

การประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออนโดย
โครงข่ายประสาทเทียมแบบแอลเอสทีเอ็ม

STATE OF CHARGE ESTIMATION FOR LITHIUM-ION BATTERY
BASED ON LSTM NEURAL NETWORK



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ.2566

KMITL-2023-EN-D-027-156

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

STATE OF CHARGE ESTIMATION FOR LITHIUM-ION BATTERY
BASED ON LSTM NEURAL NETWORK



Kritayod Rupanwong

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

2023

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

KMITL-2023-EN-D-027-156



COPYRIGHT 2023

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารลิขสิทธิ์สงวนไว้สำหรับกรใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้คนอื่นไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออนโดย โครงข่ายประสาทเทียมแบบแอลเอสทีเอ็ม
นักศึกษา	นายกฤตยชญ์ หรุปานวงษ์
รหัสประจำตัว	64601015
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้าและคอมพิวเตอร์
พ.ศ.	2566
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.สุพัฒน์ กิตติรัตน์สัจจา

บทคัดย่อ

การประมาณสถานะประจุ (SoC) ของแบตเตอรี่ลิเทียมไอออนเป็นหนึ่งในฟังก์ชันสำคัญของระบบจัดการแบตเตอรี่ (BMS) เพื่อรับรองความปลอดภัยสำหรับการใช้งานในรถยนต์ไฟฟ้า โดยการประมาณสถานะประจุให้มีความแม่นยำนั้นทำได้ยาก เนื่องจากพฤติกรรมที่ไม่เป็นเชิงเส้นของแบตเตอรี่ ซึ่งในวิทยานิพนธ์เล่มนี้จึงเสนอวิธีการประมาณสถานะประจุโดยใช้ข้อมูล ซึ่งเป็นวิธีที่ตรงข้ามกับวิธีการประมาณสถานะประจุตามแบบจำลอง โดยวิธีการประมาณสถานะประจุโดยใช้ข้อมูลไม่จำเป็นต้องมีความรู้เกี่ยวกับโมเดลวงจรสมมูลของแบตเตอรี่มาก่อนก็สามารถประมาณสถานะประจุได้ โดยใช้โครงข่ายประสาทเทียมชนิดหนึ่งที่มีชื่อว่า Long short-term memory (LSTM) ในการประมาณสถานะประจุ โดยอินพุตที่ป้อนเข้าสู่โครงข่ายคือแรงดันไฟฟ้าระหว่างขั้วและกระแสไฟฟ้า ส่วนเอาต์พุตคือ SoC ซึ่งในวิทยานิพนธ์เล่มนี้ชุดข้อมูลที่ใช้สำหรับโมเดลโครงข่าย LSTM คือชุดข้อมูลที่จำลองการวิ่งของรถยนต์ไฟฟ้าในรูปแบบของ WLTP แต่ละคลาสได้แก่ WLTP คลาส 1, WLTP คลาส 2, WLTP คลาส 3 และ WLTP แบบผสมคลาส โดยชุดข้อมูลสำหรับการเรียนรู้และชุดข้อมูลสำหรับการทดสอบคือ WLTP ในคลาสที่แตกต่างกัน ซึ่งการประเมินประสิทธิภาพของการประมาณสถานะประจุโดยโครงข่าย LSTM ถูกประเมินโดยพิจารณาจาก Root Mean Squared Error (RMSE) พบว่าจำนวนเซลล์ประสาทที่เหมาะสมที่สุดของโครงข่าย LSTM คือ 10 เซลล์ที่ทำให้ค่า RMSE มีค่าต่ำที่สุด นอกจากนี้ยังมีการนำชุดข้อมูลที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวันซึ่งประกอบด้วยแพทเทิร์นการวิ่ง, การอัดประจุ และการพัก เข้ามาทดสอบโมเดลโครงข่าย LSTM เพิ่มเติม พบว่าชุดข้อมูลสำหรับการเรียนรู้ต้องครอบคลุมทุกช่วงของ SoC เพื่อการประมาณสถานะประจุที่แม่นยำ ในการประมาณสถานะประจุโดยโครงข่าย LSTM แบบเรียลไทม์ โมเดลโครงข่าย LSTM ซึ่งประกอบด้วยจำนวนเซลล์ประสาท 10 เซลล์และความยาวของชุดข้อมูลย่อยเท่ากับ 60 สามารถดำเนินการได้บน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต่อ | อ่างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Raspberry Pi4 โดยใช้เวลาในการประมวลผล 0.2 วินาทีสำหรับคาบตัวอย่างการสุ่ม 1 วินาที พบว่า RMSE มีค่า 0.67% และในการทดสอบผลกระทบของอุณหภูมิโดยรอบของแบตเตอรี่ต่อการประมาณสถานะประจุที่อุณหภูมิ 0 °C, 25 °C และ 45 °C พบว่านอกจากแรงดันระหว่างขั้วและกระแสไฟฟ้า จะต้องเพิ่มอุณหภูมิเป็นอินพุตสำหรับโมเดลโครงข่ายด้วย จึงจะสามารถประมาณสถานะประจุได้อย่างแม่นยำ พบว่า RMSE มีค่า 0.32% ซึ่งใช้ชุดข้อมูลสำหรับการเรียนรู้และชุดข้อมูลสำหรับเป็นชุดข้อมูลเดียวกัน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Thesis	State of Charge Estimation for Lithium-Ion Battery based on LSTM Neural Network
Student	Mr.Kritayod Rupanwong
Student ID.	64601015
Degree	Master of Engineering
Program	Electrical and Computer Engineering
Year	2023
Thesis Advisor	Assoc.Prof.Dr.Supat Kittiratsatcha

ABSTRACT

The state of charge (SoC) estimation for lithium-ion batteries is an essential function of the battery management system (BMS) for ensuring reliable operation of electric vehicles. The nonlinear behavior of the battery makes estimating of SoC a challenging task. In this thesis, SoC estimation based on data-driven methodology is implemented. In contrary to the model-based method, the data-driven technique does not require prior knowledge of Equivalent Circuit Model. Long short-term memory neural network (LSTM) is adopted for data-driven estimation. The Inputs that fed into the network are terminal voltage and current, while output is SoC. In this study, WLTP driving cycle including Class 1, 2,3 and mixed Class are adopted for data set preparation. The training set and the test set are from different class. The performance of SoC estimation based on LSTM neural network is evaluated through RMSE value. The optimal number of neurons of 10 is obtained based on the lowest RMSE result. In addition, the charging, resting and driving pattern are also taken in to account for daily-life usage, the training data set covers full SoC range for accurate the SoC estimation. The resultant neural network is implemented in the Raspberry Pi 4 for real-time SoC estimation using 60 time steps and 10 neuron. The system is able to execute within 0.2s for 1-s sampling period. The RMSE of 0.67% is obtained. The effect of temperature surrounding the battery on the estimation has been investigated at 0C, 25C and 45C. In this case, in addition to current and voltage, the

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

temperature is also included to the input of the neural as well. The neural network is capable of estimating SoC with 0.32% RMSE using the same data set for training and test.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความกรุณาจากท่านอาจารย์ ดร. สมภพ ผลไม้ และ รศ.ดร.สุพัฒน์ กิตติรัตน์สัจจา ที่คอยให้ความรู้และคำปรึกษาทั้งด้านทฤษฎีและปฏิบัติเกี่ยวกับแบตเตอรี่ อีกทั้งยังคอยให้ความช่วยเหลือและชี้แนะในการแก้ไขปัญหา และข้อผิดพลาดที่เกิดขึ้น ตลอดจนช่วยสนับสนุนค่าใช้จ่ายที่ใช้ในงานวิจัย จนกระทั่งงานวิจัยนี้สำเร็จลุล่วงไปได้ด้วยดี ข้าพเจ้ารู้สึกซาบซึ้งและประทับใจในความรู้และประสบการณ์ที่ท่านมอบให้ และขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอขอบพระคุณคณาจารย์ คณะวิศวกรรมศาสตร์ไฟฟ้า สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ทุกๆท่านที่คอยอบรม สั่งสอน และประสิทธิ์ประสาทวิชาความรู้ ให้แก่ข้าพเจ้า จนงานวิจัยสามารถสำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณสมาชิกทุกคนในห้องปฏิบัติการ Power Electronic Applications and Energy Conversion Research Laboratory (PEARL LAB) ที่คอยให้คำปรึกษา ให้กำลังใจ ให้ความช่วยเหลือด้วยดีมาอย่างสม่ำเสมอ ตลอดจนสร้างบรรยากาศที่ดีในการทำงาน จนงานวิจัยสามารถสำเร็จลุล่วงไปได้ด้วยดี

ขอขอบพระคุณบิดา มารดา และครอบครัว ที่คอยให้กำลังใจ สนับสนุนเงินทุนในค่าใช้จ่ายต่างๆ อีกทั้งยังให้ความเชื่อมั่นในตัวลูกคนนี้ จนงานวิจัยสามารถสำเร็จลุล่วงไปได้ด้วยดี

สุดท้ายนี้ ข้าพเจ้าหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์เล่มนี้จะเป็นประโยชน์ต่อการศึกษาสำหรับผู้ที่สนใจไม่มากนักน้อย หากเกิดข้อผิดพลาดประการใด ข้าพเจ้าต้องขออภัยเป็นอย่างสูงไว้ ณ ที่นี้ด้วย

กฤตยชญ์ หรุปานวงษ์

สารบัญ

	หน้า
บทคัดย่อ.....	I
ABSTRACT.....	III
กิตติกรรมประกาศ	V
สารบัญ	VI
สารบัญตาราง.....	IX
สารบัญรูป.....	X
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 จุดมุ่งหมายและวัตถุประสงค์.....	2
1.3 ทฤษฎีหรือแนวคิดที่ใช้ในการวิจัย.....	3
1.4 ขอบเขตการวิจัย.....	3
1.5 ประโยชน์ที่ได้รับจากการวิจัย.....	3
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง	4
2.1 แบตเตอรี่ลิเทียมไอออน	4
2.1.1 หลักการทำงานของแบตเตอรี่ลิเทียมไอออน	5
2.1.2 แบตเตอรี่ลิเทียมไอออนชนิดต่างๆ	6
2.1.3 คำศัพท์และคำจำกัดความเกี่ยวกับแบตเตอรี่ลิเทียมไอออน	7
2.1.4 คุณสมบัติเฉพาะของแบตเตอรี่ลิเทียมไอออน.....	8
2.2 ระบบจัดการแบตเตอรี่ (Battery Management System).....	9
2.3 สถานะประจุ (Stage of Charge - SoC).....	11
2.3.1 วิธีคำนวณคูลอมบ์ (Coulomb Counting)	11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และตั้งชื่ออ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.2	วิธีการแรงดันเปิดวงจร (Open Circuit Voltage - OCV)	12
2.4	ปัญญาประดิษฐ์ (Artificial Intelligence - AI).....	13
2.5	Machine Learning	16
2.5.1	การเรียนรู้แบบมีผู้สอน (Supervised Learning)	16
2.5.2	การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning).....	17
2.5.3	การเรียนรู้แบบเสริมแรง (Reinforcement Learning).....	17
2.6	Deep Learning	17
2.6.1	โครงข่ายประสาทเทียม (Artificial Neural Network – ANN).....	18
2.6.1	Recurrent Neural Network (RNN)	22
2.6.2	Long short-term memory (LSTM)	24
2.7	Raspberry Pi 4 Model B.....	26
2.8	วงจรควบคุมชุดแบตเตอรี่ 18 เซลล์ด้วยการเชื่อมต่อเครือข่ายวิธี Daisy chain LTC6813-1	27
2.8.1	Daisy chain.....	28
2.8.2	บอร์ดสวิตช์ DC2350B.....	28
2.9	บอร์ดสวิตช์ Dual master isoSPI Adapter DC2792B	29
2.9.1	การสื่อสารอนุกรมแบบ SPI	30
2.9.2	IsoSPI (Isolated SPI).....	31
2.10	Linduino ONE (DC2026C)	33
บทที่ 3	การออกแบบและการสร้างโมเดลการประมาณสถานะประจุของแบตเตอรี่.....	34
3.1	ชุดทดสอบสำหรับแบตเตอรี่ลิเทียมไอออน.....	34
3.2	โปรไฟล์กระแสไฟฟ้าสำหรับแบตเตอรี่ (Battery Current Profile)	35
3.3	การเตรียมข้อมูล (Data Preprocessing)	36
3.3.1	การทำให้เป็นมาตรฐาน (Normalization).....	38
3.4	การสร้างและการฝึกฝนโมเดลโครงข่าย LSTM.....	40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และตั้ง VII ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.5	การประเมินประสิทธิภาพโมเดลโครงข่าย LSTM	46
3.6	การออกแบบและการสร้างวงจรประมาณสถานะประจุ	46
บทที่ 4	ผลการทดสอบ	51
4.1	การโมเดลโครงข่าย LSTM ที่เหมาะสมที่สุดสำหรับวงจรประมาณสถานะประจุของแบตเตอรี่ ...	51
4.2	ผลการทดสอบโมเดลโครงข่าย LSTM ด้วยโปรไฟล์กระแสไฟฟ้า WLTP	54
4.3	ผลการทดสอบโมเดลโครงข่าย LSTM ด้วยโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้า ในชีวิตประจำวัน	65
4.4	การเปรียบเทียบการประมาณสถานะประจุโดย LSTM กับงานวิจัยที่ผ่านมา	77
บทที่ 5	สรุปผลการวิจัยและข้อเสนอแนะ	79
5.1	สรุปผลการวิจัย	79
5.2	ข้อเสนอแนะ	79
เอกสารอ้างอิง	80
ภาคผนวก ก	83
ประวัติผู้เขียน	89

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และตั้ง VIII ่างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
ตารางที่ 2.1 คำศัพท์และคำจำกัดความเกี่ยวกับแบตเตอรี่ลิเทียมไอออน	7
ตารางที่ 3.1 การกำหนด Hyperparameters ในโครงข่าย LSTM.....	44
ตารางที่ 4.1 แสดงผลลัพธ์ของการ train โครงข่าย LSTM ที่จำนวนเซลล์ประสาทต่างๆ.....	52
ตารางที่ 4.2 แสดง %RMSE ของการประมาณสถานะประจุโดยใช้ Training set และ Test set เป็น WLTP Class ต่างๆ	58



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
รูปที่ 2.1 โครงสร้างและกระบวนการทำงานภายในเซลล์ ของแบตเตอรี่ลิเทียมไอออนขณะคายประจุ.....	5
รูปที่ 2.2 แบตเตอรี่ลิเทียมไอออนแต่ละชนิดที่นิยมใช้ในปัจจุบัน	6
รูปที่ 2.3 แผนผังการทำงานของระบบจัดการแบตเตอรี่	10
รูปที่ 2.4 กราฟความสัมพันธ์ระหว่างแรงดันเปิดวงจร กับสถานะประจุของแบตเตอรี่ (OCV-SoC curve).....	12
รูปที่ 2.5 ภาพรวมของปัญญาประดิษฐ์ (AI).....	13
รูปที่ 2.6 การเขียนแกรมแบบทั่วไปเปรียบเทียบกับการใช้ Machine Learning	14
รูปที่ 2.7 กระบวนการทำงานของ Machine Learning และ Deep learning	15
รูปที่ 2.8 ประเภทของ Machine Learning.....	16
รูปที่ 2.9 โครงสร้างของโครงข่ายประสาทเทียม	18
รูปที่ 2.10 Single-layer Perceptron.....	19
รูปที่ 2.11 Activation Function.....	21
รูปที่ 2.12 โครงสร้างของ Recurrent Neural Network (RNN)	23
รูปที่ 2.13 สถาปัตยกรรม RNN (ซ่าย) และสถาปัตยกรรม LSTM (ขวา).....	24
รูปที่ 2.14 รูปแบบของอินพุตและเอาต์พุตในโครงสร้างของ LSTM.....	26
รูปที่ 2.15 Raspberry Pi 4 Model B.....	27
รูปที่ 2.16 LTC6813-1	28
รูปที่ 2.17 บอร์ด DC2350B	29
รูปที่ 2.18 การเชื่อมต่อระหว่าง DC2026 Linduino one และ DC2792B ด้วยสาย Ribbon.....	30
รูปที่ 2.19 การสื่อสารอนุกรมแบบ SPI ระหว่าง Master และ Slave หลายตัว	31
รูปที่ 2.20 การเชื่อมต่อแบบ isoSPI ที่ Master สามารถควบคุม Slave ได้หลายตัว.....	32
รูปที่ 2.21 บอร์ด Linduino One.....	33
รูปที่ 3.1 แบตเตอรี่ลิเทียมไอออน LGGBMJ11865 และคุณสมบัติที่สำคัญ.....	34
รูปที่ 3.2 DC Electronic Power Supply DL811 และ DC Electronic Load DP3021	35
รูปที่ 3.3 MATLAB EV Reference Applications Model.....	36
รูปที่ 3.4 Library ที่ใช้สำหรับการจัดเตรียมข้อมูลและการสร้างโมเดล	36
รูปที่ 3.5 การนำเข้าชุดข้อมูลให้อยู่ในรูปของ DataFrame.....	37

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต่อxอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.6 training set และ test set	37
รูปที่ 3.7 กราฟแสดงกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างขั้ว	38
รูปที่ 3.8 การแปลง DataFrame เป็น array	39
รูปที่ 3.9 การ Normalization โดยใช้ฟังก์ชัน MinMaxScaler.....	39
รูปที่ 3.10 กราฟแสดงกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างขั้วหลังจากการทำ Normalization.....	40
รูปที่ 3.11 ฟังก์ชันในการสร้างอินพุตและเอาต์พุตสำหรับป้อนเข้าสู่โมเดล LSTM	41
รูปที่ 3.12 กระบวนการป้อนอินพุตเข้าสู่โครงข่าย LSTM [19].....	42
รูปที่ 3.13 Loss Function RMSE.....	43
รูปที่ 3.14 การสร้างโมเดลโครงข่าย LSTM.....	43
รูปที่ 3.15 Model Summary ของโครงข่าย LSTM.....	44
รูปที่ 3.16 โครงสร้างการทำงานภายในของโมเดลโครงข่าย LSTM	45
รูปที่ 3.17 กระบวนการ train โมเดลโครงข่าย LSTM.....	45
รูปที่ 3.18 กราฟแสดงผลลัพธ์ของการ train โมเดลโครงข่าย LSTM	46
รูปที่ 3.19 Schematic Diagram ของวงจรวัดกระแสไฟฟ้าของแบตเตอรี่.....	47
รูปที่ 3.20 แผนผังการทำงานของวงจรประมาณสถานะประจุของแบตเตอรี่.....	47
รูปที่ 3.21 วงจรประมาณสถานะประจุของแบตเตอรี่.....	48
รูปที่ 3.22 การ Remote ระหว่าง Raspberry Pi4 กับ GUI.....	48
รูปที่ 3.23 การเชื่อมต่อระหว่าง Linduino One กับ Raspberry Pi4 และการ load model	49
รูปที่ 3.24 Code การประมาณสถานะประจุของแบตเตอรี่โดย LSTM แบบเรียลไทม์.....	50
รูปที่ 4.1 กราฟแสดงผลลัพธ์ของการ train โครงข่าย LSTM ที่จำนวนเซลล์ประสาทต่างๆ	53
รูปที่ 4.2 โปรไฟล์กระแสไฟฟ้า WLTP Class1	54
รูปที่ 4.3 โปรไฟล์กระแสไฟฟ้า WLTP Class2	55
รูปที่ 4.4 โปรไฟล์กระแสไฟฟ้า WLTP Class3	56
รูปที่ 4.5 โปรไฟล์กระแสไฟฟ้า WLTP Mixed Class	57
รูปที่ 4.6 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Class2).....	59
รูปที่ 4.7 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Class3).....	59
รูปที่ 4.8 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Mixed Class).....	60

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 4.9 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Class1).....	60
รูปที่ 4.10 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Class3).....	61
รูปที่ 4.11 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Mixed Class).....	61
รูปที่ 4.12 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Class1).....	62
รูปที่ 4.13 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Class2).....	62
รูปที่ 4.14 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Mixed Class).....	63
รูปที่ 4.15 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class1).....	63
รูปที่ 4.16 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class2).....	64
รูปที่ 4.17 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class3).....	64
รูปที่ 4.18 Training set สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าใน	65
รูปที่ 4.19 Test set สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน	66
รูปที่ 4.20 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test set สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลอง การวิ่งของรถยนต์ไฟฟ้าใน ชีวิตประจำวัน).....	67
รูปที่ 4.21 Test set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าใน ชีวิตประจำวัน	68
รูปที่ 4.22 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลอง การวิ่งของรถยนต์ ไฟฟ้าในชีวิตประจำวัน).....	69
รูปที่ 4.23 Training set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าใน ..	70

รูปที่ 4.24 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 และ Test Set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลอง การวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน).....	71
รูปที่ 4.25 Test set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน.....	72
รูปที่ 4.26 Test set รูปแบบที่ 2 ที่อุณหภูมิ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน	73
รูปที่ 4.27 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 ที่อุณหภูมิ 25 °C และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน).....	74
รูปที่ 4.28 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 ที่อุณหภูมิ 25 °C และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน).....	75
รูปที่ 4.29 Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C, 25 °C และ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน	76
รูปที่ 4.30 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C, 25 °C และ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน).....	77
รูปที่ 4.31 RMSE การประมาณสถานะประจุโดย LSTM ของงานวิจัยที่ผ่านมา (1)	78
รูปที่ 4.32 RMSE การประมาณสถานะประจุโดย LSTM ของงานวิจัยที่ผ่านมา (2)	78
รูปที่ 4.33 RMSE การประมาณสถานะประจุโดย LSTM ของวิทยานิพนธ์เล่มนี้	78

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบันแบตเตอรี่ลิเทียมไอออนได้รับความนิยมและนำถูกนำมาใช้อย่างแพร่หลายในรถยนต์ไฟฟ้า (EV) ซึ่งในรถยนต์ไฟฟ้าระบบจัดการแบตเตอรี่ (BMS) [1] เป็นสิ่งจำเป็นในการรับรองความปลอดภัยสำหรับแบตเตอรี่ในด้านต่างๆ ได้แก่ ความปลอดภัย (Safety), ประสิทธิภาพการทำงาน (Performance) และอายุการใช้งาน (Cycle Life) ในด้านประสิทธิภาพการทำงาน ระบบจัดการแบตเตอรี่ประกอบด้วยหลายฟังก์ชัน อาทิเช่น สถานะประจุ (Stage of Charge), สถานะกำลัง (State of Power) และ สถานะพลังงาน (State of Energy) ในด้านความปลอดภัย ระบบจัดการแบตเตอรี่ต้องสามารถรับรองความปลอดภัยของผู้ปฏิบัติงานสำหรับอันตรายจากไฟฟ้าดูด และความปลอดภัยของแบตเตอรี่จากความผิดปกติขณะทำงาน เช่น การอัดประจุเกิน, การคายประจุเกิน, การใช้งานที่อุณหภูมิสูงและต่ำเกินไป และการลัดวงจรภายนอก ในด้านอายุการใช้งานระบบจัดการแบตเตอรี่ต้องสามารถประมาณสถานะสุขภาพ (SoH) และอายุการใช้งานที่เหลืออยู่ของแบตเตอรี่ได้อย่างแม่นยำ เพื่อที่จะสามารถตรวจสอบสุขภาพของแบตเตอรี่ได้ว่าเสื่อมสภาพไปมากน้อยเพียงใด โดยการประมาณสถานะประจุของแบตเตอรี่ให้มีความแม่นยำนั้นเป็นงานที่ยากและท้าทาย เนื่องจากพฤติกรรมที่ไม่เป็นเชิงเส้นของแบตเตอรี่ลิเทียมไอออน

โดยทั่วไปการประมาณสถานะประจุสามารถทำได้หลากหลายวิธี ซึ่งวิธีที่นิยมและแพร่หลายคือวิธี Open Circuit Voltage (OCV) และวิธี Coulomb Counting [2] โดยวิธี OCV สถานะประจุสามารถประมาณได้จากความสัมพันธ์ระหว่าง SoC และ OCV ถึงแม้ว่าวิธีการนี้ง่ายต่อการประมาณสถานะประจุ แต่ไม่สามารถประมาณสถานะประจุขณะแบตเตอรี่ถูกใช้งาน เนื่องจาก OCV สามารถหาได้หลังจากที่แบตเตอรี่พักผ่อนอย่างเต็มที่หรืออยู่ในสภาวะ Static Equilibrium ส่วนวิธี Coulomb Counting สถานะประจุสามารถหาได้จากการอินทิเกรตกระแสของแบตเตอรี่เทียบกับเวลา การประมาณสถานะประจุให้มีความแม่นยำโดยใช้วิธีการนี้ขึ้นอยู่กับความแม่นยำของเซนเซอร์วัดกระแสและค่าความผิดพลาดเริ่มต้นของ SOC ด้วยเหตุนี้จำเป็นต้องมีการปรับเทียบค่า SOC เป็นระยะเพื่อที่จะลดค่าความผิดพลาดสะสม ซึ่งในปัจจุบันวิธีการประมาณสถานะประจุที่ได้รับการยอมรับและนิยมใช้มากที่สุดคือวิธี model-based [2] โดยวิธี model-based จำเป็นต้องทราบพารามิเตอร์ภายในโมเดลของแบตเตอรี่ก่อนถึงจะสามารถประมาณสถานะประจุได้ ซึ่งโมเดลที่นิยมใช้คือโมเดลวงจรสมมูลของแบตเตอรี่ (Equivalent Circuit Model) จากนั้นจึงประมาณสถานะประจุ

โดยใช้เทคนิค Extended Kalman Filter (EKF)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในวิทยานิพนธ์เล่มนี้จึงเสนอวิธีการประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออนที่ตรงข้ามกับวิธี model-based คือวิธี data-driven โดยวิธี data-driven ไม่จำเป็นต้องมีความรู้เกี่ยวกับโมเดลวงจรสมมูลของแบตเตอรี่มาก่อนก็สามารถประมาณสถานะประจุได้ โดยใช้เทคโนโลยี Artificial Intelligence (AI) เข้ามาช่วยในการประมาณสถานะประจุของแบตเตอรี่ โดยใช้ Artificial Neural Network (ANN) [3] ซึ่งเปรียบเสมือนกับ black box ที่ต้องการแค่อินพุตและเอาต์พุตจำนวนมากป้อนเข้าสู่โครงข่าย โดยไม่สนใจกระบวนการทำงานภายในว่าทำงานอย่างไร เนื่องจากชุดข้อมูลที่ป้อนเข้าสู่โครงข่ายเป็นชุดข้อมูลลำดับที่มีความยาวมากและ SoC ที่สถานะปัจจุบันมีความสัมพันธ์เชิงข้อมูลกับ SoC ที่สถานะก่อนหน้า จึงใช้ ANN ชนิดหนึ่งที่มีชื่อว่า Recurrent Neural Network (RNN) [4] ในการประมาณสถานะประจุ ซึ่ง RNN มีโครงสร้างคล้ายกับ ANN ปกติ แต่มีข้อแตกต่างคือมีการเก็บค่าสถานะก่อนหน้าเอาไว้ใช้สำหรับป้อนเข้าสู่โครงข่ายสถานะปัจจุบัน อย่างไรก็ตาม RNN ไม่สามารถประมาณสถานะประจุให้มีความแม่นยำได้ดีพอ เนื่องจากไม่มีความทรงจำระยะยาวทำให้ลืมข้อมูลในช่วงแรก จึงเสนอ Long short-term memory (LSTM) [5] ในการประมาณสถานะประจุ ซึ่งคือ RNN ชนิดหนึ่งที่มีทั้งความทรงจำระยะสั้นและระยะยาวทำให้สถานะประจุที่ได้จากการประมาณมีความแม่นยำมากยิ่งขึ้น วิธีการประมาณสถานะประจุโดยวิธีการนี้สามารถเรียกได้ว่าเป็นวิธี data-driven [6]

1.2 จุดมุ่งหมายและวัตถุประสงค์

- 1.2.1 เพื่อศึกษาพฤติกรรมของแบตเตอรี่ลิเทียมไอออน
- 1.2.2 เพื่อศึกษาโครงข่ายประสาทเทียม (Artificial Neural Network) และการเรียนรู้เชิงลึก (Deep learning)
- 1.2.3 เพื่อศึกษาวิธีการประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออนโดยโครงข่าย Long short-term memory (LSTM)
- 1.2.4 เพื่อศึกษาการนำโมเดลโครงข่ายประสาทเทียมไปทำให้เป็นจริง (Realization) ในระบบฝังตัว (Embedded System)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.3 ทฤษฎีหรือแนวคิดที่ใช้ในการวิจัย

