

โมเดลการเรียนรู้ด้วยเครื่องเพื่อทำนายความต้องการในการอัดประจุรถยนต์พลังงานไฟฟ้า



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2565

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Machine learning model for Predicting EV charging demand



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	โมเดลการเรียนรู้ด้วยเครื่องเพื่อทำนายความต้องการในการ อัดประจุรถยนต์พลังงานไฟฟ้า
โดย	นายปรัชญา อุดมประดิษฐ์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.กุลธิดา โรจน์วิบูลย์ชัย
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	รองศาสตราจารย์ ดร.พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.ดวงดาว วิชาดากุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.กุลธิดา โรจน์วิบูลย์ชัย)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
(รองศาสตราจารย์ ดร.พีรพล เวทีกุล)

..... กรรมการภายนอกมหาวิทยาลัย
(ดร.ธนภัทร ช้างคะจิตร)

ปรัชญา อุดมปริฉัตร : โมเดลการเรียนรู้ด้วยเครื่องเพื่อทำนายความต้องการในการอัดประจุรถยนต์พลังงานไฟฟ้า. (Machine learning model for Predicting EV charging demand) อ.ที่ปรึกษาหลัก : รศ. ดร.กุลธิดา โรจนวิบูลย์ชัย, อ.ที่ปรึกษาร่วม : รศ. ดร.พีรพล เวทีกุล

การควบคุมการอัดประจุรถยนต์พลังงานไฟฟ้าอัจฉริยะ (Smart Charging) เป็นวิธีการจัดกำหนดการอัดประจุรถยนต์ไฟฟ้าให้ได้อย่างเหมาะสม ทำให้สถานีอัดประจุสาธารณะทำกำไรได้มากขึ้น ผลกำไรดังกล่าวนี้มักมาจากการลดค่าใช้จ่ายของค่าความต้องการพลังงานไฟฟ้าสูงสุด โดยที่ยังคงสามารถตอบสนองความต้องการของผู้ใช้รถยนต์ไฟฟ้าได้ สถานีอัดประจุสาธารณะที่มีการใช้ Smart charging ส่วนใหญ่จะให้ผู้ใช้รถยนต์ไฟฟ้าเป็นผู้กำหนดความต้องการของพวกเขาเอง อย่างไรก็ตามผู้ใช้รถยนต์ไฟฟ้าอาจจะป้อนข้อมูลความต้องการที่ไม่ตรงกับความเป็นจริง ส่งผลให้ผลกำไรของสถานีอัดประจุสาธารณะลดลงได้ ในงานวิจัยนี้ผู้ทำวิจัยได้ทำการนำเสนอ End-to-end framework ซึ่งมีเป้าหมายในการสร้างกำไรสูงสุดแก่สถานีอัดประจุสาธารณะโดยที่ยังคงตอบสนองกับความต้องการของผู้ใช้รถยนต์ไฟฟ้า โดย framework จะประกอบด้วยโมดูลหลักสองอย่าง ได้แก่ โมดูลการพยากรณ์ความต้องการของผู้ใช้รถยนต์ไฟฟ้าอันได้แก่ระยะเวลาในการเชื่อมต่อและความต้องการพลังงานไฟฟ้า ที่ใช้เทคนิคการเรียนรู้ของเครื่อง (machine learning) ต่างๆ เช่น XGBoost, Random Forest (RF), และ TabNet กับโมดูลการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุรถยนต์ไฟฟ้าที่มีพื้นฐานจากเทคนิค Model predictive control (MPC) ซึ่งโมดูลการหาค่าที่เหมาะสมที่สุดนี้ได้รับการปรับปรุงให้ดีขึ้นโดยใช้ข้อมูลจากการป้อนกลับและพฤติกรรมของการดึงกระแสของรถยนต์ไฟฟ้าที่เรียกว่า Constant Current Constant Voltage (CC-CV) การทดลองได้ทำกับข้อมูลธุรกรรมการอัดประจุจริงจากกับสี่สถานีอัดประจุ จากผลการทดลองพบว่า framework นั้นสามารถทำให้สถานีอัดประจุได้รับกำไรที่มากขึ้น

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์

ปีการศึกษา 2565

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

ลายมือชื่อ อ.ที่ปรึกษาร่วม

6370160721 : MAJOR COMPUTER SCIENCE

KEYWORD: Smart charging, Machine learning, Model predictive control

Prachaya Udomparichatr : Machine learning model for Predicting EV charging demand. Advisor: Assoc. Prof. KULTIDA ROJVIBOONCHAI, Ph.D. Co-advisor: Assoc. Prof. PEERAPON VATEEKUL, Ph.D.

Smart Charging of Electric Vehicles (EVs) is a method of optimizing the EV charging schedule. As a result, it can provide more profit for EV charging stations. This profit usually comes from reducing the peak demand charge cost while still satisfying the EV user demand. Most charging stations let EV users input their demand. However, users can intentionally or unintentionally poorly estimate their demand, leading to lower profit for EV charging stations. In this thesis, an end-to-end framework of Smart Charging that aims to maximize the profit of charging stations while satisfying EV user demand has been proposed. The framework consists of two main modules. First, the demand forecasting module focuses on predicting the EV user's energy demand and session duration using various machine learning techniques, e.g., XGBoost, Random Forest (RF), and TabNet. Second, the EV charging schedule optimization based on model predictive control (MPC) has been employed to optimize the charging schedule. The optimization module has been further improved by using the feedback information and behavior of EV charging profiles called Constant Current Constant Voltage (CC-CV). The experiment was conducted on simulation with real EV charging data up to four charging stations. The results showed that the framework improves profit for the charging stations.

Field of Study: Computer Science

Student's Signature

Academic Year: 2022

Advisor's Signature

Co-advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปด้วยดี ด้วยความช่วยเหลือของอาจารย์กุลธิดา โรจน์วิบูลย์ชัย และอาจารย์พีรพล เวทีกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ซึ่งท่านได้ให้คำแนะนำและข้อคิดเห็นต่าง ๆ อันเป็นประโยชน์อย่างยิ่งในการทำวิจัย อีกทั้งยังช่วยแก้ปัญหาต่าง ๆ ที่เกิดขึ้นระหว่างการดำเนินงานอีกด้วย ขอขอบคุณพี่ๆที่การไฟฟ้านครหลวงที่ให้คำแนะนำและความช่วยเหลือในทุกๆ ด้านในการทำวิจัย ขอขอบคุณผู้ช่วยปรับแต่งพาวเวอร์พอยท์สอบจบให้สวยงามถ้าไม่มีสไลด์คงเป็นแค่พื้นขาว และสุดท้ายนี้ ขอขอบคุณครอบครัวและเพื่อนๆที่ส่งเสริมและให้กำลังใจจนสำเร็จ

ปรีชญา อุดมปริฉัตร



สารบัญ


	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
บทที่ 1 บทนำ.....	11
1.1 ที่มาและความสำคัญ.....	11
1.2 วัตถุประสงค์ของการวิจัย.....	12
1.3 ขอบเขตของการวิจัย.....	12
1.4 คุณค่าทางวิชาการ.....	13
1.5 วิธีดำเนินการวิจัย.....	13
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	14
2.1 กำหนดปัญหา (Problem statement).....	14
2.1.1 การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า (Prediction of EV user demand)	16
2.1.2 การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule).....	16
2.2 ทฤษฎีที่เกี่ยวข้อง.....	17
2.2.1 กระบวนการตรวจสอบสำรวจข้อมูลเบื้องต้น (Exploratory data analysis).....	17
2.2.2 Feature engineering.....	18
2.2.1.1. Feature engineering: Numerical data.....	18

2.2.1.2. Feature engineering: Categorical data	18
2.2.1.3. Feature engineering: Datetime data	18
2.2.3 การเรียนรู้ของเครื่อง (Machine learning).....	19
2.2.4 การวิเคราะห์การถดถอย (Statistical Regression).....	19
2.2.5 XGBoost	19
2.2.6 Random forest (RF)	19
2.2.7 TabNet20	
2.2.8 Evaluation metrics	20
2.2.9 การหาค่าที่เหมาะสมที่สุด (Optimization).....	21
2.2.1.1. Decision variables.....	21
2.2.1.2. Discrete time step.....	22
2.2.1.3. State variables	22
2.2.1.4. Objective function	23
2.2.1.5. Constraint.....	23
2.2.10 Model predictive control.....	24
2.3 งานวิจัยที่เกี่ยวข้อง.....	25
2.3.1 งานวิจัยเกี่ยวกับการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า	25
2.3.2 งานวิจัยที่เกี่ยวกับการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า	29
บทที่ 3 ระเบียบวิธีวิจัย (Methodology)	30
3.1 End-to-end framework.....	30
3.2 (I) โมเดลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า (Prediction of EV user demand)	
30	
3.2.1 Data preprocessing.....	31

3.2.2 Prediction models	32
3.3 (II) โมเดลการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule)	32
3.3.1 ฟังก์ชันวัตถุประสงค์	33
3.3.1.1 Quick charge	33
3.3.1.2 Energy cost	34
3.3.1.3 Demand charge	34
3.3.1.4 Energy share	34
3.3.2 เงื่อนไขแสดงขอบข่าย	34
3.4 (III) รองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้า.....	35
บทที่ 4 ขั้นตอนการทดลอง (Experimental setup).....	39
4.1 ขั้นตอนการทดลองการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า.....	39
4.1.1 ชุดข้อมูล	40
4.1.2 กระบวนการตรวจสอบสำรวจข้อมูลเบื้องต้น (Exploratory data analysis).....	44
4.1.3 Input features.....	46
4.1.4 การแบ่งข้อมูล Train validation test.....	48
4.2 ขั้นตอนการทดลองการหาค่าที่เหมาะสมที่สุด	48
4.2.1 การตั้งค่า (Simulation setting)	48
4.2.2 สถานการณ์ (Simulation cases).....	50
บทที่ 5 ผลลัพธ์การทดลอง (Result)	52
5.1 ผลลัพธ์การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า.....	52
5.1.1 สถานี ACN: JPL	52
5.1.2 สถานี ACN: Caltech	55
5.1.3 สถานี MEA: Mall.....	58

5.1.4	สถานี MEA: University	61
5.2	ผลลัพธ์การ Simulation การหาค่าที่เหมาะสมที่สุด	64
5.2.1	สถานี ACN: JPL	64
5.2.2	สถานี ACN: Caltech	67
5.2.3	สถานี MEA: Mall	70
5.2.4	สถานี MEA: University	73
5.3	วิเคราะห์ผลการทดลองเพิ่มเติม	76
5.3.1	วิเคราะห์ผลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าของสถานี JPL ในช่วงเวลาที่มีผู้ใช้งานเป็นจำนวนมาก.....	76
5.3.2	วิเคราะห์ประสิทธิภาพของโมเดลการเรียนรู้ของสถานีการไฟฟ้านครหลวง	78
5.3.3	การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าอย่างง่ายจากค่าสถิติ.....	79
บทที่ 6	สรุปผลงานวิจัยและงานในอนาคต (Conclusion and future work)	82
6.1	สรุปผลงานวิจัย.....	82
6.2	แนวทางการวิจัยในอนาคต	83
6.2.1	โหลดทั่วไป และพลังงานสะอาด.....	83
6.2.2	เครื่องอัดประจุรุ่นใหม่ และความสัมพันธ์ของเครื่องอัดประจุกับรถยนต์ไฟฟ้า	84
6.2.3	การประยุกต์ใช้กับการไฟฟ้า.....	87
6.2.4	การทำนายความต้องการของผู้ใช้ให้ Underpredicted หรือ Overpredicted.....	88
บทที่ 7	ภาคผนวก	89
7.1	ผลลัพธ์ของการ Offline Scheduling เพื่อหาค่า Peak hint	89
7.1.1	สถานี ACN: JPL	89
7.1.2	สถานี ACN: Caltech	89
7.1.3	สถานี MEA: Mall	90
7.1.4	สถานี MEA: University	90

7.2 การกระจายตัวของข้อมูลสถานี Caltech, Mall, และ University	91
7.2.1 สถานี ACN: Caltech	91
7.2.2 สถานี MEA: Mall	92
7.2.3 สถานี MEA: University	93
7.3 ผลลัพธ์ของการปรับ Hyper parameter ของโมเดลการเรียนรู้.....	94
7.3.1 สถานี ACN: JPL	94
7.3.2 สถานี ACN: Caltech	97
7.3.3 สถานี MEA: Mall.....	100
7.3.4 สถานี MEA: University.....	103
บรรณานุกรม.....	2
ประวัติผู้เขียน.....	6



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

กระแสการใช้งานของรถยนต์พลังงานไฟฟ้าหรือรถยนต์ไฟฟ้า (Electric vehicles: EVs) มีแนวโน้มไปในทิศทางที่มากขึ้น จากข้อมูลสถิติของ International energy agency (IEA) [1] รถยนต์พลังงานไฟฟ้ามีการเติบโตอย่างก้าวกระโดดเป็นอย่างมาก การที่จำนวนรถยนต์ไฟฟ้าที่มีจำนวนที่มากขึ้นนี้จะทำให้ความต้องการพลังงานไฟฟ้าเพิ่มขึ้นตามไปด้วย และความต้องการพลังงานไฟฟ้าของรถยนต์ไฟฟ้าที่เพิ่มขึ้นนี้จะก่อให้เกิดปัญหาให้กับระบบโครงข่ายไฟฟ้า (Electric infrastructure) ในปัจจุบันได้ กล่าวคือตามปกติแล้วผู้ให้บริการทางไฟฟ้า (Electric utility) อันได้แก่ การไฟฟ้านครหลวง และการไฟฟ้าภูมิภาคสำหรับประเทศไทย จะออกแบบขีดจำกัดของระบบโครงข่ายไฟฟ้าให้รองรับกับความต้องการพลังงานไฟฟ้าในพื้นที่นั้นๆ ยกตัวอย่างเช่น ขนาดพิกัดของหม้อแปลงไฟฟ้าจำหน่ายในหมู่บ้านแห่งหนึ่งมีขีดจำกัดในการจ่ายพลังงานไฟฟ้าให้เพียงพอกับความต้องการพลังงานไฟฟ้าของหมู่บ้านเท่านั้น หากในอนาคตผู้อยู่อาศัยของหมู่บ้านนั้นมีการเปลี่ยนไปใช้รถยนต์ไฟฟ้าเป็นจำนวนมาก ขนาดของหม้อแปลงไฟฟ้าจำหน่ายก็อาจจะไม่สามารถรองรับความต้องการพลังงานไฟฟ้าที่เพิ่มขึ้นได้อย่างเพียงพอ ซึ่งจากงานวิจัยพบว่า ความต้องการพลังงานไฟฟ้าของรถยนต์ไฟฟ้านั้นสามารถทำให้กำลังงานสูงสุดหรือค่าความต้องการพลังงานไฟฟ้า (Peak demand) ของบ้านอยู่อาศัยโดยทั่วไปเพิ่มถึง 0.3kW ต่อหลัง [2] นอกจากนี้ยังมีงานวิจัยเป็นจำนวนมากที่ศึกษาถึงผลกระทบของรถยนต์พลังงานไฟฟ้าต่อผู้ให้บริการทางไฟฟ้า [3-5]

สำหรับในกรณีของสถานีอัดประจุสาธารณะ (EV charging station) ที่มีจำนวนของเครื่องอัดประจุ (EV charger) เป็นจำนวนมาก ก็จะทำให้ค่าความต้องการพลังงานไฟฟ้าสูงตามไปด้วย การไฟฟ้าจะยับยั้งสถานการณ์ที่ความต้องการพลังงานไฟฟ้าสูงนี้ในรูปแบบของกลไกราคา (price mechanism) ที่เรียกว่าค่าความต้องการพลังงานไฟฟ้าสูงสุด (demand charge) เป็นการสนับสนุนสถานีอัดประจุให้ทำการควบคุมการอัดประจุของรถยนต์ไฟฟ้าเพื่อลดต้นทุน

เทคนิคที่ใช้ในการควบคุมการอัดประจุนั้นได้แก่การควบคุมการอัดประจुरถยนต์ไฟฟ้าอัจฉริยะหรือการอัดประจุอัจฉริยะ (Smart charging) [6-9] ซึ่งเป็นการทำการหาค่าที่เหมาะสมที่สุดของกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule) กระทำโดยการโยกย้ายหรือลดกำลังในการอัดประจุของรถยนต์ไฟฟ้าออกไปไม่ให้เกิดช่วงเวลาที่รถยนต์พลังงานไฟฟ้าอัดประจุพร้อมกันแล้วความต้องการพลังงานไฟฟ้าเกินขีดจำกัดของระบบโครงข่ายไฟฟ้า นอกจากนี้การอัดประจุอัจฉริยะยังมีข้อดีกับสถานีอัดประจุสาธารณะ (Public EV charging station) อีกด้วย โดยถ้าหากสามารถควบคุมการอัดประจุให้อ้างอิงกับโครงสร้างของค่าไฟ จะสามารถลดต้นทุนที่สถานี

อัดประจุสาธารณะต้องจ่ายให้กับผู้ให้บริการทางไฟฟ้า เป็นการเพิ่มผลกำไรให้กับสถานีอัดประจุสาธารณะ [9]

อย่างไรก็ตามการลดกำลังหรือโยกย้ายช่วงเวลาการอัดประจุนั้น อาจทำให้เกิดกรณีที่ทำให้ผู้ใช้รถยนต์ไฟฟ้าไม่พึงพอใจได้ ดังนั้นแล้วการอัดประจุอัจฉริยะที่ได้นั้นจะต้องทราบถึงความต้องการต่างๆของผู้ใช้รถยนต์ไฟฟ้า อันได้แก่ ระยะเวลาในการเชื่อมต่อ (Session duration) และ พลังงานไฟฟ้าที่ต้องการ (Energy demand) เพื่อให้ผลลัพธ์ที่ได้ตอบสนองต่อความต้องการของผู้ใช้รถยนต์ไฟฟ้าอย่างถูกต้อง การทำให้ผู้ใช้รถยนต์ไฟฟ้าเป็นผู้ป้อนค่าระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการเองนั้น มักจะมีความคลาดเคลื่อนเป็นอย่างมาก [10] หากแต่การใช้วิธีการเรียนรู้ของเครื่อง (Machine learning) จากข้อมูลสถิติของธุรกรรมการอัดประจุนั้นจะมีความแม่นยำมากกว่า [10-15]

