

2554-2557 วิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
2562 วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ประสบการณ์การทำงาน:

2558 – 2561 วิศวกรไฟฟ้า บริษัท ไทยโตโก เอ็นจิเนียริง จำกัด
2562 - ปัจจุบัน วิศวกรทดสอบ สถาบันไฟฟ้าและอิเล็กทรอนิกส์

ผลงานทางด้านวิชาการ ธนวิทย์ เต่าเอก สมภพ ผลไม้ และ สุพัฒน์ กิตติรัตน์สังจา
“การประมาณสถานะสุขภาพของแบตเตอรี่ลิเทียมไอออน
ด้วยโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว”,
การประชุมวิชาการทางวิศวกรรมไฟฟ้า ครั้งที่ 47

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้