เนื่องจากพฤติกรรมที่ไม่เป็นเชิงเส้นของแบตเตอรี่ลิเทียมไอออน ทำให้การหาโมเดลของแบตเตอรี่เพื่อนำมาใช้ในการประมาณสถานะประจุนั้นมีขั้นตอนยุ่งยาก โดยโครงข่ายประสาทเทียมมีข้อได้เปรียบในการประมาณความสัมพันธ์ที่ไม่เป็นเชิงเส้นโดยอาศัยชุดข้อมูลของอินพุตและเอาต์พุตจำนวนมากป้อนเข้าสู่โครงข่าย โดยไม่จำเป็นต้องรู้เกี่ยวกับโมเดลของแบตเตอรี่ก็สามารถประมาณสถานะประจุนั้นได้ อย่างไรก็ตาม ในการประมาณสถานะประจุนั้นของแบตเตอรี่โดยโครงข่ายประสาทเทียม นั้นต้องใช้ทั้งแรงดันระหว่างขั้วและกระแสไฟฟ้ามาเป็นอินพุตของกระบวนการประมาณ โดยชุดข้อมูลที่นำมาใช้เป็นอินพุตนั้นเป็นข้อมูลลำดับที่มีความยาวมากและขึ้นอยู่กับเวลารวมถึงพฤติกรรมที่ไม่เป็นเชิงเส้น ทำให้โครงข่ายประสาทเทียม Long short-term memory (LSTM) มีความเหมาะสมที่จะนำมาประยุกต์ใช้ในการประมาณสถานะประจุนั้นของแบตเตอรี่ลิเทียมไอออน

1.4 ขอบเขตการวิจัย

1.4.1 ศึกษาภาษา Python และ library TensorFlow เพื่อใช้ในการสร้างโมเดลการประมาณสถานะประจุนั้นของแบตเตอรี่โดย LSTM

1.4.2 ออกแบบและสร้างวงจรประมาณสถานะประจุนั้นของแบตเตอรี่

1.4.3 ทดสอบและประเมินประสิทธิภาพการทำงานของโมเดลการประมาณสถานะประจุนั้นของแบตเตอรี่โดย Root Mean Squared Error (RMSE)

1.4.4 โมเดลการประมาณสถานะประจุนั้นของแบตเตอรี่สามารถประมวลผลบนระบบฝังตัว (Embedded System)

1.4.5 โมเดลการประมาณสถานะประจุนั้นของแบตเตอรี่ สามารถประมาณสถานะประจุนั้นจากโปรไฟล์ที่จำลองการวิ่งของรถยนต์ไฟฟ้าต่างๆ (Driving Cycle Source)

1.5 ประโยชน์ที่ได้รับจากการวิจัย

1.5.1 สามารถเข้าใจพฤติกรรมของแบตเตอรี่ลิเทียมไอออน

1.5.2 สามารถเข้าใจการทำงานและโครงสร้างของโครงข่าย LSTM (Long short-term memory)

1.5.3 สามารถสร้างโมเดลการประมาณสถานะประจุนั้นของแบตเตอรี่โดย LSTM ได้อย่างมีประสิทธิภาพ

1.5.3 โมเดลโครงข่าย LSTM สามารถประมาณสถานะประจุนั้นของแบตเตอรี่ได้อย่างถูกต้องและแม่นยำ

1.5.4 สามารถสร้างวงจรประมาณสถานะประจุนั้นของแบตเตอรี่ได้

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

2.1 แบตเตอรี่ลิเทียมไอออน

แบตเตอรี่ (Battery) คืออุปกรณ์เคมีไฟฟ้าที่ทำหน้าที่กักเก็บพลังงาน ในรูปแบบพลังงานเคมีหรือพลังงานไฟฟ้า ซึ่งกระแสไฟฟ้าเกิดจากการเปลี่ยนแปลงพลังงานเคมีเป็นพลังงานไฟฟ้า โดยองค์ประกอบหลักของเซลล์แบตเตอรี่มีดังนี้

- ขั้วลบ (Negative electrode) หรือ แอโนด (Anode) เป็นขั้วที่ประจุลบเข้ามาอยู่และเมื่อทำปฏิกิริยาเคมีจะปลดปล่อยอิเล็กตรอนสู่วงจรภายนอกหรือเกิดปฏิกิริยาออกซิเดชัน (Oxidation reaction)
- ขั้วบวก (Positive electrode) หรือ แคโทด (cathode) เป็นขั้วที่ประจุบวกเข้ามาอยู่และเมื่อทำปฏิกิริยาเคมีจะรับอิเล็กตรอนจากวงจรภายนอกหรือเกิดปฏิกิริยารีดักชัน (Reduction reaction)
- สารละลายอิเล็กโทรไลต์ (Electrolyte solution) ประกอบด้วยเกลือที่แตกตัวทำให้ประจุไฟฟ้าสามารถถ่ายโอนไปมาระหว่างขั้วบวกกับขั้วลบ
- แผ่นแยก (Separator) ทำหน้าที่แยกกันทางไฟฟ้าระหว่างขั้วบวกกับขั้วลบ เพื่อป้องกันการลัดวงจรจากภายใน

แบตเตอรี่สามารถแบ่งออกเป็น 2 ประเภทหลักคือ เซลล์ปฐมภูมิ (Primary cell) และเซลล์ทุติยภูมิ (Secondary cell) โดยเซลล์ปฐมภูมิเป็นเซลล์ที่ใช้แล้วหมดไป ไม่สามารถอัดประจุไฟฟ้าใหม่ได้ เนื่องจากปฏิกิริยาเคมีเกิดขึ้นได้ทิศทางเดียว ไม่สามารถเกิดปฏิกิริยาเคมีย้อนกลับได้จึงใช้ได้เพียงครั้งเดียว ส่วนเซลล์ทุติยภูมิ สามารถอัดประจุไฟฟ้าใหม่ได้ทำให้สามารถใช้ได้หลายครั้ง เนื่องจากปฏิกิริยาเคมีเกิดขึ้นได้สองทิศทางคือปฏิกิริยาเคมีไปข้างหน้า และปฏิกิริยาเคมีย้อนกลับ


แบตเตอรี่ลิเทียมไอออน จัดอยู่ในประเภทเซลล์ทุติยภูมิที่สามารถอัดประจุไฟฟ้าใหม่ได้ ซึ่งมีโครงสร้างภายในเซลล์ดังนี้

- ขั้วลบ (Negative electrode) หรือ แอโนด (Anode) ใช้วัสดุคาร์บอนที่มีรูพรุน เช่น แกรไฟต์ (Graphite) หรือแกรฟีน (Graphene)
- ขั้วบวก (Positive electrode) หรือ แคโทด (cathode) ใช้ Lithium Metal Oxide ซึ่ง

ตัว Metal คือธาตุที่ทำมาจากโลหะเช่น Co, Mn, Ni หรือ Al

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- สารละลายอิเล็กโทรไลต์ (Electrolyte solution) ใช้ตัวทำละลายออร์แกนิก (Organic solvent) ร่วมกับเกลือลิเทียมเป็นอิเล็กโทรไลต์
- แผ่นแยก (Separator) ใช้ฟิล์มพลาสติกที่มีรูพรุนขนาดเล็กทำจาก Polyethylene (PE) หรือ Polypropylene (PP)
- Current collector เป็นตัวนำไฟฟ้าที่ใช้ในการต่อกับวงจรภายนอก เพื่อนำกระแสไฟฟ้าไปใช้งาน โดยวัสดุที่นำมาใช้เป็นตัวนำไฟฟ้า ต้องมีความเข้ากันได้กับวัสดุขั้วบวกและขั้วลบ เพื่อป้องกันการกัดกร่อนทางเคมีระหว่างตัวนำไฟฟ้าและอิเล็กโทรด ซึ่งขั้วบวกใช้ Al ส่วนขั้วลบใช้ Cu [1]



รูปที่ 2.1 โครงสร้างและกระบวนการทำงานภายในเซลล์ของแบตเตอรี่ลิเทียมไอออนขณะคายประจุ [7]

2.1.1 หลักการทำงานของแบตเตอรี่ลิเทียมไอออน

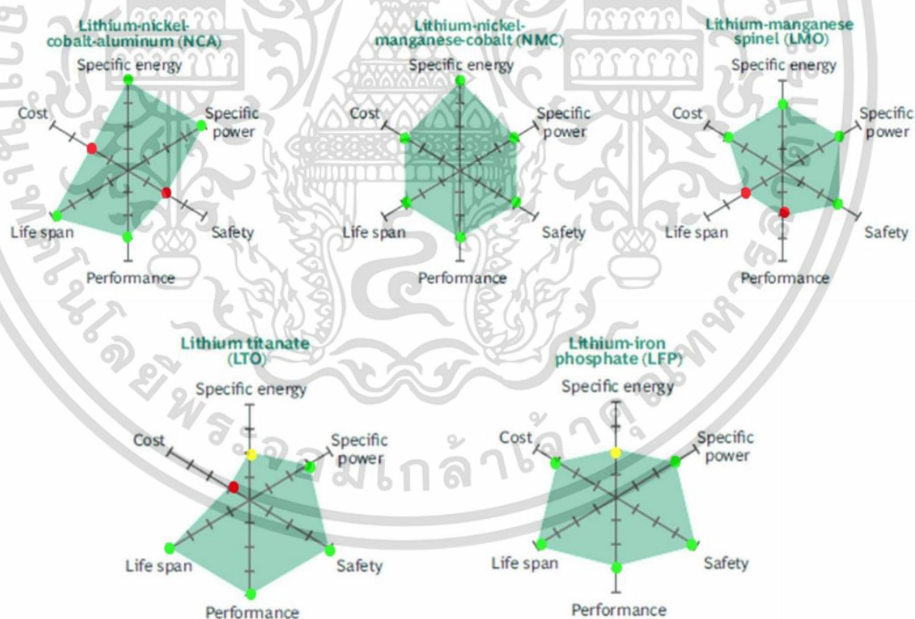
หลักการทำงานของแบตเตอรี่ลิเทียมไอออนคือ กระแสไฟฟ้าเกิดจากการเคลื่อนที่ของประจุ Li^+ ในสารละลายอิเล็กโทรไลต์ ไปมาระหว่างขั้วลบและขั้วบวก โดยการเกาะไปกับ Solvent molecule โดยที่ความเข้มข้นของสารละลายอิเล็กโทรไลต์ไม่เปลี่ยนแปลง และในระหว่างที่ประจุ Li^+ แทรกเข้าและแทรกออกในโครงสร้างผลึกของอิเล็กโทรด เรียกกระบวนการนี้ว่า Intercalation และ Deintercalation

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.1 ระหว่างกระบวนการทำงานของแบตเตอรี่ลิเทียมไอออนขณะคายประจุ อิเล็กตรอนและประจุ Li^+ จะเคลื่อนที่จากขั้วลบไปยังขั้วบวก ส่วนกระแสไฟฟ้าภายในเซลล์จะไหลตรงข้ามกับทิศทางการเคลื่อนที่ของอิเล็กตรอนคือจากขั้วบวกไปยังขั้วลบ ในทางตรงกันข้ามถ้าเป็นขณะอัดประจุ อิเล็กตรอนและประจุ Li^+ จะเคลื่อนที่จากขั้วบวกไปยังขั้วลบ ส่วนกระแสไฟฟ้าภายในเซลล์จะไหลจากขั้วลบไปยังขั้วบวก [1]

2.1.2 แบตเตอรี่ลิเทียมไอออนชนิดต่างๆ

แบตเตอรี่ลิเทียมไอออนแต่ละชนิดจะเรียกชื่อตามวัสดุโลหะที่ใช้เป็นขั้วบวกเช่น Lithium-Cobalt (LCO) ใช้ Lithium Cobalt Oxide (LiCoO_2) หรือ Lithium-Nickel-Manganese-Cobalt (NMC) ใช้ Lithium Nickel Manganese Cobalt Oxide ($\text{Li}(\text{Ni}, \text{Mn}, \text{Co})\text{O}_2$) โดยทั่วไปแบตเตอรี่ลิเทียมไอออนแต่ละชนิดจะเปลี่ยนแปลงเพียงวัสดุโลหะที่ใช้เป็นขั้วบวก ส่วนขั้วลบส่วนมากจะใช้เหมือนกันคือแกรไฟต์ ซึ่งแบตเตอรี่ลิเทียมไอออนแต่ละชนิดก็มีลักษณะเด่นในแต่ละด้านที่แตกต่างกันขึ้นอยู่กับว่าต้องการนำแบตเตอรี่ไปใช้งานในด้านใด [1]



รูปที่ 2.2 แบตเตอรี่ลิเทียมไอออนแต่ละชนิดที่นิยมใช้ในปัจจุบัน [8]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.3 คำศัพท์และคำจำกัดความเกี่ยวกับแบตเตอรี่ลิเทียมไอออน

คำศัพท์และคำจำกัดความที่ใช้ในการศึกษาเกี่ยวกับแบตเตอรี่ลิเทียมไอออน แสดงดังตารางต่อไป [1]

ตารางที่ 2.1 คำศัพท์และคำจำกัดความเกี่ยวกับแบตเตอรี่ลิเทียมไอออน

คำศัพท์	หน่วย	คำจำกัดความ
ความจุพลังงาน (Specific Energy)	Wh/kg Wh/l	พลังงานของแบตเตอรี่ ต่อหน่วยน้ำหนักหรือปริมาตร ขึ้นอยู่กับคุณลักษณะของวัสดุเคมีของแบตเตอรี่และการบรรจุหีบห่อ ถ้าความจุพลังงานมีค่าสูงแบตเตอรี่ยิ่งใช้งานได้นาน แต่ขึ้นอยู่กับน้ำหนักหรือปริมาตรของแบตเตอรี่ด้วย
ความจุกำลังไฟฟ้า (Specific Power)	W/kg W/l	กำลังไฟฟ้าของแบตเตอรี่ที่คายออกมาต่อหน่วยน้ำหนักหรือปริมาตร ขึ้นอยู่กับคุณลักษณะของวัสดุเคมีของแบตเตอรี่และการบรรจุหีบห่อ เป็นตัวกำหนดขนาดของแบตเตอรี่ในการบรรจุวัสดุประสงค์การใช้งาน และเป็นตัวกำหนดว่าแบตเตอรี่สามารถอัดประจุและคายประจุได้เร็วเท่าไร
ความจุพลังงาน (Discharge Capacity)	Ah	ปริมาณพลังงานไฟฟ้าที่บรรจุอยู่ในแบตเตอรี่ มีค่าเท่ากับกระแสไฟฟ้าที่มีหน่วยเป็นแอมแปร์คูณกับเวลาที่หน่วยเป็นชั่วโมง ในขณะที่แบตเตอรี่จ่ายกระแสไฟฟ้าที่มีความต่างศักย์คงที่
อัตราการจ่าย กระแสไฟฟ้า (Discharge rate)	C	กระแสไฟฟ้าที่จ่ายออกมาโดยส่วนใหญ่แสดงด้วย C-rate เพื่อเทียบกับความจุพลังงานของแบตเตอรี่ โดย 1 C หมายถึงกระแสไฟฟ้าที่ทำให้คายประจุออกจนหมดภายในหนึ่งชั่วโมง ดังนั้นถ้า 2 C หมายถึงกระแสไฟฟ้า Ah/2 ทำให้คายประจุออกจนหมดภายในครึ่งชั่วโมง
แรงดันกำหนด (Nominal Voltage)	V	ค่าแรงดันเฉลี่ยในระหว่างกระบวนการจ่ายไฟออกจนหมดของแบตเตอรี่ เมื่อจ่ายกระแสไฟฟ้าด้วยอัตรา 0.2 C โดยส่วนมากแบตเตอรี่ลิเทียมไอออนมีแรงดันกำหนดอยู่ที่ประมาณ 3.6-3.7 V
ความจุพิกัด (Rated Capacity)	Ah	ปริมาณพลังงานไฟฟ้าที่บรรจุอยู่ในแบตเตอรี่ ในกระบวนการจ่ายไฟออกจนหมดเมื่อจ่ายกระแสไฟฟ้าด้วยอัตรา 0.2 C โดยส่วนมากแบตเตอรี่ลิเทียมไอออนมีความจุพิกัดอยู่ที่ประมาณ 3,000-3,250 mAh
แรงดันเปิดวงจร (Open Circuit Voltage)	V	แรงดันไฟฟ้าระหว่างขั้วอิเล็กโทรดบวกและลบเมื่อไม่มีโหลด
แรงดันระหว่างขั้ว	V	แรงดันไฟฟ้าระหว่างขั้วอิเล็กโทรดบวกและลบเมื่อมีโหลด

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Terminal Voltage)		
ความลึกของการคายประจุ (DOD – Depth of Discharge)	%	ความจุพลังงานที่ได้ถูกคายออกไปแสดงเป็นเปอร์เซ็นต์ของความจุพลังงานสูงสุดของแบตเตอรี่ การคายประจุจนถึง 80% DOD จะเรียกว่าการคายประจุเชิงลึก ซึ่ง DOD จะมีค่าเท่ากับ 1-SOC ด้วยเช่นกัน
แรงดันจบ/แรงดันตัด (Cut off Voltage)	V	แรงดันสุดท้ายระหว่างขั้วอิเล็กโทรดบวกและลบระหว่างกระบวนการอัดหรือคายประจุ ค่าแรงดันนี้ขึ้นอยู่กับอัตราการอัดหรือคายประจุ และสถานะประจุ (State of Charge หรือ SoC ซึ่งคือค่าที่ตรงข้ามกับ DOD) และมักจะมีค่าแตกต่างจากแรงดันกำหนดเล็กน้อย โดยส่วนมากแบตเตอรี่ลิเทียมไอออนผู้ผลิตจากโรงงานอุตสาหกรรมจะกำหนดแรงดันจบอยู่ที่ 2.5 V แต่เวลาใช้งานจริงจะกำหนดแรงดันจบอยู่ที่ 3 V
อายุ (Cycle life)	Cycle	จำนวนครั้งในการวนรอบอัดประจุและคายประจุก่อนที่จะสูญเสียความสามารถในการรับประจุสำหรับแบตเตอรี่ชนิดอัดประจุใหม่ได้ มักนิยามไว้เมื่อความจุพลังงานลดลงเหลือ 80% ของค่าความจุกำหนด
ประสิทธิภาพเชิงคูลอมบ์ (Coulombic Efficiency)		อัตราส่วนซึ่งมักแสดงเป็นเปอร์เซ็นต์ของความจุพลังงานขณะคายประจุต่อค่าความจุพลังงานขณะที่อัดประจุ

2.1.4 คุณลักษณะเฉพาะของแบตเตอรี่ลิเทียมไอออน

แบตเตอรี่ลิเทียมไอออนได้รับความนิยมในการใช้งานอย่างแพร่หลาย เนื่องจากประกอบไปด้วยข้อดีมากมายดังนี้ [1]

- ความจุพลังงานสูง ความจุพลังงานต่อปริมาตรและน้ำหนักในระดับ 500 Wh/l และ 230 Wh/kg ตามลำดับ
- ช่วงแรงดันในการใช้งานสูงกว่าแบตเตอรี่ทุติยภูมิชนิดอื่น ๆ แรงดันกำหนดต่อเซลล์สูงประมาณ 3.6-3.7 V เมื่อเทียบกับแรงดันกำหนดของแบตเตอรี่ Ni-MH อยู่ที่ 1.2 V ซึ่งมากกว่าถึง 3 เท่า
- กำลังไฟฟ้าสูงประมาณ 2000 W/kg จ่ายในระยะเวลาสั้นๆได้
- การสูญเสียประจุขณะไม่ได้ใช้งาน (Self-discharge) ต่ำเพียง 2-3% ต่อเดือน
- ไม่มี Memory Effect
- มีขนาดเล็กและน้ำหนักเบา
- ค่าประสิทธิภาพเชิงคูลอมบ์สูง เกือบ 100% หลังจากรอบการใช้งานครั้งแรก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- อายุการใช้งาน (Cycle Life) สูงสามารถใช้งานได้มากกว่า 1,000 รอบ
- สามารถทำงานได้ดีในย่านอุณหภูมิที่กว้าง (-25 °C ถึง 45 °C)

แบตเตอรี่ลิเทียมไอออนก็ยังข้อดีอยู่เช่นกันดังนี้

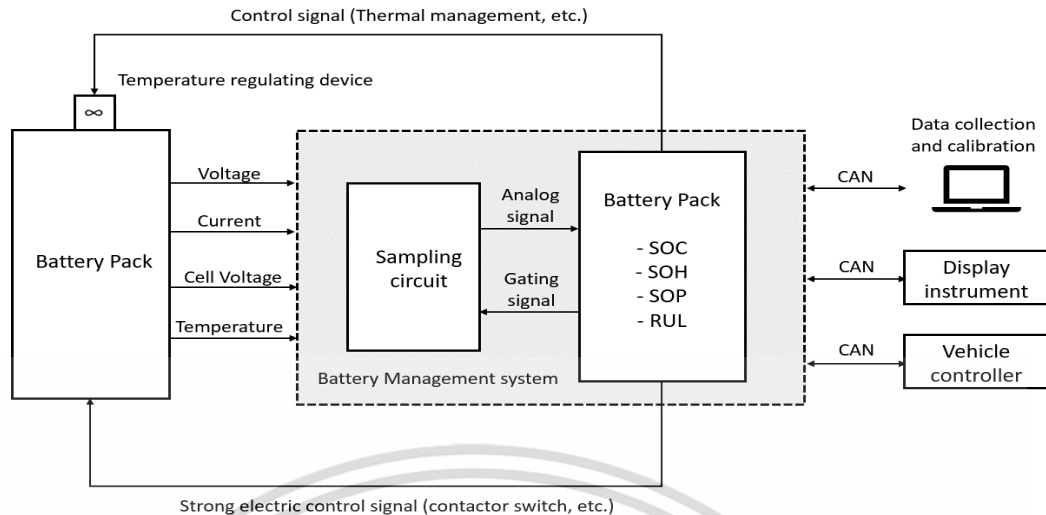
- ลิเทียมเป็นธาตุที่ติดไฟง่าย จึงจำเป็นต้องมีวงจรป้องกันแบตเตอรี่เพื่อหลีกเลี่ยงการเกิด Exothermic reaction จากการอัดประจุเกินจนอาจทำให้เกิด Thermal runaway
- การใช้งานแบตเตอรี่ที่อุณหภูมิต่ำ และการอัดประจุเกินมากเกินไปด้วยกระแสที่สูง ส่งผลให้เกิด Lithium Plating
- อุณหภูมิมีผลต่อการใช้งาน หากอุณหภูมิสูงเกินไปจะทำให้ทำให้ความต้านทานภายในเพิ่มขึ้น ส่งผลให้แบตเตอรี่เสื่อมสภาพไวยิ่งขึ้น
- ราคายังสูงกว่าแบตเตอรี่ชนิดอื่นหากเทียบราคาต่อ Wh

2.2 ระบบจัดการแบตเตอรี่ (Battery Management System)

ระบบจัดการแบตเตอรี่ (Battery Management System) หรือ BMS เป็นสิ่งจำเป็นสำหรับการรับรองความปลอดภัยของแบตเตอรี่ และทำหน้าที่บริหารจัดการหรือควบคุมเพื่อให้บรรลุวัตถุประสงค์ดังนี้

- Protection and Safety: ช่วยรับรองความปลอดภัยของผู้ปฏิบัติงานจากอันตรายจากไฟฟ้าดูด และความปลอดภัยของแบตเตอรี่จากความผิดปกติขณะทำงาน เช่น การอัดประจุเกิน, การคายประจุเกิน, การใช้งานที่อุณหภูมิสูงและต่ำเกินไป และการลัดวงจรภายนอก
- Performance: ประกอบด้วยหลายฟังก์ชัน อาทิเช่น สถานะประจุ (Stage of Charge – SoC), สถานะสุขภาพ (Stage of Health - SoH), สถานะกำลัง (State of Power – SoP), สถานะพลังงาน (State of Energy - SoE), Cell Balance, Cell monitoring และอื่นๆ
- Cycle Life: สามารถประมาณสถานะสุขภาพ (SoH) และอายุการใช้งานที่เหลืออยู่ของแบตเตอรี่ได้อย่างแม่นยำ เพื่อที่จะสามารถตรวจสอบสุขภาพของแบตเตอรี่ได้ว่าเสื่อมสภาพไปมากน้อยเพียงใดและยังสามารถนำมาใช้ต่อได้อีกหรือไม่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 แผนผังการทำงานของระบบจัดการแบตเตอรี่ [9]

ระบบจัดการแบตเตอรี่เปรียบเสมือนสมองกลในการจัดการและดูแลการทำงานของแบตเตอรี่ ซึ่งเป็นศูนย์กลางของระบบแบตเตอรี่ทั้งหมด โดยจะรวบรวมข้อมูลผ่านเซนเซอร์ต่างๆ เช่น เซนเซอร์วัดกระแสไฟฟ้า, เซนเซอร์วัดแรงดันไฟฟ้า หรือเซนเซอร์วัดอุณหภูมิ จากนั้นจะทำการประมวลผลผ่านอัลกอริทึมต่างๆ เช่น สถานะประจุ (SOC), สถานะสุขภาพ (SoH) หรือ สถานะกำลัง (SoP) และแสดงผลออกมาผ่านหน้าจอ หรือสามารถส่งข้อมูลไปแสดงผลบนซอฟต์แวร์ได้ โดยใช้ CAN เป็นตัวกลางในการสื่อสารสำหรับการส่งและรับข้อมูล ฟังก์ชันพื้นฐานที่จำเป็นของระบบจัดการแบตเตอรี่ประกอบด้วย [1]

1. Sensing and high-voltage control: BMS ต้องสามารถวัดแรงดันไฟฟ้า, กระแสไฟฟ้า และอุณหภูมิของแบตเตอรี่ได้ นอกจากนี้ยังต้องสามารถตรวจจับความผิดปกติของการแยกกันทางไฟฟ้าระหว่างขั้วบวกหรือขั้วลบกับ Chassis ground, การควบคุมคอนแทคเตอร์ในระหว่างการต่อหรือต่อกับแบตเตอรี่ และระบบการจัดการความร้อน
2. Protection: BMS ต้องประกอบด้วยระบบอิเล็กทรอนิกส์เพื่อปกป้องผู้ปฏิบัติงานจากแบตเตอรี่ขณะทำงาน และตัวแบตเตอรี่เองจากการอัดประจุเกิน, การคายประจุเกิน, กระแสไฟฟ้าเกิน, การลัดวงจรของแบตเตอรี่ และการทำงานที่อุณหภูมิสูงเกินไป
3. Interface: BMS ต้องสื่อสารเป็นประจำกับซอฟต์แวร์ที่แสดงผลข้อมูลเกี่ยวกับชุดแบตเตอรี่ โดยรายงานพลังงานและกำลังไฟที่เหลืออยู่ และตัวบ่งชี้อื่นๆ เกี่ยวกับสถานะของแบตเตอรี่ นอกจากนี้จะต้องบันทึกข้อผิดพลาดที่ผิดปกติหรือเหตุการณ์การละเมิดใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หน่วยความจำถาวร เพื่อสำหรับการวินิจฉัยความผิดปกติที่เกิดขึ้น ซึ่งอาจส่งผลทำให้เกิด
อัตราภัยกับแบตเตอรี่

4. Performance management: BMS ต้องสามารถประมาณสถานะประจุ (SOC) ของแต่ละเซลล์แบตเตอรี่ รวมทั้งคำนวณพลังงานที่เหลืออยู่ภายในแบตเตอรี่ และสามารถปรับสมดุลระหว่างเซลล์ในชุดแบตเตอรี่
5. Diagnostics: BMS ต้องสามารถประมาณสถานะสุขภาพ (SOH) ของแบตเตอรี่ รวมถึงการตรวจจับความผิดปกติที่เกิดขึ้น อีกทั้งยังจำเป็นต้องประเมินสถานะอายุการใช้งาน (SOL) ของแบตเตอรี่

2.3 สถานะประจุ (Stage of Charge - SoC)