กำหนดการอัดประจุที่ได้จากการอัดประจุอัจฉริยะจะถูกส่งไปควบคุมเครื่องอัดประจุผ่านสิ่งที่เรียกว่าคำสั่งสัญญาณควบคุม (Pilot signal) ที่กำหนดภายในมาตรฐาน J1772 สำหรับการอัดประจุระดับ 2 หรือ AC normal charge [16] สัญญาณควบคุมนี้จะเป็นตัวกำหนดค่าขอบเขตบนหรือค่ามากที่สุดที่รถยนต์ไฟฟ้าจะได้รับอนุญาตให้ใช้ได้ใน การอัดประจุ ในปัจจุบันมาตรฐาน J1772 นั้นยังไม่ได้รองรับวิธีในการแลกเปลี่ยนข้อมูลสถานะของประจุ (SoC) หรือระดับประจุของแบตเตอรี่ไฟฟ้าภายในรถยนต์ไฟฟ้า จึงทำให้เป็นการยากที่จะทราบพลังงานไฟฟ้าที่ต้องการของรถยนต์แต่ละคันได้

1.2 วัตถุประสงค์ของการวิจัย

งานวิจัยนี้มีจุดประสงค์ต้องการที่จะทำการสร้างอัลกอริทึมการเรียนรู้ด้วยเครื่องที่หลากหลายเพื่อนำมาใช้ในการทำนายค่าระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์พลังงานไฟฟ้าผ่านการสร้าง Feature engineering ที่สะท้อนกับพฤติกรรมของผู้ใช้รถยนต์ไฟฟ้ากับข้อมูลที่มีตอนที่ผู้ใช้รถยนต์ไฟฟ้าเริ่มทำการอัดประจุเพื่อให้ผลลัพธ์ในการทำนายที่ดีขึ้น และทำการประเมินผลการทำนายของแต่ละอัลกอริทึมด้วยการทำ Framework end-to-end เชื่อมโยงระหว่างการนำค่าจากการทำนายไปใช้ในส่วนการหาค่าที่เหมาะสมที่สุดเพื่อตรวจสอบผลลัพธ์การทำนายที่วัดได้เป็นตัวเลขในการลดต้นทุนค่าใช้จ่ายของสถานีอัดประจุ

1.3 ขอบเขตของการวิจัย

- การสร้างตัวแปรต้นผ่านการทำ Feature engineering ให้กับโมเดล Machine learning ที่สะท้อนถึงพฤติกรรมของผู้ใช้รถยนต์พลังงานไฟฟ้า
- การสร้างอัลกอริทึมการเรียนรู้ด้วยเครื่องที่หลากหลายเพื่อใช้ในการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ประกอบไปด้วยระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ

- การทำ Framework end-to-end เชื่อมโยงระหว่างส่วนทำนายและส่วนการหาค่าที่เหมาะสมที่สุดเพื่อวัดผลประสิทธิภาพของการทำนายที่ได้เป็นตัวเลขในการลดค่าใช้จ่ายทางต้นทุนของสถานีอัดประจุ

1.4 คุณค่าทางวิชาการ

- นำเสนอการวิธีการสร้าง Feature จากการศึกษาข้อมูลดิบด้วย Exploratory data analysis
- นำเสนอการทำส่วน การทำนาย และแสดงผลการเปรียบเทียบ ที่ใช้อัลกอริทึมการเรียนรู้ของเครื่องที่หลากหลาย และผลลัพธ์ที่ได้
- การทำนายค่าระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการที่แม่นยำจะส่งผลให้การหาค่าที่เหมาะสมที่สุดทำงานได้ดีขึ้น
- Framework end-to-end เชื่อมโยงระหว่างส่วนทำนายและส่วนการหาค่าที่เหมาะสมที่สุดสามารถนำไปใช้ในสถานีอัดประจุไฟฟ้าเพื่อลดค่าใช้จ่ายได้
- นำเสนอผลลัพธ์การลดต้นทุนจาก Framework end-to-end

1.5 วิธีดำเนินการวิจัย

- ศึกษางานวิจัยที่เกี่ยวข้อง ทั้งในด้านการหาค่าที่เหมาะสมที่สุดของการจัดกำหนดการอัดประจุ และ การทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์พลังงานไฟฟ้า
- ศึกษาและทำความสะอาดข้อมูลดิบและทำ Exploratory data analysis
- ศึกษาและสร้างโมเดลอัลกอริทึมการเรียนรู้ด้วยเครื่องที่หลากหลายเพื่อใช้ในการทำนายค่าระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ
- วัดและประเมินผลของการทำนายของอัลกอริทึมการเรียนรู้ด้วยเครื่อง
- ศึกษาและทดลองนำค่าจากผลการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการให้กับส่วนการหาค่าที่เหมาะสมที่สุด และประเมินผลลัพธ์


บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

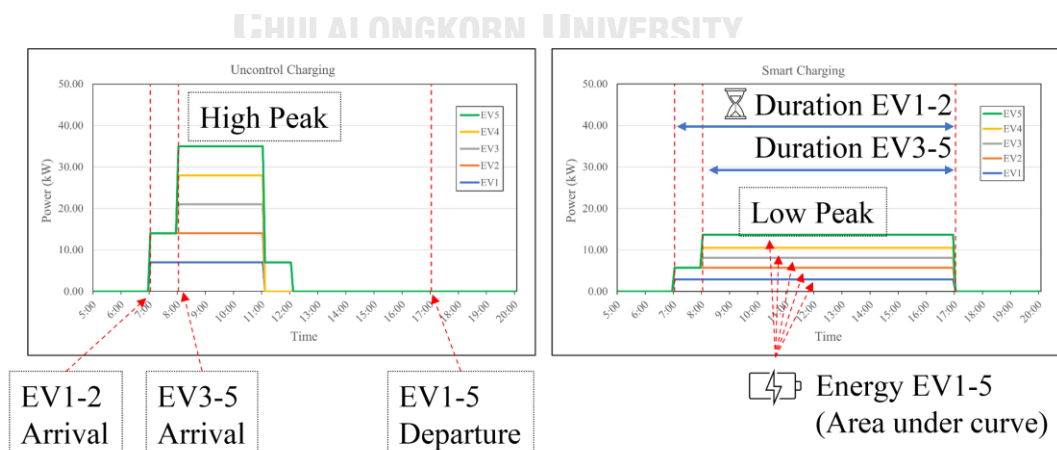
2.1 กำหนดปัญหา (Problem statement)

พิจารณาจากตัวอย่างของสถานีอัดประจุในลานจอดรถของสถานที่ทำงานตามรูปที่ 2-1 ที่ประกอบไปด้วยเครื่องอัดประจุไฟฟ้า 5 เครื่อง ในสถานที่ทำงานนั้นพนักงานมักจะเข้างานและเลิกงานในเวลาใกล้เคียงกัน ทำให้ตัวอย่างนี้เวลาในการเชื่อมต่อรถยนต์ไฟฟ้ากับเครื่องอัดประจุ และเวลาทำการถอดการเชื่อมต่อทั้งสองเหตุการณ์จะเกิดที่เวลาใกล้เคียงกัน

ในกรณีปกติหรือการอัดประจุที่ไม่มีการควบคุม (Uncontrol charging) ซึ่งเป็นกรณีส่วนใหญ่ของสถานีอัดประจุ รถยนต์ไฟฟ้าทั้งหมดจะดึงกระแสไฟฟ้าทันทีเมื่อเชื่อมต่อ ส่งผลให้เกิดความต้องการพลังงานไฟฟ้าที่สูง (พิจารณารูปที่ 2-2 ซ้าย) แต่ถ้าหากมีการใช้งานการอัดประจุอัจฉริยะ จะสามารถทำให้ความต้องการพลังงานไฟฟ้ามีค่าที่น้อยลงได้ (พิจารณารูปที่ 2-2 ขวา)



รูปที่ 2-1 ตัวอย่างสถานีอัดประจุในสถานที่ทำงานที่มีเครื่องอัดประจุ 5 เครื่อง




รูปที่ 2-2 ตัวอย่างการอัดประจุในกรณีที่ไม่มีการควบคุม (ซ้าย) กับที่มีการควบคุม (ขวา)

หากกล่าวอย่างง่ายถึงสิ่งที่การอัดประจุอัจฉริยะทำนั้นคือ ในเซตของรถยนต์ไฟฟ้าที่เชื่อมต่อ V_k พิจารณาพลังงานไฟฟ้าที่ต้องการหรือก็คือพื้นที่ใต้กราฟ (Energy ในสมการที่ (2-1)) จากนั้นทำการหารด้วยระยะเวลาในการเชื่อมต่อของผู้ใช้รถยนต์ไฟฟ้าแต่ละคัน (Duration ในสมการที่ (2-1)) จะทำให้ได้กำลังหรือพลังไฟฟ้าที่รถยนต์แต่ละคันควรได้รับ (Power ในสมการที่ (2-1)) ด้วยวิธีการนี้ จะทำให้สถานีอัดประจุลดค่าพลังไฟฟ้าสูงสุดได้โดยที่ผู้ใช้รถยนต์ไฟฟ้ายังคงพึงพอใจ

$$Power_i (kW) = \frac{Energy_i (kWh)}{Duration_i (h)}, i \in V_k \quad (2-1)$$

จะเห็นได้ว่าการอัดประจุอัจฉริยะนั้นประกอบไปด้วยสองปัญหาย่อยได้แก่ ปัญหาย่อยที่หนึ่งคือการทราบถึงความต้องการของผู้ใช้รถยนต์ไฟฟ้าซึ่งประกอบไปด้วยระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ ปัญหาย่อยที่สองคือการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule)

สำหรับปัญหาย่อยแรก ในการทราบถึงความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่แม่นยำร้อยละแปดสิบจะเป็นไปได้ยากในทางปฏิบัติ เนื่องจากระยะเวลาเชื่อมต่อและพลังงานไฟฟ้าที่ใช้ไปที่แท้จริงจะทราบได้ก็ต่อเมื่อการอัดประจุเสร็จสิ้นแล้ว วิธีที่ง่ายและตรงไปตรงมาที่สุดในการทราบความต้องการของผู้ใช้คือการให้ผู้ใช้รถยนต์ไฟฟ้าเป็นผู้ป้อนข้อมูลดังกล่าวด้วยตนเอง อย่างไรก็ตามผู้ใช้รถยนต์ไฟฟ้าบางคนอาจจะประเมินความต้องการที่ไม่ตรงกับความเป็นจริงหรือมีความคลาดเคลื่อน [10] นอกจากนี้ผู้ใช้บางคนอาจจะจงใจป้อนข้อมูลที่ผิดเพื่อใช้ประโยชน์จากการทำงานของระบบ เช่น จงใจป้อนข้อมูลระยะเวลาเชื่อมต่อที่สั้นกับพลังงานไฟฟ้าที่ต้องการสูงเพื่อให้ระบบจัดสรรพลังงานให้ทันที จากที่กล่าวมาจะเห็นว่ากรณีที่ให้ผู้ใช้เป็นผู้ป้อนข้อมูลด้วยตนเองจะมีความแม่นยำที่น้อยและผู้ใช้สามารถที่จะหลอกระบบได้ ในอีกวิธีหนึ่งที่มีความแม่นยำคือการใช้การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าด้วยเทคนิคการเรียนรู้ของเครื่อง (อธิบายเพิ่มเติมใน 2.1.1) จากนั้นความต้องการของผู้ใช้รถยนต์ไฟฟ้าจะเป็นส่วนหนึ่งของอินพุตในปัญหาย่อยที่สองหรือการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (อธิบายเพิ่มเติมใน 2.1.2) ปัญหาย่อยทั้งสองปัญหามีลักษณะการเชื่อมโยงกันตามรูปที่ 2-3




รูปที่ 2-3 รูปแสดงความเชื่อมโยงระหว่างปัญหาการทำนายและปัญหาการหาค่าที่เหมาะสมที่สุด

2.1.1 การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า (Prediction of EV user demand)

การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นมาจากข้อสันนิษฐานที่ว่าพฤติกรรมการอัดประจุของรถยนต์ไฟฟ้าที่สถานที่ใดที่หนึ่งมักจะมีพฤติกรรมที่ค่อนข้างใกล้เคียงกับพฤติกรรมในอดีต หรือมีลักษณะเป็นกิจวัตร ซึ่งจากข้อสันนิษฐานนี้ทำให้ในบางกรณี สามารถที่จะทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าโดยง่ายโดยใช้ข้อมูลความต้องการเฉลี่ยในอดีตของผู้ใช้รถยนต์ไฟฟ้าเป็นค่าผลลัพธ์ของการทำนาย แต่อย่างไรก็ตามการใช้ค่าเฉลี่ยก็ยังมีคงความแม่นยำที่น้อยกว่าการใช้วิธีเทคนิคการเรียนรู้ของเครื่อง [10] การใช้เทคนิคการเรียนรู้ของเครื่องในการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าจะนำข้อมูลธุรกรรมการอัดประจุในอดีตมาเป็นอินพุตในการสร้างโมเดลการเรียนรู้ของเครื่องดังแสดงในรูปที่ 2-4

Prediction Problem

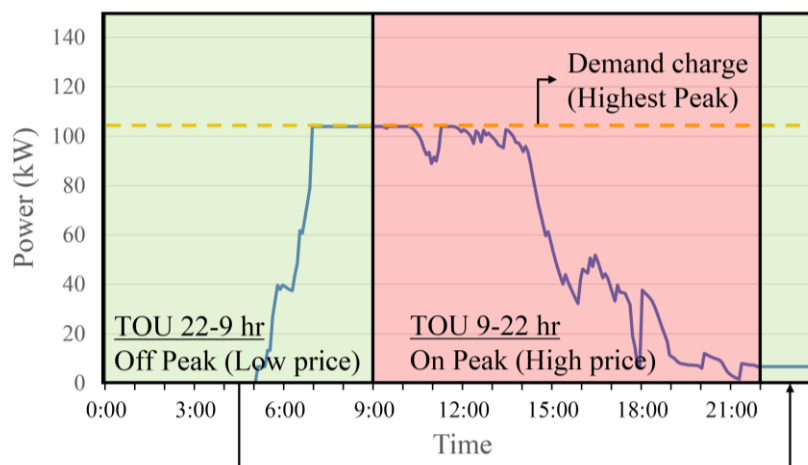


รูปที่ 2-4 วิธีการนำข้อมูลในอดีตของผู้ใช้รถยนต์ไฟฟ้ามาสร้างอัลกอริทึมการเรียนรู้ของเครื่อง

2.1.2 การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule)

การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์พลังงานไฟฟ้าในที่นี้คือการคำนวณหาการกำหนดการอัดประจุของกลุ่มของรถยนต์พลังงานไฟฟ้าที่เชื่อมต่อกับสถานีอัดประจุ โดยมีเป้าหมายเบื้องต้นเพื่อให้การอัดประจุของกลุ่มของรถยนต์พลังงานไฟฟ้ามีการใช้พลังงานรวมกันไม่เกินค่าลิมิตของอุปกรณ์ทางไฟฟ้า เช่น หม้อแปลงไฟฟ้าหรือสายไฟ นอกจากนี้ยังสามารถเพิ่มเป้าหมายในการลดต้นทุนให้กับสถานีอัดประจุได้ กล่าวคือโครงสร้างค่าไฟฟ้าสำหรับผู้ใหญ่ ในที่นี้คือสถานีอัดประจุ จะมีสิ่งๆที่เรียกว่า Time of use (TOU) หรืออัตราค่าไฟฟ้าตามช่วงเวลาของการใช้ ซึ่งถ้าหากสามารถโยกย้ายช่วงเวลาการอัดประจุที่มีอัตราค่าไฟฟ้าสูงไปยังช่วงที่มีอัตราค่าไฟฟ้าต่ำได้ ก็จะสามารถลดต้นทุนของสถานีอัดประจุได้ นอกจากอัตราค่าไฟฟ้าตามช่วงเวลาของการใช้แล้วนั้น สถานีอัดประจุมักที่จะต้องจ่ายสิ่งๆที่เรียกว่าค่าความต้องการพลังไฟฟ้าสูงสุด (Demand charge)

อีกด้วย ซึ่งค่านี้จะคิดคำนวณจากกำลังไฟฟ้าที่สถานีใช้สูงที่สุดในรอบเดือน โดยถ้าหากทำการโยกย้ายการอัดประจุให้ทำการกระจายออกไปทุกช่วงเวลาหรือที่เรียกว่าการทำการกระจายโหลดก็จะสามารถลดกำลังงานสูงสุดได้ ส่งผลให้สถานีอัดประจุลดค่าใช้จ่ายจากค่าความต้องการพลังไฟฟ้าสูงสุดได้



รูปที่ 2-5 ตัวอย่างแสดง Time of use และ Demand charge

เพื่อให้การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์พลังงานไฟฟ้าเหมาะสมกับการใช้งานจริงในทางปฏิบัติ มีสิ่งที่ต้องพิจารณาในการเลือกใช้อัลกอริทึมดังนี้

1. สภาพแวดล้อม (Environment) ซึ่งในที่นี้คือสถานีอัดประจุ มีลักษณะเปลี่ยนแปลงอยู่ตลอดเวลา จำนวนรถยนต์ไฟฟ้าที่เชื่อมต่ออยู่สามารถเพิ่มหรือลดได้ตลอดเวลาขึ้นอยู่กับปัจจัยภายนอกหรือผู้ใช้รถยนต์
2. กำหนดการอัดประจุที่ทำการส่งไปให้กับเครื่องอัดประจุนั้นเป็นค่าอัตราการอัดประจุมากที่สุดที่รถยนต์ไฟฟ้าสามารถใช้งานได้ แต่อัตราการอัดประจุที่เกิดขึ้นจริงจะขึ้นอยู่กับรถยนต์ไฟฟ้าเอง ซึ่งอาจจะมีค่าน้อยกว่าที่กำหนดได้ ส่งผลให้กำหนดการอัดประจุกับการอัดประจุจริงสามารถที่จะเบี่ยงเบนจากกันได้
3. ค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้า ไม่ว่าจะเป็นจากกรณีที่ใช้เป็นผู้อินพุตหรือจากกรณีที่เป็นคำตอบของโมเดลการเรียนรู้ จะมีความไม่แน่นอน (Uncertainty) ที่อาจจะมากหรือน้อยกว่าความเป็นจริงได้

2.2 ทฤษฎีที่เกี่ยวข้อง

2.2.1 กระบวนการตรวจสอบสำรวจข้อมูลเบื้องต้น (Exploratory data analysis)

กระบวนการตรวจสอบสำรวจข้อมูลเบื้องต้น กระทำเพื่อให้สามารถทำความเข้าใจเกี่ยวกับชุดของข้อมูลที่ทำการสนใจอยู่ กระทำเพื่อให้เราสามารถตรวจสอบสมมติฐานเบื้องต้นที่มี สามารถช่วยในการตรวจหาความผิดปกติของชุดข้อมูล ช่วยในการตรวจจับหาค่าผิดปกติแปลกผิดปกติ (Outlier) ได้

นอกจากนี้ยังช่วยให้มองเห็นการกระจายตัวของข้อมูล มองเห็นแนวทางหรือแนวโน้มและแบบแผนของข้อมูลก่อนที่จะเริ่มดำเนินการทำแบบจำลองทางสถิติ (Statistical modeling)

2.2.2 Feature engineering

การทำ Feature engineering นั้นคือการสกัดข้อมูลเพิ่มออกจากชุดข้อมูลเดิม มีจุดประสงค์เพื่อให้อัลกอริทึมทำการเรียนรู้ชุดข้อมูลที่ทำการสกัดแล้วได้ง่ายขึ้น ส่งผลให้เพิ่มประสิทธิภาพในการทำนาย ในที่นี้จะขอยกตัวอย่างการทำ Feature engineering จากชนิดของข้อมูล

2.2.1.1. Feature engineering: Numerical data

ข้อมูลประเภทตัวเลขหรือ Numerical นั้นควรจะถูกรับทำการ Normalize เพื่อให้มีค่าอยู่ในช่วงที่ต้องการ สาเหตุที่ควรทำการ Normalize ข้อมูลประเภทตัวเลขนั้นเนื่องจาก ในบางอัลกอริทึมการเรียนรู้ด้วยเครื่องนั้นจะทำงานได้ดีขึ้นกับชุดข้อมูลที่ผ่านการ Normalize แล้ว นอกจากนี้หากทำการ Normalize ข้อมูลประเภทตัวเลขแล้วจะทำให้บางอัลกอริทึมการเรียนรู้ด้วยเครื่องลด bias ของข้อมูลที่มีช่วงที่แตกต่างกันมากได้ การทำ Normalize นั้นมีได้หลายวิธีการ เช่น Minmax Scaler ที่เป็นการแปลงข้อมูลตัวเลขให้มีช่วงอยู่ในช่วง 0 ถึง 1 โดยใช้ค่ามากที่สุดและค่าน้อยที่สุดของข้อมูลเป็นตัวการทำการ scale ของข้อมูล หรือ Standard Scaler ที่จะแปลงข้อมูลชุดตัวเลขให้มีค่าเฉลี่ยเป็น 0 และส่วนเบี่ยงเบนมาตรฐานเป็น 1 เป็นต้น

2.2.1.2. Feature engineering: Categorical data

ข้อมูลรูปแบบประเภทหรือ Categorical นั้นควรจะถูกรับทำการแปลง เนื่องจากบางอัลกอริทึมการเรียนรู้ด้วยเครื่องจะไม่สามารถป้อนข้อมูลรูปแบบประเภทได้โดยตรง หรือจะทำงานได้ไม่ดีหากไม่ทำการแปลงข้อมูลก่อน วิธีการแปลงข้อมูลรูปแบบประเภทนั้นมีหลากหลายวิธี เช่น Ordinal encoding สำหรับข้อมูลรูปแบบประเภทชนิด Ordinal, One-hot encoding ที่เป็นวิธีการแปลงข้อมูลรูปแบบประเภทให้มีมิติที่มากขึ้นตามจำนวนชนิดของข้อมูล หรือ Label encoding ที่เป็นวิธีการแปลงข้อมูลให้เป็นตัวเลขตั้งแต่ 0 ถึงจำนวนข้อมูล -1 เป็นต้น

2.2.1.3. Feature engineering: Datetime data

ข้อมูลรูปแบบวันและเวลานั้นสามารถที่จะถูกสกัดออกมาให้เป็นหลาย Feature ได้เช่น ถูกรับสกัดออกมาเป็น Feature วินาที, นาที, ชั่วโมง, วัน, สัปดาห์, เดือน, ปี หรือแม้กระทั่งฤดูกาล เป็นต้น การสกัดข้อมูลออกเป็นหลาย Feature เหล่านี้ จะช่วยให้อัลกอริทึมการเรียนรู้ด้วยเครื่องสามารถเรียนรู้ความสัมพันธ์ของวันและเวลากับค่าที่ต้องการทำนายได้

นอกจากนี้ในบางกรณียังสามารถแปลงข้อมูลที่ถูกรับสกัดเหล่านี้ต่อได้โดยวิธีการที่เรียกว่า Time cyclic feature โดยแนวคิดของการแปลงรูปแบบนี้มีอยู่ว่า เวลานั้นมีการวนเป็นวงกลม เวลาที่ 23.00 น. มีความใกล้กับเวลา 0.00 น. มากกว่าที่ 18.00 น. จึงสมควรทำการแปลงข้อมูลลักษณะนี้โดยใช้ความห่างกันในลักษณะวงกลมที่จะแสดงถึงความห่างกันของแต่ละค่าที่แม่นยำกว่า

2.2.3 การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่องคือการให้คอมพิวเตอร์เรียนรู้บางสิ่งจากข้อมูลได้ด้วยตนเอง การเรียนรู้ของเครื่องสามารถแบ่งออกเป็นได้ 2 ลักษณะ ได้แก่ การเรียนรู้แบบมีผู้สอน (Supervised learning) และการเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) ในวิธีการเรียนรู้แบบมีผู้สอนนั้นจะต้องมีการระบุข้อมูลตัวแปรตาม (Dependent variable) เพื่อให้เครื่องสามารถเรียนรู้ได้หาความสัมพันธ์ระหว่างข้อมูลตัวแปรต้น (Independent variable) และข้อมูลตัวแปรตาม ต่างกันสำหรับการเรียนรู้แบบไม่มีผู้สอนนั้นไม่มีความจำเป็นที่จะต้องระบุข้อมูลตัวแปรตามและมักจะใช้ในการหาความสัมพันธ์ของชุดข้อมูลเพื่อใช้ในการจัดกลุ่ม สำหรับงานวิจัยนี้ที่จะมีการทำนายค่าระยะเวลาในการเชื่อมต่อและความต้องการพลังงานไฟฟ้าผู้ใช้รถยนต์พลังงานไฟฟ้า ซึ่งค่าดังกล่าวจะเป็นตัวแปรตาม ดังนั้นแล้วจะมีการใช้วิธีการเรียนรู้แบบมีผู้สอน

ในการเรียนรู้ของเครื่องแบบมีผู้สอนยังสามารถแบ่งได้ด้วยลักษณะค่าของตัวแปรตาม ซึ่งแบ่งออกได้เป็น 2 รูปแบบ ได้แก่ถ้าข้อมูลตัวแปรตามเป็นรูปแบบประเภท (Categorical) จะเรียกรูปแบบนี้ว่าการแบ่งประเภทข้อมูล (Statistical classification) และในกรณีที่ข้อมูลตัวแปรตามเป็นรูปแบบประเภทต่อเนื่อง (Continuous) จะเรียกรูปแบบนี้ว่าการวิเคราะห์การถดถอย (Statistical Regression) ในงานวิจัยนี้ค่าที่ทำกรทำนายจะเป็นค่าที่ต่อเนื่อง ดังนั้นแล้วการทำนายจะเป็น การเรียนรู้แบบมีผู้สอนรูปแบบการวิเคราะห์การถดถอย

2.2.4 การวิเคราะห์การถดถอย (Statistical Regression)

การวิเคราะห์การถดถอยการคือเป็นวิธีการทางสถิติที่ใช้วิเคราะห์หาความสัมพันธ์ระหว่างข้อมูลตัวแปรต้นและข้อมูลตัวแปรตาม วิธีการวิเคราะห์การถดถอยที่ง่ายที่สุดและใช้อย่างแพร่หลายกับชุดข้อมูลที่ไม่มีความซับซ้อนคือการวิเคราะห์การถดถอยเชิงเส้น (Linear regression) แต่กับชุดข้อมูลที่มีความซับซ้อนมีความไม่เป็นเชิงเส้นก็จะมีอัลกอริทึมที่เหมาะสมกว่ายกตัวอย่างเช่น Random forest, XGBoost, TabNet

2.2.5 XGBoost

XGBoost เป็นรูปแบบหนึ่งของ Gradient boosting ซึ่งคล้ายกับ RF ตรงที่มีการนำต้นไม้หลายๆต้นให้มาทำงานร่วมกัน แต่ในกรณีของ Gradient boosting นั้นจะมีความแตกต่างกับ RF ตรงที่วิธีการสร้างต้นไม้ กล่าวคือใน Gradient boosting นั้นจะสร้างต้นไม้ ต่อๆกันในรูปแบบตามลำดับ (Sequential) ซึ่งทำให้สามารถลดค่าผิดพลาดจากต้นไม้ต้นก่อนหน้าได้ ส่งผลให้ได้ผลลัพธ์ในการทำนายที่ดีขึ้น

2.2.6 Random forest (RF)

Random forest คือ อัลกอริทึมที่ทำกรรวบรวมต้นไม้ (Decision trees) หลายๆต้นให้มาทำงานร่วมกันเพื่อให้ได้ผลลัพธ์ในการทำนายที่ดีขึ้น ซึ่งเรียกรูปแบบการทำงานร่วมกันนี้ว่าการเรียนรู้

ร่วมกัน (Ensemble) ซึ่ง RF นั้นสามารถที่จะทำนายการวิเคราะห์การถดถอยที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นได้ดี

2.2.7 TabNet

TabNet นั้นถูกพัฒนามาเพื่อตอบโจทย์ในการใช้ Deep learning กับข้อมูลตาราง (Tabular data) โดยปกติแล้ว Deep learning นั้นมักจะทำให้ผลลัพธ์ที่ดีกับการทำเกี่ยวกับรูปภาพหรือเสียง โดย Deep learning จะสามารถเข้ารหัส (Encode) ข้อมูลดิบให้ออกมาอยู่ในรูปตัวแทนที่มีความหมายได้ดี ทำให้ผลลัพธ์ที่ใช้กับข้อมูลรูปภาพหรือเสียงออกมาได้ดี [17] อย่างไรก็ตามกับข้อมูลตารางนั้นยังไม่ค่อยมีอัลกอริทึมที่ใช้ Deep learning แล้วได้ผลลัพธ์ที่ดี จึงเป็นที่มาของ TabNet ที่ถูกสร้างขึ้นมาเพื่อต้องการนำ Deep learning ที่มีข้อดีในความสามารถในการทำ “End-to-end gradient descent based learning”

TabNet นั้นจะนำเข้าสู่ชุดข้อมูลและทำการเรียนรู้ด้วยวิธี Gradient descent-based optimization ตัว TabNet จะใช้การเลือกตัวแปรต้น ด้วย Attention transformer ที่ต่อกันในรูปแบบตามลำดับในทุกๆขั้นตอนการตัดสินใจ (Decision step) วิธีการนี้ส่งเสริมให้สามารถช่วยในการอธิบายอัลกอริทึมได้ว่าตัวอัลกอริทึมนั้นเลือกตัวแปรต้นตัว ไหนเป็นหลัก

2.2.8 Evaluation metrics

การประเมินผลการทำนายจะใช้ Evaluation metrics ในการเปรียบเทียบประสิทธิภาพของอัลกอริทึมว่ามีความสามารถในการทำนายที่แม่นยำแค่ไหน

วิธีการประเมินผลการทำนายจากอัลกอริทึมประเภทการวิเคราะห์การถดถอยจะใช้ Evaluation metrics ที่มีการใช้กันโดยทั่วไปดังนี้

Root mean square error (RMSE)

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

Mean absolute error (MAE)

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

Coefficients of determination (R^2)

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (2-4)$$

Mean absolute percentage error (MAPE)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2-5)$$

Symmetric mean absolute percentage error (SMAPE)

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i| + |\hat{y}_i|} \quad (2-6)$$

โดยที่ค่า y_i คือค่าที่แท้จริง (True value) \hat{y}_i คือค่าจากการทำนาย (Predicted value) \bar{y}_i คือค่าเฉลี่ยและ n คือ จำนวนของข้อมูล

RMSE และ MAE นั้นจะมีหน่วยเดียวกันกับค่าที่ทำการตรวจสอบซึ่งในที่นี้คือ ระยะเวลาในการอัดประจุ (minute) และ ความต้องการทางพลังงานไฟฟ้า (kWh)

MAPE, SMAPE นั้นจะไม่มีหน่วยเนื่องจากค่าที่ได้จะเป็นในรูปแบบเปอร์เซ็นต์ ซึ่งทำให้ง่ายต่อการเปรียบเทียบผลลัพธ์ที่ได้กับชุดข้อมูลอื่น

R^2 นั้นคือค่าทางสถิติที่ใช้วัดว่าตัวแปรต้นนั้นอธิบายความแปรผันของตัวแปรตามหรือค่าการทำนายของอัลกอริทึมการถดถอยที่ได้มานั้นดีแค่ไหน

2.2.9 การหาค่าที่เหมาะสมที่สุด (Optimization)

การหาค่าที่เหมาะสมที่สุดคือกระบวนการหาจุดทำงานที่ดีที่สุดโดยการทำการหาค่าต่ำสุด (Minimize) หรือการหาค่าสูงสุด (Maximize) ของฟังก์ชันวัตถุประสงค์ (Objective function) ที่ใช้ในการแสดงถึงตัวเลือกต่างๆที่เป็นไปได้ (Decision variable) เพื่อให้ได้ผลลัพธ์ที่ดีที่สุดภายใต้ข้อจำกัดหรือเงื่อนไขแสดงขอบข่าย (Constraint)


ในการหาค่าที่เหมาะสมที่สุดจะมีศัพท์ที่ใช้ในการอธิบายกระบวนการการทำงานต่างๆ ดังนี้ Decision variables, State variables, Discrete time step, Objective function, Constraint ในหัวข้อนี้จะอธิบายศัพท์เหล่านี้โดยใช้ตัวอย่างจากกรณีของการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุรถยนต์พลังงานไฟฟ้าจากงานวิจัยที่ [9]

2.2.1.1. Decision variables

Decision variables หรือ Control variables คือตัวแปรที่การหาค่าที่เหมาะสมที่สุดใช้ในการปรับเปลี่ยนไปมาหรือใช้ในการเลือกเพื่อให้ได้ผลลัพธ์ที่ดีที่สุดที่ต้องการ ซึ่งในกรณีของการอัดประจุรถยนต์พลังงานไฟฟ้าคือการเลือกค่าอัตราการอัดประจุ (rate) ให้แก่เครื่องอัดประจุที่มีรถยนต์พลังงานไฟฟ้าเชื่อมต่ออยู่ โดยจะกำหนดให้อัตราการอัดประจุแทนที่ด้วย

$$r_i, \quad i \in V_k \quad (2-7)$$

โดยที่ r_i คืออัตราการการอัดประจุ และ V_k คือเซตของรถยนต์พลังงานไฟฟ้าที่ทำการเชื่อมต่ออยู่และยังไม่ได้รับพลังงานถึงค่าที่ต้องการ (active EVs) รูปที่ 2-6 แสดงถึงค่าอัตราการอัดประจุของเครื่องอัดประจุที่มีรถยนต์พลังงานไฟฟ้าเชื่อมต่ออยู่



รูปที่ 2-6 ค่าอัตราการอัดประจุ

2.2.1.2. Discrete time step


ในบางกรณีการหาค่าที่เหมาะสมที่สุดมีรูปแบบเป็นการหาค่าที่เหมาะสมที่สุดแบบเป็นลำดับต่อกัน (Sequence) ในแต่ละช่วงเวลา ซึ่งช่วงเวลานี้จะมีทั้งรูปแบบต่อเนื่อง (Continuous) และไม่ต่อเนื่อง (Discrete) แต่เพื่อให้ง่ายต่อการคำนวณมักจะใช้รูปแบบ Discrete time step

ซึ่งในกรณีของการอัดประจुरถยนต์ไฟฟ้านั้นจะไม่ได้เป็นการหาค่าอัตราการอัดประจุแค่ค่าเดียวในเวลาหนึ่ง แต่จะเป็นการหาค่ากำหนดการของการอัดประจुरถยนต์พลังงานไฟฟ้าจนถึงช่วงเวลาที่กำหนด (Optimization horizon) โดยในที่นี้จะกำหนดให้เป็น $\mathcal{T} := \{1, 2, 3, \dots, T\}$ ซึ่งแต่ละ Discrete time step จะมีค่าห่างกันแล้วแต่กำหนด เช่น 5 นาที

ดังนั้นแล้วการหาค่ากำหนดการของการอัดประจुरถยนต์ไฟฟ้าจะทำให้ Decision variables หรือในกรณีนี้คืออัตราการอัดประจุ r_i กลายเป็น Vector ขนาด T ดังนั้นแล้วกำหนดการของการอัดประจुरถยนต์ไฟฟ้าจะแทนที่ด้วยสมการที่ (2-8)

$$r_i := (r_i(1), r_i(2), \dots, r_i(T)), \quad i \in V_k \quad (2-8)$$

โดยที่ r_i คือกำหนดการของการอัดประจुरถยนต์พลังงานไฟฟ้า รูปที่ 2-7 แสดงถึงกำหนดการของการอัดประจुरถยนต์ไฟฟ้า




รูปที่ 2-7 กำหนดการของการอัดประจुरถยนต์ไฟฟ้า

2.2.1.3. State variables

คือตัวแปรที่แสดงถึงสถานะของระบบหรือสภาพแวดล้อมที่การหาค่าที่เหมาะสมที่สุดทำการสนใจ ในกรณีของการอัดประจุอัจฉริยะคือจำนวนของรถยนต์ไฟฟ้าที่อยู่ในสถานีอัดประจุ และสถานะของรถยนต์ไฟฟ้าที่เชื่อมต่อที่เครื่องอัดประจุ โดยสถานะของรถยนต์ไฟฟ้าที่เวลา k ประกอบไปด้วย