สถานะประจุ (State of Charge) หรือ SoC คือระดับปริมาณประจุของแบตเตอรี่ที่แสดงเป็นเปอร์เซ็นต์ ซึ่งสามารถหาได้จากค่าความจุที่ยังคงเหลืออยู่ของแบตเตอรี่เทียบกับค่าความจุพิกัดของแบตเตอรี่ ซึ่งค่าความจุพิกัดของแบตเตอรี่สามารถทราบได้จากผู้ผลิต เมื่อแบตเตอรี่อัดประจุเต็ม SoC มีค่าเท่ากับ 100% และเท่ากับ 0% เมื่อแบตเตอรี่ไม่มีประจุคงเหลืออยู่ ดังนั้นจึงจำเป็นต้องประมาณสถานะประจุให้มีความแม่นยำเพื่อรับรองความปลอดภัยของแบตเตอรี่ เนื่องจากสถานะประจุไม่สามารถวัดได้โดยตรง จึงจำเป็นต้องหาวิธีในการประมาณสถานะประจุ โดยทั่วไปการประมาณสถานะประจุสามารถทำได้หลากหลายวิธี ซึ่งวิธีที่นิยมและแพร่หลายคือ วิธีตัวนับคูลอมบ์ (Coulomb Counting) และวิธีการแรงดันเปิดวงจร (Open Circuit Voltage – OCV) [2]

2.3.1 วิธีตัวนับคูลอมบ์ (Coulomb Counting)

วิธีตัวนับคูลอมบ์ หรือวิธีการรวมกระแส (Current Integration Method) เป็นวิธีที่ถูกใช้คำนวณ SoC โดยทั่วไป วิธีนี้อาศัยการอ่านค่ากระแสไฟฟ้าที่ไหลผ่านแบตเตอรี่ จากนั้นสถานะประจุสามารถคำนวณได้จากการอินทิเกรตกระแสไฟฟ้าของแบตเตอรี่เทียบกับเวลาดังสมการที่ 2.1

$$\text{SoC}(t) = \text{SoC}(t_0) + \frac{\int_{t_0}^t I(t) dt}{Q_{\text{Rated}}} \quad (2.1)$$

เมื่อ $\text{SoC}(t_0)$ คือ SoC เริ่มต้น, $I(t)$ คือ กระแสไฟฟ้าขณะอัดหรือคายประจุให้กับแบตเตอรี่ และ Q_{Rated} คือ ความจุพิกัดของแบตเตอรี่ (Rated Capacity)

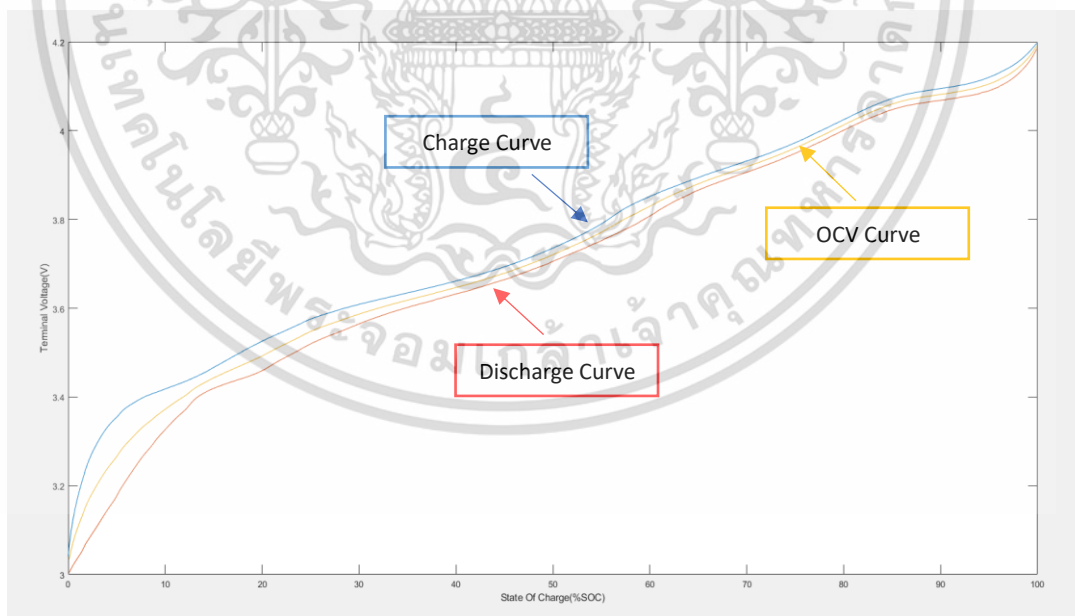
การประมาณสถานะประจุให้มีความแม่นยำโดยวิธีตัวนับคูลอมบ์ ขึ้นอยู่กับความแม่นยำของเซนเซอร์วัดกระแสไฟฟ้าและค่าความผิดพลาดเริ่มต้นของ SoC ด้วยเหตุนี้จึงจำเป็นต้องมีการปรับเทียบเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนำไปใช้ประโยชน์ในการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่า SoC เป็นระยะเพื่อที่จะลดค่าความผิดพลาดสะสม ทำให้ SoC ที่ได้จากการประมาณมีความถูกต้องและแม่นยำมากยิ่งขึ้น

2.3.2 วิธีการแรงดันเปิดวงจร (Open Circuit Voltage - OCV)

วิธีแรงดันเปิดวงจรสถานะประจุสามารถประมาณได้ จากกราฟความสัมพันธ์ระหว่างแรงดันเปิดวงจรกับสถานะประจุของแบตเตอรี่ (OCV-SoC curve) ซึ่งแรงดันไฟฟ้าเปิดวงจรได้รับผลกระทบอย่างมีนัยสำคัญมากขึ้นจากกระแสไฟฟ้าของแบตเตอรี่และอุณหภูมิ ถึงแม้ว่าวิธีการนี้ง่ายต่อการประมาณสถานะประจุ แต่อย่างไรก็ตามหากจะใช้วิธีการนี้แบตเตอรี่ต้องอยู่ในสภาวะพักผ่อนเป็นเวลานาน (Static Equilibrium) กล่าวคือแบตเตอรี่ไม่ได้ต่อกับโหลดเป็นเวลานาน ดังนั้นวิธีการนี้จึงไม่สามารถประมาณสถานะประจุได้ขณะแบตเตอรี่ถูกใช้งาน

ในการหาแรงดันเปิดวงจรในสภาวะปกติสามารถหาได้จาก ค่าเฉลี่ยของกราฟแรงดันระหว่างช่วงขณะอัดประจุและคายประจุด้วยกระแสคงที่ภายในสภาวะที่สามารถควบคุมได้ จากนั้นสถานะประจุสามารถประมาณได้จากกราฟเปรียบเทียบ (Lookup Table) ของ OCV-SoC curve แสดงดังรูปที่ 2.4 ซึ่งจะเห็นได้ว่าที่ SoC เท่ากับ 100% แรงดันเปิดวงจร (OCV) จะมีค่าประมาณ 4.2 V ในขณะที่ SOC เท่ากับ 0% แรงดันเปิดวงจร (OCV) จะมีค่าประมาณ 3 V



รูปที่ 2.4 กราฟความสัมพันธ์ระหว่างแรงดันเปิดวงจรกับสถานะประจุของแบตเตอรี่ (OCV-SoC curve) [2]

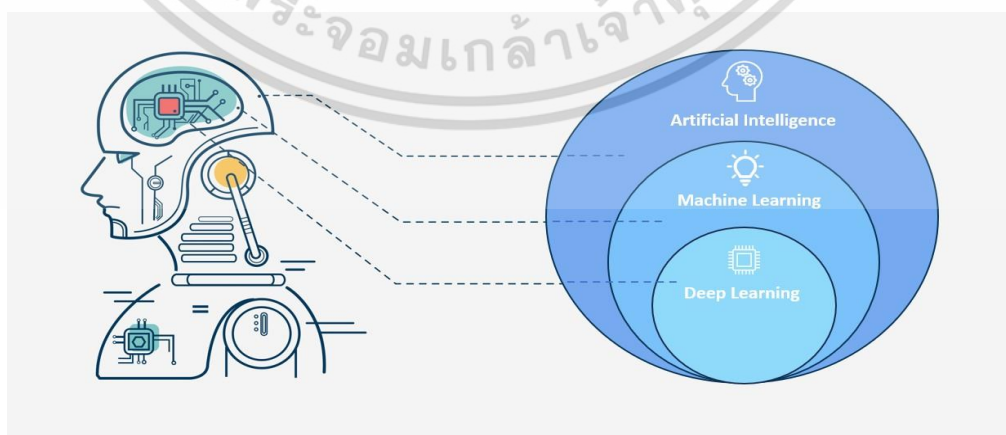
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 ปัญญาประดิษฐ์ (Artificial Intelligence - AI)

ปัญญาประดิษฐ์ (Artificial Intelligence - AI) เป็นศาสตร์แขนงหนึ่ง ที่มีมาตั้งแต่ ค.ศ.1956 เป็นเรื่องที่เกี่ยวข้องกับการศึกษาวิจัยและพัฒนาระบบคอมพิวเตอร์รวมถึงจักรกลให้มีความสามารถอันชาญฉลาดในการเรียนรู้ สามารถจดจำ แยกแยะ และประมวลผลข้อความ ภาพ เสียง ได้อย่างน่าทึ่ง เช่น การสร้างหุ่นยนต์, การสร้างสมองกล, การสร้างระบบประสาทรับรู้เลียนแบบมนุษย์, การสร้างระบบการมองเห็นภาพ, การประมวลผลภาษาธรรมชาติของมนุษย์, การช่วยตัดสินใจ, การคาดการณ์, การทำนาย หรือการทำอะไรต่างๆ ที่มีการตัดสินใจแทนมนุษย์ การทำให้หุ่นยนต์สื่อสารโต้ตอบกับมนุษย์ได้ ฯลฯ

Machine Learning (ML) เป็นศาสตร์ย่อยแขนงหนึ่งของ AI ที่ทำให้คอมพิวเตอร์หรือสมองกลเกิดการเรียนรู้จากข้อมูลหรือจากกระบวนการเรียนรู้ด้วยเครื่องจักรกล แล้วนำความรู้นั้นมาใช้ในการวิเคราะห์ คาดการณ์ หรือขับเคลื่อนสิ่งต่าง ๆ ให้กับ AI เช่น การแสดงข้อมูล, การแนะนำ, การตัดสินใจ, การควบคุมหุ่นยนต์ เครื่องจักร หรืออื่น ๆ โดยอาจกล่าวได้ว่า Machine Learning เป็นส่วนสำคัญที่สนับสนุนการทำงานของ AI ก็ว่าได้

Deep Learning (DL) เป็นศาสตร์แขนงย่อยที่อยู่ใน Machine Learning อีกชั้นหนึ่ง ซึ่งมีเป้าหมายเช่นเดียวกับ Machine Learning คือทำให้คอมพิวเตอร์เกิดการเรียนรู้ แล้วนำความรู้นั้นมาใช้งาน แต่ Deep Learning ใช้วิธีการหรือเทคนิคลักษณะโครงข่ายประสาทเทียม (Artificial Neural Network) มีความลึกหลายชั้น (Deep Neural Network: DNN) ที่เลียนแบบการทำงานของเซลล์โครงข่ายสมอง โดยในวิทยานิพนธ์เล่มนี้จะเน้นไปที่ Deep Learning เป็นหลัก เนื่องจากมีการใช้ Deep Learning มาช่วยในการประมาณสถานะประจักษ์ที่มีความถูกต้องและแม่นยำ




รูปที่ 2.5 ภาพรวมของปัญญาประดิษฐ์ (AI) [10]


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดย Machine Learning และ Deep learning ต่างมีจุดมุ่งหมายเดียวกันคือ การทำให้ระบบคอมพิวเตอร์หรือสมองกลเกิดเรียนรู้ได้ด้วยตนเอง แล้วนำความรู้เหล่านั้นมาใช้งานต่อ แต่ก็มี ความแตกต่างกันอยู่บ้าง โดยขอยกตัวอย่างของการเขียนโปรแกรมแบบทั่วไป (Traditional Programming) เปรียบเทียบกับการใช้ Machine Learning และ Deep Learning ดังนี้

Traditional Programming



Machine Learning



รูปที่ 2.6 การเขียนโปรแกรมแบบทั่วไปเปรียบเทียบกับการใช้ Machine Learning [10]

การสร้างหรือเขียนโปรแกรมปกติทั่วไป (Traditional Programming) มีวิธีการคือ ผู้พัฒนาหรือโปรแกรมเมอร์จะทำการรวบรวม ศึกษาวิเคราะห์ความต้องการ รายละเอียดของงาน และรายละเอียดอื่น ๆ พร้อมทั้งเลือกหรือกำหนดวิธีการคำนวณประมวลผลหรืออัลกอริทึมจากนั้นก็เขียนโปรแกรมให้มีการทำงานของลอจิกตามที่ต้องการ กล่าวคือผู้พัฒนาเป็นคนสร้างโปรแกรมในส่วนของ การคำนวณ เงื่อนไข การตัดสินใจต่าง ๆ ตามลักษณะงาน ในส่วนขั้นตอนการใช้งานโปรแกรม เมื่อใส่ อินพุต (Input) เข้าไปประมวลผลในโปรแกรมจะได้ผลลัพธ์เอาต์พุต (Output) ออกมาดังแสดงใน รูปที่ 2.6

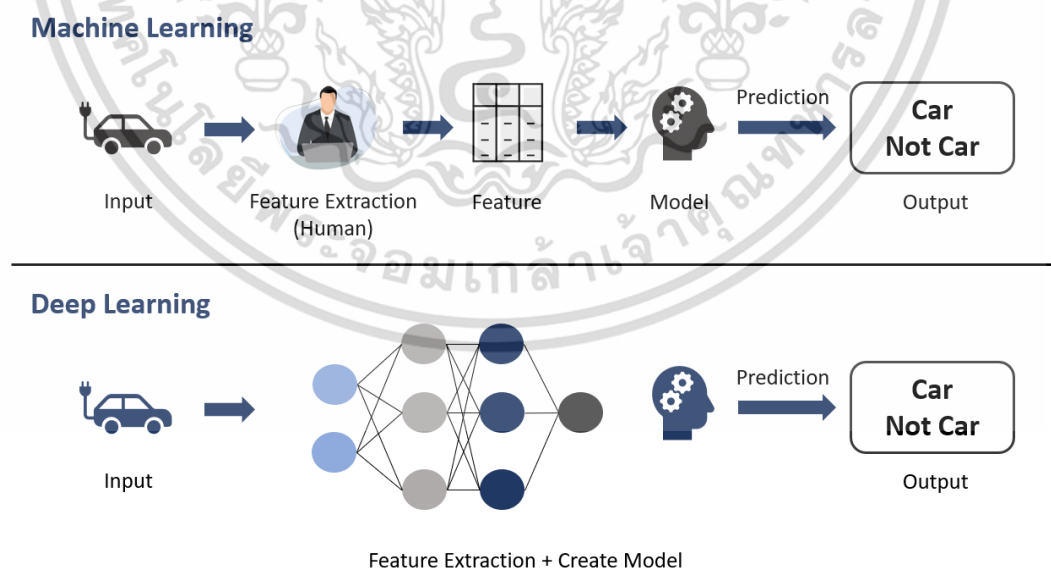
โดย Machine Learning มีความแตกต่างตรงที่ ในส่วนของโปรแกรมที่ทำการคำนวณ ประมวลผล การกำหนดเงื่อนไขของโปรแกรม การตัดสินใจต่างๆ เป็นเหมือนกับมันสมองหลักของ โปรแกรมหรือที่เรียกว่า โมเดล (Model) จะถูกสร้างโดยคอมพิวเตอร์ โดยผู้พัฒนาจะนำชุดข้อมูล (Dataset) ทั้งที่เป็นส่วน Data (Input) และ Output (Label หรือ Target) เข้าไปให้คอมพิวเตอร์ เรียนรู้ เรียกกระบวนการนี้ว่าการ Train, การสอน หรือการฝึกฝนข้อมูล เพื่อให้คอมพิวเตอร์สร้าง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โมเดลหรือสร้างสมองขึ้นมา เมื่อได้โมเดลที่เกิดจากการฝึกฝนแล้ว ก็สามารถนำโมเดลนี้ไปทำนายเอาต์พุตในอนาคตต่อไปได้ โดยการรับอินพุตค่าใหม่เข้ามาจากนั้นส่งเข้าไปประมวลผลใน Model Inference ซึ่งโมเดลจะทำนายเอาต์พุตออกมาดังแสดงในรูปที่ 2.6

ชุดข้อมูล (Dataset) ที่นำเข้าไป Train หรือนำไปฝึกฝนให้คอมพิวเตอร์เกิดการเรียนรู้ นั้นจะต้องคัดหรือค้นหาข้อมูลที่เป็นคุณลักษณะเด่น (Feature) เองเช่น ระบบจำแนกแยกแยะมะนาวกับส้มเขียวหวาน คุณลักษณะเด่นที่สามารถใช้แยกแยะได้คือ ขนาด, ลักษณะเปลือก และสี หรือ ระบบจำแนกปลากับแมว คุณลักษณะเด่นที่ชัดเจนก็เช่น มีขาหรือมีครีบ ฯลฯ ประเด็นสำคัญคือ ใน Machine Learning การค้นหาข้อมูล Feature (Feature Extraction) นี้จะดำเนินการโดยมนุษย์

ในขณะที่ Deep Learning สามารถทำการเรียนรู้และค้นหา Feature (Feature Extraction) ได้ด้วยตัวเอง โดยที่ไม่ต้องใช้มนุษย์ช่วย ด้วยโครงข่ายประสาทเทียมหลายชั้นเช่น ในระบบจำแนกแยกแยะปลากับแมว สามารถนำรูปภาพปลาหรือแมวป้อนเข้าสู่โครงข่ายได้เลย โดยที่ไม่จำเป็นต้องหาหลักคุณลักษณะเด่นก่อนเช่น มีขา, มีครีบ หรือมีหาง ซึ่งตัว Deep Learning จะทำการค้นหา Features ให้เองเปรียบเสมือนกับการเรียนรู้จากรูปภาพโดยตรง ซึ่งคล้ายกับการที่สอนเด็กโดยการเอาภาพแมวให้ดู แล้วเด็กบอกว่านี่คือแมว เอาภาพสุนัขให้ดูแล้วเด็กบอกว่านี่คือสุนัข จะเห็นได้ว่า Deep Learning มีการทำงานคล้ายกับสมองมนุษย์เป็นอย่างมาก



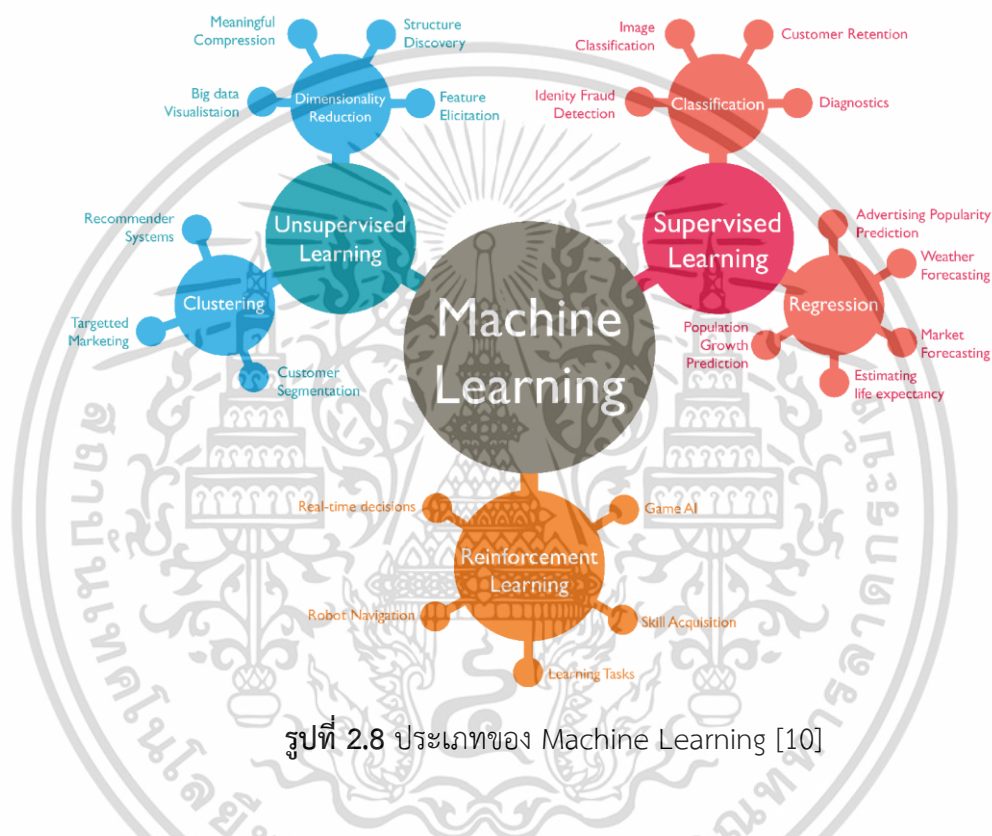
รูปที่ 2.7 กระบวนการทำงานของ Machine Learning และ Deep learning [10]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5 Machine Learning

Machine Learning สามารถแบ่งออกเป็น 3 ประเภทดังนี้ [10]

- Supervised Learning: การเรียนรู้แบบมีผู้สอน
- Unsupervised Learning: การเรียนรู้แบบไม่มีผู้สอน
- Reinforcement Learning: การเรียนรู้แบบเสริมแรง



รูปที่ 2.8 ประเภทของ Machine Learning [10]

2.5.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

เป็นการเรียนรู้แบบที่ต้องมีการสอน โดยการให้คอมพิวเตอร์เรียนรู้จากชุดข้อมูลที่น่าเข้าไปฝึกฝน ซึ่งชุดข้อมูลที่น่าเข้าไปฝึกฝนเรียกว่า Training data หรือ Training set แต่ชุดข้อมูลที่น่าไปฝึกฝนต้องมี Label กำกับไว้ด้วย โดย Supervised Learning สามารถแบ่งออกเป็น 2 ประเภทย่อยได้ดังนี้

- Classification (การจำแนกประเภท) คือการจำแนกข้อมูลออกเป็นประเภทต่างๆ ตามที่ Label กำหนดไว้ ซึ่งโมเดลจะให้คำตอบออกมาเป็น Label หรือ Class เท่านั้น ไม่สามารถให้คำตอบที่นอกเหนือจาก Label ในชุดฝึกฝน หรือให้คำตอบออกมาเป็นตัว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เลขที่ผ่านการคำนวณได้ เช่น การแยกเพศว่าเป็นผู้หญิงหรือผู้ชาย, การแยกแยะว่าเป็นแมวหรือสุนัข ฯลฯ

- Regression (การวิเคราะห์การถดถอย) คือการนำอินพุตเข้าไปฝึกฝนและให้คำตอบออกมาเป็นตัวเลขเท่านั้น คำตอบไม่สามารถออกมาเป็น Label หรือ Class ได้ เช่น การทำนายการขึ้นลงราคาหุ้น, การทำนายการใช้วัตถุดิบในอนาคต หรือการทำนายผลทำนายผลกำไร ฯลฯ

2.5.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

เป็นการเรียนรู้แบบที่ไม่ต้องมีการสอน โดยชุดข้อมูลที่ใช้ในการฝึกฝนไม่จำเป็นต้องใช้ชุดข้อมูลที่มี Label จึงเรียกว่า Unsupervised ในการทำงานโดยป้อนข้อมูลที่ต้องการทำนาย จากนั้นโมเดลจะทำการประมวลผลข้อมูลให้เอง ซึ่งการเรียนรู้แบบนี้จะเน้นไปที่การวิเคราะห์ข้อมูลมากกว่า โดย Unsupervised Learning สามารถแบ่งออกเป็น 2 ประเภทย่อยได้ดังนี้

- Clustering (การจัดกลุ่มของข้อมูล) คือการจับกลุ่มของข้อมูลที่มีลักษณะใกล้เคียงกัน เป็นกลุ่มเดียวกัน ซึ่งการแบ่งกลุ่มในลักษณะนี้จะใช้พื้นฐานทางสถิติเข้ามาช่วย
- Dimensionality Reduction (การลดจำนวนมิติของข้อมูล) คือการลดจำนวนมิติเพื่อบีบอัดข้อมูลเป็นกลไกที่ทำให้ไม่จำเป็นต้องเก็บข้อมูลไว้ครบ แต่ก็ยังสามารถจำแนกข้อมูลได้

2.5.3 การเรียนรู้แบบเสริมแรง (Reinforcement Learning)


เป็นระบบการเรียนรู้ที่อาศัยการป้อนกลับแล้วให้ระบบเกิดการเรียนรู้แล้วปรับปรุงตัวเองเช่นระบบทรงตัวของหุ่นยนต์ เริ่มแรกหุ่นยนต์อาจล้มในตอนแรกๆ จากนั้นระบบจะทำการป้อนกลับแล้วนำค่าข้อมูลต่างๆ ในการทรงตัวมาปรับปรุงตัวเอง จนในที่สุดหุ่นยนต์สามารถทรงตัวได้อย่างมีประสิทธิภาพ

2.6 Deep Learning

สถาปัตยกรรมของ Deep Learning ประกอบด้วยโครงข่ายประสาทเทียม (Artificial Neural Network – ANN) เป็นหัวใจสำคัญของอัลกอริทึมต่างๆ ที่ใช้ในการประมวลผล ซึ่งโครงข่ายประสาทเทียมนำหลักการมาจากระบบประสาทจริงทางชีววิทยา โดยในสถาปัตยกรรมของ Deep Learning นอกเหนือจาก ANN แล้วยังมีโครงข่ายประเภทอื่นที่มีอัลกอริทึมเฉพาะทางอีกมากมาย เช่น Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Generative Adversarial Network (GAN) ในวิทยานิพนธ์เล่มนี้จะเน้นไปที่ ANN และ RNN เป็นหลัก [10]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6.1 โครงข่ายประสาทเทียม (Artificial Neural Network – ANN)



รูปที่ 2.9 โครงสร้างของโครงข่ายประสาทเทียม [10]

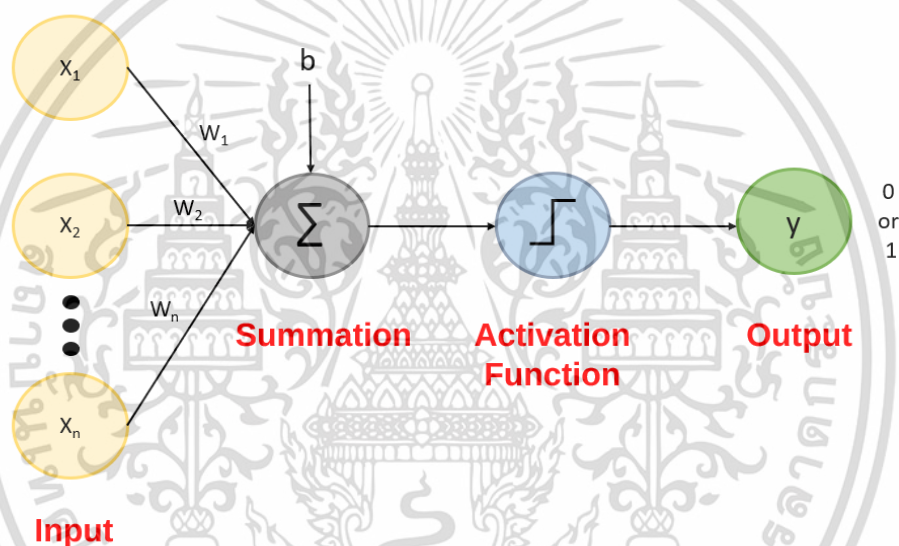
โดยปกติโครงข่ายประสาทเทียมประกอบด้วย 3 ชั้นคือชั้นอินพุต (Input layer), ชั้นซ่อน (Hidden layer) และชั้นเอาต์พุต (Output layer) ซึ่งก่อนทรงกลมในแต่ละชั้นคือเซลล์ประสาท (Neuron หรือ Perceptron) โดยโครงข่ายประสาทเทียมสามารถกำหนดความลึกของชั้น Hidden Layer ได้ซึ่งเป็นอีกหนึ่งคุณสมบัติเด่นที่ Deep Learning สามารถทำได้แต่ Machine Learning ไม่สามารถทำได้