เซต($e_i(k), d_i(k), \bar{r}_i(k)$) โดยที่พลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้าแทนที่ด้วย $e_i(k)$, ระยะเวลาในการเชื่อมต่อของรถยนต์ไฟฟ้าแทนที่ด้วย $d_i(k)$ และค่ามากที่สุดของอัตราการอัดประจุที่เครื่องอัดประจุสามารถจ่ายได้แทนที่ด้วย $\bar{r}_i(k)$



รูปที่ 2-8 สถานะของรถยนต์ไฟฟ้า

2.2.1.4. Objective function

Objective function หรือ Utility function คือฟังก์ชันวัตถุประสงค์ ฟังก์ชันวัตถุประสงค์ เป็นฟังก์ชันที่กำหนดเป้าหมายหรือวัตถุประสงค์ของปัญหาการหาค่าที่เหมาะสมที่สุด สามารถเป็นได้ ทั้งในรูปแบบการหาค่าต่ำสุดหรือค่าสูงสุดของสมการ ในกรณีของการอัดประจुरยนต์ไฟฟ้าจะแสดง ในรูปสมการที่ (2-9)

$$\max_r U_k(r) \quad (2-9)$$

โดยที่ r คือกำหนดการของการอัดประจुरยนต์พลังงานไฟฟ้า และ $U_k(r)$ คือฟังก์ชัน วัตถุประสงค์ที่จะทำการกำหนดเพื่อให้ได้ผลลัพธ์ตามที่ต้องการ เช่น การลดต้นทุนค่าไฟของสถานีอัด ประจุโดยอ้างอิงจากโครงสร้างค่าไฟ ฟังก์ชันวัตถุประสงค์ที่ใช้จะอธิบายอย่างละเอียดในหัวข้อ 3.3.1

2.2.1.5. Constraint

Constraint หรือเงื่อนไขแสดงขอบข่าย คือข้อจำกัดหรือข้อกำหนดที่คำตอบจากการหาค่าที่ เหมาะสมที่สุดห้ามทำการละเมิด เงื่อนไขแสดงขอบข่ายนั้นจะจำกัดเซตคำตอบที่เป็นไปได้ (Feasible region) ในกรณีของการอัดประจुरยนต์ไฟฟ้าจะแสดงในรูปสมการที่ (2-10)

$$\text{s. t. } r \in \mathcal{R}_k \quad (2-10)$$

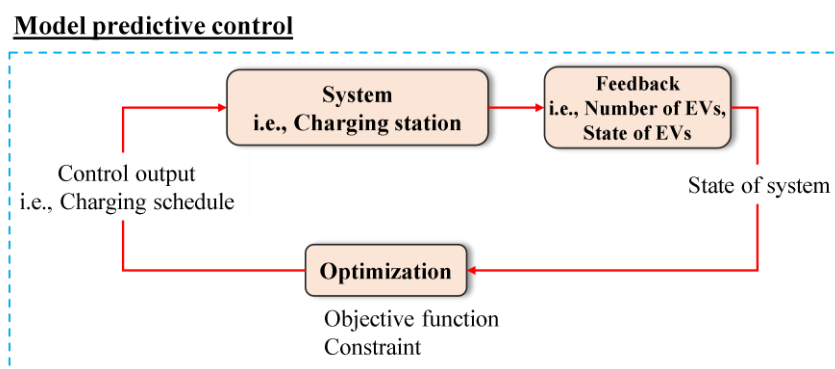
โดยที่ r คือกำหนดการของการอัดประจुरยนต์ไฟฟ้า และ \mathcal{R}_k คือเซตคำตอบของ กำหนดการของการอัดประจुरยนต์ไฟฟ้าที่เป็นไปได้ เช่นผลรวมของอัตราการอัดประจุของรถยนต์ ไฟฟ้าทุกคันรวมกันจะต้องไม่เกินขีดจำกัดของหม้อแปลงไฟฟ้า เงื่อนไขแสดงขอบข่ายที่ใช้จะอธิบาย อย่างละเอียดในหัวข้อ 3.3.2

2.2.10 Model predictive control

Model predictive control (MPC) คือเทคนิคในการควบคุมระดับสูง โดยตัวมันนั้นจะใช้สมการทางคณิตศาสตร์ในการทำนายถึงผลลัพธ์ของในควบคุมที่จะเกิดขึ้นในอนาคตกับระบบที่สนใจ เพื่อให้ค่าการควบคุมที่คำนวณได้สอดคล้องกับระบบ

การทำงานของ MPC นั้น จะคำนวณหาค่าการควบคุมในเวลาปัจจุบันจนถึงช่วงเวลาที่กำหนด (Optimization horizon) ด้วยการทำการหาค่าที่เหมาะสมที่สุดโดยอ้างอิงจากสถานะของระบบในปัจจุบัน จากนั้นจะทำการควบคุมระบบด้วยค่าการควบคุมของช่วงเวลาแรกเท่านั้น เมื่อถึงช่วงเวลาถัดมาก็จะทำการคำนวณหาค่าที่เหมาะสมที่สุดใหม่ จากนั้นระบบที่อ้างอิงจะทำการอัปเดตกับสิ่งที่เกิดขึ้นกับระบบ

MPC นั้นประกอบไปด้วยสองส่วนใหญ่ๆ ได้แก่ระบบที่สนใจและการหาค่าที่เหมาะสมที่สุดในกรณีของการอัดประจุรถยนต์ไฟฟ้าจะแสดงดังรูปที่ 2-9 โดยระบบที่สนใจคือสถานีอัดประจุซึ่งจะมีข้อมูลสถานะของระบบที่ประกอบไปด้วยจำนวนของรถยนต์ไฟฟ้าและสถานะของรถยนต์เหล่านั้น ข้อมูลสถานะของระบบจะเป็นอินพุตให้การหาค่าที่เหมาะสมที่สุดในการหาค่าการควบคุมหรือกำหนดการอัดประจุ จากนั้นจะทำการควบคุมสถานีอัดประจุด้วยอัตราการอัดประจุแรกของกำหนดการอัดประจุ เมื่อถึงช่วงเวลาถัดมาก็จะทำการคำนวณหาการกำหนดการอัดประจุใหม่ โดยจะอัปเดตถึงสิ่งที่เกิดขึ้นกับสถานีอัดประจุ เช่น จำนวนของผู้ใช้รถยนต์ไฟฟ้าที่เปลี่ยนไปจากการเข้ามาจอดหรือออกจากสถานีของผู้ใช้ สถานะของรถยนต์ไฟฟ้าที่อัปเดตจากการอัดประจุในเวลาที่ผ่านมา



รูปที่ 2-9 Model predictive control

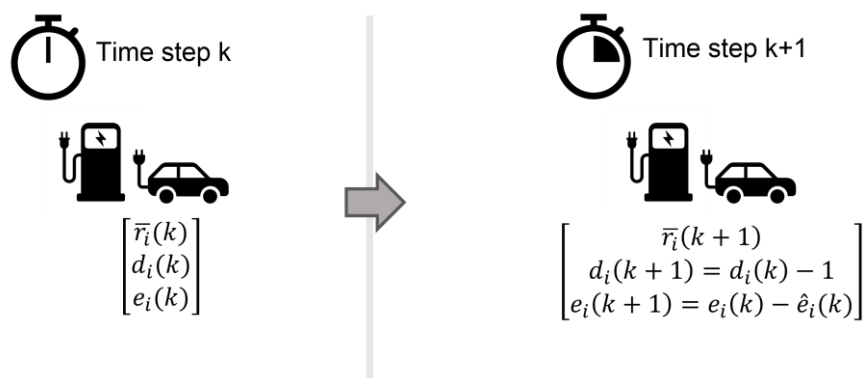
สถานะของรถยนต์ไฟฟ้าจะมีการทำการอัปเดตในแต่ละช่วงเวลาดังรูปที่ 2-10 ใน Time step k รถยนต์ไฟฟ้า EV_i จะมีสถานะ $(e_i(k), d_i(k), \bar{r}_i(k))$ เมื่อเวลาผ่านไปหนึ่งช่วงเวลาและรถยนต์ไฟฟ้า EV_i ได้รับการอัดประจุด้วยอัตรา $r_i(k)$ จะทำให้ใน Time step $(k + 1)$ ต่อมา รถยนต์ไฟฟ้า EV_i จะมีการอัปเดตสถานะเป็น $(e_i(k + 1), d_i(k + 1), \bar{r}_i(k + 1))$ โดยสถานะของรถยนต์ไฟฟ้า EV_i จะทำการอัปเดตดังสมการที่ (2-11)-(2-12)

$$e_i(k+1) = e_i(k) - \hat{e}_i(k), \quad i \in V_k \quad (2-11)$$

$$d_i(k+1) = d_i(k) - 1, \quad i \in V_k \quad (2-12)$$

โดยที่ $\hat{e}_i(k)$ คือค่าพลังงานที่รถยนต์ไฟฟ้า EV_i ได้รับไปในช่วงระหว่างเวลา Time step (k) ไป Time step (k+1) ค่า $\hat{e}_i(k)$ จะคำนวณจากค่าอัตราการอัดประจุคูณกับระยะเวลาของแต่ละ Time step (δ) ดังสมการที่ (2-13)

$$\hat{e}_i(k) = r_i(k) \times \delta \quad (2-13)$$



รูปที่ 2-10 สถานะของรถยนต์ไฟฟ้ามีการอัปเดตจากการอัดประจุในเวลาที่ผ่านไป

2.3 งานวิจัยที่เกี่ยวข้อง

2.3.1 งานวิจัยเกี่ยวกับการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า

งานวิจัยที่เกี่ยวกับการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ประกอบไปด้วยระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้าจัดอยู่ในหมวดหมู่ของการวิเคราะห์การถดถอย ข้อมูลอินพุตที่ใช้โดยส่วนใหญ่ในการทำนายจะใช้ข้อมูลธุรกรรมการอัดประจุในอดีต

ในงาน [10] ได้มีการใช้เทคนิค Gaussian mixture model (GMM) กับชุดข้อมูล ACN public charging data ที่เป็นสถานีอัดประจุในมหาวิทยาลัย Caltech และออฟฟิศที่ทำงาน JPL ในประเทศสหรัฐอเมริกา โดยทำการสร้างโมเดล GMM ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการจากเวลาที่รถยนต์ไฟฟ้าทำการเชื่อมต่อ (Connection time) ในงานนี้ได้มีการทำอัลกอริทึม GMM สำหรับประชากรและการทำ GMM สำหรับรายบุคคล

งานวิจัย [11] มีการใช้เทคนิค Random forest, SVM, XGBoost, Deep Ann และทำการเรียนรู้แบบกลุ่มให้กับอัลกอริทึมเหล่านี้ด้วยวิธี Stacking กับ Voting เพื่อทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการกับข้อมูลการอัดประจุของชุดข้อมูล ACN public charging data ในงานนี้ได้ใช้ข้อมูลประวัติธุรกรรมอัดประจุของผู้ใช้รถยนต์ไฟฟ้ามาเป็นอินพุต อันได้แก่ วันเวลา

ที่รถยนต์ทำการอัดประจุ, ค่าเฉลี่ยระยะเวลาการเชื่อมต่อ, ค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการ และ ค่าเฉลี่ยเวลาที่รถยนต์ออกจากสถานีอัดประจุ นอกจากนี้ยังมีการเพิ่มข้อมูลสภาพอากาศ ข้อมูลการจราจร และข้อมูลเหตุการณ์ในมหาวิทยาลัย มาเพิ่มอีกด้วย โดยได้ผลลัพธ์ค่า Mean absolute error (MAE) เป็น 66.5 นาที และ 3.38 kWh สำหรับ ระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ และค่า SMAPE เป็น 9.92 และ 11.6 สำหรับระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ ในส่วน Feature ที่ส่งผลต่อการทำนายพลังงานไฟฟ้าที่ต้องการ คือค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการ และ Feature ที่ส่งผลต่อการทำนายระยะเวลาในการเชื่อมต่อคือ สภาพการจราจร เวลาในการเชื่อมต่อและค่าเฉลี่ยระยะเวลาในการเชื่อมต่อ แต่อย่างไรก็ตามในงานวิจัยนี้ได้ใช้วิธี k-fold cross validation ซึ่งปกติแล้วไม่น่ามีปัญหาและเป็นเทคนิคที่ใช้กันโดยทั่วไป แต่ในกรณีนี้ที่อินพุต Feature ที่ใช้จะมีค่าเฉลี่ยจากอดีตป้อนอยู่ ผู้เขียนมีความเห็นว่าการทำสุ่มสลับด้วย k-fold cross validation นั้นอาจเกิดสิ่งที่เรียกว่าข้อมูลรั่ว (Data leakage) ได้

ใน [13] ได้ใช้เทคนิค XGBoost, Random forest, และ SVM ในการทำนายพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้าจากข้อมูลการอัดประจุจากสถานีอัดประจุในรัฐเนแบรสกา ประเทศสหรัฐอเมริกา ในงานนี้ได้ใช้ค่าข้อมูลสถิติการอัดประจุในอดีตของผู้ใช้เป็นอินพุตในการทำนาย เช่น จำนวนครั้งที่เคยทำการอัดประจุ, ค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการ ค่ามากและค่าน้อยที่สุดของพลังงานไฟฟ้าที่ต้องการ เป็นต้น และยังมีอินพุตที่นอกเหนือจากข้อมูลสถิติเช่น วันและเวลา, ฤดูกาล และสถานที่อัดประจุ ผลลัพธ์ของงานวิจัยพบว่า XGBoost มีการทำนายที่ดีกว่าอัลกอริทึมอื่นและ Feature ที่ส่งผลต่อการทำนายมากที่สุดได้แก่ค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้า

ในงาน [14] ได้มีการใช้อัลกอริทึม SVM, Random forest, Diffusion-based kernel density estimator มาทำการเรียนรู้ร่วมกัน ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการโดยในงานนี้ได้มีการสร้างอัลกอริทึมในรูปแบบการวิเคราะห์การถดถอย (Regressor chain) กล่าวคือ การทำนายระยะเวลาในการเชื่อมต่อจะใช้วันเวลาที่รถเชื่อมต่อเป็นอินพุต แต่สำหรับการทำนายพลังงานไฟฟ้าที่ต้องการจะใช้ วันเวลา และระยะเวลาในการเชื่อมต่อที่ทำนายมาก่อนหน้าเป็นอินพุต

ในงานวิจัย [18] ได้มีการใช้โมเดลการวิเคราะห์การถดถอยต่างๆ ได้แก่ Linear regression, Artificial neural network, และ XGBoost มาทำนายเวลาที่รถยนต์ออกจากสถานีอัดประจุ โดยใช้ข้อมูลประวัติการอัดประจุมาทำการสร้างอินพุต Feature ได้แก่ carID, car type, weekday, charging point, car park location, parking floor, ค่าเฉลี่ยเวลาที่รถยนต์เชื่อมต่อกับสถานีอัดประจุ, ค่าเฉลี่ยเวลาที่รถยนต์ออกจากสถานีอัดประจุ, ค่าเฉลี่ยระยะเวลาในการเชื่อมต่อ, และเวลาที่รถยนต์เชื่อมต่อกับสถานีอัดประจุ โดยผลลัพธ์ของงานวิจัยพบว่า XGBoost ให้ผลลัพธ์ที่ดีที่สุดในค่า MAE ที่ 82 นาที ซึ่งถึงแม้ว่าในงานวิจัยนี้จะทำนายเวลาที่รถยนต์ออกจากสถานีอัดประจุ แต่อย่างไรก็ตาม

ตามค่าเวลาที่รถยนต์ออกจากสถานีอัดประจุ จะสอดคล้องกับระยะเวลาในการเชื่อมต่อกล่าวคือ ระยะเวลาในการเชื่อมต่อคือผลต่างระหว่างเวลาที่รถยนต์ออกจากสถานีอัดประจุกับเวลาที่รถยนต์เชื่อมต่อกับสถานีอัดประจุ ในส่วนของ Feature ที่ส่งผลต่อการทำนายที่ดีที่สุดคือค่าเฉลี่ยเวลาที่รถยนต์ออกจากสถานี

จากบทความวิจัยต่างๆที่ทำการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ ที่กล่าวมาจะพบว่า งานทั้งหลายจะมีส่วนร่วมกันคือจะมีการใช้ข้อมูลประวัติการอัดประจุของแต่ละผู้ใช้รถยนต์ มาสร้างเป็นอินพุต Feature เพิ่มเติมเช่น ค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการ, ค่าเฉลี่ยระยะเวลาในการเชื่อมต่อ, และ ค่าเฉลี่ยเวลาที่รถยนต์ออกจากสถานีอัดประจุ และอินพุต Feature ที่ดีที่สุดในการทำนายมักจะเป็นค่าเฉลี่ยของค่าที่ต้องการจะทำนาย ซึ่งเป็นสิ่งที่สมเหตุสมผลเนื่องจากการอัดประจुरถยนต์ไฟฟ้ามักจะเป็นกิจวัตรและผู้ใช้รถยนต์มีแนวโน้มที่จะทำพฤติกรรมเดิมซ้ำ

แต่อย่างไรก็ตาม อินพุต Feature ค่าเฉลี่ยจากการอัดประจุในอดีตของค่าที่ต้องการจะทำนายนั้นค่อนข้างที่จะมีความหยاب กล่าวคือค่าเฉลี่ยในช่วงเช้า ช่วยบ่งชี้ ช่วงเย็น น่าที่จะมีความแตกต่างกัน ดังนั้นแล้วผลการทำนายจะมีความแม่นยำมากขึ้นหากมีการใช้ช่วงเวลามาเป็นส่วนร่วมในการสร้างอินพุต Feature และนอกจากนี้ในงานวิจัยที่กล่าวมาไม่ได้มีการใช้เทคนิคโมเดลการเรียนรู้ใหม่ที่เพิ่งเกิดขึ้นมาเช่น TabNet

Source	Year	Prediction	Model (Bold mean winner)	Data Used	Evaluation	Result Session duration	Result Energy demand	Best feature
[10]	2019	Session duration Energy demand	GMM	ACN Historical Charging data	SMAPE	SMAPE: 14.4%	SMAPE: 15.9%	-
[11]	2021	Session duration Energy demand	SVM, XGBoost, ANN, Voting Ensemble, Stacking Ensemble	ACN Historical Charging data	RMSE MAE R2 SMAPE	RMSE: 97.5 minute MAE: 66.5 minute R2: 0.73 SMAPE: 9.92%	RMSE: 5.50 kWh MAE: 3.38 kWh R2: 0.7 SMAPE: 11.6%	Traffic Connection time Average Session duration Average Energy demand
[13]	2020	Energy demand	RF, XGBoost , SVM	State of Nebraska EV chargers	RMSE MAE R2	-	RMSE: 6.68 kWh MAE: 4.6 kWh R2: 0.52	Average Energy demand
[14]	2019	Session duration Energy demand	SVR, MLR, RF, DKDE, Ensemble models	UCLA campus as working space and real residential EV	SMAPE	SMAPE: 10.4%	SMAPE: 7.5%	-
[18]	2021	Departure time	Linear regressing, ANN, XGBoost	Company in Germany Historical Charging data	MAE	-	-	Average departure time

2.3.2 งานวิจัยที่เกี่ยวกับการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้าสามารถจัดออกได้ สองหมวดหมู่ ได้แก่ Offline scheduling และ Online scheduling [19] ในกรณีของ Offline scheduling นั้นจะหมายถึงการหาค่าที่เหมาะสมที่สุดที่ทราบข้อมูลค่าอินพุต และพารามิเตอร์ทุกอย่างอันได้แก่ เวลาที่รถยนต์ไฟฟ้ามาถึงสถานี, เวลาที่รถยนต์ไฟฟ้าออกจากสถานี, ระยะเวลาในการเชื่อมต่อ และพลังงานไฟฟ้าที่ต้องการ ส่วนใหญ่จะใช้ในกรณีเพื่อประเมินประสิทธิภาพหรือใช้เพื่อหาค่าการตั้งค่าของ Online scheduling

ในกรณีของ Online scheduling ที่เป็นวิธีการที่เหมาะสมกับการใช้งานจริงนั้น จะไม่ได้ทราบข้อมูลทุกอย่างแต่จะใช้ข้อมูลที่ทราบในปัจจุบันแทน ยกตัวอย่างเช่น จะไม่ทราบว่าในอนาคตจะมีรถยนต์ไฟฟ้ามาเชื่อมต่อหรือไม่เวลาใด แต่จะทราบในทันทีเมื่อรถยนต์ไฟฟ้าทำการเชื่อมต่อ ในบาง Online scheduling อย่างง่ายจะใช้การจัดกำหนดการในรูปแบบการจัดลำดับงาน เช่น Earliest deadline first [18], Round robin, First come first serve หรือ Least laxity [20] เป็นต้น สำหรับ Online scheduling ที่มีความซับซ้อนมากขึ้นนั้นมักจะใช้เทคนิค Model predictive control (MPC) เช่นในงาน [21] นั้นได้อธิบายถึงวิธีการทำงานของ MPC และแสดงขั้นตอนการสร้างฟังก์ชันวัตถุประสงค์ในการลดค่าใช้จ่ายของการอัดประจุ หรือในงาน [22] ที่แสดงเทคนิคการใช้งาน MPC ที่ใช้เวลาในการคำนวณ $O(1)$ เพื่อทำการกระจายตัวของโหลดจากการอัดประจุ หรือในงาน [9] ที่คิดคำนึงถึงพฤติกรรมในความเป็นจริงของเครื่องอัดประจรรวมถึงแบตเตอรี่ในรถยนต์ไฟฟ้า

อย่างไรก็ตามในงานที่ใช้เทคนิค MPC ที่กล่าวมานี้ ล้วนแล้วแต่ใช้ค่าที่แท้จริงของความ ต้องการของผู้ใช้รถยนต์ไฟฟ้าเป็นค่าอินพุตในการหาค่ากำหนดการอัดประจุ ละเลยถึงความไม่แน่นอน ของความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่สามารถทำให้ผลลัพธ์ของการหาค่าที่เหมาะสมที่สุดแย่งได้ ดังนั้นแล้วเพื่อให้การหาค่าที่เหมาะสมที่สุดทำงานได้ดีควรจะมีการใช้อัลกอริทึมที่รองรับค่าความไม่แน่นอนนี้

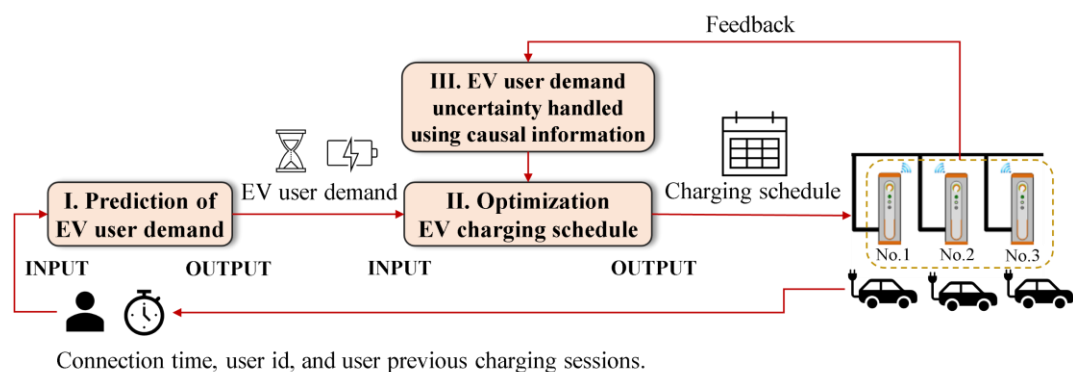
บทที่ 3

ระเบียบวิธีวิจัย (Methodology)

3.1 End-to-end framework.

รูปที่ 3-1 แสดงถึงภาพรวมของ End-to-end framework ในการอัดประจุอัจฉริยะ ซึ่งประกอบไปด้วยสองโมดูลด้วยกัน: (I) โมดูลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า (Prediction of EV user demand) และ (II) โมดูลการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule) ที่มีการพัฒนาให้สามารถ (III) รองรับการไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้า

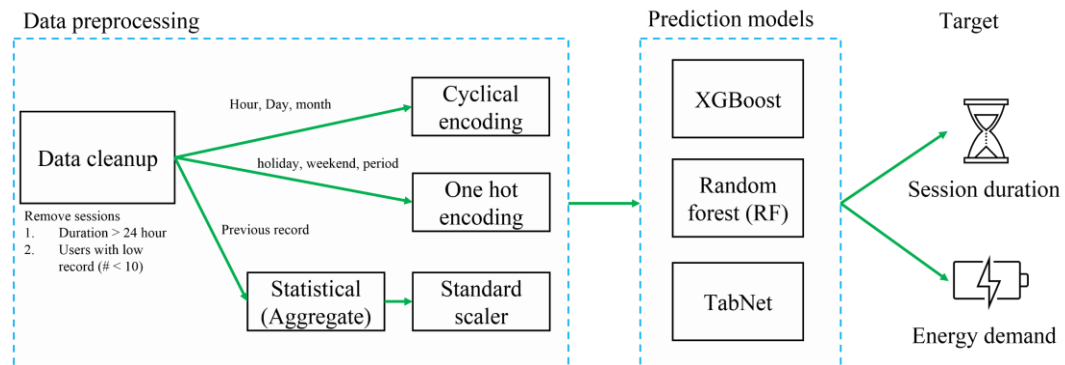
ในโมดูลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าจะถูกจำกัดให้ใช้เฉพาะข้อมูลที่มีในเวลาที่ยานยนต์ไฟฟ้ามาทำการเชื่อมต่อเพื่อให้สอดคล้องกับความเป็นจริง เช่น เวลาในการเชื่อมต่อ, รหัสระบุตัวตนผู้ใช้รถยนต์ไฟฟ้า (User Id), และข้อมูลประวัติธุรกรรมอัดประจุของผู้ใช้รถยนต์ไฟฟ้า เอาต์พุตของโมดูลนี้จะได้แก่ ระยะเวลาในการเชื่อมต่อ และพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้า ซึ่งจะเป็นอินพุตให้กับโมดูลการหาค่าที่เหมาะสมที่สุดไปทำการจัดกำหนดการอัดประจุ



รูปที่ 3-1 End to end framework

3.2 (I) โมดูลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า (Prediction of EV user demand)

โมดูลนี้คือส่วนที่ (I) จากรูปที่ 3-1 และมีรายละเอียดแสดงดังรูปที่ 3-2 ในโมดูลนี้จะทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ประกอบไปด้วยระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการด้วยข้อสันนิษฐานว่าพฤติกรรมการอัดประจุผู้ใช้รถยนต์ไฟฟ้ามีแนวโน้มที่จะเป็นกึ่งวัตร ส่งผลให้ข้อมูลธุรกรรมอัดประจุในอดีตสามารถมีส่วนช่วยในการทำนายความต้องการในการอัดประจุที่กำลังจะเกิดขึ้น โมดูลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าจะประกอบไปด้วยส่วนย่อยสองส่วนด้วยกันได้แก่ Data preprocessing และ Prediction models



รูปที่ 3-2 โมเดลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า

3.2.1 Data preprocessing

ใน Data preprocessing จะเริ่มทำ Data cleanup โดยการนำข้อมูลธุรกรรมที่มีระยะเวลาในการเชื่อมต่อเกิน 24 ชั่วโมงออก เนื่องจากพิจารณาได้ว่าธุรกรรมดังกล่าวมีเป็นจำนวนสัดส่วนที่น้อยและจะส่งผลให้การหาค่าที่เหมาะสมที่สุดต้องพิจารณาช่วงเวลาของกำหนดการอัดประจุที่ยาวเกินไป นอกจากนี้เพื่อให้โมเดลการเรียนรู้ของเครื่องเรียนรู้พฤติกรรมของผู้ใช้รถยนต์ไฟฟ้าได้ดี จึงทำการนำข้อมูลธุรกรรมของผู้ใช้ที่มีประวัติการอัดประจุน้อยกว่า 10 ครั้งออก

จากนั้นจะดำเนินการ Feature engineering เพื่อให้โมเดลการเรียนรู้ของเครื่องทำงานได้อย่างมีประสิทธิภาพขึ้น โดยจะดำเนินการ Feature engineering ดังนี้

- ข้อมูลประเภทเวลา ได้แก่ เวลา (Hour), วัน (Day) และเดือน (Month) จะถูกแปลงด้วยเทคนิค Cyclical encoding เนื่องจากข้อมูลประเภทเวลานั้นจะมีลักษณะวนเป็นวงกลม ยกตัวอย่างเช่นเวลา 23.00 มีความใกล้เคียงกับเวลา 00.00 มากกว่าที่เวลา 18.00 หรือวันจันทร์กับวันอาทิตย์มีความใกล้เคียงกันมากกว่าวันจันทร์กับวันศุกร์ ซึ่งสมการของ Cyclical encoding จะใช้สมการที่ (3-1) และ (3-2) โดยที่ f คือค่า Cyclic feature ที่ต้องการทำการแปลงและ f_x, f_y คือส่วนประกอบหลังจากทำการแปลงแล้ว

$$f_x = \sin\left(\frac{2\pi f}{\max(f)}\right) \quad (3-1)$$

$$f_y = \cos\left(\frac{2\pi f}{\max(f)}\right) \quad (3-2)$$

- ข้อมูลรูปแบบประเภท ได้แก่ ช่วงเวลา (period), วันธรรมดาหรือวันเสาร์อาทิตย์ (isWeekend), วันธรรมดาหรือวันหยุด (is_holiday) จะทำการแปลงด้วยเทคนิค one-hot encoder

- ข้อมูลทางสถิติ หรือคือข้อมูลที่จะไม่ทราบในขณะที่รถยนต์ไฟฟ้ามาทำการเชื่อมต่อแต่จะทราบเมื่อธุรกรรมการอัดประจุสิ้นสุดลง ได้แก่ ระยะเวลาในการเชื่อมต่อ, พลังงานไฟฟ้าที่ต้องการ และ เวลาที่สิ้นสุดการเชื่อมต่อ ข้อมูลเหล่านี้จะถูกนำมาใช้ในลักษณะคำนวณค่าทางสถิติของธุรกรรมอัดประจุในอดีตของผู้ใช้รถยนต์ไฟฟ้ารายนั้นยกตัวอย่างเช่น ค่าเฉลี่ยระยะเวลาในการเชื่อมต่อของผู้ใช้รถยนต์ไฟฟ้า เป็นต้น ทั้งนี้เพื่อให้โมเดลการเรียนรู้ทราบถึงพฤติกรรมในอดีตของผู้ใช้รถยนต์ไฟฟ้ารายนั้น และเนื่องจากข้อมูลทางสถิตินั้นมีลักษณะเป็นตัวเลขจึงมีการแปลงข้อมูลทางสถิติด้วยวิธี Standard scaler

3.2.2 Prediction models

โมเดลการเรียนรู้ที่นำมาใช้ใช้งานในการทำนายค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้ามีดังนี้

1. *XGBoost*: (พิจารณาหัวข้อ 2.2.5)
2. *RF*: (พิจารณาหัวข้อ 2.2.6)
3. *TabNet*: (พิจารณาหัวข้อ 2.2.7)

3.3 (II) โมเดลการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า (Optimization of EV charging schedule)

ในโมเดลนี้คือส่วนที่ (III) จากรูปที่ 3-1 การหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุนั้นจัดว่าอยู่ในรูปแบบ Deterministic problem หากทราบค่าอินพุตและพารามิเตอร์ต่างๆที่เกี่ยวข้อง เช่นความต้องการของผู้ใช้รถยนต์ไฟฟ้า ดังนั้นแล้วแทนที่จะทำการนิยามสมการขึ้นมาซ้ำ ในงานนี้จะเลือกใช้ Framework จากงานวิจัย [9] ที่เรียกว่า Adaptive Scheduling Algorithm (ASA) และมุ่งเน้นในการพัฒนา Framework ให้รองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้า (รายละเอียดในหัวข้อถัดไป; หัวข้อ 3.4)

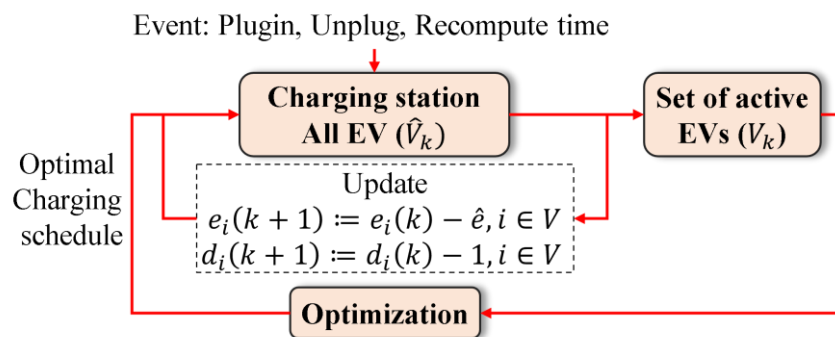
ASA Framework นั้นมีพื้นฐานอยู่บน Convex optimization และ Model predictive control ซึ่งเนื้อหาเกี่ยวกับทฤษฎีเบื้องต้นพิจารณาได้จากหัวข้อ 2.2.9 และหัวข้อ 2.2.10

รูปที่ 3-3 แสดงการทำงานของ ASA framework ซึ่งมีขั้นตอนการทำงานดังนี้

1. เวลาต่อเนื่องรูปแบบ Discrete time step k จะพิจารณาถึงรถยนต์ไฟฟ้าทุกคันในสถานีอัดประจุแสดงเป็น \hat{V}_k และทำการพิจารณารถยนต์ไฟฟ้าที่ยังทำการเชื่อมต่ออยู่ และการอัดประจุยังไม่เสร็จสิ้นให้แสดงด้วย V_k
2. สถานะของรถยนต์ไฟฟ้า $i \in \hat{V}_k$ ที่ Discrete time step k จะแสดงด้วย $(e_i(k), d_i(k), \bar{r}_i(k))$ โดยที่ $e_i(k)$, $d_i(k)$, และ $\bar{r}_i(k)$ คือพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้า, ระยะเวลาในการเชื่อมต่อของรถยนต์ไฟฟ้า, และค่ามากที่สุดของอัตราการอัดประจุที่เครื่องอัดประจุสามารถจ่ายได้ตามลำดับ โดยที่ค่า $e_i(k)$ และ

$d_i(k)$ ในตอนที่รถยนต์ไฟฟ้าเริ่มเชื่อมต่อคือค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้าและจะมีค่าลดลงเรื่อยเมื่อรถยนต์ไฟฟ้าทำการอัดประจุ

3. เมื่อมีอีเวนต์เกิดขึ้น อันได้แก่รถยนต์มาทำการเชื่อมต่อ รถยนต์เสร็จสิ้นการเชื่อมต่อ หรือถึงรอบเวลาการคำนวณของ Time step ใหม่ จะทำการคำนวณหากำหนดการที่เหมาะสมที่สุดที่มีช่วงความยาวของเวลา T ซึ่งจะได้ผลลัพธ์ออกมาเป็นกำหนดการอัดประจุแสดงโดย $r := (r_i(1), \dots, r_i(T), i \in V_k)$ และทำการควบคุมเครื่องอัดประจุโดยการตั้งค่าสัญญาณควบคุม (Pilot signal) ที่ Time step ปัจจุบันด้วย $r_i(1)$
4. ใน Time step ถัดมาจะทำการอัปเดตสถานะของรถยนต์ไฟฟ้าตามสมการ (2-11)-(2-12)



รูปที่ 3-3 ASA framework

ในการหาค่าที่เหมาะสมที่สุดของขั้นตอนที่ 3 นั้นจะอยู่ในรูปของฟังก์ชันวัตถุประสงค์ (พิจารณาหัวข้อ 3.3.1) และเงื่อนไขแสดงขอบข่าย (พิจารณาหัวข้อ 3.3.2)