- Input layer: ทำหน้าที่ในการรับข้อมูลเข้ามาในโครงข่ายประสาทเทียม โดย Input Layer จะเพียงชั้นเดียวเท่านั้นและมีหน้าส่งข้อมูลไปยังชั้น Hidden Layer ซึ่งในแต่ละเซลล์ประสาทจะแสดงถึง Feature ที่ป้อนเข้าสู่โครงข่าย
- Hidden layer: เป็นชั้นที่อยู่ระหว่าง Input layer และ Output layer ทำหน้าที่ในการรับข้อมูลจาก Input layer เข้ามาประมวลผล โดย Hidden layer สามารถกำหนดความลึกของจำนวนชั้นได้ตามที่ต้องการ ซึ่งการเพิ่มขึ้นหรือลดลงของจำนวนชั้นและเซลล์ประสาทจะส่งผลต่อประสิทธิภาพการทำงานของโมเดล ในการทำงานของ Hidden layer เปรียบเสมือนส่วนที่เรียนรู้ข้อมูลเชิงลึกจึงเรียกว่า Deep Learning นั่นเอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Output layer: เป็นชั้นสุดท้ายที่รอรับค่าจาก Hidden layer ชั้นสุดท้ายสุด เพื่อแสดงผลเป็นผลลัพธ์ออกมา (Label) โดยถ้าเป็น Regression ค่าตอบจะออกมาเป็นตัวเลข แต่ถ้าเป็น Classification ค่าตอบจะออกมาเป็น Class

ในการทำงานของโครงข่ายประสาทเทียมจนได้เอาต์พุตออกมา อาศัยหลักการทาคณิตศาสตร์ในการคำนวณและประมวลผล จึงขอยกตัวอย่างในการอธิบายการดำเนินการทางคณิตศาสตร์ของโครงข่ายประสาทเทียมที่มีความซับซ้อนน้อยที่สุดคือมีจำนวนเซลล์ประสาทใน Hidden layer เพียงเซลล์เดียว หรือเรียกอีกชื่อหนึ่งว่า Single-layer Perceptron



รูปที่ 2.10 Single-layer Perceptron [10]

จากรูปที่ 2.10 จะเห็นได้ว่าในชั้นอินพุตแต่ละเซลล์ประสาทจะรับค่าจากแต่ละ Feature เข้ามา โดยจะมีค่าน้ำหนัก (Weight) คูณอยู่ ซึ่ง weight จะเป็นตัวกำหนดความสำคัญของอินพุต กล่าวคือถ้าอินพุตตัวนี้มี weight มากก็จะมีผลกระทบบต่อโมเดลมาก นอกจากนี้ยังมี bias หรือเป็นตัวช่วยปรับในการคำนวณตัดสินใจ ซึ่ง bias จะมีอยู่ในทุกเซลล์ประสาทยกเว้นเซลล์ประสาทในชั้นอินพุต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ใน Hidden Layer จะเป็นชั้นที่ใช้ในการประมวลผลทางคณิตศาสตร์ โดยการรับค่าจากอินพุตที่คูณกับ weight ของแต่ละตัวนำมารวมกับค่า bias จากนั้นส่งไปประมวลผลและตัดสินใจโดย Activation Function ซึ่งจะเห็นได้ว่าสมการคณิตศาสตร์ที่ใช้ในโครงข่ายประสาทเทียม มีรากฐานมาจากสมการเส้นตรงทั่วไปแสดงดังสมการต่อไปนี้

$$y = mx + c \quad (2.2)$$


$$s = \sum_1^n w_i \cdot x_i + b \quad (2.3)$$

โดย w คือค่าน้ำหนัก (weight) เปรียบเสมือนกับค่า m ในสมการเส้นตรงและ b คือค่าช่วยปรับในการคำนวณตัดสินใจ (bias) เปรียบเสมือนกับค่า c ในสมการเส้นตรง

เมื่อนำผลรวมในสมการที่ 2.3 ไปประมวลผลและตัดสินใจโดยใช้ Activation Function คือ Binary step function ดังแสดงในสมการที่ 2.4 เป็นเกณฑ์ตัดสินใจ (Threshold) ซึ่งฟังก์ชันดังกล่าวมีลักษณะเป็นขั้นบันได 2 ค่าคือ ถ้าผลรวมของสมการมีค่ามากกว่าค่า Threshold จะให้เอาต์พุตเป็น 1 แต่ถ้าผลรวมของสมการมีค่าน้อยกว่าค่า Threshold จะให้เอาต์พุตเป็น 0 กล่าวคือเอาต์พุตสามารถเป็นได้ 2 ค่าคือ 0 กับ 1 ซึ่งในโครงข่ายประสาทเทียมสามารถกำหนด Activation Function ให้เหมาะสมกับลักษณะงานรวมถึงเป้าหมายและเอาต์พุตตามที่ต้องการได้

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

Activation Function หรือ Transfer Function ทำหน้าที่เป็นตัวประมวลผลสมการผลรวมของอินพุตและ weight รวมถึง bias เพื่อตัดสินใจว่าเอาต์พุตควรออกมาเป็นค่าอะไร ซึ่ง Activation Function ที่ใช้ในโครงข่ายประสาทเทียมมีหลากหลายรูปแบบ แต่ละแบบมีลักษณะเด่นที่แตกต่างกัน ซึ่งทำหน้าที่ในลักษณะเดียวกัน คือเป็นเกณฑ์ตัดสินใจค่าผลลัพธ์ของเอาต์พุต



รูปที่ 2.11 Activation Function [3]

ในโครงข่ายประสาทเทียม จะได้ว่าได้ยังไม่ว่าโมเดลมีความแม่นยำมากน้อยแค่ไหน ซึ่งอัลกอริทึมที่ใช้ในการประมวลผลความแม่นยำของโมเดลคือ Loss Function หรือ Cost Function เป็นฟังก์ชันที่ใช้ในการเปรียบเทียบเอาต์พุตที่ได้จากโมเดลและเอาต์พุตค่าจริง ยิ่ง Loss Function มีค่าน้อยโมเดลก็จะยิ่งมีความแม่นยำมาก ในระหว่างการฝึกฝนโมเดลจะอาศัยอัลกอริทึม Optimizer เข้ามาช่วย ซึ่งทำหน้าที่ในการคำนวณปรับค่า weight และค่า Bias ที่เชื่อมต่อกับเซลล์ประสาทให้เหมาะสม เพื่อให้ Loss Function มีค่าน้อยที่สุด ซึ่ง Optimizer ที่นิยมใช้ในการฝึกฝนโมเดลได้แก่ Stochastic Gradient Descent (SGD), Momentum, Adagrad, AdaDelta และ Adam

การเลือก Loss Function ของโมเดลให้เหมาะสมกับลักษณะงาน มีความสำคัญอย่างยิ่งต่อการฝึกฝนโมเดลเพื่อให้โมเดลที่ได้ออกมามีความแม่นยำมากที่สุด ซึ่งงานประเภท Classification ใช้ Loss Function เป็น Cross-entropy Loss ส่วนงานประเภท Regression เป็น Mean Absolute

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Error (MAE หรือ L1 Loss), Mean Squared Error (MSE หรือ L2 Loss) หรือ Root Mean Squared Error (RMSE) ดังแสดงในสมการที่ 2.5, 2.6 และ 2.7 ตามลำดับ

Mean Absolute Error (MAE)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.5)$$

Mean Squared Error (MSE)

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.6)$$


Root Mean Squared Error (RMSE)

$$\text{RMSE} = \frac{1}{n} \sum_{i=1}^n \sqrt{(y_i - \hat{y}_i)^2} \quad (2.7)$$

2.6.1 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) เป็นโครงข่ายประสาทเทียมชนิดหนึ่ง ที่ใช้กับข้อมูลที่มีลักษณะเป็นข้อมูลลำดับที่มีความสัมพันธ์กัน (Sequence) หรือข้อมูลชนิดลำดับเวลา (Time series) เช่น การวิเคราะห์ทำนายการขึ้นลงของหุ้น, การวิเคราะห์หรือพยากรณ์อากาศในอนาคต หรือการแนะนำคำ เช่น ขณะที่กำลังพิมพ์คำว่า I love แล้วระบบแนะนำคำต่อไปให้เป็นคำว่า you

สถาปัตยกรรม RNN มีโครงสร้างคล้ายกับโครงข่ายประสาทเทียม (ANN) ปกติ แต่มีข้อแตกต่างกันคือมีการนำค่าสถานะก่อนหน้า (Hidden state ก่อนหน้า หรือ h_{t-1}) มาป้อนเข้าสู่โครงข่ายสถานะปัจจุบัน โดยค่าสถานะปัจจุบันสามารถคำนวณได้จาก การนำค่าสถานะก่อนหน้ามาประมวลผลรวมกับข้อมูลอินพุต ณ ปัจจุบัน แสดงดังรูปต่อไปนี้



รูปที่ 2.12 โครงสร้างของ Recurrent Neural Network (RNN) [10]

จากรูปโครงสร้างของ RNN จะเห็นได้ว่า ในการทำงานจริงๆแล้วมีจำนวน RNN เพียงเซลล์เดียว แต่แสดงให้เห็นการทำงาน 3 รอบเมื่อคลี่การวนรอบออกมา (Unfold) ซึ่งในแต่ละรอบจะมีการนำค่า weight ของอินพุต (w_i) คูณกับอินพุตและ weight ของสถานะปัจจุบัน (w_h) คูณกับค่าสถานะก่อนหน้า รวมถึง bias (จากรูปจริงๆแล้วโครงสร้างของ RNN ประกอบด้วย bias ด้วยแต่ละเวกซ์) ไปประมวลผลเพื่อส่งเป็นค่า weight ให้กับสถานะต่อไป โดยการประมวลผลของสถาปัตยกรรม RNN สามารถแสดงได้ดังสมการต่อไปนี้

$$h_t = f_h(w_i \cdot x_t + w_h \cdot h_{t-1} + b_h) \quad (2.8)$$

$$y_t = f_y(w_o \cdot h_t + b_o) \quad (2.9)$$

โดยสมการที่ 2.8 และ 2.9 คือสมการที่ใช้ในการคำนวณหาค่าสถานะ (Hidden state) และเอาต์พุตในแต่ละรอบตามลำดับ เมื่อ h_t คือค่าสถานะ (Hidden state) ณ ปัจจุบัน, f_h คือ Activation Function ที่ใช้ในการประมวลผลในที่นี้ใช้ Relu หรือ tanh, w_i คือค่า weight ของอินพุต, x_t คือข้อมูลอินพุต ณ ปัจจุบัน, w_h คือค่า weight ของสถานะ (Hidden state) ซึ่งเป็น weight คนละตัวกับที่คูณกับค่าอินพุต โดยจะเห็นได้ว่าสถาปัตยกรรม RNN จะประกอบด้วย weight 2 ตัวคือ weight ของอินพุตและ weight ของ Hidden state ซึ่งต่างจาก ANN ทั่วไปที่มี weight เพียงตัวเดียว, h_{t-1} คือค่าสถานะก่อนหน้านี้นี้ ถ้าสถานะนี้เป็นสถานะแรกสุดจะไม่มีค่าสถานะก่อนหน้าป้อนเข้าสู่โครงข่าย

และ b_h คือค่า bias ของเซลล์ Hidden state

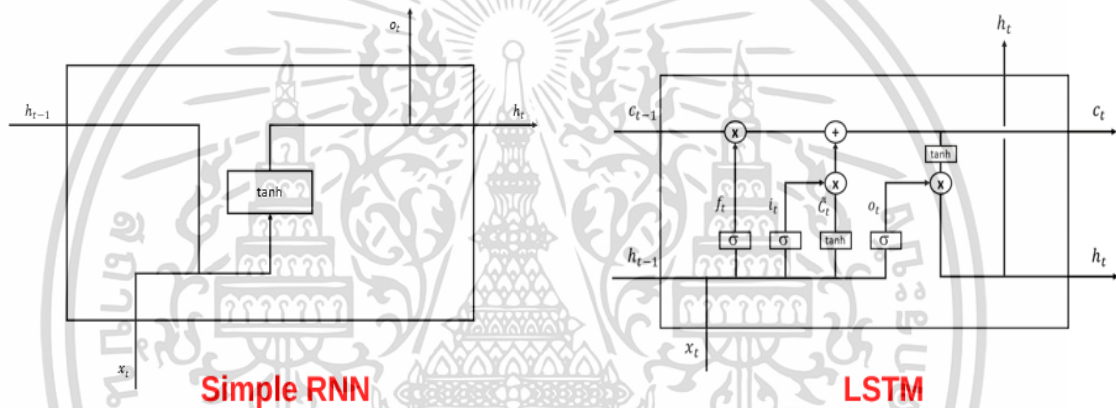
เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในส่วนของการเอาต์พุตเมื่อ y_t คือค่าเอาต์พุต ณ ปัจจุบัน, f_y คือ Activation Function ที่ใช้ในการประมวลผลในที่นี้ใช้ Sigmoid หรือ Softmax, w_o คือค่า weight ของเอาต์พุต และ b_o คือค่า bias ของเซลล์เอาต์พุต

2.6.2 Long short-term memory (LSTM)

ในกรณีที่ชุดข้อมูลที่ใช้เป็นอินพุตเป็นข้อมูลลำดับที่มีความยาวมาก ทำให้ RNN ประสบปัญหาเรื่อง Vanishing Gradient หรือ Exploding Gradient [11] จึงมีการคิดค้น RNN ชนิดหนึ่งที่มีชื่อว่า Long short-term memory (LSTM) ซึ่งเป็นโครงข่ายประสาทเทียมที่มีโครงสร้างและหลักการคล้ายกับ RNN แต่มีส่วนที่ปรับปรุงเพิ่มเติมขึ้นมาเพื่อแก้ไขปัญหาเหล่านี้



รูปที่ 2.13 สถาปัตยกรรม RNN (ซ้าย) และสถาปัตยกรรม LSTM (ขวา) [10]

Vanishing Gradient คือการที่ค่า gradient ที่ใช้สำหรับการปรับค่าพารามิเตอร์ของ weight มีค่าลดลงเรื่อยๆ จนเหลือค่าน้อยมากมีค่าเข้าใกล้ศูนย์ ส่งผลให้ไม่เกิดการอัปเดต weight อีกต่อไป ในทางตรงกันข้าม ถ้าหากค่า gradient เพิ่มขึ้นอย่างรวดเร็วในลักษณะ exponential จนมีค่าเข้าใกล้อนันต์ ส่งผลให้ไม่สามารถลู่เข้าสู่คำตอบที่ถูกต้องได้ ซึ่งปัญหานี้เรียกว่า Exploding Gradient หรือ อาจกล่าวได้ว่าถ้าหากค่า gradient มีค่าใหญ่มากๆ จะทำให้การ Optimization นั้นลู่ออกจากคำตอบที่ถูกต้อง แต่หากค่า gradient มีค่าเล็กมากๆ จะทำให้การ Optimization นั้นไม่ไปไหนเลย ด้วยเหตุนี้ทำให้ RNN ไม่สามารถเรียนรู้ข้อมูลที่มีลำดับยาวๆ ได้ อาจกล่าวอีกนัยหนึ่งได้ว่า RNN มีความสามารถเฉพาะ Short term memory ไม่มี Long term memory ทำให้ลืมข้อมูลในช่วงแรกๆ จึงมีการคิดค้น LSTM เข้ามาช่วยแก้ไขปัญหาเหล่านี้ ซึ่งมีทั้ง Long term และ Short term memory

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โครงสร้างของสถาปัตยกรรม LSTM แสดงดังรูปที่ 2.12 ซึ่งประกอบด้วย 3 gate คือ Forget gate, Input gate และ Output gate

- Forget gate: ทำหน้าที่เป็นตัวกำหนดว่าจะให้ลืมหรือเก็บ Cell state ของสถานะก่อนหน้า เพื่อส่งต่อไปประมวลผลในรอบถัดไป อาจกล่าวได้ว่า Forget gate เปรียบเสมือนประตูที่ปิดหรือเปิดเพื่อลดหรือปิดกั้นค่าก่อนหน้าที่จะบ้อนเข้าไปประมวลผลในรอบต่อไป ถ้าข้อมูลใดไม่มีความสำคัญก็จะถูกลดหรือตัดทิ้งไป
- Input gate: ทำหน้าที่เป็นตัวกำหนดว่าควรรับอินพุตค่าใหม่และ Hidden state ก่อนหน้าเข้ามาเพื่ออัปเดต Cell state ในรอบถัดไปหรือไม่ อาจกล่าวได้ว่า Forget gate ทำหน้าที่ตัดหรือลดค่าที่ไม่จำเป็น ส่วน Input gate เป็นประตูที่เปิดรับเพิ่มข้อมูลที่สำคัญเข้าไปเสริม
- Output gate: ทำหน้าที่เหมือนเป็นประตูรวบรวมและทำการกรองด้านสุดท้าย ซึ่งเป็นตัวกำหนดว่าจะส่งค่า Hidden state ที่สถานะนี้ไปสู่สถานะหน้าหรือไม่ โดยสมการในโครงสร้างของ LSTM สามารถแสดงดังสมการต่อไปนี้

$$f_t = \sigma(w_{xf} \cdot x_t + w_{hf} \cdot h_{t-1} + b_f) \quad (2.10)$$

$$i_t = \sigma(w_{xi} \cdot x_t + w_{hi} \cdot h_{t-1} + b_i) \quad (2.11)$$

$$o_t = \sigma(w_{xo} \cdot x_t + w_{ho} \cdot h_{t-1} + b_o) \quad (2.12)$$

$$\tilde{c}_t = \tanh(w_{xc} \cdot x_t + w_{hc} \cdot h_{t-1} + b_c) \quad (2.13)$$


$$c_t = f_t \odot C_{t-1} + i_t \odot \tilde{c}_t \quad (2.14)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2.15)$$

เมื่อ x_t คืออินพุตที่เวลา t , h_t คือ Hidden state หรือ Short term memory ที่เวลา t , c_t คือ Cell state หรือ Long term memory ที่เวลา t , \tilde{c}_t คือ memory ที่สถานะปัจจุบัน f_t , i_t และ o_t คือ forget gate, input gate และ output gate ตามลำดับ σ และ \tanh คือ Activation Function ชนิด Sigmoid Function และ Hyperbolic Tangent Function (\tanh), W และ b คือ weight และ bias ของเซลล์ต่างๆ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดย LSTM สามารถกำหนดลักษณะของอินพุตที่ป้อนเข้าสู่โครงข่ายและเอาต์พุตในแต่ละรูปแบบได้ แสดงดังรูปต่อไปนี้



รูปที่ 2.14 รูปแบบของอินพุตและเอาต์พุตในโครงสร้างของ LSTM [12]

2.7 Raspberry Pi 4 Model B

Raspberry Pi เป็นบอร์ดไมโครคอนโทรลเลอร์ขนาดเล็ก ถือว่าเป็นระบบฝังตัว หรือสมองกลฝังตัว (Embedded System) ที่มีประสิทธิภาพในการประมวลผลเป็นอย่างมาก อีกทั้งยังสามารถติดตั้ง OS ลงไปได้ด้วย โดยที่นิยมใช้เช่น Raspbian หรือ Ubuntu และสามารถรองรับในการเชื่อมต่อกับอุปกรณ์ภายนอกโดยผ่านขา GPIO

Raspberry Pi 4 Model B เป็นบอร์ดตัวใหม่จาก Raspberry Pi Foundation ที่ใช้ Broadcom BCM2711 Quad-Core ARM Cortex-A72 ความเร็ว 1.5 GHz เป็นหน่วยประมวลผลหลัก โดยมีขนาดของหน่วยความจำ LPDDR4-2400 RAM 8 GB บอร์ดใช้ชิพ Wireless LAN แบบ Dual-Band รองรับ 2.4 GHz และ 5 GHz พร้อมรองรับ Bluetooth 5.0 BLE มีพอร์ต LAN รองรับ Gigabit Ethernet พอร์ต USB 3.0 Host Type A จำนวน 2 พอร์ต และ USB 2.0 Host Type A จำนวน 2 พอร์ต มีพอร์ต micro-HDMI จำนวน 2 พอร์ต รองรับการเชื่อมต่อจอ 4K60P บอร์ดรุ่นใหม่ี่ต้องใช้แหล่งจ่ายไฟที่มีคอนเน็คเตอร์แบบ USB Type-C ควรใช้งานร่วมกับแหล่งจ่ายที่สามารถจ่ายกระแสได้ 3A ที่ระดับแรงดัน 5V (15 W) [13]



รูปที่ 2.15 Raspberry Pi 4 Model B

2.8 วงจรควบคุมชุดแบตเตอรี่ 18 เซลล์ด้วยการเชื่อมต่อเครือข่ายวิธี Daisy chain LTC6813-1

LTC6813-1 เป็นชุดควบคุมแบตเตอรี่หลายเซลล์ที่สามารถวัดแบตเตอรี่ที่ต่ออนุกรมกันได้ สูงสุด 18 เซลล์ โดยมีความผิดพลาดน้อยกว่า 2.2 mV ซึ่งแต่ละเซลล์นั้นมีช่วงของการวัดอยู่ระหว่าง 0 ถึง 5V แบตเตอรี่ทั้ง 18 เซลล์สามารถวัดได้ในระยะเวลา 290 μ s และเนื่องจากอัตราการรับข้อมูลที่ต่ำทำให้สามารถลดสัญญาณรบกวนความถี่สูงได้

LTC6813-1 จำนวนหลายชุดนี้สามารถเชื่อมต่อกันได้แบบอนุกรมและสามารถควบคุมได้พร้อมกันด้วยสายแบตเตอรี่แรงดันสูง โดยในแต่ละชุดมีการเชื่อมต่อแบบ isoSPI เพื่อให้มีความเร็วที่สูง มีความต้านทานต่อย่านความถี่วิทยุ (RF) และระยะทางการสื่อสารที่ไกล อุปกรณ์จำนวนหลายชุดนี้ถูกเชื่อมต่อด้วย daisy chain โดยมีหนึ่งชุดหลักเพื่อประมวลผลการเชื่อมต่อสำหรับอุปกรณ์ทั้งหมด ซึ่ง daisy chain นี้สามารถใช้งานได้ทั้งสองทิศทาง เพื่อให้มั่นใจในความสมบูรณ์ของการสื่อสาร แม้ในกรณีที่เกิดข้อผิดพลาดระหว่างเส้นทางการสื่อสาร

LTC6813-1 สามารถทำงานได้โดยตรงจากชุดแบตเตอรี่หรือจากแหล่งจ่ายไฟที่มีการ isolated ซึ่งบอร์ด LTC6813-1 นี้ประกอบไปด้วย Passive balancing สำหรับแต่ละเซลล์โดยมีการควบคุม PWM duty cycle สำหรับแต่ละเซลล์ คุณสมบัติอื่นๆ ประกอบไปด้วย 5V regulator บนบอร์ด General purpose I/O (GPIO) จำนวน 9 ขาและมีโหมดพักพอนเมื่อการใช้กระแสไฟฟาลดเหลือ 6 μ A [14]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.16 LTC6813-1

2.8.1 Daisy chain

Daisy chain คือการเชื่อมต่อระหว่างอุปกรณ์คอมพิวเตอร์ อุปกรณ์ต่อพ่วงหรือโหนดเครื่องต่อกันเป็นชุด ๆ แบบอนุกรมของคอมพิวเตอร์ซึ่งเทียบเท่ากับการต่ออนุกรมของวงจรไฟฟ้า ตัวอย่างเช่นในคอมพิวเตอร์ส่วนบุคคลมีการเชื่อมต่อแบบ daisy-chainable ได้แก่ Small Computer System Interface (SCSI) และ FireWare ที่ช่วยให้คอมพิวเตอร์สามารถสื่อสารกับฮาร์ดแวร์ของอุปกรณ์ต่อพ่วง เช่น Disk drives tape drives CD-ROM drive เครื่องพิมพ์และสแกนเนอร์ให้เร็วขึ้นและมีความยืดหยุ่นมากกว่าการเชื่อมต่อเครื่องต่อก่อนหน้านี้


ข้อได้เปรียบหลักของ Daisy chain คือมีความเรียบง่ายและสามารถปรับขนาดได้ ซึ่งผู้ใช้งานสามารถเพิ่มโหนดที่โหนดใดบนสายตามข้อสูงสุดที่กำหนดไว้ (16 โหนดใน SCSI-2 หรือ SCSI-3 เป็นต้น) และในเครือข่าย Daisy-chain นั้นเหมาะกับเครือข่ายที่มีความยาวตรงๆ จากด้านหนึ่งไปอีกด้านหนึ่ง แต่ไม่เหมาะสมกับเครือข่ายที่โหนดกระจายไปรอบๆ โดยในกรณีนี้สายเคเบิลต้องวางในลักษณะซิกแซกรอบๆ และความยาวทั้งหมดของเครือข่ายจะมีขนาดใหญ่มากเมื่อเทียบกับระยะทางจริงระหว่างโหนด ซึ่งอาจจะทำให้เครือข่ายทำงานช้าสำหรับผู้ใช้งานที่อยู่ใกล้กับปลายอีกด้านหนึ่งของสาย [15]

2.8.2 บอร์ดสาธิต DC2350B

วงจรสาธิต 2350B มีคุณสมบัติของ LTC6813-1 โดยบอร์ดจำนวนหลายบอร์ดสามารถเชื่อมต่อผ่าน สาย isolated serial interface 2 สาย (isoSPITM) เพื่อควบคุมชุดแบตเตอรี่ที่ต่ออนุกรมกันจำนวนมาก นอกจากนี้บอร์ดสาธิต DC2350B ยังมีการใช้งานเส้นทางการสื่อสารที่ซ้ำซ้อน

ของ isoSPI แบบย้อนกลับได้ และทั้งบอร์ด PCB ส่วนประกอบต่างๆ และตัวเชื่อมต่อ DuraClik ถูกเพิ่มประสิทธิภาพเพื่อลดการแพร่ EMI และลดการยอมรับได้ของ EMI

บอร์ดสาธิต DC2350B สามารถสื่อสารกับคอมพิวเตอร์ด้วยการเชื่อมต่อ Dual master isoSPI DC2972B ร่วมกับ Linduino One DC2026C ซึ่ง Linduino One ต้องโหลดข้อมูลด้วยโปรแกรมที่เหมาะสม (เรียกว่า sketch) เพื่อควบคุม IC ของชุดควบคุมแบตเตอรี่และรับข้อมูลผ่านซีเรียลพอร์ต USB Linduino One นั้นมีการเชื่อมต่อ SPI มาตรฐานที่สามารถแปลงเป็น isoSPI ได้ จากนั้นเชื่อมต่อกับพอร์ต isoSPI ของ DC2350B (ตัวเชื่อมต่อ J4 หรือ J5) และบอร์ด DC2972B มี SPI-isoSPI สองช่องสำหรับการทำงานแบบย้อนกลับ [16]




รูปที่ 2.17 บอร์ด DC2350B

2.9 บอร์ดสาธิต Dual master isoSPI Adapter DC2792B

วงจรสาคิต 2792B คือตัวแปลงสัญญาณซีเรียล SPI ไปเป็น Dual-port isoSPI ที่ใช้ตัวรับสัญญาณ isoSPI แบบ Multiplex LTC6820 และตัวเชื่อมต่อ isoSPI ขนาดเล็ก (ตัวเชื่อมต่อ Duraclik 2 หน้าสัมผัส) ซึ่งบอร์ดสามารถแทนที่ DC1941 ในกรณีที่อุปกรณ์ระบบจัดการแบตเตอรี่ (BMS) กำลังถูกใช้งาน แต่จะให้ isoSPI หลักตัวที่สองใช้คุณสมบัติทำงานย้อนกลับของ isoSPI ที่สามารถใช้งานได้ การเชื่อมต่อ SPI สามารถทำได้ผ่านสายริบบอน 14 หน้าสัมผัสชนิดดั้งเดิมจากตัวแปลง USB DC590 หรือ DC2026 หรือติดตั้งโดยตรงบน DC2026 เช่นเดียวกับ Linduino shield