3.3.1 ฟังก์ชันวัตถุประสงค์

ฟังก์ชันวัตถุประสงค์ในที่นี้คือค่าผลรวมของค่าน้ำหนักคูณกับฟังก์ชันวัตถุประสงค์ย่อยตามสมการที่ (3-3) โดยที่ค่า α คือค่าน้ำหนักที่เป็นจำนวนบวก ฟังก์ชันวัตถุประสงค์ย่อยและคำอธิบายพิจารณาตามหัวข้อ 3.3.1.1 - 3.3.1.4

$$\max_r \sum_{v=1}^V \alpha_k^v u_k^v(r) \quad (3-3)$$

3.3.1.1 Quick charge

ฟังก์ชันวัตถุประสงค์ย่อย Quick charge นี้มีเพื่อให้สถานีอัดประจุทำการอัดประจुरถยนต์ไฟฟ้าโดยเร็ว รถยนต์ไฟฟ้าจะได้เสร็จสิ้นการอัดประจุและออกจากสถานีโดยเร็ว หลีกเลี่ยงเหตุการณ์รถยนต์ไฟฟ้าแอดที่สถานีอัดประจุ ฟังก์ชันวัตถุประสงค์ย่อย Quick charge จะแสดงดังสมการ (3-4) โดยรางวัลของฟังก์ชันวัตถุประสงค์ย่อยจะลดลงตามเวลา

$$u^{QC}(r) := \sum_{t \in T} \frac{T-t+1}{T} \sum_{i \in V} r_i(t) \quad (3-4)$$

3.3.1.2 Energy cost

ฟังก์ชันวัตถุประสงค์ย่อย Energy cost นี้มีเพื่อให้สถานีอัดประจุเน้นจัดกำหนดการอัดประจุในช่วงเวลาที่ค่าไฟฟ้าถูก จะแสดงโดยสมการ (3-5) โดยที่ π คือรายได้ต่อหน่วยการใช้ไฟฟ้าที่สถานีอัดประจุทำการเก็บกับผู้ใช้งานรถยนต์ไฟฟ้า $C(t)$ คือค่า TOU หรือค่าไฟตามช่วงเวลาการใช้งาน และ $N(t)$ คือผลรวมของการใช้ไฟฟ้าของสถานีอัดประจุที่ประกอบไปด้วย $\sum_{i \in V} r_i(t)$ อัตราการอัดประจุของรถยนต์ไฟฟ้าทั้งหมด $L(t)$ โหลดไฟฟ้าทั่วไปในสถานี และ $G(t)$ ไฟฟ้าที่ผลิตได้ของโซลาร์เซลล์ หากสถานีนั้นมีการติดตั้งโซลาร์เซลล์ตามสมการ (3-6)

อย่างไรก็ตามในงานวิจัยนี้จะละเลย $L(t)$ และ $G(t)$ เนื่องจากไม่มีข้อมูลดังกล่าว

$$u^{EC}(r) := \pi \sum_{t \in T, i \in V} r_i(t) - \sum_{t \in T} C(t) N(t) \quad (3-5)$$

$$N(t) := \sum_{i \in V} r_i(t) + L(t) - G(t) \quad (3-6)$$

3.3.1.3 Demand charge

ฟังก์ชันวัตถุประสงค์ย่อย Demand charge นี้มีเพื่อลดค่าใช้จ่ายเกี่ยวกับด้านค่าความต้องการพลังไฟฟ้าแสดงโดยสมการ (3-7) โดยที่ค่า \hat{P} , q_0 , และ \hat{q} คือค่าอัตราความต้องการพลังไฟฟ้าที่จ่ายให้การไฟฟ้า ค่าความต้องการพลังไฟฟ้าสูงสุดที่ผ่านมา ค่าประมาณความต้องการพลังไฟฟ้าซึ่งมักคำนวณจากรอบเดือนที่แล้ว ตามลำดับ

จะเห็นได้ว่าฟังก์ชันวัตถุประสงค์ย่อยนี้มีค่าติดลบเพื่อให้รางวัลของฟังก์ชันมีค่าที่น้อยลงหากค่าความต้องการพลังไฟฟ้ามีค่าสูงขึ้น

$$u^{DC}(r) := -\hat{P} \cdot \max(\max_{t \in T} N(t), q_0, \hat{q}) \quad (3-7)$$

3.3.1.4 Energy share

ฟังก์ชันวัตถุประสงค์ย่อย Energy share นี้มีเพื่อส่งเสริมให้รถยนต์ไฟฟ้าแต่ละคันได้รับพลังงานเท่าๆกันแสดงด้วยสมการ (3-8)

$$u^{ES}(r) := - \sum_{t \in T, i \in V} r_i(t)^2 \quad (3-8)$$

3.3.2 เงื่อนไขแสดงขอบข่าย

เงื่อนไขแสดงขอบข่ายจะแสดงดังสมการ (3-9) - (3-12) โดยที่สมการ (3-9) - (3-10) จะเกี่ยวข้องกับระยะเวลาในการเชื่อมต่อของผู้ใช้รถยนต์ไฟฟ้า กล่าวคือสมการ (3-9) จะกำหนดให้อัตราการอัด

ประจุในขณะที่อยู่ในสถานะของรถยนต์ไฟฟ้าอยู่ระหว่างศูนย์ถึงค่ามากที่สุดที่เครื่องอัดประจุสามารถจ่ายได้ ในขณะที่เดียวกันสมการ (3-10) จะกำหนดให้อัตราการอัดประจุเป็นศูนย์เมื่อถึงเวลาเสร็จสิ้นการเชื่อมต่อ สมการ (3-11) จะเกี่ยวข้องกับค่าพลังงานไฟฟ้าที่ต้องการของผู้ใช้รถยนต์ไฟฟ้าโดยที่สมการนี้จะให้พลังงานไฟฟ้าที่รถยนต์ไฟฟ้าได้รับมีค่าอย่างมากที่สุดคือเท่ากับพลังงานไฟฟ้าที่ต้องการ

สมการ (3-12) จะเกี่ยวข้องกับขีดจำกัดของอุปกรณ์ทางไฟฟ้าต่างๆเช่น สายไฟฟ้า และหม้อแปลงไฟฟ้า โดยที่ $f_j(r(t))$ คือผลรวมของอัตราการอัดประจุของรถยนต์ไฟฟ้าในเวลา t ซึ่งจะต้องมีค่าไม่เกินค่าขีดจำกัดในการจ่ายไฟฟ้าของอุปกรณ์ทางไฟฟ้า c_j โดยที่ \mathcal{L} หมายถึงเซตของอุปกรณ์ทางไฟฟ้าที่พิจารณา เงื่อนไขแสดงขอบข่ายนี้จะป้องกันไม่ให้อัตราการอัดประจุส่งผลให้อุปกรณ์ไฟฟ้าเสียหาย

$$0 \leq r_i(t) \leq \bar{r}_i(t), \quad t \leq d_i, i \in V_k \quad (3-9)$$

$$r_i(t) = 0, \quad t > d_i, i \in V_k \quad (3-10)$$

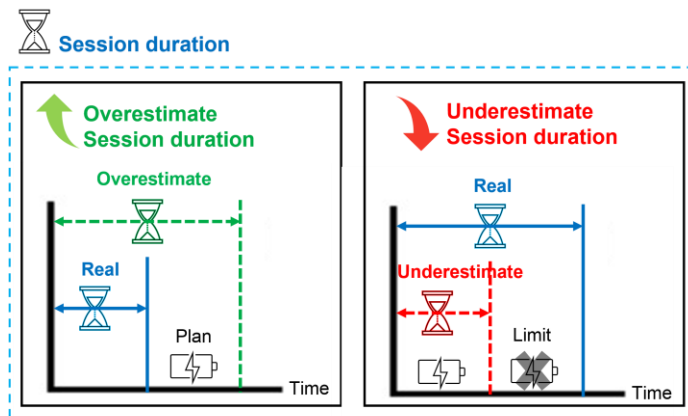
$$\sum_{t \in T} r_i(t) \leq e_i, \quad i \in V_k \quad (3-11)$$

$$f_j(r_1(t), r_2(t), \dots, r_i(t)) \leq c_j, \quad i \in V_k, t \in T, j \in \mathcal{L} \quad (3-12)$$

3.4 (III) รองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้า


โมดูลนี้คือ (III) จากรูปที่ 3-1 สำหรับโมดูลนี้จะอธิบายวิธีการในการพัฒนา ASA framework จากหัวข้อ 3.3 ให้รองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้า ความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นจะถูกแบ่งออกเป็นสี่หมวดหมู่ด้วยกัน ได้แก่ Underestimated session duration, Underestimated energy demand, Overestimated session duration, และ Overestimated energy demand ผลลัพธ์ของความไม่แน่นอนจะวิเคราะห์ได้โดยพิจารณากับเงื่อนไขแสดงของข่ายสมการ (3-9) - (3-11) ซึ่งเป็นสมการที่เกี่ยวข้องโดยตรงกับความต้องการของผู้ใช้รถยนต์ไฟฟ้า

ในกรณีผลลัพธ์ของความไม่แน่นอนของระยะเวลาในการเชื่อมต่อจะแสดงดังรูปที่ 3-4 ซึ่งถ้าหาก Overestimated หรือมีค่ามากกว่าความเป็นจริงจะส่งผลให้การหาค่าที่เหมาะสมที่สุดพิจารณาว่ารถยนต์ไฟฟ้านี้มีความยืดหยุ่นสูงและอาจจัดกำหนดการอัดประจุให้ในช่วงเวลาที่รถยนต์ไฟฟ้าอาจจะออกไปแล้ว ในทางตรงกันข้ามถ้าหาก Underestimated หรือมีค่าน้อยกว่าความเป็นจริงจะส่งผลให้เกิดเหตุการณ์ที่วารถยนต์ไฟฟ้ายังคงอยู่ในสถานะแต่การหาค่าที่เหมาะสมที่สุดพิจารณาว่ารถยนต์ไฟฟ้าออกไปแล้วและลิมิตการอัดประจุให้เป็นศูนย์(พิจารณาสมการ (3-10))



รูปที่ 3-4 ผลลัพธ์ของความไม่แน่นอนของระยะเวลาในการเชื่อมต่อ

ในกรณีผลลัพธ์ของความไม่แน่นอนของพลังงานไฟฟ้าที่ต้องการจะแสดงดังรูปที่ 3-5 ซึ่งถ้าหาก Overestimated จะส่งผลให้การหาค่าที่เหมาะสมที่สุดพิจารณาว่าต้องจัดพลังงานไฟฟ้าให้กับรถยนต์ไฟฟ้าคันนี้ให้มากจึงจะทำให้เกิดเหตุการณ์ที่วารถยนต์ไฟฟ้าได้รับพลังงานครบก่อนกำหนดเป็นการใช้ระยะเวลาในการเชื่อมต่ออย่างไม่เต็มประสิทธิภาพ ในทางตรงกันข้ามหาก Underestimated จะส่งผลให้รถยนต์ไฟฟ้าคันนี้ได้รับพลังงานไฟฟ้าน้อยกว่าความเป็นจริง (พิจารณาสมการ (3-11))



รูปที่ 3-5 ผลลัพธ์ของความไม่แน่นอนของพลังงานไฟฟ้าที่ต้องการ

ในการรองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นจะทำโดยใช้ประโยชน์จากพฤติกรรมของ MPC ที่มีการทำการหาค่าที่เหมาะสมที่สุดใหม่อยู่เรื่อยๆพร้อมทั้งอัปเดตป้อนกลับ (Feedback) กับสิ่งที่เกิดขึ้นในเวลาที่ผ่านมา ด้วยการที่มีการป้อนกลับนั้นจะทำให้สามารถตรวจสอบกรณีของ Underestimated session duration และ Underestimated energy demand ได้โดยง่าย กล่าวคือถ้า Underestimated session duration รถยนต์ไฟฟ้าจะยังคงอยู่ในสถานีถึงแม้ว่าค่าประมาณระยะเวลาในการเชื่อมต่อจะครบเวลาแล้วก็ตาม เช่นเดียวกันในกรณี

Underestimated energy demand รถยนต์ไฟฟ้ายังคงสามารถรับพลังงานต่อได้แม้ว่ารถยนต์ไฟฟ้าได้รับพลังงานถึงค่าที่ประมาณไว้แล้วก็ตาม ดังนั้นแล้วเมื่อได้รับข้อมูลแล้วพบว่าได้ประมาณค่าความต้องการของผู้ใช้น้อยไปก็จะทำการอัปเดตค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้า เพื่อลดผลกระทบจากเงื่อนไขแสดงขอบข่ายสมการ (3-9) - (3-11) และให้รถยนต์ไฟฟ้าได้รับพลังงานต่อไป การอัปเดตค่าความต้องการจะอัปเดตในรูปแบบที่ทำให้การหาค่าที่เหมาะสมที่สุดจัดพลังงานให้กับรถยนต์ไฟฟ้าคันนี้โดยเร็วเพื่อลดผลกระทบจากที่ประมาณค่าความต้องการไว้ น้อยและจะอัปเดตดังนี้

- ในกรณีที่ Underestimated session duration จะทำการเพิ่มค่าระยะเวลาในการเชื่อมต่อ Δd อย่างต่อเนื่องหากค่าที่ทำการอัปเดตแล้วเกิดน้อยไปอีกแสดงดังสมการ (3-13) ในงานวิจัยนี้จะให้ค่า Δd มีค่าเท่ากับ 2 ชั่วโมง

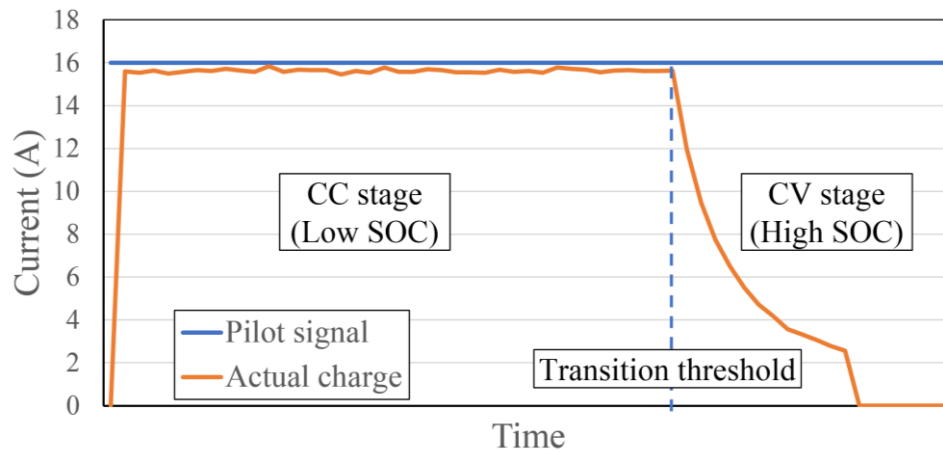
$$d(k+1) := d(k) + n\Delta d, \quad d(k+1) - t > 0, n \in Z^+ \quad (3-13)$$

- ในกรณีที่ Underestimated energy demand จะให้ค่าพลังงานไฟฟ้าที่ความต้องการใหม่มีค่าเท่ากับ ค่าประมาณระยะเวลาในการเชื่อมต่อคูณกับพิกัดกำลังจ่ายไฟมากที่สุดของเครื่องอัดประจุแสดงดังสมการ (3-14)

$$e(k+1) := d(k+1) \times \bar{r}_i \quad (3-14)$$

นอกจากนี้ การป้อนกลับยังสามารถให้ข้อมูลว่ารถยนต์ไฟฟ้าคันไหนได้รับพลังงานจน State of charge (SOC) มีค่าที่สูง ซึ่งสามารถทราบได้จากการวัดค่าผลต่างของค่าสัญญาณควบคุม Pilot signal กับค่าดึงกระแสจริงของรถยนต์ไฟฟ้าของช่วงเวลาที่ผ่านไป กล่าวคือตามมาตรฐาน J1772 สำหรับการอัดประจุระดับ 2 หรือ AC normal charge นั้นเครื่องอัดประจุจะทำการสื่อสารกับรถยนต์ไฟฟ้าด้วยสัญญาณควบคุม เป็นการแจ้งแก่รถยนต์ไฟฟ้าถึงค่ากระแสมากที่สุดที่รถยนต์ไฟฟ้าสามารถอัดประจุได้ แต่ระบบควบคุมแบตเตอรี่ (Battery management system: BMS) จะเป็นผู้ทำการตัดสินใจถึงค่ากระแสที่จะทำการอัดประจุเองโดยจะมีค่าไม่เกินค่าสัญญาณควบคุม ซึ่งใน BMS โดยทั่วไปนั้นจะอัดประจุในลักษณะที่เรียกว่า Constant Current Constant Voltage (CC-CV) [23] แสดงดังรูปที่ 3-6 และมีลักษณะเป็นดังนี้

1. ในกรณีที่ SOC ของรถยนต์ไฟฟ้ามีค่าต่ำกว่า Transition threshold หรือคือมี SOC ต่ำกว่าประมาณ 70-90% จะทำให้ BMS ทำงานอยู่ในย่าน CC stage และสามารถดึงกระแสได้สูงใกล้เคียงกับค่าสัญญาณควบคุม
2. ในกรณีที่ SOC ของรถยนต์ไฟฟ้ามีค่าสูงกว่า Transition threshold หรือคือมี SOC ที่สูง จะทำให้ BMS ทำงานอยู่ในย่าน CV stage และดึงกระแสได้น้อยลงมีค่าที่แตกต่างจากสัญญาณควบคุมอย่างมีนัยยะสำคัญ



รูปที่ 3-6 Pilot signal vs Actual charge of CC-CV charging profile

การที่ทราบข้อมูลรถยนต์ไฟฟ้าที่มี SOC สูงนี้สามารถนำไปใช้ในการจัดความสำคัญ โดยให้ความสำคัญแก่รถยนต์ไฟฟ้าที่มี SOC ต่ำก่อน ซึ่งสามารถสร้างฟังก์ชันวัตถุประสงค์ในการจัดลำดับความสำคัญ (Priority) ได้ดังสมการ (3-15) โดยที่ V คือเซตของรถยนต์ไฟฟ้าที่มี SOC ต่ำ

$$u^{PR}(r) := \sum_{t=1, i \in V} r_i(t) \quad (3-15)$$

บทที่ 4

ขั้นตอนการทดลอง (Experimental setup)


4.1 ขั้นตอนการทดลองการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า

รูปที่ 4-1 แสดงภาพรวมของขั้นตอนการทดลองการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า จะไปกอบไปด้วยหัวข้อย่อยชุดข้อมูล, Exploratory data analysis (EDA), Input features, และการแบ่งข้อมูล Train validation and test split

การทดลองจะเปรียบเทียบความต้องการของผู้ใช้รถยนต์ไฟฟ้าจากสามตัวประเมินอันได้แก่

1. User inputs: คือค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ผู้ใช้เป็นคนป้อนผ่านมือถือ โดยที่ค่านี้จะมีเฉพาะชุดข้อมูล ACN
 2. *Baselines*: เพื่อตรวจสอบประสิทธิภาพในการทำนายของโมเดลการเรียนรู้ จะมีการใช้ค่าทางสถิติเพื่อเป็นตัวเปรียบเทียบพื้นฐาน โดยค่าทางสถิติที่ใช้จะมีด้วยกันสองค่าได้แก่
 - a. *Baseline1*: คือค่าเฉลี่ยจากรูกรกรมในอดีตของค่าที่ต้องการทำนายของผู้ใช้รถยนต์ไฟฟ้า (Mean of target variables by user id)
 - b. *Baseline2*: คือค่าเฉลี่ยจากรูกรกรมในอดีตของค่าที่ต้องการทำนายของผู้ใช้รถยนต์ไฟฟ้าในแต่ละช่วงเวลา (Mean of target variables by user id and period)
 3. ML models: หรือผลลัพธ์ของโมเดลการเรียนรู้จากหัวข้อ 3.2 ซึ่งประกอบไปด้วย XGBoost, RF, และ TabNet
- โดยใช้ Evaluation matrix ในการประเมินผลลัพธ์ซึ่งได้แก่ RMSE, MAE, SMAPE และ R^2

Experimental Setup (Prediction of EV user demand)



รูปที่ 4-1 ภาพรวมการทดลองการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า

4.1.1 ชุดข้อมูล

ชุดข้อมูลที่น่ามาใช้ทำการทำนายระยะเวลาในการเชื่อมต่อและความต้องการพลังงานไฟฟ้านั้นมีสองชุดข้อมูลใหญ่ด้วยกัน ได้แก่ชุดข้อมูลของ[10] [ข้อมูล ACN public charging data](#) ของประเทศสหรัฐอเมริกาและเป็นชุดข้อมูลที่เปิดให้สามารถใช้ได้โดยทั่วไป กับชุดข้อมูลสถานีอัดประจุของการไฟฟ้านครหลวงของประเทศไทย

ชุดข้อมูลดังกล่าวทั้งสองชุดจะเก็บข้อมูลธุรกรรมการอัดประจุของแต่ละสถานีอัดประจุ ซึ่งชุดข้อมูลดังกล่าวนี้จะมีสถานีอัดประจุและรายละเอียดดังนี้ (*หมายเหตุ เพื่อให้สามารถระบุถึงตัวสถานีได้โดยง่ายในการอ่าน จะมีการใช้การใช้สีของตัวอักษรดังนี้ **JPL**, **Caltech**, **Mall**, **University**)

1. ชุดข้อมูล [ACN public charging data](#): สถานีอัดประจุของชุดข้อมูล ACN มีทั้งหมด 3 สถานี (ข้อมูลปี ค.ศ. 2023) แต่ในที่นี้จะยกมาเฉพาะกรณีของสถานีที่จะนำมาใช้ในการทดลองเนื่องจากเป็นสถานีที่มีข้อมูลเพียงพอ ในชุดข้อมูล ACN นอกจากข้อมูลธุรกรรมการอัดประจุโดยทั่วไปแล้วจะมีการเก็บข้อมูลความต้องการของผู้ใช้รถยนต์ไฟฟ้าไว้ด้วย โดยได้ทำการเก็บโดยให้ผู้ใช้เป็นผู้ป้อนผ่านแอปพลิเคชันในโทรศัพท์มือถือ สำหรับชุดข้อมูล ACN จะใช้ข้อมูลธุรกรรมของปี ค.ศ. 2019
 - a. **JPL** เป็นห้องปฏิบัติการวิจัยหรือสถานที่ทำงาน โดยสถานีอัดประจุนี้จะเปิดให้เฉพาะพนักงานใช้งานเท่านั้น จึงจำลองได้ว่าเป็นสถานีอัดประจุสำหรับสถานที่ทำงาน และมีเครื่องอัดประจุทั้งหมดในสถานี 52 เครื่อง
 - b. **Caltech** คือสถานีอัดประจุในมหาวิทยาลัย Caltech โดยสถานีอัดประจุนี้จะเปิดให้บุคคลทั่วไปสามารถเข้ามาใช้งานได้ และมีเครื่องอัดประจุทั้งหมดในสถานี 54 เครื่อง
2. ชุดข้อมูลสถานีอัดประจุของการไฟฟ้านครหลวง (MEA): สถานีอัดประจุของการไฟฟ้านครหลวงมีทั้งหมด 53 สถานี (ข้อมูลปี ค.ศ. 2023) แต่ในที่นี้จะยกมาเฉพาะกรณีของสถานีที่จะนำมาใช้ในการทดลองเนื่องจากเป็นสถานีที่มีข้อมูลเพียงพอ และจะไม่เปิดเผยถึงชื่อของสถานี ในชุดข้อมูลนี้จะแตกต่างจากชุดข้อมูลแรกโดยที่ไม่ได้มีการเก็บค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้าไว้แต่อย่างใด สำหรับชุดข้อมูลสถานีอัดประจุของการไฟฟ้านครหลวงจะใช้ข้อมูลธุรกรรมของปี ค.ศ. 2022
 - a. **ห้างสรรพสินค้า (Mall)** เป็นสถานีอัดประจุที่เป็นตัวแทนของห้างสรรพสินค้า ซึ่งในปัจจุบันสถานีนี้ยังไม่เรียกเก็บค่าใช้งานจากผู้ใช้รถยนต์ไฟฟ้า และมีเครื่องอัดประจุทั้งหมดในสถานี 3 เครื่อง
 - b. **มหาวิทยาลัย (University)** เป็นสถานีอัดประจุที่เป็นตัวแทนของมหาวิทยาลัย และมีเครื่องอัดประจุทั้งหมดในสถานี 5 เครื่อง

ตารางที่ 4-1 สรุปชุดข้อมูล

Dataset	Year	Station type	EV chargers	Transaction
ACN: JPL	2019	Office	52	17,399
ACN: Caltech	2019	University	54	10,596
MEA: Mall	2022	Mall	3	4,007
MEA: University	2022	University	5	1,448

ในงานวิจัยนี้จะเลือกใช้สถานี **JPL** มาเป็นชุดข้อมูลที่ใช้ในการวิเคราะห์สร้างในการสร้างโมเดลการเรียนรู้ เนื่องจากเป็นชุดข้อมูลที่มีข้อมูลธุรกรรมการอัดประจุมากและเป็นสถานที่ทำงาน ดังนั้นแล้วพฤติกรรมของผู้ใช้บริการสถานีอัดประจุจะมีความซ้ำซ้อน ทำให้สามารถทำนายพฤติกรรมจากข้อมูลในอดีตได้ง่าย แต่อย่างไรก็ตามวิธีการสร้างโมเดลการเรียนรู้ที่ได้จะถูกนำมาใช้กับสถานีที่เหลือเพื่อวัดผลเช่นเดียวกัน ชุดข้อมูล ACN ตั้งเดิมจะประกอบไปด้วยข้อมูลตามตารางที่ 4-2 และสิ่งที่จะให้โมเดลทำการทำนายคือ

1. ระยะเวลาในการเชื่อมต่อ ซึ่งคือระยะเวลาที่รถยนต์ไฟฟ้าทำการเชื่อมต่ออยู่ที่สถานีอัดประจุ จะมีค่าเท่ากับ เวลาที่รถยนต์ไฟฟ้าเสร็จสิ้นการเชื่อมต่อ - เวลาที่รถยนต์ไฟฟ้าเชื่อมต่อ
2. พลังงานไฟฟ้าที่ต้องการ ซึ่งคือ kWhDelivered จากตารางที่ 4-2

ในส่วนของฟิลด์ข้อมูล (Field) อื่นนั้นเช่น `_id`, `clusterID`, `sessionID`, `sitelD`, `spaceID`, `stationID`, `userInputs`, `Timezone` จะไม่ได้นำมาใช้เนื่องจากไม่มีส่วนเกี่ยวข้องกับการทำนาย หลังจากการทำเตรียมชุดข้อมูล ทำการลบฟิลด์ข้อมูลที่ไม่เกี่ยวข้อง ทำการเพิ่มฟิลด์ข้อมูล และทำการเปลี่ยนชื่อฟิลด์ข้อมูล แล้วจะได้ชุดข้อมูลออกมาตามตารางที่ 4-3

ตารางที่ 4-2 ชุดข้อมูลดั้งเดิมของ ACN Dataset


Field	Type	Description
_id	String	ตัวเลขจำแนกการเก็บข้อมูล
clusterID	String	ตัวเลขจำแนกกลุ่มของเครื่องอัดประจุ เช่นกลุ่มเครื่องอัดประจุในลานจอดรถชั้นที่ 1
connectionTime	Datetime	เวลาที่รถยนต์ไฟฟ้าเชื่อมต่อ
disconnectTime	Datetime	เวลาที่รถยนต์ไฟฟ้าเสร็จสิ้นการเชื่อมต่อ
doneChargingTime	Datetime	เวลาที่รถยนต์ไฟฟ้าไม่ทำการดึงกระแสแล้วหรือคือเวลาที่รถยนต์ไฟฟ้าเสร็จสิ้นการอัดประจุแต่ยังเชื่อมต่ออยู่
kWhDelivered	Float	ปริมาณพลังงานไฟฟ้าที่รถยนต์ไฟฟ้าอัดประจุไปในธุรกรรมนี้
sessionID	String	ตัวเลขจำแนกธุรกรรมอัดประจุนี้
siteID	String	ตัวเลขจำแนกสถานีอัดประจุ
spaceID	String	ตัวเลขจำแนกช่องจอดสำหรับการอัดประจุ
stationID	String	ตัวเลขจำแนกเครื่องอัดประจุ
Timezone	String	Timezone ของสถานีอัดประจุ. เก็บในรูปแบบ pytz format.
userID	String	ตัวเลขจำแนกผู้ใช้รถยนต์ไฟฟ้า จะมีข้อมูลเฉพาะธุรกรรมที่ผู้ใช้ป้อนข้อมูลผ่านมือถือ
userInputs	List(userInput)	ข้อมูลความต้องการของผู้ใช้รถยนต์ไฟฟ้าป้อนโดยผู้ใช้ โดยผู้ใช้สามารถปรับเปลี่ยนความต้องการได้เรื่อยๆ จึงเก็บข้อมูลในลักษณะ List

ตารางที่ 4-3 ชุดข้อมูล ACN Dataset หลังจากทำการเพิ่มและลบฟิลด์

Field	Type	Description
user_ID	String	ตัวเลขจำแนกผู้ใช้รถยนต์ไฟฟ้า จะมีข้อมูลเฉพาะธุรกรรมที่ผู้ใช้ป้อนข้อมูลผ่านมือถือ
connectionTime_ Numerical	Float	ตัวเลขแสดงเวลาที่รถยนต์ไฟฟ้าเชื่อมต่อ แสดงออกมาในรูปของตัวเลขชั่วโมง เศษของนาฬิกาจะถูกหารด้วย 60 และบวกเข้าไปในชั่วโมง เช่น เวลา 11.30 จะถูกแปลงเป็น 11.50
disconnectionTime_ Numerical	Float	ตัวเลขเวลาที่รถยนต์ไฟฟ้าเสร็จสิ้นการเชื่อมต่อ แสดงออกมาในรูปของตัวเลขชั่วโมง เศษของนาฬิกาจะถูกหารด้วย 60 และบวกเข้าไปในชั่วโมง เช่น เวลา 11.30 จะถูกแปลงเป็น 11.50
day	Integer	ตัวเลขแสดงวันในสัปดาห์ เช่น วันจันทร์และอังคารจะเป็น 0, 1 ตามลำดับ
month	Integer	ตัวเลขแสดงเดือน
isWeekend	Integer	ตัวเลขแสดงว่า ธุรกรรมการอัดประจุนี้เป็นวันเสาร์อาทิตย์หรือไม่ 1 คือแสดงว่าใช่
Is_holiday	Integer	ตัวเลขแสดงว่า ธุรกรรมการอัดประจุนี้เป็นวันหยุดหรือไม่ 1 คือแสดงว่าใช่
period	Integer	ตัวเลขแสดงช่วงเวลาของการเริ่มการอัดประจุ โดยใน 1 วัน จะแบ่งออกเป็น 6 ช่วงเวลาได้แก่ 1: 22.00 – 01.59 2: 02.00 – 05.59 3: 06.00 – 09.59 4: 10.00 – 13.59 5: 14.00 – 17.59 6: 18.00 – 21.59
Session duration (Target)	Float	ระยะเวลาที่รถยนต์ไฟฟ้าทำการเชื่อมต่อ (disconnectTime – connectionTime จากตารางที่ 4-2)
Energy demand (Target)	Float	ปริมาณพลังงานไฟฟ้าที่รถยนต์ไฟฟ้าอัดประจุในธุรกรรมนี้ (=kWhDelivered จากตารางที่ 4-2)


4.1.2 กระบวนการตรวจสอบสำรวจข้อมูลเบื้องต้น (Exploratory data analysis)

ในหัวข้อนี้จะแสดงการตรวจสอบข้อมูลเบื้องต้นของสถานีอัดประจุ JPL โดยรูปที่ 4-2 (ซ้าย) แสดงถึงการกระจายตัวของเวลาที่รถยนต์เชื่อมต่อกับสถานีอัดประจุพบว่ามีจุดยอด 3 จุดด้วยกันของได้แก่เวลาช่วงเช้า 05.00-08.00 ซึ่งสอดคล้องกับเวลาเริ่มทำงาน, ช่วงเที่ยง 12.00-13.00 และช่วงเย็น 16.00-17.00 ขณะเดียวกันในรูปที่ 4-2 (ขวา) แสดงถึงการกระจายตัวของเวลาที่รถยนต์เสร็จสิ้นการเชื่อมต่อ พบว่ามีจุดยอดด้วยกัน 2 จุด คือช่วงเที่ยง 12.00-13.00 และช่วงเย็น 16.00-18.00 ซึ่งสอดคล้องกับเวลาเลิกงาน



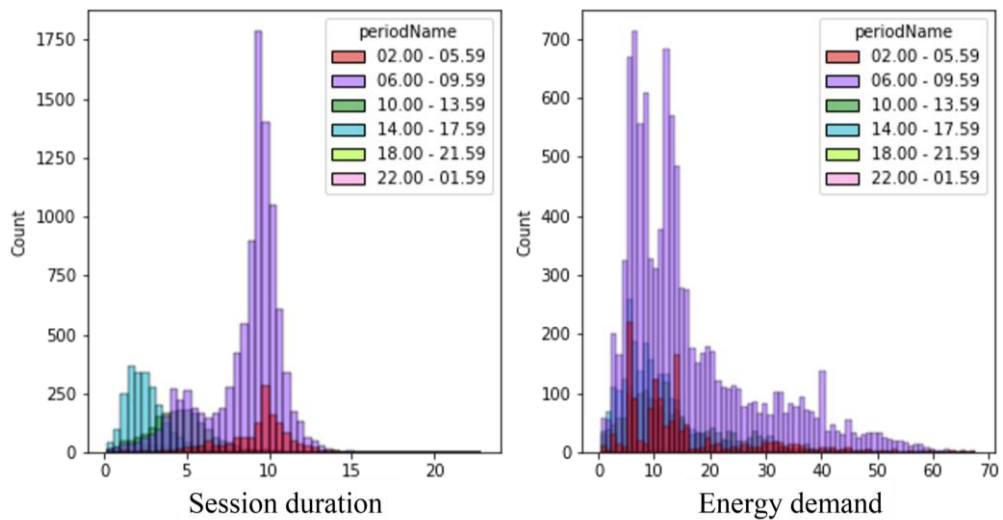
รูปที่ 4-2 การกระจายตัวของเวลาในการเชื่อมต่อ (ซ้าย) เวลาในการเสร็จสิ้นการเชื่อมต่อ (ขวา)

รูปที่ 4-3 แสดงถึงการกระจายตัวของระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ ออกเป็น 3 รูปแบบได้แก่ แถวแรกคือระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของข้อมูลทั้งหมด แถวที่สองคือระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของข้อมูลในช่วงวันทำงานธรรมดา และแถวที่สามคือระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการของข้อมูลในช่วงวันหยุด จากรูปที่ 4-3 จะพบว่าการกระจายตัวของข้อมูลมีการเปลี่ยนแปลงไประหว่างวันธรรมดาและวันหยุด ดังนั้นแล้วหากใส่อินพุต Feature ที่เกี่ยวกับวันหยุดเข้าไป จะมีส่วนช่วยให้กับโมเดลทำนายได้ดีขึ้น



รูปที่ 4-3 การกระจายตัวของระยะเวลาในการเชื่อมต่อ (ซ้าย) และพลังงานไฟฟ้าที่ต้องการ (ขวา)

รูปที่ 4-4 (ซ้าย) แสดงการกระจายตัวแต่ละช่วงเวลาของระยะเวลาในการเชื่อมต่อ จากรูปจะพบว่า การกระจายตัวแต่ละช่วงเวลามีความแตกต่างกันในแต่ละช่วงเวลา เช่น ในช่วงเวลา 06.00-09.59 โอกาสที่ระยะเวลาในการเชื่อมต่อจะมีค่า 10 ชั่วโมงนั้นมีสูงมาก ในขณะที่ช่วงเวลา 14.00-17.59 โอกาสที่ระยะเวลาในการเชื่อมต่อจะมีค่า 10 ชั่วโมงนั้นแทบไม่มีเลย ดังนั้นการให้ช่วงเวลา (Period) เป็นอินพุต Feature น่าจะช่วยให้อัลกอริทึมทำนายค่าระยะเวลาในการเชื่อมต่อได้แม่นยำขึ้น ขณะเดียวกัน รูปที่ 4-4 (ขวา) แสดงการกระจายตัวแต่ละช่วงเวลาของพลังงานไฟฟ้าที่ต้องการ เช่นเดียวกัน แต่จากรูป พบว่าการกระจายตัวของความต้องการพลังงานไฟฟ้าไม่ได้มีความแตกต่างกันในแต่ละช่วงเวลาแต่อย่างใด



รูปที่ 4-4 การกระจายตัวแต่ละช่วงเวลาของระยะเวลาในการเชื่อมต่อ (ซ้าย) และพลังงานไฟฟ้าที่
ต้องการ (ขวา)