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พอร์ต isoSPI ทั้งสองพอร์ตเป็นทั้งพอร์ตหลักและพอร์ตช่วย โดยการทำงานของแต่ละพอร์ต จะถูกแสดงผลด้วยแสง LED สีน้ำเงิน สำหรับการใช้งานแทน DC1941 หรือเครือข่าย isoSPI ที่ไม่สามารถย้อนกลับได้นั้นจะใช้งานพอร์ตหลักเป็นส่วนใหญ่ ซึ่งกำลังไฟฟ้าของ DC2792B ได้รับมาจาก พอร์ต USB ของคอมพิวเตอร์หลักโดยอ้อม โดยที่ตัวแปลง USB to serial กำลังถูกใช้งาน [17]



รูปที่ 2.18 การเชื่อมต่อระหว่าง DC2026 Linduino one และ DC2792B ด้วยสาย Ribbon

2.9.1 การสื่อสารอนุกรมแบบ SPI

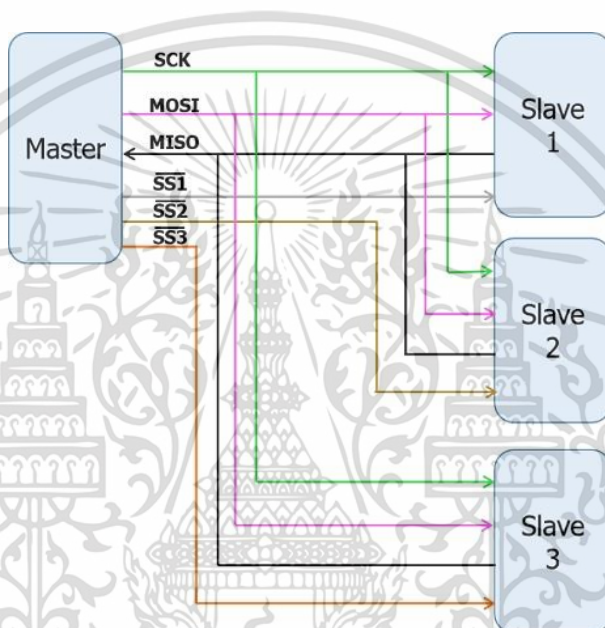
SPI ย่อมาจาก Serial Peripheral Interface คือรูปแบบของการสื่อสารข้อมูลแบบอนุกรมแบบซิงโครไนส์รูปแบบหนึ่ง ถูกพัฒนาขึ้นมาโดยบริษัทโมโตโรล่าในกลางปี ค.ศ. 1980 เพื่อใช้ในการสื่อสารระยะใกล้โดยเฉพาะในระบบสมองกลฝังตัว การสื่อสารอนุกรมแบบ SPI จะอาศัยสัญญาณนาฬิกาเป็นตัวกำหนดจังหวะการรับส่งข้อมูล ซึ่งสามารถส่งข้อมูลไปยังปลายทางและรับข้อมูลจากปลายทางกลับมาในครั้งเดียวกัน (Full Duplex) การสื่อสารอนุกรมแบบ SPI จะแบ่งอุปกรณ์ออกเป็น 2 ฝ่าย คือ Master เป็นตัวควบคุมการรับส่งข้อมูลและ Slave เป็นอุปกรณ์ที่รอรับคำสั่งจาก Master ในบัสการสื่อสารแบบอนุกรมแบบ SPI สามารถมี Slave มีได้มากกว่า 1 ตัว การสื่อสารอนุกรมแบบ SPI นั้นใช้สายสัญญาณทั้งหมด 4 สายดังนี้

1. สาย SCK Clock data ใช้สำหรับส่งสัญญาณนาฬิกาจาก Master ไปยัง Slave
2. สาย MISO Master In Slave Out ใช้สำหรับรับข้อมูลจาก slave
3. สาย MOSI Master Out Slave In ใช้สำหรับรับข้อมูลจาก Master ไปยัง Slave

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4. สาย SS/CS (Slave Select/Chip Select) ใช้สำหรับเลือก Slave ที่ต้องการใช้งาน

โดยภายในการสื่อสารระหว่าง Master กับ Slave หลาย ๆ อุปกรณ์นั้น สายสัญญาณ SCK MOSI และ MISO จะใช้งานร่วมกันในทุก Slave แต่มีเพียงสายสัญญาณ SS เท่านั้นที่ไม่ได้ใช้ร่วมกัน เนื่องจากเมื่อเวลาที่ Master ต้องการจะสื่อสารกับ Slave ตัวไหน Master จะส่งสัญญาณลอจิก LOW ให้กับ Slave ตัวนั้นผ่านสายสัญญาณ SS ทำให้สามารถเลือกสื่อสารกับ Slave ที่ต้องการได้อย่างถูกต้อง [18]



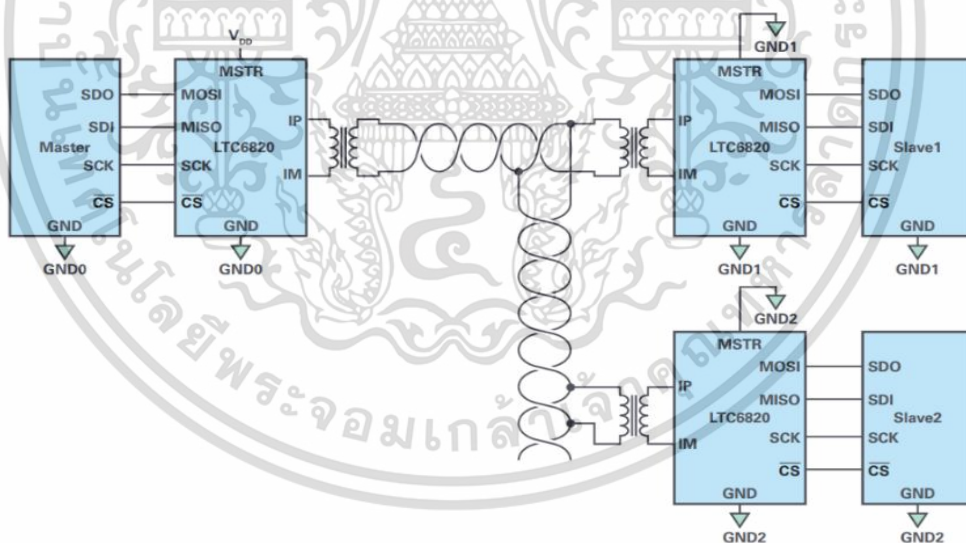
รูปที่ 2.19 การสื่อสารอนุกรมแบบ SPI ระหว่าง Master และ Slave หลายตัว

2.9.2 IsoSPI (Isolated SPI)

การสื่อสารอนุกรมแบบ SPI โดยทั่วไปนั้นเหมาะสำหรับระยะทางไม่เกิน 10 เมตร ซึ่งหากต้องการเชื่อมต่อระยะทางที่ไกลกว่าเดิม มักจะใช้ repeater ร่วมด้วย เนื่องจากความต้านทานสายที่เพิ่มขึ้นตามความยาวของสายเคเบิลทำให้เกิดการลดทอนสัญญาณ ดังนั้นสัญญาณเหล่านี้จึงต้องได้รับการขยาย นอกจากนี้ repeater ยังช่วยให้อัตราส่วนสัญญาณต่อสัญญาณรบกวน (SNR) ที่ใหญ่กว่าสามารถทำงานในเวลาเดียวกันได้ โดย repeater นั้นหมายถึง isoSPI LTC6820 ที่สามารถใช้ในการอ่านสัญญาณ

isoSPI นี้สามารถขยายสัญญาณได้อย่างง่ายดายด้วยการเพิ่มการแยกส่วนทางไฟฟ้าด้วยสายเคเบิลบิดคู่และหม้อแปลงที่เหมาะสม เนื่องจากสถานะที่รุนแรงที่มักพบในเขตอุตสาหกรรม การสื่อสารด้วยการแยกส่วนทางไฟฟ้าจึงจำเป็นเพื่อป้องกันผู้ใช้งานจากแรงดันที่เป็นอันตรายรวมถึงเพื่อให้แน่ใจว่าระบบมีความน่าเชื่อถือ นอกจากนี้การแยกส่วนยังช่วยให้สามารถวัดค่าต่างๆ ได้อย่างแม่นยำ แม้จะมีแรงดัน common - mode เป็นบางครั้ง ดังนั้นตัวคั่นสำหรับการแยกส่วนจึงเป็นกุญแจสำคัญในการแยกของ input stage จากส่วนที่เหลือของระบบในขณะที่การเชื่อมต่อยังคงเปิดใช้งานอยู่


จากการใช้งานการสื่อสารด้วย isoSPI ความซับซ้อนของวงจรสำหรับการส่งสัญญาณของการสื่อสาร SPI แบบแยกส่วนในระยะทางไกลสามารถทำให้ง่ายขึ้นได้ เนื่องจากสามารถละเว้นส่วนประกอบจำนวนมากที่จำเป็นในวงจรทั่วไปได้ และ isoSPI LTC6820 นั้นทำให้การเชื่อมต่อแบบ Daisy chain สำเร็จได้ง่ายขึ้น นอกจากนี้ยังเป็นอุปกรณ์ในอุดมคติสำหรับระบบควบคุมแบตเตอรี่เนื่องจากภายในระบบควบคุมแบตเตอรี่ต้องการการสื่อสารแบบการแยกส่วนทางไฟฟ้าเพราะว่ามีประจุบางส่วนที่สามารถระเบิดได้ เช่น ลิเทียมไอออนแบตเตอรี่ [19]



รูปที่ 2.20 การเชื่อมต่อแบบ isoSPI ที่ Master สามารถควบคุม Slave ได้หลายตัว

2.10 Linduino ONE (DC2026C)

Linduino One เป็นบอร์ดไมโครคอนโทรลเลอร์ที่คล้ายกับ Arduino UNO ซึ่งใช้ Atmel เป็นตัวประมวลผล โดยจะมีส่วนที่เพิ่มมาจากบอร์ด Arduino UNO คือ มีตัวเชื่อมต่อ QuikEval 14 ขาที่สามารถเสียบเข้ากับอุปกรณ์อนาล็อกต่าง ๆ เช่น ตัวแปลงอนาล็อกเป็นดิจิทัล ตัวแปลงดิจิทัลเป็นอนาล็อก การจัดการพลังงาน ระบบตรวจสอบและควบคุม ตัววัดแรงดันรวมของแบตเตอรี่ เป็นต้น และส่วนที่สำคัญคือมีการแยกส่วนการทำงานของระบบไฟฟ้าระหว่างข้อมูล USB และกำลังไฟฟ้า เพื่อให้ทั้งสองส่วนมีความปลอดภัยและลดการรบกวน โดยในโครงงานนี้ใช้เพื่อทำการสื่อสารกัน ระหว่างบอร์ด LTC6813 เพื่อให้ LTC6813 สามารถใช้โปรแกรม Arduino IDE เพื่อทำการเขียนโปรแกรมสั่งการได้ โดยทำการเขียนโปรแกรมผ่านโปรแกรม Arduino IDE ให้แสดงค่าแรงดันของแต่ละเซลล์แบตเตอรี่ และกระแสที่ไหลเข้าและออกจากแบตเตอรี่โดยแสดงผลผ่านจอมอนิเตอร์ [20]



รูปที่ 2.21 บอร์ด Linduino One

บทที่ 3

การออกแบบและการสร้างโมเดล การประมาณสถานะประจุของแบตเตอรี่

เนื่องจากการประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออน ชุดข้อมูลที่ใช้เป็นอินพุต เป็นข้อมูลลำดับที่มีความยาวมาก ในวิทยานิพนธ์เล่มนี้จึงเสนอวิธีการประมาณสถานะประจุของ แบตเตอรี่ โดยใช้โครงข่ายประสาทเทียมชนิดหนึ่งที่มีชื่อว่า Long short-term memory (LSTM) ในการประมาณสถานะประจุ โดยวิธีการนี้สามารถเรียกได้ว่าเป็นวิธี data-driven

การสร้างโมเดลสำหรับการประมาณสถานะประจุโดย LSTM ในวิทยานิพนธ์เล่มนี้ ใช้ภาษา Python ในการเขียนโปรแกรมสำหรับการสร้างโมเดล ซึ่งภาษา Python เป็น Open source ที่มี Package library ที่รองรับ Machine Learning และ Deep Learning และมีประสิทธิภาพในการทำงานสูง โดยการเขียนโปรแกรมสามารถเขียนผ่าน Code editor ซึ่งในที่นี้ใช้โปรแกรม Visual Studio Code (VSCode) ที่รองรับภาษา Python โดยในการสร้างโมเดลจะใช้ library ที่มีชื่อว่า TensorFlow ซึ่งเป็น library ที่ใช้ในการการสร้างและการฝึกโมเดลสำหรับ Deep Learning

3.1 ชุดทดสอบสำหรับแบตเตอรี่ลิเทียมไอออน

ในการประมาณสถานะประจุของแบตเตอรี่ ในวิทยานิพนธ์เล่มนี้ใช้แบตเตอรี่ลิเทียมไอออน LGGBMJ11865 ซึ่งมี Nominal Voltage อยู่ที่ 3.7 V และ Rated Capacity อยู่ที่ 3.25 Ah [21]



Item	Condition / Note	Specification
2.1 Capacity	Std. charge / discharge	Nominal 3350 mAh Minimum 3250 mAh
2.2 Nominal Voltage	Average	3.63V
2.3 Standard Charge	Constant current Constant voltage End current(Cut off)	0.3C (975mA) 4.2V 50mA
2.4 Max. Charge Voltage		4.2 ± 0.05V
2.5 Max. Charge Current		0.5C (1625mA)
2.6 Standard Discharge	Constant current End voltage(Cut off)	0.2C (650mA) 2.5V
2.7 Max. Discharge Current	-20 ~ 5°C	0.5C(1625mA)
	5 ~ 45°C	1.5C(4875mA)
	45 ~ 50°C	1.5C(4875mA)
2.8 Weight	Approx.	Max. 49.0 g
2.9 Operating Temperature	Charge	0 ~ 45°C
	Discharge	-20 ~ 50°C (cell skin temperature ~60°C)
2.10 Storage Temperature (for shipping state)	1 month	-20 ~ 50°C
	3 month	-20 ~ 45°C
	1 year	-20 ~ 20°C

รูปที่ 3.1 แบตเตอรี่ลิเทียมไอออน LGGBMJ11865 และคุณสมบัติที่สำคัญ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ในการทดสอบแบตเตอรี่โดยใช้ DC Electronic Power Supply DL811 และ DC Electronic Load DP3021 ทำหน้าที่อัดประจุและคายประจุให้กับแบตเตอรี่ตามโปรไฟล์ที่ต้องการเพื่อใช้เป็นอินพุตโพรไฟล์สำหรับโมเดลการประมาณสถานะประจุ และใช้คอมพิวเตอร์ในการเก็บข้อมูลขณะทำการทดสอบ แบตเตอรี่อยู่ภายในตู้ควบคุมอุณหภูมิที่อุณหภูมิ 25 °C ด้วยเหตุนี้ผลของอุณหภูมิจึงไม่ส่งผลกระทบต่อการประมาณสถานะประจุ



รูปที่ 3.2 DC Electronic Power Supply DL811 และ DC Electronic Load DP3021 [22]

3.2 โพรไฟล์กระแสไฟฟ้าสำหรับแบตเตอรี่ (Battery Current Profile)

โพรไฟล์ที่ใช้เป็นอินพุตสำหรับโมเดลการประมาณสถานะประจุคือ โพรไฟล์ที่จำลองการวิ่งของรถยนต์ไฟฟ้าในห้องทดสอบรถยนต์ไฟฟ้าโดยใช้ MATLAB EV Reference Applications Model ในการจำลอง และเลือกใช้ Driving Cycle Source เป็น WLTP ใน Class ต่างๆ ได้แก่ WLTP Class1, WLTP Class2 และ WLTP Class3 [23] โดยโพรไฟล์กระแสไฟฟ้าก่อนที่จะนำไปทดสอบแบตเตอรี่ต้องทำให้เป็นมาตรฐาน (Normalization) กับค่า Rated Capacity ของเซลล์ก่อน ขณะทำการทดสอบ ทำการเก็บและบันทึกค่าแรงดันระหว่างช่วงและกระแสไฟฟ้า เพื่อใช้เป็นอินพุตสำหรับโมเดลการประมาณสถานะประจุโดยกำหนดให้กระแสไฟฟ้าขณะคายประจุมีค่าเป็นบวก และกระแสไฟฟ้าขณะอัดประจุมีค่าเป็นลบ



รูปที่ 3.3 MATLAB EV Reference Applications Model

3.3 การเตรียมข้อมูล (Data Preprocessing)

โดยขั้นตอนนี้เป็นขั้นตอนการในการจัดเตรียมข้อมูล (Data Preprocessing) ก่อนที่จะนำชุดข้อมูล (Dataset) ป้อนเข้าสู่โมเดลโครงข่ายประสาทเทียมสำหรับการประมาณสถานะประจุ

ในขั้นตอนแรกเริ่มต้นจากการ import library ที่จำเป็นต้องใช้สำหรับการจัดเตรียมข้อมูล และการสร้างโมเดลก่อน ซึ่ง library ที่ใช้สำหรับจัดเตรียมข้อมูลจะใช้ numpy และ pandas โดย numpy ใช้สำหรับนำชุดข้อมูลมาสร้างเป็น array หรือ matrix ในมิติต่างๆ ส่วน pandas ใช้สำหรับการนำเข้าของชุดข้อมูลให้อยู่ในรูปแบบของ DataFrame ซึ่งมีลักษณะเป็นตารางประกอบด้วย 2 คอลัมป์ขึ้นไป

```
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
import tensorflow
from tensorflow.keras import Sequential
from tensorflow.keras.layers import LSTM, Dense
from sklearn.preprocessing import MinMaxScaler
from tensorflow.keras import metrics
from tensorflow.keras import backend as K
```

✓ 4.6s

รูปที่ 3.4 Library ที่ใช้สำหรับการจัดเตรียมข้อมูลและการสร้างโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นำเข้าสู่ชุดข้อมูลที่ได้อาจมาจากโปรไฟล์กระแสไฟฟ้าของแบตเตอรี่ เข้ามาให้อยู่ในรูปของ DataFrame ทั้ง training set และ test set แสดงดังรูปต่อไปนี้

```
df_train = pd.read_csv("training_set.csv")
df_test = pd.read_csv("test_set.csv")
✓ 0.0s
```


รูปที่ 3.5 การนำเข้าสู่ชุดข้อมูลให้อยู่ในรูปของ DataFrame

ขอยกตัวอย่างการทดสอบโดย training set เป็น WLTP Class3 และ test set เป็น WLTP Class2 จากรูป 3.5 จะเห็นได้ว่า DataFrame ประกอบด้วยกันทั้งหมด 3 คอลัมป์ ซึ่ง 2 คอลัมป์แรกคือ Feature ที่ใช้เป็นอินพุตสำหรับโมเดลการประมาณสถานะประจุได้แก่ กระแสไฟฟ้า และแรงดันระหว่างขั้ว ส่วนคอลัมป์ที่ 3 คือผลลัพธ์คำตอบหรือเอาต์พุต (label) ในที่นี้คือสถานะประจุ (SoC)

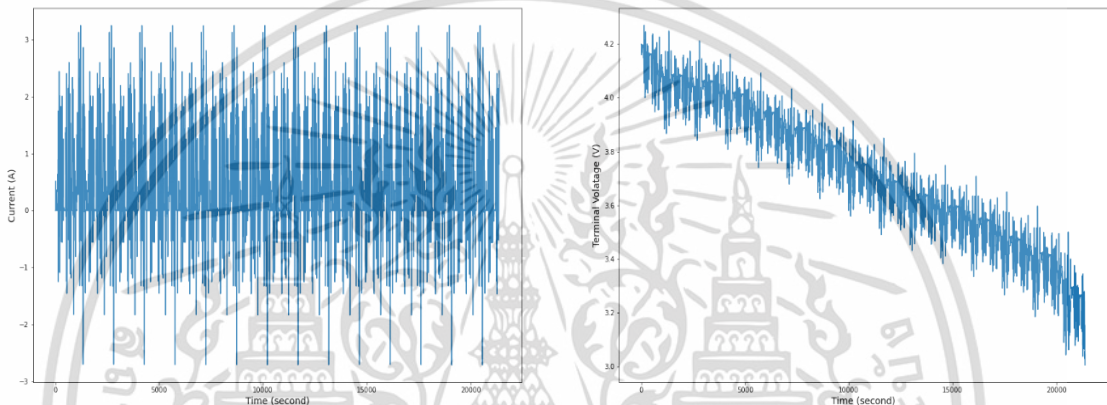
df_train				df_test			
	Im	V	SOC		Im	V	SOC
0	0.0005	4.1999	99.999995	0	0.0005	4.1999	99.999995
1	0.0006	4.1997	99.999990	1	0.0004	4.1999	99.999992
2	0.0005	4.1999	99.999985	2	0.0005	4.1999	99.999987
3	0.0007	4.1996	99.999978	3	0.0004	4.1998	99.999983
4	0.0004	4.1997	99.999975	4	0.0006	4.1998	99.999978
...
23182	0.9698	3.1569	0.075276	21368	2.0695	3.0422	0.078569
23183	1.4295	3.1182	0.061852	21369	1.8755	3.0535	0.061153
23184	1.8445	3.0823	0.044531	21370	2.2133	3.0272	0.040600
23185	2.1793	3.0515	0.024066	21371	1.9143	3.0449	0.022823
23186	2.5628	3.0172	0.000000	21372	2.4578	3.0039	0.000000

รูปที่ 3.6 training set และ test set

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)

รูปที่ 3.7 กราฟแสดงกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างขับ

(a) โพรไฟล์ WLTP Class3, (b) โพรไฟล์ WLTP Class2

3.3.1 การทำให้เป็นมาตรฐาน (Normalization)

การทำ Normalization คือการปรับค่าของชุดข้อมูลให้อยู่ในขอบเขตที่กำหนดเดียวกัน หรือ ช่วงเดียวกันก่อนที่จะป้อนเข้าสู่โมเดล เพื่อให้ในระหว่างการฝึกฝน (train) โมเดล Optimizer สามารถประมวลผลได้อย่างมีประสิทธิภาพมากขึ้น

ก่อนที่จะนำชุดข้อมูลไปทำการ Normalization ต้องทำการแปลง DataFrame ให้อยู่ในรูปแบบของ array 1 มิติที่มีขนาด $N \times 1$ ก่อน ซึ่ง N คือจำนวนแถวของชุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Im_train = df_train["Im"].values.reshape(-1,1)
V_train = df_train["V"].values.reshape(-1,1)
SOC_train = df_train["SOC"].values.reshape(-1,1)

Im_test = df_test["Im"].values.reshape(-1,1)
V_test = df_test["V"].values.reshape(-1,1)
SOC_test = df_test["SOC"].values.reshape(-1,1)

print(Im_train.shape, V_train.shape , SOC_train.shape,Im_test.shape ,V_test.shape,SOC_test.shape)
✓ 0.0s
(23187, 1) (23187, 1) (23187, 1) (21373, 1) (21373, 1) (21373, 1)

```

รูปที่ 3.8 การแปลง DataFrame เป็น array

โดยอีกหนึ่งเหตุผลที่ต้องแปลง DataFrame มาเป็น array ก่อนคือต้องการแยก DataFrame แต่ละคอลัมน์ออกจากกัน เนื่องจากการกำหนดช่วงขอบเขตการ Normalization ของแรงดันระหว่างขั้วและกระแสไฟฟ้ามีค่าไม่เท่า ซึ่งแรงดันระหว่างขั้วกำหนดให้อยู่ในช่วง [0,1] ส่วนกระแสไฟฟ้ากำหนดให้อยู่ในช่วง [-1,1] เนื่องจากโปรไฟล์กระแสไฟฟ้าของแบตเตอรี่ มีทั้งขณะอัดประจุและคายประจุ จากนั้นทำการ Normalization โดยใช้ library จาก sklearn และเลือกใช้ฟังก์ชัน MinMaxScaler หลังจากนั้นค่อยนำข้อมูลมารวมกัน

```

scalerV = MinMaxScaler()
scalerI = MinMaxScaler(feature_range=(-1,1))
V_train = scalerV.fit_transform(V_train)
Im_train = scalerI.fit_transform(Im_train)

V_test = scalerV.transform(V_test)
Im_test = scalerI.transform(Im_test)

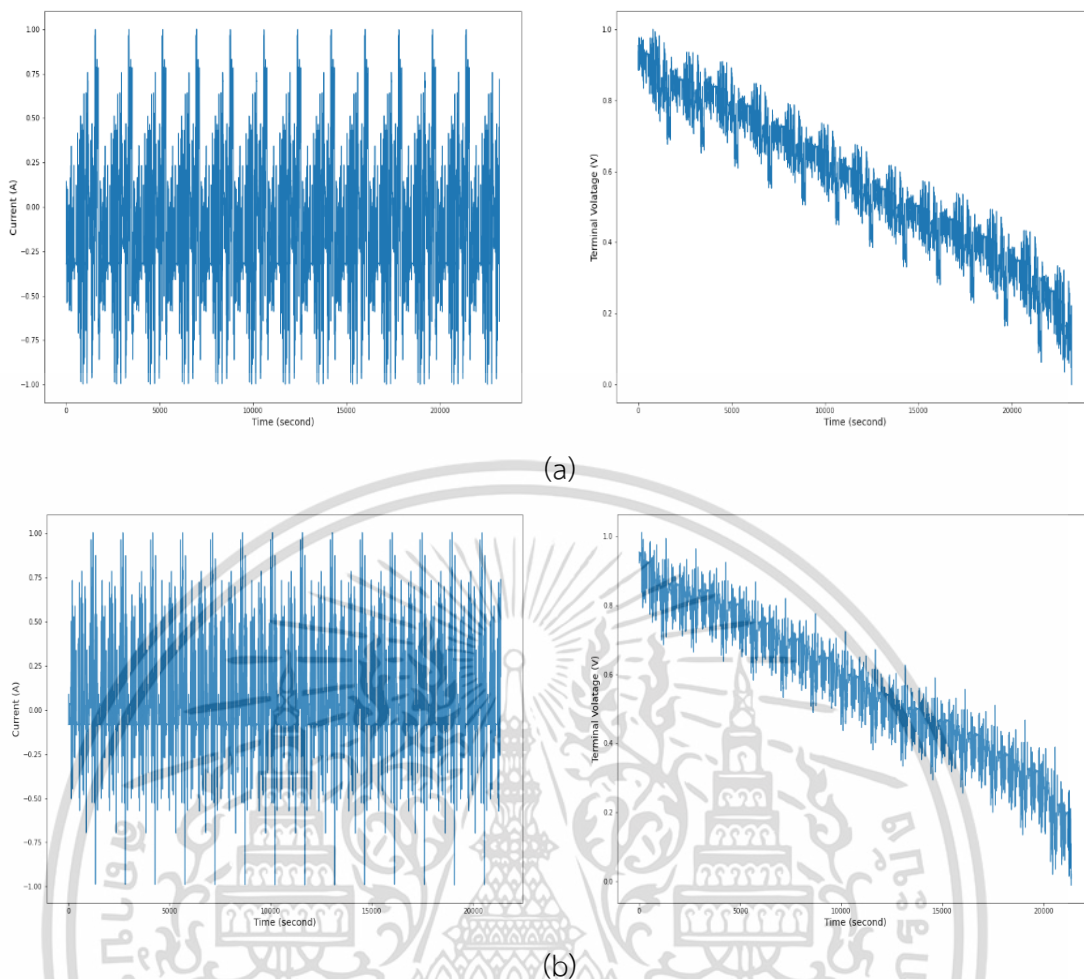
df_train = np.column_stack( (Im_train,V_train,SOC_train) )
df_test = np.column_stack( (Im_test,V_test,SOC_test) )

print(df_train.shape,df_test.shape)
✓ 0.0s
(23187, 3) (21373, 3)

```

รูปที่ 3.9 การ Normalization โดยใช้ฟังก์ชัน MinMaxScaler

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.10 กราฟแสดงกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างขั้วหลังจากการทำ Normalization
(a) โปรไฟล์ WLTP Class3, (b) โปรไฟล์ WLTP Class2

3.4 การสร้างและการฝึกฝนโมเดลโครงข่าย LSTM

ในการสร้างโมเดลการประมาณสถานะประจุของแบตเตอรี่โดย LSTM สามารถทำได้โดยการใช้ library ที่มีชื่อว่า TensorFlow ในการสร้าง ซึ่งโครงข่าย LSTM ต้องการอินพุตในรูปแบบของ array 3 มิติ โดย $input_shape = (batch_size, timesteps, features)$ ซึ่ง $batch_size$ คือจำนวนชุดข้อมูลย่อยทั้งหมด, $timesteps$ คือขนาดความยาวของชุดข้อมูลย่อย และ $features$ คือจำนวน Features ของชุดข้อมูล

เนื่องจากตอนนี้ชุดข้อมูลอยู่ในรูปของ array 2 มิติ ที่มีขนาด $N \times 3$ ดังนั้นต้องทำการแปลงให้เป็น array 3 มิติก่อน โดยการนำชุดข้อมูลที่ป้อนเข้ามาซึ่งเป็นข้อมูลลำดับแบบ Time Series แบ่งออกเป็นจำนวนชุดข้อมูลย่อยที่มีขนาดความยาวของชุดข้อมูลเท่ากับ $timesteps$ ในที่นี้ขอแทน $timesteps$ ด้วยตัวแปร k โดยกำหนดตัวแปรให้มีค่าเท่ากับ 60 และ Features มีค่าเท่ากับ 2 คือแรงดันไฟฟ้าระหว่างขั้วและกระแสไฟฟ้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในแต่ละชุดข้อมูลย่อย ภายในจะประกอบด้วยข้อมูลที่มีลำดับต่อกันไปเรื่อยๆ จนเมื่อจำนวนข้อมูลภายในชุดข้อมูลย่อยมีค่าเท่ากับ timesteps แล้วจะเริ่มชุดข้อมูลย่อยถัดไป ซึ่งภายในชุดข้อมูลถัดไป ข้อมูลลำดับแรกจะเป็นข้อมูลที่เลื่อน (shift) มาจากข้อมูลลำดับแรกของชุดข้อมูลย่อยที่ผ่านมา 1 ค่า แสดงดังต่อไปนี้

- ชุดข้อมูลย่อยที่ 1 คือแรงดันระหว่างขั้วและกระแสไฟฟ้าค่าที่ 1 ถึง 60 ซึ่งจะตรงกับเอาต์พุตคือสถานะประจุ (SoC) ค่าที่ 60
- ชุดข้อมูลย่อยที่ 2 คือแรงดันระหว่างขั้วและกระแสไฟฟ้าค่าที่ 2 ถึง 61 ซึ่งจะตรงกับเอาต์พุตคือสถานะประจุ (SoC) ค่าที่ 61
- ชุดข้อมูลย่อยที่ 3 คือแรงดันระหว่างขั้วและกระแสไฟฟ้าค่าที่ 3 ถึง 62 ซึ่งจะตรงกับเอาต์พุตคือสถานะประจุ (SoC) ค่าที่ 62
- ชุดข้อมูลย่อยที่ N-k คือแรงดันระหว่างขั้วและกระแสไฟฟ้าค่าที่ N-k ถึง N-1 ซึ่งจะตรงกับเอาต์พุตคือสถานะประจุ (SoC) ค่าที่ N-1

ดังนั้นจะได้อินพุต array 3 มิติสำหรับป้อนเข้าสู่โมเดลขนาด (N-k, k, 2) และเอาต์พุต array 1 มิติ ขนาด (N-k,1)

```
def create_lstm_data(data, k):
    X_data = np.zeros([data.shape[0]-k, k, data.shape[1]-1])
    y_data = []

    for i in range(k, data.shape[0]):
        cur_sequence = data[i-k: i, :-1]
        cur_target = data[i-1, -1]

        X_data[i-k, :, :] = cur_sequence.reshape(1, k, X_data.shape[2])
        y_data.append(cur_target)

    return X_data, np.asarray(y_data)
```

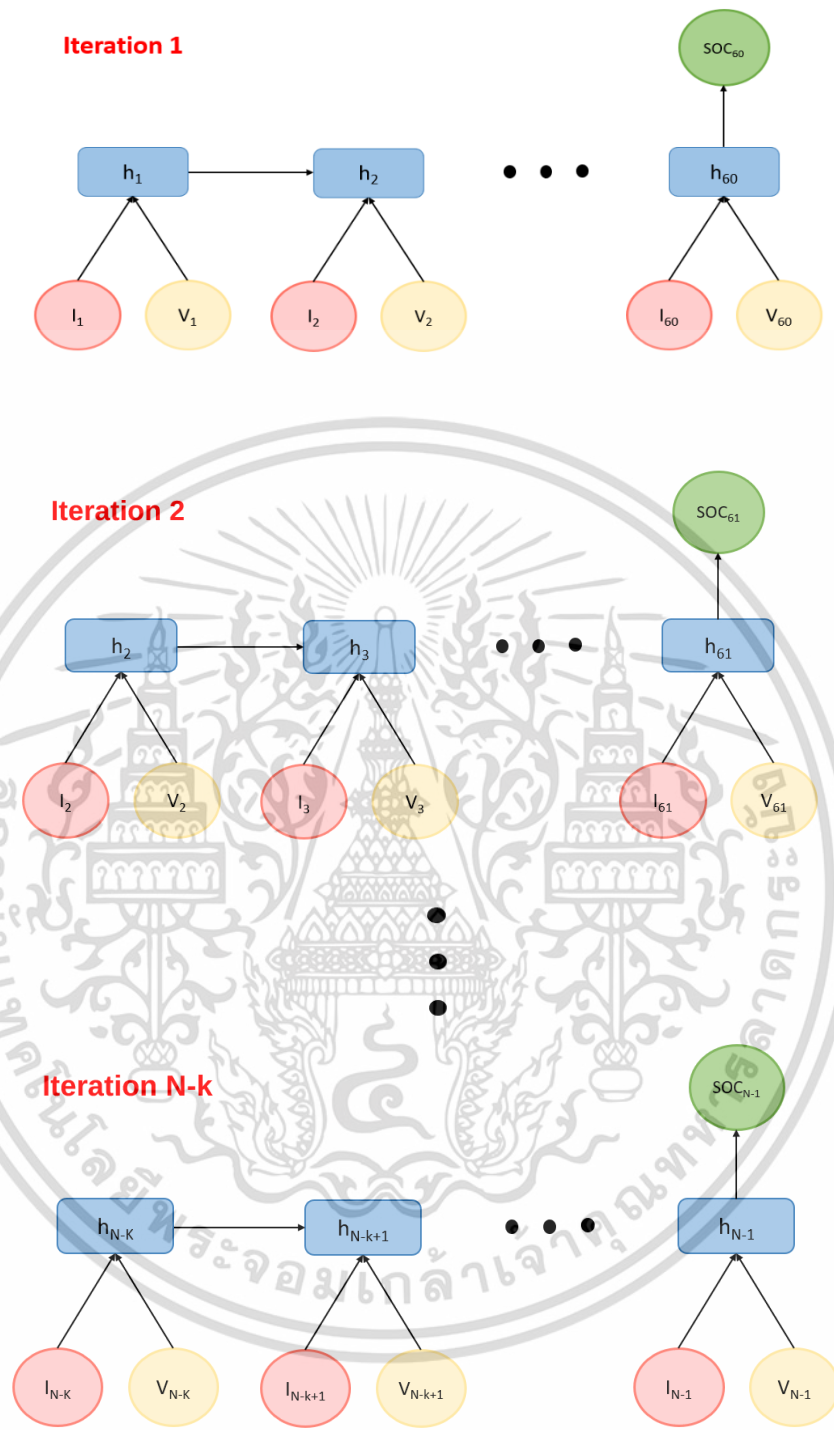
```
k = 60
X_train, y_train = create_lstm_data(df_train, k)
X_test, y_test = create_lstm_data(df_test, k)

print(X_train.shape, y_train.shape, X_test.shape, y_test.shape)
```

(23127, 60, 2) (23127,) (21313, 60, 2) (21313,)

รูปที่ 3.11 ฟังก์ชันในการสร้างอินพุตและเอาต์พุตสำหรับป้อนเข้าสู่โมเดล LSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.12 กระบวนการป้อนอินพุตเข้าสู่โครงข่าย LSTM [12]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การสร้างโมเดลการประมาณสถานะประจุโดย LSTM ทำการสร้างให้อยู่ในรูปแบบของ Many to One และกำหนด Hyperparameters ของโมเดลดังต่อไปนี้ จำนวน Hidden layer เท่ากับ 1 ชั้นซึ่งประกอบเซลล์ประสาท 10 เซลล์ [24-25], Optimizer เป็น Adam ที่มี learning rate เท่ากับ 0.01 ซึ่งค่านี้คือค่าความเร็วในการเรียนรู้ของโมเดล ถ้าหากมีค่ามากจะทำให้โมเดลสามารถเรียนรู้ได้เร็ว แต่ก็อาจจะทำให้การเรียนรู้นั้นเลยค่าผลลัพธ์ที่ต้องการ ส่วนถ้าหากมีค่าน้อยจะทำให้โมเดลเรียนรู้ได้ช้าทำให้โมเดลนำไปสู่ผลลัพธ์ที่ต้องการได้ช้า, Loss Function เป็น Root Mean Squared Error (RMSE) เนื่องจากใน library TensorFlow ไม่มี RMSE ใน Loss Function ดังนั้นต้องทำการสร้าง Loss Function RMSE ขึ้นมาเอง และโดยปกติแล้วโมเดลจะกำหนด Activation Function ให้เป็น tanh และ Recurrent Activation Function เป็น Sigmoid Function ให้เองโดยอัตโนมัติ

```
def my_rmse(y_true, y_pred):
    error = y_true - y_pred
    sqr_error = K.square(error)
    mean_sqr_error = K.mean(sqr_error)
    sqrt_mean_sqr_error = K.sqrt(mean_sqr_error)
    return sqrt_mean_sqr_error
```

✓ 0.0s

รูปที่ 3.13 Loss Function RMSE

```
model = Sequential()
model.add(LSTM(10, input_shape=(k, X_train.shape[2])))
model.add(Dense(1))
opt = tensorflow.keras.optimizers.Adam(learning_rate=0.01)
model.compile(optimizer=opt, loss= my_rmse )
```

✓ 0.1s

รูปที่ 3.14 การสร้างโมเดลโครงข่าย LSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

model.summary()
✓ 0.0s
Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
lstm (LSTM)                  (None, 10)                  520
dense (Dense)                (None, 1)                   11
-----
Total params: 531
Trainable params: 531
Non-trainable params: 0
-----


```

รูปที่ 3.15 Model Summary ของโครงข่าย LSTM

ตารางที่ 3.1 การกำหนด Hyperparameters ในโครงข่าย LSTM

Hyperparameters	
Input layer (Features)	2 Neuron
Hidden layer	10 Neuron
Output layer	1 Neuron
Activation Function	tanh
Recurrent Activation Function	Sigmoid Function
Learning rate	0.01
Learner Parameters	531
Batch size	32
epochs	50
Optimizer	Adam
Loss function	Root Mean Squared Error (RMSE)
Training Set	WLTP Class 3
Test Set	WLTP Class 2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.16 โครงสร้างการทำงานภายในของโมเดลโครงข่าย LSTM [10]


ทำการ train และ test โมเดลโครงข่าย โดยใช้ Training set เป็น WLTP Class3 และ Test set เป็น WLTP Class2 โดยผลลัพธ์ของการ train โมเดลโครงข่าย LSTM พบว่ากระบวนการ train ประมวลผลทั้งหมด 50 epochs ในขณะที่ Batch size เท่ากับ 32 และ Root Mean Squared Error (RMSE) ลดลงจนถึง 0.67%

```

history = model.fit(X_train, y_train,
                    validation_data=(X_test, y_test),
                    epochs=50, batch_size=32, verbose=1)
5m 41.8s
Epoch 1/50
723/723 [=====] - 11s 13ms/step - loss: 34.9875 - val_loss: 25.2088
Epoch 2/50
723/723 [=====] - 7s 10ms/step - loss: 14.2179 - val_loss: 2.4261
Epoch 3/50
723/723 [=====] - 7s 9ms/step - loss: 1.6553 - val_loss: 1.1444
Epoch 4/50
723/723 [=====] - 7s 9ms/step - loss: 1.1503 - val_loss: 0.7636
Epoch 5/50
723/723 [=====] - 7s 9ms/step - loss: 0.9259 - val_loss: 0.7329
Epoch 6/50
723/723 [=====] - 7s 9ms/step - loss: 0.8543 - val_loss: 0.6170
Epoch 7/50
723/723 [=====] - 7s 9ms/step - loss: 0.8110 - val_loss: 0.5855
Epoch 8/50
723/723 [=====] - 7s 9ms/step - loss: 0.7989 - val_loss: 0.7778
Epoch 9/50
723/723 [=====] - 7s 9ms/step - loss: 0.7247 - val_loss: 0.8195
Epoch 10/50
723/723 [=====] - 7s 9ms/step - loss: 0.7316 - val_loss: 0.7084
Epoch 11/50
723/723 [=====] - 7s 9ms/step - loss: 0.7276 - val_loss: 0.5771
Epoch 12/50
723/723 [=====] - 7s 9ms/step - loss: 0.6843 - val_loss: 0.6341
Epoch 13/50
723/723 [=====] - 7s 9ms/step - loss: 0.6903 - val_loss: 0.7778
...
Epoch 49/50
723/723 [=====] - 7s 9ms/step - loss: 0.5648 - val_loss: 0.7786
Epoch 50/50
723/723 [=====] - 7s 9ms/step - loss: 0.6755 - val_loss: 0.5883
    
```

รูปที่ 3.17 กระบวนการ train โมเดลโครงข่าย LSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.18 กราฟแสดงผลลัพธ์ของการ train โมเดลโครงข่าย LSTM

3.5 การประเมินประสิทธิภาพโมเดลโครงข่าย LSTM

โดยทั่วไปในการประเมินประสิทธิภาพของโมเดลการประมาณสถานะประจุโดย LSTM จะถูกประเมินโดยพิจารณาจาก Root Mean Squared Error (RMSE) ซึ่งสามารถคำนวณได้ดังสมการต่อไปนี้

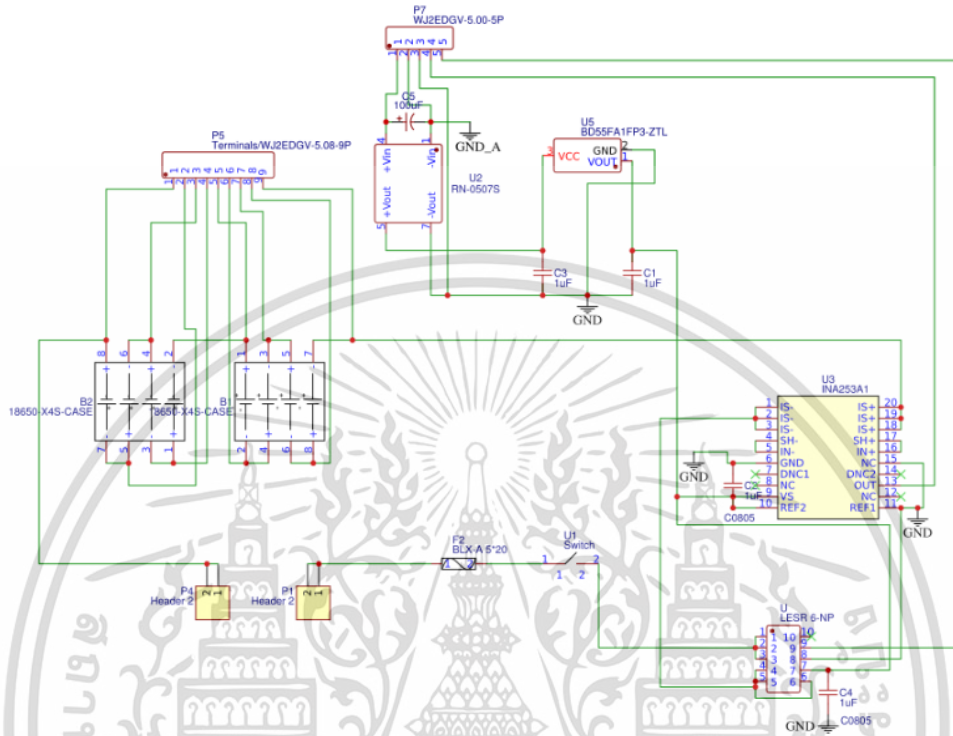
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SoC_i - \widehat{SoC}_i)^2} \quad (3.1)$$

เมื่อ n คือจำนวนข้อมูลของ SoC, SoC_i คือสถานะประจุจริงที่จุดข้อมูล i และ \widehat{SoC}_i คือสถานะประจุที่ได้จากการประมาณที่จุดข้อมูล i

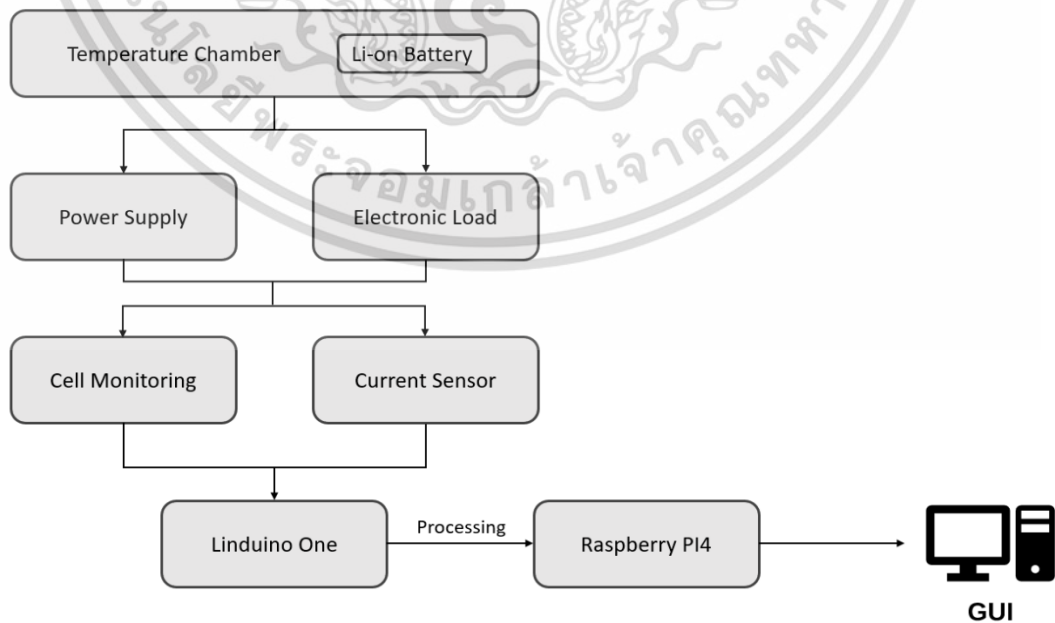
3.6 การออกแบบและการสร้างวงจรประมาณสถานะประจุ

การสร้างวงจรประมาณสถานะประจุของแบตเตอรี่โดย LSTM แบบเรียลไทม์ โดยการใช้ Arduino Uno รับค่าแรงดันไฟฟ้าระหว่างขั้วและกระแสไฟฟ้า จาก LTC6813-1 ซึ่งทำหน้าที่เป็น Cell Monitoring ในการอ่านค่าแรงดันไฟฟ้าระหว่างขั้วของแบตเตอรี่ในแต่ละเซลล์ และ Current-Shunts รุ่น INA253A3 [26] ซึ่งทำหน้าที่เป็นตัววัดค่ากระแสไฟฟ้าที่ไหลผ่านแบตเตอรี่ โดยค่าที่วัดได้จะเป็น Analog จึงต้องส่งไปแปลงค่าเป็น Digital (ADC) ที่ขา GPIO ของ LTC6813-1 จากนั้นจึงส่งเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ข้อมูลทั้งสองไปประมวลผลบน Embedded System โดยใช้ไมโครคอนโทรลเลอร์เป็น Raspberry Pi4 Model B ในการประมวลผล



รูปที่ 3.19 Schematic Diagram ของวงจรวัดกระแสไฟฟ้าของแบตเตอรี่



รูปที่ 3.20 แผนผังการทำงานของวงจรประมาณสถานะประจุของแบตเตอรี่ เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตเห็นไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.21 วงจรประมาณสถานะประจุของแบตเตอรี่

ก่อนที่จะนำ Raspberry Pi4 Model B ไปใช้เป็นตัวการประมวลผล ต้องติดตั้ง OS (Operation System) ก่อน ในที่นี้เลือกใช้เป็น Linux และระบบปฏิบัติการ Ubuntu จากนั้นติดตั้งภาษา Python เพื่อใช้สำหรับเขียนโปรแกรม และลง library ที่ใช้สำหรับจัดการข้อมูลและสร้างโมเดลโครงข่าย LSTM ได้แก่ numpy, pandas และ Tensorflow

ในการแสดงผลบน Graphical User Interface (GUI) ในที่นี้ จะทำการ Remote ตัว Raspberry Pi4 Model B ไปแสดงผลผ่าน Visual Studio Code โดยคำสั่ง ssh username@ip ซึ่ง ip คือ ip address ของ Raspberry Pi4 Model B โดยจะขึ้นอยู่กับเครือข่ายที่เชื่อมต่อ ซึ่งตัวกลางสำหรับการเชื่อมต่อ สามารถเชื่อมต่อผ่านสาย LAN หรือ Wi-Fi ได้

```
PS C:\Users\kpsom\Desktop> ssh hehe_man@10.66.4.223
hehe_man@10.66.4.223's password:
Welcome to Ubuntu 22.04.2 LTS (GNU/Linux 5.15.0-1035-raspi aarch64)

 * Documentation:  https://help.ubuntu.com
 * Management:    https://landscape.canonical.com
 * Support:       https://ubuntu.com/advantage

Expanded Security Maintenance for Applications is not enabled.

57 updates can be applied immediately.
To see these additional updates run: apt list --upgradable

Enable ESM Apps to receive additional future security updates.
See https://ubuntu.com/esm or run: sudo pro status

The list of available updates is more than a week old.
To check for new updates run: sudo apt update
Last login: Fri Sep 22 14:36:27 2023 from 10.66.4.185
hehe_man@heheman-desktop:~$
```

รูปที่ 3.22 การ Remote ระหว่าง Raspberry Pi4 กับ GUI

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้เพื่อการเรียนการสอนเท่านั้น เมื่ออนุญาตให้นำไปใช้โดยไม่หวังกำไรใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการเชื่อมต่อระหว่าง Linduino One กับ Raspberry Pi4 Model B จะเชื่อมต่อผ่านสาย USB เนื่องจาก OS เป็น Ubuntu ตัว Serial port จะเป็น ttyUSB แทน COM port และต้องกำหนด Baud Rate ให้ตรงกันในที่นี้ใช้เท่ากับ 115200

โมเดลโครงข่ายสำหรับการประมาณสถานะประจุโดย LSTM แบบเรียลไทม์ โดยเริ่มต้นจากการ train โมเดลโครงข่ายจนได้โมเดลที่มีความแม่นยำตามที่ต้องการแล้ว จากนั้นทำการเซฟโมเดลโดยใช้คำสั่ง `model.save("name.h5")` และในการเรียกใช้โมเดลสามารถทำได้โดยใช้คำสั่ง `load_model("name.h5")` ดังนั้นเมื่อรับอินพุตเข้ามาสู่โครงข่าย ก็ไม่จำเป็นต้อง train โครงข่ายอีกแล้ว สามารถประมาณเอาต์พุตได้เลยซึ่งคือค่าสถานะประจุ (SoC)

```
port = serial.Serial("/dev/ttyUSB0", 115200 )
model = load_model("LSTM_model.h5", custom_objects={'my_rmse': my_rmse})
✓ 1.6s
```

รูปที่ 3.23 การเชื่อมต่อระหว่าง Linduino One กับ Raspberry Pi4 และการ load model

ในกระบวนการทำงานวงจรประมาณสถานะประจุของแบตเตอรี่โดย LSTM แบบเรียลไทม์ โดยเริ่มต้นจาก Raspberry Pi4 Model B จะส่งคำสั่งไปยัง Serial port ของ Linduino One ให้อ่านค่าแรงดันไฟระหว่างขั้วและกระแสไฟฟ้าจาก LTC6813-1 จากนั้นจะส่งข้อมูลกลับไปประมวลผลบน Raspberry Pi4 Model B โดยเริ่มจากการ Normalization เนื่องจากไม่สามารถใช้ฟังก์ชัน MinMaxScaler ในการ Normalization ได้เพราะเป็นการประมาณสถานะประจุแบบเรียลไทม์ จึงต้องใช้สมการทางคณิตศาสตร์เข้ามาช่วยซึ่งเป็นสมการที่เหมือนกับฟังก์ชัน MinMaxScaler ดังสมการที่ 3.2 จากนั้นจึงนำข้อมูลมาต่อกันเป็นชุดข้อมูลย่อย แล้วนำไปประมาณสถานะประจุของแบตเตอรี่โดยใช้คำสั่ง `model.predict()`

$$X_{scaled} = \left(\frac{X - X_{min}}{X_{max} - X_{min}} \right) * (X_{range_max} - X_{range_min}) + X_{range_min} \quad (3.2)$$

เมื่อ x คือค่าของข้อมูล, x_{min} คือค่าต่ำสุดของข้อมูล, x_{max} คือค่าสูงสุดของข้อมูล, x_{range_min} คือค่าช่วงขอบเขตต่ำสุดของข้อมูล และ x_{range_max} คือค่าช่วงขอบเขตสูงสุดของข้อมูล

```

k = 60
count = 30000

V, Im = np.zeros((0, 1)), np.zeros((0, 1))
V_scale, Im_scale = np.zeros((0, 1)), np.zeros((0, 1))
data = np.zeros((0, 2))

X_data = np.zeros([0, k, 2])
predictions = np.zeros((0,1))

V_max = 4.199864
V_min = 3.006464
Vscale_max = 1.000076
Vscale_min = -0.017779

Im_max = 3.250872
Im_min = -2.7454
Imscale_max = 1.000019
Imscale_min = -1.01521
end_time = time.time()

for i in range(count):

    start_time = time.time()

    port.write(b"4")
    data = port.readline().decode('ascii')
    value_list = data.split(' ')

    in_V = float(value_list[0])
    in_Im = float(value_list[1])
    V = np.concatenate((V, [[in_V]]), axis=0)
    Im = np.concatenate((Im, [[in_Im]]), axis=0)

    scaleV = ((in_V - V_min) / (V_max - V_min) * (Vscale_max - Vscale_min)) + Vscale_min
    scaleIm = ((in_Im - Im_min) / (Im_max - Im_min) * (Imscale_max - Imscale_min)) + Imscale_min

    V_scale = np.concatenate((V_scale, [[scaleV]]), axis=0)
    Im_scale = np.concatenate((Im_scale, [[scaleIm]]), axis=0)
    input = np.column_stack((Im_scale, V_scale))

    if i >= k:
        cur_sequence = input[i-k: i, :]
        X_data = np.vstack((X_data, cur_sequence.reshape(1, k, 2)))
        cur_predict = model.predict(np.expand_dims(X_data[i-k], axis=0))
        predictions = np.vstack((predictions, cur_predict))

        print("Predicted output value:", predictions[i-k])

    if float(value_list[0]) <= 3:
        break

    end_time = time.time()
    time.sleep(abs(1 - (end_time - start_time)))

```

รูปที่ 3.24 Code การประมาณสถานะประจุของแบตเตอรี่โดย LSTM แบบเรียลไทม์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการทดสอบ

ในการทดสอบโมเดลที่ใช้สำหรับวงจรประมาณสถานะประจุของแบตเตอรี่โดย LSTM แบบเรียลไทม์ ในระหว่างการทดสอบจะประเมินประสิทธิภาพการทำงานของโมเดลผ่าน Root Mean Squared Error (RMSE) โดยโปรไฟล์กระแสไฟฟ้าที่ใช้สำหรับทดสอบโมเดลคือโปรไฟล์ที่จำลองการวิ่งของรถยนต์ไฟฟ้าได้แก่ WLTP Class1, WLTP Class2, WLTP Class3, WLTP Mixed Class (WLTP Class 1,2 และ 3 รวมกัน) รวมถึงโปรไฟล์ที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวันซึ่งประกอบด้วยแพทเทิร์นการวิ่ง, การอัดประจุ และการพัก


4.1 การหาโมเดลโครงข่าย LSTM ที่เหมาะสมที่สุดสำหรับวงจรประมาณสถานะประจุของแบตเตอรี่

ในการ Optimization เพื่อที่จะทำให้โมเดลโครงข่าย LSTM มีประสิทธิภาพในการทำงานสูงสุด ขึ้นอยู่กับการกำหนดค่า Hyperparameters ให้เหมาะสมกับโมเดล ซึ่งในการทดสอบนี้จะทำการหาจำนวนเซลล์ประสาทใน Hidden layer ของโมเดลที่เหมาะสมที่สุด ในการทดสอบกำหนด Training set เป็น WLTP Class3, Test set เป็น WLTP Class2 และ epochs เท่ากับ 50 จากการทดสอบโดยการ train โมเดลโครงข่าย LSTM ซึ่งทำการกำหนดจำนวนเซลล์ประสาทใน Hidden layer ตามตารางที่ 4.1 พบว่าถ้ากำหนดจำนวนเซลล์ประสาทน้อยเกินไป จำนวนของ learner parameters จะน้อยตามและใช้เวลาในการ train (Execution Time) ค่อนข้างน้อย แต่ประสิทธิภาพของโมเดลยังไม่ดีพอให้ค่า RMSE ที่สูงถึง 1.16% หรืออาจกล่าวได้ว่าโมเดลยังฝึกฝนไม่เพียงพอ (Under Fitting) ในทางตรงกันข้ามถ้ากำหนดจำนวนเซลล์ประสาทมากเกินไป จำนวนของ learner parameters ก็จะมีเพิ่มขึ้นตามและ Execution Time ค่อนข้างนาน แต่กลับให้ค่า RMSE ที่สูงถึง 1.26% จะเห็นได้ว่าถึงแม้โมเดลจะมีจำนวนเซลล์ประสาทที่มากกว่าไม่ได้ทำให้โมเดลมีประสิทธิภาพเสมอไป เนื่องจากโมเดลเกิดการเรียนรู้มากเกินไป (Over Fitting) ดังนั้นต้องหาจุดที่เหมาะสมที่สุดของโมเดล ในโมเดลนี้จำนวนเซลล์ประสาทที่เหมาะสมที่สุดคือ 10 เซลล์ เนื่องจากใช้ learner parameters และ Execution Time ค่อนข้างน้อย แต่กลับให้ค่า RMSE ที่น้อยเพียง 0.61% ในที่นี้ต้องคำนึงถึงชุดข้อมูลที่ใช้เป็น Training set และ Test set ด้วยถ้าหากเปลี่ยนชุดข้อมูลอาจทำให้ประสิทธิภาพการทำงานของโมเดลเปลี่ยนไปด้วยเช่นกัน ตารางที่ 4.1 แสดงผลลัพธ์ของการ train โครงข่าย LSTM ที่จำนวนเซลล์ประสาทต่างๆ โดยผลลัพธ์ที่ได้ในแต่ละค่าเกิดจากการ train ซ้ำๆ จำนวน 3 รอบแล้วนำมาหาค่าเฉลี่ย [27]


ตารางที่ 4.1 แสดงผลลัพธ์ของการ train โครงข่าย LSTM ที่จำนวนเซลล์ประสาทต่างๆ

Neuron	Learner Parameters	Execution Time (s)	RMSE (%)
5	166	305.1	1.16
10	531	314.3	0.61
15	1,096	339	0.69
20	1,861	372.5	0.78
25	2,826	410	0.82
50	10,651	494.6	0.78
75	23,476	609.6	0.75
100	41,301	713.4	0.95
150	91,951	1074.7	1.22
200	162,601	1474	1.26

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)



(c)

รูปที่ 4.1 กราฟแสดงผลลัพธ์ของการ train โครงข่าย LSTM ที่จำนวนเซลล์ประสาทต่างๆ

(a) กราฟแสดงความสัมพันธ์ระหว่างจำนวนเซลล์ประสาทใน Hidden layer กับค่า RMSE,

(b) กราฟแสดงความสัมพันธ์ระหว่างเวลากับจำนวนเซลล์ประสาทใน Hidden layer,


(c) กราฟแสดงความสัมพันธ์ระหว่าง Learner Parameters

กับจำนวนเซลล์ประสาทใน Hidden layer

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


4.2 ผลการทดสอบโมเดลโครงข่าย LSTM ด้วยโปรไฟล์กระแสไฟฟ้า WLTP

ในการทดสอบโมเดลโครงข่าย LSTM ที่ใช้สำหรับวงจรประมาณสถานะประจุของแบตเตอรี่แบบเรียลไทม์ โดยใช้โปรไฟล์กระแสไฟฟ้า WLTP ในแต่ละ Class เป็นตัวทดสอบ ซึ่งในแต่ละ Class จะมีแพทเทิร์นการวิ่งที่คล้ายกันซึ่งประกอบด้วยการวิ่งในเมือง, ชานเมือง, ชนบท และถนนใหญ่เส้นหลักนอกเมือง แต่จะแตกต่างกันตรงที่ช่วงเวลาการวิ่งในแต่ละช่วง และความจุกำลังไฟฟ้าหรือกำลังไฟฟ้าต่อน้ำหนัก (W/kg) ของรถยนต์ไฟฟ้าในแต่ละ Class โปรไฟล์กระแสไฟฟ้า WLTP Class1, WLTP Class2, WLTP Class3 และ WLTP Mixed Class แสดงดังรูปต่อไปนี้




รูปที่ 4.2 โปรไฟล์กระแสไฟฟ้า WLTP Class1 (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขั้ว, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ภายในเพื่อการศึกษาเท่านั้น เมื่อผู้ใดเห็นชอบใช้เอกสารนี้ในการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)




(b)




(c)

รูปที่ 4.3 โพรไฟล์กระแสไฟฟ้า WLTP Class2 (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขั้ว, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)




(b)




(c)

รูปที่ 4.4 โปรไฟล์กระแสไฟฟ้า WLTP Class3 (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)



(c)

รูปที่ 4.5 โปรไฟล์กระแสไฟฟ้า WLT Mixed Class (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขั้ว, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการทดสอบโมเดลโครงข่าย LSTM ด้วยโพรไฟล์กระแสไฟฟ้า WLTP ในแต่ละ Class ซึ่งจะทำทดสอบแบบพบกันหมดโดยการสลับกันเป็น Training set และ Test set แสดงดังตารางที่ 4.2 จากตารางจะเห็นได้ว่าโมเดลโครงข่าย LSTM มีประสิทธิภาพในการประมาณสถานะประจุได้อย่างถูกต้องและแม่นยำถึงแม้ว่า Training set และ Test set จะไม่ใช่ชุดข้อมูลเดียวกัน อีกทั้งยังพบว่า RMSE มีค่าน้อยมากโดยเฉพาะ WLTP Class2, WLTP Class3 และ WLTP Mixed Class แต่ถ้าทดสอบโดยใช้ Training set หรือ Test set เป็น WLTP Class1 พบว่า RMSE จะมีค่าสูงกว่า Class อื่นเพียงเล็กน้อยมีค่าประมาณเกือบ 1% ซึ่งอาจจะมีสาเหตุมาจากชุดข้อมูล WLTP Class1 มีลำดับความยาวของข้อมูลและความสัมพันธ์เชิงข้อมูลน้อยกว่า Class อื่น


จากกราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM จะเห็นได้ว่า SoC ที่ได้จากการประมาณโดย LSTM เกือบจะซ้อนทับกันกับ SoC จริง ยกเว้น SoC ที่ได้จากการประมาณโดยใช้ Training set หรือ Test set เป็น WLTP Class 1 ดังนั้นโมเดลโครงข่าย LSTM มีประสิทธิภาพในการอธิบายพฤติกรรมที่ไม่เป็นเชิงเส้นของแบตเตอรี่

ตารางที่ 4.2 แสดง %RMSE ของการประมาณสถานะประจุโดยใช้ Training set และ Test set เป็น WLTP Class ต่างๆ

Training Set / Test Set	WLTP 1	WLTP 2	WLTP 3	WLTP Mixed
WLTP 1	-	0.99	0.98	0.98
WLTP 2	0.96	-	0.69	0.56
WLTP 3	0.93	0.62	-	0.68
WLTP Mixed	0.98	0.69	0.61	-




รูปที่ 4.6 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Class2)



รูปที่ 4.7 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Class3)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.8 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class1 และ Test Set เป็น WLTP Mixed Class)




รูปที่ 4.9 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Class1)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.10 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Class3)



รูปที่ 4.11 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class2 และ Test Set เป็น WLTP Mixed Class)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.12 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Class1)



รูปที่ 4.13 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Class2)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.14 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Class3 และ Test Set เป็น WLTP Mixed Class)



รูปที่ 4.15 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class1)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.16 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class2)




รูปที่ 4.17 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set เป็น WLTP Mixed Class และ Test Set เป็น WLTP Class3)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


4.3 ผลการทดสอบโมเดลโครงข่าย LSTM ด้วยโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน

ในการทดสอบนี้จะทดสอบโมเดลโครงข่าย LSTM ด้วยโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวันในรูปแบบต่างๆ ซึ่งประกอบด้วยแพทเทิร์นการวิ่ง, การอัดประจุ และการพัก โดย Training set และ Test set จะใช้เป็นโปรไฟล์กระแสไฟฟ้าที่ประกอบด้วยแพทเทิร์นการคายประจุจนหมดและการอัดประจุจนเต็มด้วยอัตรา 0.5C , การพัก และการวิ่งโดยใช้โปรไฟล์ WLTP Class3 ในช่วงระยะเวลาที่ต่างกัน แสดงดังรูปที่ 4.18 และ 4.19 ตามลำดับ




รูปที่ 4.18 Training set สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงสถานะประจุ (SoC)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)




(c)

รูปที่ 4.19 Test set สำหรับโพรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดสอบจะเห็นได้ว่ากราฟ SoC ที่ได้จากการประมาณโดย LSTM แทบจะซ้อนทับกับ SoC จริง แสดงให้เห็นว่าโมเดลโครงข่าย LSTM มีความสามารถในการประมาณสถานะประจุได้อย่างถูกต้องและแม่นยำพบว่า RMSE เท่ากับ 0.54% เนื่องจาก Training set และ Test set เป็นชุดข้อมูลที่มีสัมพันธ์กัน จะเห็นได้ว่าใน Test set ประกอบด้วยแพทเทิร์นของกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างช่วงที่ปรากฏอยู่แล้วใน Training set ทำให้ในกระบวนการ train โมเดลเกิดการจดจำลักษณะของชุดข้อมูลไว้แล้ว พอนำ Test set ที่มีลักษณะคล้ายกันมาทดสอบ จึงทำให้โมเดลโครงข่าย LSTM สามารถประมาณสถานะประจุได้อย่างแม่นยำ




รูปที่ 4.20 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test set สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)


ในการทดสอบต่อไปจะทำการเปลี่ยน Test set เป็นโปรไฟล์กระแสไฟฟ้าที่ประกอบด้วยแพทเทิร์นการวิ่งโดยใช้โปรไฟล์ WLTP Class3 ที่ Cycle มากกว่าเดิม, การพักในระยะเวลาสั้นๆ และการอัดประจุด้วยอัตรา 0.5C ในระยะเวลาต่างๆ แต่ไม่ได้อัดประจุจนแบตเตอรี่เต็ม แสดงดังรูปที่ 4.21



(a)



(b)




(c)


รูปที่ 4.21 Test set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงสถานะประจุ (SoC)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

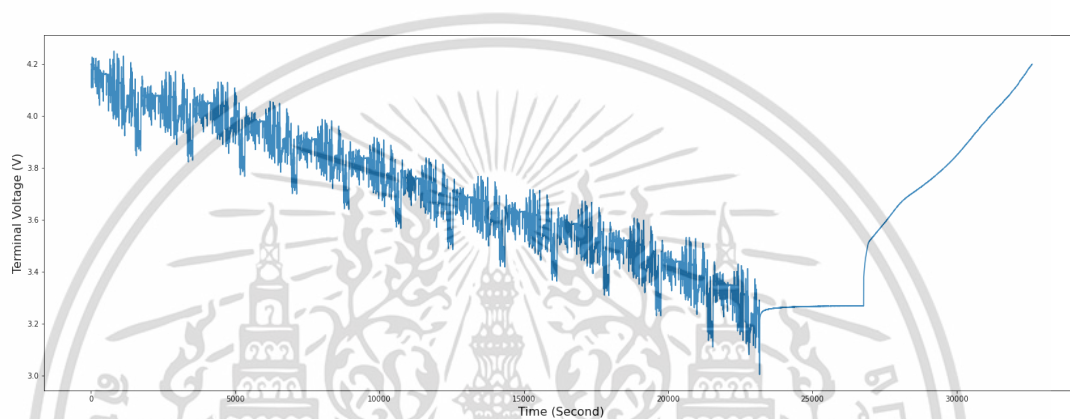
จากผลการทดสอบจะเห็นได้ว่ากราฟ SoC ที่ได้จากการประมาณโดย LSTM ซ้อนทับกับ SoC จริงแค่ในช่วงของการอัดประจุด้วยอัตรา 0.5C ส่วนช่วงที่วิ่งด้วยโปรไฟล์ WLTP Class3 จะเห็นได้ว่ามีข้อผิดพลาดระหว่างจาก SoC จริงอย่างเห็นได้ชัด มีแค่เฉพาะช่วงที่ปรากฏอยู่ใน training set เท่านั้นที่มีข้อผิดพลาดเพียงเล็กน้อย พบว่า RMSE สูงถึง 3.76% อาจมีสาเหตุมาจากการที่ Test set ประกอบด้วยแพทเทิร์นของกระแสไฟฟ้าและแรงดันไฟฟ้าระหว่างช่วงช่วงที่ไม่เคยปรากฏอยู่ใน Training set ส่งผลให้เมื่อทำการทดสอบโมเดล โมเดลไม่สามารถลู่เข้าสู่คำตอบที่ถูกต้องได้ ทำให้โมเดลไม่มีความแม่นยำในการประมาณสถานะประจุมากพอ ดังนั้นจึงทำการเปลี่ยน Training set ให้มีแพทเทิร์นที่ครอบคลุม Test set แสดงดังรูปที่ 4.23



รูปที่ 4.22 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)



(a)



(b)




(c)

รูปที่ 4.23 Training set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดสอบจะเห็นได้ว่าเมื่อเปลี่ยน Training set ให้มีแพทเทิร์นที่ครอบคลุม Test set แล้ว โมเดลสามารถประมาณสถานะประจุได้อย่างแม่นยำมากยิ่งขึ้น พบว่า RMSE ลดลงจนเหลือ 0.67%




รูปที่ 4.24 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 และ Test Set รูปแบบที่ 2 สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)


ในการทดสอบสุดท้ายจะทำการทดสอบผลกระทบของอุณหภูมิต่อโมเดลโครงข่าย LSTM สำหรับการประมาณสถานะประจุ ซึ่งจะทำการทดสอบโดยใช้ Test set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C และ 45 °C แสดงดังรูปที่ 4.25 และ 4.26 ส่วน Training set จะใช้เป็นตัวเดิมคือ Training set รูปแบบที่ 2 ที่อุณหภูมิ 25 °C แสดงดังรูปที่ 4.21



(a)




(b)




(c)

รูปที่ 4.25 Test set รูปแบบที่ 2 ที่อุณหภูมิ 0°C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขั้ว, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(a)



(b)




(c)

รูปที่ 4.26 Test set รูปแบบที่ 2 ที่อุณหภูมิ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขั้ว, (c) กราฟแสดงสถานะประจุ (SoC)


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากการทดสอบจะเห็นได้ว่ากราฟ SoC ที่ได้จากการประมาณโดย LSTM ที่อุณหภูมิที่ 0 °C และ 45 °C มีข้อผิดพลาดจาก SoC จริงอย่างเห็นได้ชัดพบว่า RMSE เท่ากับ 6.50% และ 1.86% ตามลำดับ ซึ่งจากที่อุณหภูมิที่ 25 °C พบว่า RMSE เพียง 0.67% โดยมีสาเหตุมาจากการที่อุณหภูมิมีผลกระทบต่อแรงดันระหว่างขั้วและกระแสไฟฟ้าขณะอัดประจุและคายประจุของแบตเตอรี่ จะเห็นได้ว่าใน Test set แรงดันระหว่างขั้วที่อุณหภูมิ 0 °C มีค่าสูงขึ้นเป็นอย่างมาก ส่วนที่อุณหภูมิ 45 °C มีค่าสูงขึ้นเพียงเล็กน้อย ทำให้ Training set และ Test set ไม่มีความสัมพันธ์เชิงข้อมูลกันส่งผลให้ SoC ที่ได้จากการประมาณมีข้อผิดพลาดอย่างเห็นได้ชัด ถ้าต้องการเพิ่มความแม่นยำของการประมาณสถานะประจุอาจจะต้องเปลี่ยนค่าของ Training set ให้มีอุณหภูมิสอดคล้องกับ Test set แต่อาจเกิดปัญหาตรงที่ แบตเตอรี่ลิเทียมไอออนไม่แนะนำให้ทำการอัดประจุที่อุณหภูมิต่ำ เนื่องจากจะทำให้ความต้านทานของแบตเตอรี่ภายในสูงขึ้นและยังเป็นต้นเหตุของ Lithium Plating อีกด้วย




รูปที่ 4.27 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 ที่อุณหภูมิ 25 °C และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.28 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set รูปแบบที่ 2 ที่อุณหภูมิ 25 °C และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)


ดังนั้นจึงทำการทดสอบโดยการเพิ่ม Feature ให้กับโมเดลโครงข่าย LSTM ซึ่งคืออุณหภูมิ เพื่อทดสอบประสิทธิภาพในการประมาณสถานะประจุ ในการทดสอบจะใช้ Training set และ Test เป็นโปรไฟล์กระแสไฟฟ้าเดียวกัน โดยการนำแรงดันระหว่างขั้วและกระแสไฟฟ้าที่อุณหภูมิ 0 °C, 25 °C และ 45 °C มาต่อกัน แสดงดังรูปที่ 4.29



รูปที่ 4.29 Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C, 25 °C และ 45 °C สำหรับโปรไฟล์ กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน (a) กราฟแสดงกระแสไฟฟ้า, (b) กราฟแสดงแรงดันไฟฟ้าระหว่างขับ, (c) กราฟแสดงอุณหภูมิ, (d) กราฟแสดงสถานะประจุ (SoC)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากการทดสอบจะเห็นได้ว่าถึงแม้จะใช้ Training set และ Test set เป็นข้อมูลชุดเดียวกัน กราฟ SoC ที่ได้จากการประมาณโดย LSTM ที่ช่วงอุณหภูมิต่างๆ ก็ไม่ได้ซ้อนทับกับ SoC จริงทั้งหมด ยังมีข้อผิดพลาดอยู่บ้างเพียงเล็กน้อย พบว่า RMSE เท่ากับ 0.32% แต่ในช่วงอุณหภูมิต่างๆ โมเดลสามารถประมาณสถานะประจุได้อย่างแม่นยำถึงแม้ว่าจะไม่ใช่ในช่วงอุณหภูมิเดียวกัน เนื่องจากในโมเดลมีการเพิ่ม Feature อุณหภูมิเข้ามาทำให้มีอุณหภูมิกำกับอยู่ หรืออาจเกิดจากการที่ Training set และ Test set มีความสัมพันธ์เชิงข้อมูลกันก็เป็นได้



รูปที่ 4.30 กราฟแสดงการเปรียบเทียบระหว่าง SoC จริงกับ SoC ที่ได้จากการประมาณโดย LSTM (Training set และ Test Set รูปแบบที่ 2 ที่อุณหภูมิ 0 °C, 25 °C และ 45 °C สำหรับโปรไฟล์กระแสไฟฟ้าที่จำลองการวิ่งของรถยนต์ไฟฟ้าในชีวิตประจำวัน)

4.4 การเปรียบเทียบการประมาณสถานะประจุโดย LSTM กับงานวิจัยที่ผ่านมา

ในการเปรียบเทียบประสิทธิภาพของโมเดลการประมาณสถานะประจุโดย LSTM ในแง่ของ RMSE กับงานวิจัยที่ผ่านมา โดยในงานวิจัยแรก [1] ใช้แบตเตอรี่ลิเทียมไอออน 18650 ชนิด NCA ยี่ห้อ Panasonic โมเดลโครงข่าย LSTM ประกอบด้วยชั้นซ่อนเท่ากับ 1 ชั้นและมีจำนวนเซลล์ประสาทในชั้นซ่อน 500 เซลล์ และเลือกใช้ timesteps เท่ากับ 1000 ในการทดสอบโมเดลใช้ Training set และ Test set เป็นข้อมูลชุดเดียวกันคือ Driving cycle source ที่ประกอบด้วย HWFET, UDDS, LA92, และ US06 มารวมกัน ส่วนงานวิจัยที่สอง [25] ใช้แบตเตอรี่ลิเทียมไอออน โมเดลโครงข่าย LSTM ประกอบด้วยชั้นซ่อนเท่ากับ 1 ชั้นและมีจำนวนเซลล์ประสาทในชั้นซ่อน 7

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เซลล์ ในการทดสอบโมเดลใช้ Training set เป็นโพรไฟล์กระแสไฟฟ้าที่ประกอบด้วยแพทเทิร์นการคายประจุ, การอัดประจุด้วย C-rate สูงๆ, การอัดประจุ และการพัก ส่วน Test set ใช้เป็นโพรไฟล์กระแสไฟฟ้าที่ประกอบด้วยแพทเทิร์นการอัดประจุและการคายประจุอย่างละหนึ่งรอบ เมื่อทำการเปรียบเทียบประสิทธิภาพในการประมาณสถานะประจุกับงานวิจัยที่ผ่านมา พบว่าสถานะประจุที่ได้จากการประมาณในวิทยานิพนธ์เล่มนี้มีความถูกต้องและแม่นยำมากกว่างานวิจัยที่ผ่านมา ในแง่ของ RMSE พบว่ามีค่า RMSE ที่ต่ำกว่า โดยเฉพาะในเปรียบเทียบกับงานวิจัยแรกๆ ที่ทำการทดสอบในลักษณะเดียวกันคือใช้ Training set และ Test set เป็นข้อมูลชุดเดียวกันที่อุณหภูมิต่างๆมาต่อกัน

Ambient Temperature	MAE(%)	RMS(%)	STDDEV(%)	MAX(%)
25 °C	0.774	1.110	0.796	3.692
10 °C	0.782	0.995	0.616	4.047
0 °C	2.088	2.444	1.270	6.687
Varying temperature	1.606	2.038	1.256	5.815

รูปที่ 4.31 RMSE การประมาณสถานะประจุโดย LSTM ของงานวิจัยที่ผ่านมา (1) [24]

Models	Error Benchmarks		
	RMSE	MAE	MaxAE
ECM-EKF	9.5%	8.5%	19.3%
LSTM	5.0%	4.1%	12.8%

รูปที่ 4.32 RMSE การประมาณสถานะประจุโดย LSTM ของงานวิจัยที่ผ่านมา (2) [25]

Ambient Temperature	RMSE (%)
25 °C	0.67
45 °C	1.86
0 °C	6.50
Varying temperature	0.32

รูปที่ 4.33 RMSE การประมาณสถานะประจุโดย LSTM ของวิทยานิพนธ์เล่มนี้ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ในวิทยานิพนธ์เล่มนี้เสนอวิธีการประมาณสถานะประจุของแบตเตอรี่ลิเทียมไอออนโดยใช้โครงข่ายประสาทเทียมชนิดหนึ่งที่มีชื่อว่า Long short-term memory (LSTM) ในการประมาณสถานะประจุ หรือสามารถเรียกได้ว่าเป็นวิธี data-driven ในการสร้างโมเดลโครงข่าย LSTM ที่ใช้สำหรับการประมาณสถานะประจุของแบตเตอรี่ ในวิทยานิพนธ์เล่มนี้จะใช้ภาษา Python และ library TensorFlow ในการสร้างโมเดล โดยโมเดลโครงข่าย LSTM ประกอบด้วยจำนวนเซลล์ประสาทใน Hidden layer 10 เซลล์ จากนั้นทำการฝึกฝนและทดสอบโมเดลโดยใช้ Training set และ Test set เป็นโปรไฟล์กระแสไฟฟ้า WLTP ในแต่ละ Class ได้แก่ WLTP Class1, WLTP Class2, WLTP Class3 และ WLTP Mixed Class รวมถึงโปรไฟล์ที่จำลองการวิ่งของยนต์ไฟฟ้าในชีวิตประจำวันซึ่งประกอบด้วยแพทเทิร์นการวิ่ง, การอัดประจุ และการพัก จากผลการทดสอบพบว่าโมเดลโครงข่าย LSTM มีประสิทธิภาพในการประมาณสถานะประจุได้อย่างถูกต้องและแม่นยำ ในแง่ของ RMSE พบว่า RMSE มีค่าน้อยมาก ถ้าหาก Training set และ Test set เป็นชุดข้อมูลลำดับที่มีความสัมพันธ์เชิงข้อมูลกัน และในการทดสอบที่อุณหภูมิต่างๆ จะต้องเพิ่มผลของอุณหภูมิให้กับโมเดลโครงข่ายด้วย เนื่องจากอุณหภูมิมีผลต่อการประมาณสถานะประจุของแบตเตอรี่ ด้วยเหตุนี้ทำให้โมเดลโครงข่าย LSTM มีประสิทธิภาพในการอธิบายพฤติกรรมที่ไม่เป็นเชิงเส้นของแบตเตอรี่

5.2 ข้อเสนอแนะ

ในการฝึกฝนโมเดลโครงข่าย LSTM จะใช้ GPU (Graphic Processing Unit) หรือ TPU (Tensor Processing Unit) ในการประมวลผล ซึ่งโมเดลโครงข่าย LSTM มีขนาดค่อนข้างใหญ่ถ้าหาก GPU ไม่แรงพออาจใช้เวลาประมวลผลค่อนข้างนาน หรือถ้าหากใช้ TPU ในการประมวลผลผ่าน Google Colab ที่เปิดให้ใช้บริการฟรีก็ค่อนข้างใช้เวลานานในการประมวลผล ถ้าหากไม่ซื้อแพ็คเกจ TPU เพิ่มเติมเพื่อเพิ่มความเร็วในการประมวลผล และในการทดสอบโมเดลโครงข่าย LSTM ถ้าหาก Training set และ Test set เป็นชุดข้อมูลที่ไม่มีความสัมพันธ์เชิงข้อมูลกัน จะทำให้สถานะประจุที่ได้จากการประมาณไม่มีความถูกต้องและแม่นยำ

เอกสารอ้างอิง

- [1] Gregory L. Plett. **Battery Management Systems Battery Modeling**. Boston. Artech House. 2015.
- [2] Gregory L. Plett. **Battery Management Systems Battery Equivalent-Circuit Methods**. Boston. Artech House. 2015.
- [3] I. Goodfellow, Y. Bengio, A. Courville. **Deep Learning**. MIT Press. 2016.
- [4] Manjot Kaur and Aakash Mohta. “A Review of Deep Learning with Recurrent Neural Network” **2019 International Conference on Smart Systems and Inventive Technology (ICSSIT)**, pp. 460-465, 2019.
- [5] Sepp Hochreiter and Jürgen Schmidhuber. “Long Short-Term Memory” **Neural Computation**, vol. 9, issue 8, pp. 1735-1780, 1997.
- [6] Zhekai Du, Lin Zuo, Jingjing Li, Yu Liu and Heng Tao Shen. “Data-Driven Estimation of Remaining Useful Lifetime and State of Charge for Lithium-Ion Battery” **IEEE Transactions on Transportation Electrification**, vol. 8, issue 1, pp. 356-357, 2022.
- [7] Xu, K. “Nonaqueous liquid electrolytes for lithium-based rechargeable batteries” **Chem. Rev**, pp. 4303–4418, 2004.
- [8] Jeff Shepard. “The difference between lithium ion and lithium polymer batteries” [Online]. Available : <https://www.batterypowertips.com/difference-between-lithium-ion-lithium-polymer-batteries-faq/>. 2021.
- [9] Rui Xiong. **Battery Management Algorithm for Electric Vehicles**. Beijing. Springer. 2020.
- [10] กอบเกียรติ สระอุบล. **เรียนรู้ AI:Deep Learning ด้วย Python**. กรุงเทพฯ. อินเทอร์เน็ตเดีย. 2565.
- [11] Mei Liu, Liangming Chen, Xiaohao Du, Long Jin and Mingsheng Shang. “Activated Gradients for Deep Neural Networks” **IEEE Transactions on Neural Networks and Learning Systems**, pp. 1-13.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

[12] Kyungnam Park, Yohwan Choi, Won Jae Choi, Hee-Yeon Ryu, Hongseok Kim. “LSTM-Based Battery Remaining Useful Life Prediction With Multi-Channel Charging Profiles” *IEEE Access*, vol. 8, pp. 20786 – 20798, 2020.

[13] Liz Upton. “Raspberry Pi 4 Model B.” [Online]. Available : <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>. 2020.

[14] Analog Devices. “18-Cell Battery Stack Monitor with Daisy Chain Interface LTC6813-1.” [Online]. Available : <https://www.analog.com/en/products/ltc6813-1.html>. 2020

[15] Analog Devices. “Daisy chain.” [Online]. Available : <https://www.analog.com/en/technical-articles/daisy chaining-spi-devices.html> 2006.

[16] Analog Devices. “DEMO MANUAL DC2350B.” [Online]. Available : <https://www.analog.com/media/en/technical-documentation/userguides/dc2350b.pdf> 2020

[17] ThaiEasyElec. “บทความ ESPino32 ตอนที่ 9 การสื่อสารอนุกรมแบบ SPI.” [Online]. Available : <https://blog.thaieasyelec.com/espino32-ch9-how-to-use-spi/> 2020

[18] Thomas Brand “Isolated SPI Communication Made Easy.” [Online]. Available : <https://www.analog.com/en/technical-articles/isolated-spi-communication-made-easy.html> 2015.

[19] Analog Devices. “DEMO MANUAL DC2792B.” [Online]. Available : <https://www.analog.com/en/design-center/evaluation-hardware-and-software/evaluation-boards-kits/dc2792b.html> 2020.

[20] Analog Devices. “Linduino One.” [Online]. Available : <https://www.analog.com/en/design-center/evaluation-hardware-and-software/evaluation-boards-kits/dc2026c.html> 2020.

[21] Lee Yong Seok. “Lithium-Ion Battery LGGBMJ11865.” [Online]. Available : <https://secondlifestorage.com/index.php?threads/lg-lgebmj11865-cell-specifications.8109/>. 2015.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [22] Rigol. “DC Electronic Power Supply DL811 และ DC Electronic Load DP3021.” [Online]. Available : <https://www.rigolna.com/products/dc-power-loads/>. 2011.
- [23] John Deere. “Worldwide Harmonized Light Vehicles Test Cycle (WLTC).” [Online]. Available : <https://dieselnet.com/standards/cycles/wltp.php>. 2019.
- [24] S. Bockrath, A. Roskopf, S. Koffel, S. Waldhör, K. Srivastava and V.R.H. Lorentz. “State of Charge Estimation using Recurrent Neural Networks with Long Short-Term Memory for Lithium-Ion Batteries” **IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society**, pp. 2507-2511, 2019.
- [25] Ephrem Chemali, Phillip J. Kollmeyer, Matthias Preindl, Ryan Ahmed and Ali Emadi. “Long Short-Term Memory Networks for Accurate State-of-Charge Estimation of Li-ion Batteries” **IEEE Transactions on Industrial Electronics**, vol. 65, issue 8, pp. 6730 - 6739, 2018.
- [26] Texas Instruments. “INA253A3.” [Online]. Available : https://www.ti.com/lit/ds/symlink/ina253.pdf?ts=1696362097832&ref_url=https%253A%252F%252Fwww.google.co.th%252F 2018.
- [27] Carlos Vidal, Pawel Malysz, Mina Naguib, Ali Emadi, Phillip J. Kollmeyer. “Estimating battery state of charge using recurrent and non-recurrent neural networks” **Journal of Energy Storage**. vol. 47, 2022.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

9th
Iceast
2023
Vientiane, Lao PDR.

The 9th International Conference on Engineering, Applied Sciences and Technology

1 – 4 June 2023, at Vientiane, Lao PDR

The International Conference on Engineering, Applied Sciences and Technology (ICEAST) was inaugurated in 2007 to provide opportunities for enhancing collaboration and exploring current interdisciplinary topics. This year is the 9th event and being held in Vientiane, Lao, a prime location in Lao PDR which has overfull of things to see and things to do.

Honorary Chairs

- Komsan Maleesee (KMITL, Thailand)
- Oudom Phonekhampheng (NUOL, Lao PDR)
- Pongsakorn Yuthagovit (IEEE Thailand Section, Thailand)
- Anantawat Kunakorn (KMITL, Thailand)

General Chair

- Somyot Kaitwanidvilai (KMITL, Thailand)

General Co-Chairs

- Sathaporn Promwong (IEEE BTS Thailand Chapter, Thailand)
- Khamphoui Southisombath (NUOL, Lao PDR)

Organizing-Chairs

- Chanin Bunlaksanusorn (KMITL, Thailand)
- Soulyphan Kannitha (NUOL, Lao PDR)

International Advisory Committee (IAC)

- Yoshikazu Miyakawa (Hokkaido University, Japan)
- Jun-ichi Takada (Tokyo Tech., Japan)
- Takao Onoye (Osaka University, Japan)
- Kazuhiko Hamamoto (Tokai University, Japan)
- Kyung Sup Kwak (Inha University, South Korea)
- Dusit Niyato (NTU, Singapore)
- Tadashi Ariga (Tokai University, Japan)
- Tomotaka Homae (National Institute of Technology, Toyama College, Japan)
- Nobutaka Ito (Chiang Mai University, Thailand)
- Satoru Seto (National Institute of Technology, Ishikawa College, Japan)
- Kuniaki Yajima (National Institute of Technology, Sendai College, Japan)
- Somphone Kanthavong (NUOL, Lao PDR)
- Phonekeo Chanthamaly (NUOL, Lao PDR)
- Sengpasong Phrakonekham (NUOL, Lao PDR)
- Eryk Dutkiewicz (University of Technology Sydney, Australia)
- Myo Myint Maw (MTU, Myanmar)

ICEAST Steering Committee

- Sathaporn Promwong (IEEE BTS, Thailand Chapter and KMITL, Thailand)
- Wiboon Promphanich (KMITL, Thailand)
- Norasage Pattanadech (KMITL, Thailand)
- Chanin Bunlaksanusorn (KMITL, Thailand)
- Theerayod Wiangtong (KMITL, Thailand)
- Vanchai Riewruja (KMITL, Thailand)
- Worapong Tangsirat (KMITL, Thailand)
- Uma Seeboonruang (KMITL, Thailand)
- Chuwong Phongcharoenpanich (KMITL, Thailand)
- Chaowalit Hamontree (KMITL, Thailand)
- Khamphoui Southisombath (NUOL, Lao PDR)
- Somsanouk Pathoumvanh (NUOL, Lao PDR)
- Khanthanou Luangxaysana (NUOL, Lao PDR)
- Phouthong Southisombath (NUOL, Lao PDR)
- Myint Thein (YTU, Myanmar)
- Sint Soe (MTU, Myanmar)
- Myo Myint Maw (Mandalay Technological University, Myanmar)
- Thanadol Tiengthong (IEEE BTS, Thailand Chapter)
- Thanadon Mankong (N&N Project, Thailand)
- Nattapan Sukwansukho (IEEE BTS, Thailand Chapter)
- Sukkasem Pathumthong (IEEE BTS, Thailand Chapter)

Technical Program Chairs

- Khanthanou Luangxaysana (NUOL, Lao PDR)
- Sarun Duangsuwan (KMITL, Thailand)
- Aditep Chaisang (RBRU, Thailand)

Technical sponsor by



Technical Committee

- Pichaya Supanakoon (KMITL, Thailand)
- Nachanant Chitanont (KMITL, Thailand)
- Khamphong Khongsomboon (NUOL, Lao PDR)
- Savath Saypadith (NUOL, Lao PDR)
- Senglathsamy Chanthamenavong (NUOL, Lao PDR)
- Vilay Vannaladsaysy (NUOL, Lao PDR)
- Soumek Inthala (NUOL, Lao PDR)

Special Session Chairs

- Norasage Pattanadech (KMITL, Thailand)
- Rachen Kanahna (PBRU, Thailand)

Publication Chairs

- Nattapan Sukwansukho (IEEE BTS, Thailand Chapter)
- Chayapol Khamyod (MFU, Thailand)
- Khamphao Sisaat (NUOL, Lao PDR)

Information System Chair/ Performance Publicity/

Public Relation Chairs

- Jirapat Sangthong (MUT, Thailand)
- Wipassom Vinichayakul (CATC, Thailand)
- Virot Wuti (KMITL, Thailand)
- Rathachai Chavuthai (KMITL, Thailand)
- Ammata Luangphon (KMITL, Thailand)

Financial Chairs

- Wiboon Promphanich (KMITL, Thailand)
- Vidhya Rugpong (IEEE Thailand Section, Thailand)

Registration Chairs

- Phouthong Southisombath (NUOL, Lao PDR)
- Vimontha Khievongphachanh (NUOL, Lao PDR)
- Sanit Teawchim (KMITL, Thailand)

Sponsor & Exhibition Chairs

- Thanadon Mankong (N&N Project, Thailand)
- Kaythavy Louangvilay (NUOL, Lao PDR)
- Budit Ruckveratham (MCOT, Thailand)
- Vongkeo Kingsakda (Lao Tel, Lao PDR)

Local Arrangements Chairs

- Phosy Panthongsy (NUOL, Lao PDR)
- Saisamone Soysouvanh (NUOL, Lao PDR)

General Secretary

- Thanadol Tiengthong (IEEE BTS, Thailand Chapter)
- Donekeo Lakanchanh (NUOL, Lao PDR)

Post-conference Publication

- We regret to inform you that due to unforeseen circumstances, we have had to make the difficult decision to cancel three tracks of our upcoming conference: Track 1, Track 2, and Track 3.

- The accepted papers in Track 4 - 5 will be submitted for inclusion into IEEE Xplore. (Prospective authors in tracks 4 - 5 are invited to submit original full papers WITHOUT authors' names and affiliations, in English, of 4 pages in standard IEEE two-column format only, reporting their original work and results, applications, and/or implementation in one or more of the listed areas. Papers must be submitted online only through the submission system of the conference website)



Technical Tracks

- Track 1** Industrial Engineering, Materials and Manufacturing
- Track 2** Mechanical, Mechatronics and Civil Engineering
- Track 3** Food, Chemical and Agricultural Engineering
- Track 4** Telecommunications, Computer Science, Instrumentation and Control, Electrical and Electronic Engineering
- Track 5** Acoustic and music engineering, The science and applications of music technology, and other related fields

IMPORTANT DATES

Online Submission Open	Oct-3,2022
	Dec 16, 2022
Paper Submission Deadline	Dec 12, 2022
(!!!Final Extended!!!)	Jan 13, 2023
	Feb 17, 2023
	Feb 28, 2023
Notification of Acceptance	Jan 23, 2023
(!!!Final Extended!!!)	Feb 17, 2023
	March 10, 2023
	March 20, 2023
Final Paper Submission Deadline	March 20, 2023
(!!!Final Extended!!!)	March 31, 2023
Author Registration Deadline	April 21, 2023
(!!!Final Extended!!!)	March 20, 2023
	March 31, 2023
	April 21, 2023
Conference Date	June 1-4, 2023



Contact

Website: <https://iceast.kmitl.ac.th/2023/>
Email: iceast.con@gmail.com



Comparison of Extended Kalman Filter and Long Short-Term Memory Neural Network for State of Charge Estimation of Lithium-Ion Battery

Kritayod Rupanwong
Department of Electrical Engineering,
School of Engineering
King Mongkut's Institute of Technology
Ladkrabang
Bangkok 10520, Thailand
64601015@kmitl.ac.th

Supat Kittiratsatcha
Department of Electrical Engineering,
School of Engineering
King Mongkut's Institute of Technology
Ladkrabang
Bangkok 10520, Thailand
supat.ki@kmitl.ac.th

Sompob Polmai
Department of Electrical Engineering,
School of Engineering
King Mongkut's Institute of Technology
Ladkrabang
Bangkok 10520, Thailand
sompob.po@kmitl.ac.th

Corresponding authors : Kritayod Rupanwong and Supat Kittiratsatcha

Abstract— The state of charge (SoC) estimation for lithium-ion batteries is an essential function of the battery management system (BMS) for ensuring reliable operation of electric vehicles. The nonlinear behavior of the battery makes estimating of SoC a challenging task. In this paper, SoC estimation based on model-based and data-driven methodology are implemented and compared. In the case of model-based estimation, static OCV-SoC test, AC impedance measurement and system identification technique are utilized to obtain accurate third order equivalent circuit model of the battery. Subsequently, SoC was estimated using Extended Kalman Filter (EKF). In the case of data-driven estimation, long short-term memory recurrent neural network (LSTM-RNN) is adopted. The input that fed into the network are terminal voltage and current, while output is SoC. The training set is WLTP Class 3 driving cycle, and the test set is WLTP Class 2 driving cycle. The performance of state estimation based on EKF and LSTM-RNN is evaluated through the RMSE. Considering only the accuracy of estimation, the SoC estimation using EKF is more accurate than LSTM-RNN, demonstrating the effectiveness of model-based state estimation.

Keywords— State Estimation, SoC (State of Charge), Extended Kalman Filter (EKF), Long short-term memory (LSTM)

I. INTRODUCTION

Nowadays, lithium ion batteries are utilized in electric vehicles (EV). In EVs, battery management system (BMS) [1] is essential to ensure the safety, performances and cycle life of the battery. On the performances front, BMS serves several functions including state of charge (SoC), state of power (SoP), and state of energy (SoE) estimations. On the safety front, BMS ensure safety of operator from electric shock hazard and safety of battery from operating fault such as over charge, over discharge, over temperature, low temperature and external short circuit. On the cycle life front, BMS should be capable of estimating the state of health (SoH) and the remaining utilization life of the battery pack. The SoC and SoH estimations of the battery are the most challenging task of the BMS due to the nonlinear characteristics of the Li-ion battery. In this paper, two method of SoC estimation are investigated and compared.

Open circuit voltage (OCV) and the Coulomb counting are commonly the most prevalent methods for SoC estimation. In term of OCV method, SoC can be estimated based on the relationship between SoC and OCV. Although it is simple to estimate SoC using this method, SoC cannot be estimated during battery operation because OCV can be directly

measured only when the battery is in static equilibrium. In Coulomb counting method, SoC can be calculated by time-integrating the battery current. The accuracy of a SoC estimate using this method depends on current sensor offset and gain errors, and the initial SoC error; as a result, SoC calibration (by resetting or readjustment at the battery resting state according to the OCV-SoC characteristic) is necessary to decrease the cumulative error.

In modern BMS, the model-based method has been implemented. Extended Kalman filter (EKF) and unscented Kalman filter (UKF) are the most studied and reported techniques for SoC estimation. UKF has improved performance over EKF due to higher order linearization of the battery nonlinear behavior, resulting in more accurate estimation of SoC in noisy environment. However, UKF requires more calculation step comparing to the EKF [2]. Both technique require accurate equivalent circuit model (ECM) of the battery, so various testes have to be carried out, including OCV-SoC characteristics test, impedance measurement and parameter identification. Beside the SoC estimation, EKF and UKF can also estimate some of ECM parameters, such as electrolytic resistance, at the same time. The ECM parameters can be used to estimate SoP and SoH of the battery pack.

In contrary to the model-based method, the data-driven technique do not require prior knowledge of ECM. Artificial Intelligence (AI) technology has recently been applied to state estimation based on artificial neural network (ANN) [3]. It is similar to a black box in that a large number of inputs and outputs are required to train the network. Because the SoC of the current state depends on the current and previous state of operations, the Long short term memory recurrent neural network (LSTM-RNN) has been proposed for SoC and SoH estimation [4],[5]. Data set has to be prepared and divided for training and validation.

The EKF based SOC estimation has been reported by many authors, first or second order ECM are mostly used. The low order number and inaccurate ECM may be reasons for low accuracy SoC estimation. To improve the estimation accuracy, in this paper the third order ECM is adopted and the ECM parameters are obtained using system identification technique. In the case of data-driven estimation, in this paper, long short-term memory recurrent neural network (LSTM-RNN) is adopted. The LSTM RNN is trained using WLTP Class 3 dataset and tested using WLTP Class 2 dataset. The SoC estimation results are compared and reported.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

II. BATTERY ESTIMATION METHODS

A. ECM

Due to the nonlinear behavior of the battery, the extended Kalman filter (EKF) algorithm is implemented for SoC estimation. The EKF based SOC estimation has been reported using first or second order ECM but the SoC estimation accuracy is not good. To improve the accuracy, in this paper the third order ECM is adopted and the ECM parameters are obtained using system identification technique. Fig. 1 shows the 3rd order ECM of lithium-ion battery. In this model, OCV is open-circuit voltage, V_t is terminal voltage, I is battery charge or discharge current, R_0 is the combined of electrolyte resistance and charge transfer resistance, and $R_1, C_1, R_2, C_2, R_3, C_3$ are the Foster's equivalent of Warburg impedance [2]. The electric double layer capacitance is neglected because the time constant of the charge transfer in the SEI region is much lower than the sampling period.




Fig. 1. Battery Equivalent Circuit Model 3rd order

B. OCV-SoC Curve

The relationship between OCV and SoC is nonlinear and it can be obtained using various test procedures. In this paper the static C/30 charge-discharge test method is adopted. LGBMJ11865 cell with a nominal voltage of 3.7 V and a rated capacity of 3.25 Ah was placed in a temperature chamber maintained at 25 degree Celsius. The data is recorded every second and the charge capacity and discharge capacity are obtained. The charge SoC and discharge SoC are calculated according to equation (1). The charge voltage and discharge voltage are then interpolated to the same 1000 SoC points (0.0 to 99.9% with 0.1% step). The OCV is obtained from the average between the charge voltage and discharge voltage. Fig. 2 show the experimental result of OCV-SoC test. The Matlab cftool is used to fit the curve using Gaussian model of eight term.




Fig. 2. The graph illustrates relationship between OCV and SoC.

$$\text{SoC}(t) = \text{SoC}(t_0) + \frac{\int_{t_0}^t I(t)dt}{Q_{\text{Rated}}} \quad (1)$$

C. ECM Parameters Identification

LGGBMJ11865 at 50% SoC was subjected to impedance tester BT4560 for ac impedance measurement. The frequency was varied from 1kHz to 0.1Hz and the impedance at these frequency is recorded. The ECM parameters are then obtained using impedance fitting software. These parameters are considered to be the initial guess for the next system identification stage using Matlab linear grey box model estimation. Because the tool is for linear model estimation, the ECM has to be linearized first. By substitute $V_t - \text{OCV}(\text{SoC})$ in (3) with Δv as shown in (4), the ECM can be easily transformed to a linear model. V_t is the measured value and the SoC, which can be estimated by coulomb counting, is used to estimate OCV. The WLTP Class 3 driving profile experiment was carried out and the experimental data is used to identify ECM parameters. The result is shown in Table 1. The ECM parameters gave about 96% fit with the experimental results.

$$\frac{di_R}{dt} = \begin{bmatrix} -\frac{1}{R_1 C_1} & 0 & 0 \\ 0 & -\frac{1}{R_2 C_2} & 0 \\ 0 & 0 & -\frac{1}{R_3 C_3} \end{bmatrix} [i_R] + \begin{bmatrix} \frac{1}{R_1 C_1} \\ \frac{1}{R_2 C_2} \\ \frac{1}{R_3 C_3} \end{bmatrix} i \quad (2)$$

$$v_t = \text{OCV}(\text{SoC}) - R_0 i - R_1 i_{R1} - R_2 i_{R2} - R_3 i_{R3} \quad (3)$$

$$\Delta v = R_0 i + R_1 i_{R1} + R_2 i_{R2} + R_3 i_{R3} \quad (4)$$

TABLE I. PARAMETERS IN BATTERY EQUIVALENT CIRCUIT MODEL

	R_0 (mΩ)	R_1 (mΩ)	R_2 (mΩ)	R_3 (mΩ)	C_1 (kF)	C_2 (kF)	C_3 (kF)
Initial Parameter	33.9	13.31	1.48	0.53	1.37	1.37	1.37
System Identification	36.48	10.90	0.92	1.93	16.86	13.07	2.24

D. EKF

The EKF algorithm consists of a State Transition function and Measurement function which can be expressed respectively as follows:

$$x_{k+1} = f(x_k, u_k) + w_k \quad (5)$$

$$y_k = h(x_k) + v_k \quad (6)$$

Where u_k is input, y_k is output, x_k is state variable, w_k is process noise, and v_k is measurement noise.

From the EMC shown in Fig. 1, it can be expressed in the form of a State Transition function and a Measurement function as follows:

$$\begin{bmatrix} x_1[k+1] \\ x_2[k+1] \\ x_3[k+1] \\ x_4[k+1] \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & e^{-\frac{T_s}{R_1 C_1}} & 0 & 0 \\ 0 & 0 & e^{-\frac{T_s}{R_2 C_2}} & 0 \\ 0 & 0 & 0 & e^{-\frac{T_s}{R_3 C_3}} \end{bmatrix} \begin{bmatrix} x_1[k] \\ x_2[k] \\ x_3[k] \\ x_4[k] \end{bmatrix} +$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\begin{bmatrix} -\frac{\eta T_s}{Q} \\ R_1(1 - e^{-\frac{T_s}{R_1 C_1}}) \\ R_2(1 - e^{-\frac{T_s}{R_2 C_2}}) \\ R_3(1 - e^{-\frac{T_s}{R_3 C_3}}) \end{bmatrix} u[k] + w[k] \quad (7)$$

$$y[k] = OCV(x_1[k]) - R_0 u[k] - x_2[k] - x_3[k] - x_4[k] + v[k] \quad (8)$$

Where $x_1[k]$ is SoC, $x_2[k]$ is $v_1[k]$, $x_3[k]$ is $v_2[k]$, $x_4[k]$ is $v_3[k]$, $u[k]$ is $i[k]$, $y[k]$ is $v_t[k]$. OCV(SoC) is the OCV-SoC relationship obtained from static OCV-SoC test.

E. Long short-term memory RNN

In battery state estimation, the SoC of the current state depends on the current and previous state of operation so the input datasets consist of a sequence of time series data. By this nature, recurrent neural network (RNN) is considered to be a suitable ANN structure. However, RNN will encounter issue when input datasets contain long sequence data, the gradient values implemented in updating weights will decrease over time until it vanishes. Hence, the weight is no longer updated. This issue is called vanishing gradient [3]. Furthermore, RNN only has short-term memory but no long-term memory. In order to solve these issues, LSTM-RNN is invented, which has both long-term and short-term memory. It is feasible to estimate SoC more accurately.

The structure of LSTM is shown in Fig. 3, which consists of a forget gate, an input gate, and an output gate. The forget gate decides whether or not the previous state of the cell will be forgotten or retained. The input gate decides whether to receive new input values and the previous hidden state in order to update the cell state, while the output gate decides whether to transmit the current hidden state to the following state. LSTM structure can be expressed as the following equations:

Where x_t is the input, h_t is the hidden state or short-term memory, c_t is the cell state or long-term memory at time t , \tilde{c}_t is the memory at the current state, f_t , i_t , and o_t are the forget gate, input gate, and output gate respectively. The activation functions are Sigmoid (σ) and Hyperbolic Tangent (\tanh) functions. W and b are the weights and biases of each cell.




Fig. 3. The structure of LSTM

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (9)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (10)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (11)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (12)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (13)$$

$$h_t = o_t \odot \tanh(c_t) \quad (14)$$

III. SIMULATION RESULTS

A. Battery current profile

The input current profile for state estimation is a profile that simulates the operation of an electric vehicle. In this paper the Matlab EV Reference Applications Model is used to generate the input current profile for experiment. The driving cycle sources are WLTP Class 2 and WLTP Class 3. The current is normalized to the cell rated Ah and becomes the command for the battery test set. The current and terminal voltage are recorded and used for simulations. Fig. 4 shows the WLTP Class 3 and WLTP Class 2 experimental results.




Fig. 4. The current and terminal voltage of input profile, (a) WLTP Class2, (b) WLTP Class3

The training set and test set for SoC estimation using LSTM were WLTP Class 3 and WLTP Class 2, respectively. The input of the model for SoC estimation using EKF was WLTP Class 2.

B. EKF State Estimation

A model for SoC estimation is constructed using Matlab Simulink Extended Kalman Filter block diagram, as shown in Fig. 5. The initial SoC is evaluated from the OCV-SoC relationship.




Fig. 5. The state estimation model using an Extended Kalman Filter

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

C. LSTM Training and Test

The LSTM structure, as shown in Fig. 3, is used for state estimations. The inputs are terminal voltage and current, while the output is SoC. These hyperparameters have been determined which are 10 hidden layers, 0.01 learning rate, 531 learner parameters, Adam as optimizer, Mean Squared Error (MSE) and loss function. Then WLTP Class 3 is used for the training dataset and WLTP Class 2 is used for testing dataset. Fig. 6 illustrates the MSE obtained from the LSTM network training. The training procedure stops at 19 epochs and MSE decreased to 0.29.




Fig. 6. The training result of LSTM

D. Performance Evaluation

In general, the performance of state estimation based on EKF and LSTM is evaluated through the Root Mean Squared Error (RMSE). It can be expressed as shown in equation (15)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SoC_i - \widehat{SoC}_i)^2} \quad (15)$$

Where n is number of SoC data, SoC_i is real SoC, and \widehat{SoC}_i is SoC from estimated.

E. Comparison between EKF and LSTM

From the simulation results, the RMSE from EKF is 0.01% and from LSTM is 0.54%. They are shown in Fig. 7 and 8 respectively. It can be seen that the SoC estimation using EKF almost completely overlaps with the actual SoC, compared to the SoC estimation using LSTM, which has a slightly discrepancy with the actual SoC.

The SoC estimation using EKF is more accurate than the SoC estimation using LSTM. Since, the EKF can clearly explain the nonlinear behavior of the battery. However, the EKF requires a considerable amount of time to prepare the model parameters, whereas the LSTM just requires input and output data feeding into the network for SoC estimation.




Fig. 7. The graph illustrates the comparison between actual and estimated SoC using EKF.




Fig. 8. The graph illustrates the comparison between actual and estimated SoC using LSTM.

IV. CONCLUSION

In this paper, two methods of SoC estimation have been performed and compared. The model-based technique using EKF for 3rd order ECM has been proposed. This method requires a set of test to obtain OCV-SoC characteristic and accurate ECM parameters. As a result, the SoC has been estimated with very high accuracy. The data-driven technique has been proposed using 10 hidden layer LSTM-RNN. The WLTP Class 3 driving cycle dataset was used for training and the WLTP Class 2 data set was used for test. The simulation of LSTM technique has 0.54% RMSE. In term of RMSE, EKF technique has better result. In this paper, however, the influence of operating temperatures was not taken into account. The future work will cover a range of operating temperatures and various driving cycles.

REFERENCES

- [1] L. Gregory Plett, Battery Management Systems Battery Modeling, Boston, Artech House, 2015.
- [2] L. Gregory Plett, Battery Management Systems Battery Equivalent-Circuit Methods, Boston, Artech House, 2015.
- [3] I. Goodfellow, Y. Bengio, A. Courville, Deep Learning, Deep Learning, MIT Press, 2016.
- [4] M. Kaur and A. Mohta, "A Review of Deep Learning with Recurrent Neural Network," 2019 International Conference on Smart Systems and Inventive Technology (ICSSIT), Tirunelveli, India, 2019.
- [5] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," Neural Computation, vol. 9, issue 8, pp. 1735-1780, 1997.

ประวัติผู้เขียน

ชื่อ-นามสกุล	นายกฤตยชญ์ หรุปานวงษ์
วัน เดือน ปีเกิด	23 พฤศจิกายน 2541
ที่อยู่	437 ถ.ไฮเวย์-ลำปาง-งาว ต.หัวเวียง อ.เมืองลำปาง จ.ลำปาง 52000
ประวัติการศึกษา	2560-2563 วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมไฟฟ้า สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง 2564 วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาไฟฟ้าและคอมพิวเตอร์
ความสนใจ	Artificial Intelligence (AI), Deep Learning, Lithium-ion battery และ Battery Management System (BMS)
ผลงานทางด้านวิชาการ	Kritayod Rupanwong, Supat Kittiratsatcha, Sompob Polmai “Comparison of Extended Kalman Filter and Long Short-Term Memory Neural Network for State of Charge Estimation of Lithium-Ion Battery”, ICEAST 2023

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้