4.1.3 Input features

ข้อมูลที่ผ่านกระบวนการ Data preprocessing จากหัวข้อ 3.2.1 จะได้ออกมาเป็นข้อมูล Input features และแสดงตามตารางที่ 4-4 โดยที่ข้อมูลทางสถิตินั้นจะมีรูปแบบในการคำนวณสองรูปแบบได้แก่ รูปแบบแรกคำนวณโดยคำนวณจากธุรกรรมในอดีตของผู้ใช้รถยนต์ไฟฟ้าและใช้ตัวย่อว่า (Statistical)_userId รูปแบบที่สองคำนวณโดยคำนวณจากธุรกรรมในอดีตของผู้ใช้รถยนต์ไฟฟ้าในแต่ละช่วงเวลาและใช้ตัวย่อว่า (Statistical)_userId_period


ตารางที่ 4-4 Input features

Cyclical time features	Description
hr_x, hr_y	Cyclic representation of arrival hour
day_x, day_y	Cyclic representation of arrival hour
month_x, month_y	Cyclic representation of arrival hour
Categorical features	Description
isWeekend	Boolean show the session is weekend or not
Is_holiday	Boolean show the session is holiday or not
period	Period of time in day: 1: 22.00 – 01.59 2: 02.00 – 05.59 3: 06.00 – 09.59 4: 10.00 – 13.59 5: 14.00 – 17.59 6: 18.00 – 21.59
Statistical features	Description
mean	Historical average of charging sessions
mv_mean_n	Historical moving average rolling number n= 3,5,7,10
med	Historical median of charging sessions
min, max	Historical min and max of charging sessions
prev	Previous charging sessions
std	Historical standard deviation of charging sessions

4.1.4 การแบ่งข้อมูล Train validation test

เนื่องจากผลลัพธ์ของการทำนายจะถูกนำไปใช้เป็นอินพุตในการหาค่าที่เหมาะสมที่สุดและเพื่อให้สอดคล้องกับการใช้งานในเหตุการณ์จริง การทำนายจะต้องเคารพในความต้องการของเวลาและห้ามมีข้อมูลในอนาคตเข้ามาปนอยู่ในชุดข้อมูล Train

ดังนั้นแล้วในงานวิจัยนี้จะมีการแบ่งชุดข้อมูล Train, Validation, and Test โดยการใช้เทคนิค Time series nested cross-validation และทำซ้ำด้วยกันสามครั้งแสดงดังรูปที่ 4-5 นอกจากนี้จะมีการใช้เทคนิค Grid search ในการปรับแต่ง Hyperparameter ของโมเดล



รูปที่ 4-5 Three folds iterations time series nested cross-validation

4.2 ขั้นตอนการทดลองการหาค่าที่เหมาะสมที่สุด

เพื่อทดสอบและวัดผลประสิทธิภาพของการหาค่าที่เหมาะสมที่สุดที่มีและไม่มี การรองรับความไม่แน่นอนของความต้องการผู้ใช้รถยนต์ไฟฟ้า พร้อมทั้งวัดผลลัพธ์และประเมินถึงข้อดีของการใช้ความต้องการจากการทำนายด้วยโมเดลการเรียนรู้ จึงได้มีการรัน Simulation โดยใช้เครื่องมือ ACN-Sim [24] กับเดือนสามเดือนสุดท้ายของปี อันได้แก่เดือนตุลาคมถึงเดือนธันวาคมแล้วนำผลลัพธ์ที่ได้มาหาค่าเฉลี่ย รูปที่ 4-6 แสดงภาพรวมการ Simulation การหาค่าที่เหมาะสมที่สุด ซึ่งสามารถแบ่งย่อยออกเป็น การตั้งค่า Simulation และสถานการณ์ของการ Simulation

4.2.1 การตั้งค่า (Simulation setting)

1. สถานีอัดประจุ: อันได้แก่ลักษณะโครงสร้างของสถานี เช่น ขนาดหม้อแปลง การต่อไฟของเครื่องอัดประจุ และจำนวนเครื่องอัดประจุ
 - a. ACN: **JPL (52 EV chargers)** และ **Caltech (54 EV chargers)**
 - b. การไฟฟ้านครหลวง: **ห้างสรรพสินค้า (3 EV chargers)** และ **มหาวิทยาลัย (5 EV chargers)**
2. TOU tariff: อันได้แก่ค่าไฟฟ้าที่การไฟฟ้าเรียกเก็บกับสถานีอัดประจุหรือคือของสถานีอัดประจุ
 - a. ACN: Southern California Edison TOU EV4 แสดงดังตารางที่ 4-5

- b. การไฟฟ้านครหลวง: ในปัจจุบัน (ปี ค.ศ. 2023) เพื่อส่งเสริมให้มีการลงทุนตั้งสถานีอัดประจุ ทางภาครัฐประเทศไทยมีนโยบายการเก็บค่าไฟกับสถานีอัดประจุที่เรียกว่า Low Priority ซึ่งการเก็บค่าไฟในรูปแบบนี้จะไม่มีการคิดค่า Demand charge และจะคิดค่าไฟในอัตรา Off-Peak ในทุกช่วงเวลา อย่างไรก็ตามในการ Simulation นี้จะคิดค่านึงถึงกรณีที่นโยบายดังกล่าวไม่มีความจำเป็นและมีการเก็บค่าไฟตามความเป็นจริง ดังนั้นแล้วชุดข้อมูลจากสถานีการไฟฟ้านครหลวงจะใช้อัตราค่าไฟ ผู้ใช้ไฟฟ้าประเภทที่ 3 กิจการขนาดกลาง อัตรา 3.2 แสดงดังตารางที่ 4-6
3. Revenue: คือค่าไฟต่อหน่วยไฟฟ้าที่สถานีอัดประจุเก็บจากผู้ใช้งานรถไฟฟ้า หรือคือรายได้ของสถานีอัดประจุ
 - a. ACN: 0.3\$/kWh
 - b. การไฟฟ้านครหลวง: 0.22\$/kWh (฿7.5/kWh)
 4. โมเดลแบตเตอรี่ของรถยนต์ไฟฟ้า: จะใช้งาน Non-ideal EV batteries model ซึ่งเป็นโมเดลแบตเตอรี่ที่มีใน Simulator
 5. Peak hint: คือค่าประมาณความต้องการพลังไฟฟ้า q จากสมการ (3-7) โดยค่านี้จะมาจากการหาค่าที่เหมาะสมที่สุดโดยวิธีการ Offline scheduling กับรอบเดือนก่อนหน้า ในกรณีนี้จะทำการ Offline scheduling ตั้งแต่เดือนมกราคมถึงกันยายน แล้วนำค่าประมาณความต้องการพลังไฟฟ้าที่ได้ในแต่ละเดือนมาทำการเฉลี่ย สาเหตุที่มีการกำหนดค่าดังกล่าวนี้คือเพื่อให้ทำหน้าที่เป็นตัวแปรควบคุม ทำให้ผลลัพธ์สามารถทำการเปรียบเทียบกันได้ง่ายขึ้น (รายละเอียดผลลัพธ์ของการ Offline scheduling อยู่ในภาคผนวกหัวข้อ 7.1)
 6. เครื่องอัดประจุ: เครื่องมือ ACN-Sim นั้นมีข้อจำกัดในการรองรับการ Simulation กับเครื่องอัดประจุหนึ่งเฟสเท่านั้นจะไม่มีการรองรับเครื่องอัดประจุสามเฟส ในกรณีที่ชุดข้อมูลธุรกรรมที่นำมาวิเคราะห์เกิดจากเครื่องอัดประจุสามเฟสจะทำให้ผลลัพธ์จากการ Simulation มีบางธุรกรรมการอัดประจุที่ไม่สามารถอัดประจุได้อย่างเต็มที่ ส่งผลให้ปริมาณพลังงานไฟฟ้าที่จ่ายโดยรวมทั้งหมดของสถานีจะมีค่าน้อยกว่าความเป็นจริง โดยเหตุการณ์นี้จะเกิดกับชุดข้อมูลจากการไฟฟ้านครหลวง ซึ่งแนวทางการพัฒนาในอนาคตจะอธิบายเพิ่มเติมในหัวข้อ 6.2.2

ตารางที่ 4-5 TOU tariff สำหรับสถานีจากชุดข้อมูล ACN

Tariff for USA Charging stations: Southern California Edison TOU EV4			
Name	Time Range	Weekday	Weekend
Off-Peak	23.00-08.00	\$0.056/kWh	\$0.056/kWh
Mid-Peak	08.00-12.00 18.00-23.00	\$0.092/kWh	\$0.056/kWh
Peak	12.00-18.00	\$0.267/kWh	\$0.056/kWh
Demand Charge	\$15.51/kW/month		
Revenue per kWh	\$0.3/kWh		

ตารางที่ 4-6 TOU tariff สำหรับสถานีจากชุดข้อมูลการไฟฟ้านครหลวง

Tariff for Thailand Charging stations: MEA TOU: Medium General Service (3.2 customer) for below 12kV			
Name	Time Range	Weekday	Weekend
Off-Peak	22.00-09.00	\$0.077/kWh (฿2.6369)	\$0.077/kWh (฿2.6369)
Peak	09.00-22.00	\$0.13/kWh (฿4.3297)	\$0.077/kWh (฿2.6369)
Demand Charge	\$6.16/kW/month (฿210)		
Revenue per kWh	\$0.22/kWh (฿7.5)		

4.2.2 สถานการณ์ (Simulation cases)

การ Simulation จะทดลองด้วย 3 ตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า บน 2 อัลกอริทึมในการหาค่าที่เหมาะสมที่สุด ซึ่งจะมีดังนี้

ตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า

1. True demand": คือค่าความต้องการที่แท้จริงของผู้ใช้รถยนต์ไฟฟ้า ที่จะได้มาหลังจากการอัดประจุเสร็จสิ้น
2. User inputs: คือค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ผู้ใช้เป็นคนป้อนผ่านมือถือ ตัวประเมินนี้จะถูกใช้เป็น *Baseline*
3. ML model: คือค่าความต้องการของผู้ใช้รถยนต์ไฟฟ้าที่ทำนายมาจากโมเดลการเรียนรู้ผู้ชนะจากหัวข้อ 4.1

อัลกอริทึมการหาค่าที่เหมาะสมที่สุด

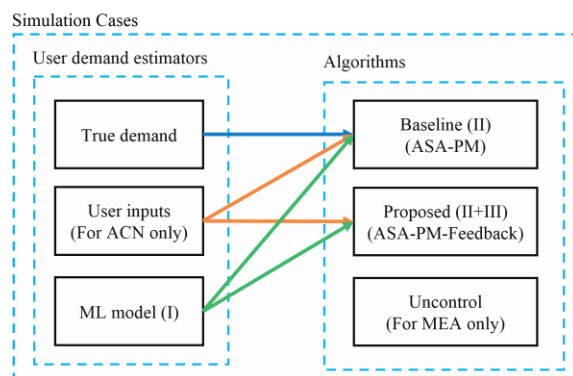
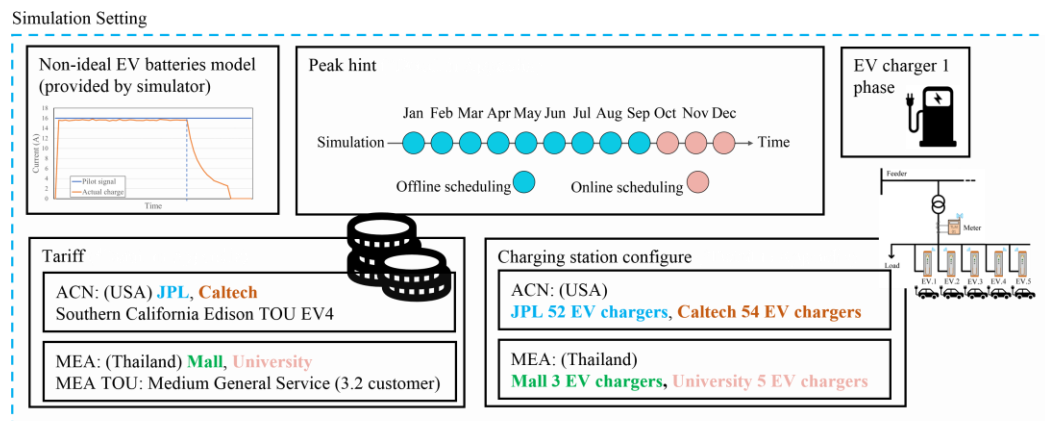
1. ASA-PM: เป็นอัลกอริทึม *Baseline* จากหัวข้อ 3.3 ด้วยฟังก์ชันวัตถุประสงค์ตามสมการ (4-1)
2. ASA-PM-Feedback: เป็นอัลกอริทึมที่มีพัฒนาให้รองรับความไม่แน่นอนของความต้องการผู้ใช้รถยนต์ไฟฟ้าจากหัวข้อ 3.3 -3.4 ด้วยฟังก์ชันวัตถุประสงค์ตามสมการ (4-2)

$$u^{PM} := u^{EC} + u^{DC} + 10^{-6}u^{QC} + 10^{-12}u^{ES} \tag{4-1}$$

$$u^{PM} := u^{EC} + u^{DC} + 10^{-6}u^{QC} + 10^{-12}u^{ES} + u^{PR} \tag{4-2}$$

3. *Uncontrol: ในกรณีของสถานีจากการไฟฟ้านครหลวงนั้นจะไม่มีการบันทึกข้อมูลความต้องการจากผู้ใช้งานรถยนต์ไฟฟ้า ทำให้ไม่มีตัวเปรียบเทียบผลลัพธ์มากนัก จึงมีการเพิ่มสถานการณ์ที่ไม่มีการควบคุมการอัดประจุเข้ามาเพิ่มเติม ซึ่งสถานการณ์นี้สามารถกล่าวได้ว่าเป็นสถานการณ์ใช้งานจริงในปัจจุบันของประเทศไทย (ปี ค.ศ. 2023)

Experimental Setup (Optimization of EV charging schedule)



รูปที่ 4-6 ภาพรวมการ Simulation การหาค่าที่เหมาะสมที่สุด

บทที่ 5

ผลลัพธ์การทดลอง (Result)

5.1 ผลลัพธ์การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า

5.1.1 สถานี ACN: JPL

ตารางที่ 5-1 และ ตารางที่ 5-2 แสดงผลการเปรียบเทียบความต้องการของผู้ใช้รถยนต์ไฟฟ้า ระหว่าง (I) User Inputs, (II) Baselines , และ (III) ML models ของสถานี JPL ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามที่ได้อธิบายไปในหัวข้อ 4.1 โดยที่ตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำกรทำนาย ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และ ธันวาคมของปี ค.ศ. 2019

ผลลัพธ์จากตารางที่ 5-1 และ ตารางที่ 5-2 แสดงให้เห็นว่า *Baseline2* มีความแม่นยำกว่า *Baseline1* ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ ซึ่งสามารถสื่อได้ว่าการนำค่าช่วงเวลามามีส่วนร่วมในการสร้างข้อมูลทางสถิติจะทำให้จับพฤติกรรมความต้องการของผู้ใช้ได้ดีขึ้น โดยที่รูปที่ 5-1 ช่วยยืนยันข้อสันนิษฐานนี้จากการแสดงให้เห็นว่า Feature ที่มีความสำคัญนั้นจะมีช่วงเวลาหรือ Period เป็นส่วนประกอบ

ในส่วนของการทำนายระยะเวลาในการเชื่อมต่อนั้นพบว่าโมเดลการเรียนรู้ทั้งสามโมเดลมีความแม่นยำที่เหนือกว่า *Baselines* โดยที่ XGBoost เป็นโมเดลการเรียนรู้ที่แม่นยำที่สุดในระหว่างที่ TabNet มีความแม่นยำน้อยที่สุด สำหรับการทำนายพลังงานไฟฟ้าที่ต้องการก็จะมีผลลัพธ์ไปในทิศทางเดียวกันนอกเสียจากว่า TabNet นั้นมีความแม่นยำที่น้อยกว่า *Baseline2* ในส่วนของ SMAPE ซึ่งสื่อได้ว่าโมเดลการเรียนรู้ในรูปแบบต้นไม้ยังคงมีประสิทธิภาพที่ดีกว่าในข้อมูลประเภทตาราง ในขณะที่เดียวกันการใช้ความต้องการจากที่ผู้ใช้เป็นคนป้อนข้อมูลหรือ User Inputs นั้นมีความแม่นยำน้อยที่สุดในทุกค่าวัดผลประสิทธิภาพ


นอกจากนี้ได้มีการแสดงการวิเคราะห์ของผลลัพธ์ในรูปแบบของ Residual plot ระหว่างความต้องการจาก User Inputs กับความต้องการจากโมเดลการเรียนรู้ที่ชนะอันได้แก่ XGBoost แสดงดังรูปที่ 5-2 และรูปที่ 5-3 ซึ่งจากรูปแสดงให้เห็นว่าความต้องการจากที่ผู้ใช้เป็นผู้ป้อนนั้นมีแนวโน้มเอนเอียงไปในทิศทางระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการสูงกว่าความเป็นจริง ซึ่งความเอนเอียงนี้จะส่งผลเป็นอย่างมากกับการหาค่าที่เหมาะสมที่สุดในหัวข้อ 5.2.1 ให้ทำการยกค่ากระแสไฟเพื่อรับรองรับความต้องการปลอม ในขณะที่เดียวกันทางฝั่ง XGBoost พบว่าจะไม่มีความเอนเอียงดังกล่าวและค่าการทำนายจะผิดพลาดอยู่ระหว่าง -5 – 5 ชั่วโมง กับ -30 – 30 kWh สำหรับระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ

ตารางที่ 5-1 (JPL) ผลลัพธ์การทำนายระยะเวลาในการเชื่อมต่อ
(หน่วยนาที, ตัวหนาหมายถึงผู้ชนะ)


Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	219.81	153.52	22.77	-0.29
Baselines				
<i>Baseline1:</i> Mean of session duration by user id	143.22	105.64	15.43	0.45
<i>Baseline2:</i> Mean of session duration by user id and period	120.68	81.63	11.79	0.61
Proposed (ML models)				
XGBoost	109.18	73.31	10.72	0.68
RF	111.44	75.03	10.86	0.67
TabNet	114.16	75.85	11.08	0.65

ตารางที่ 5-2 (JPL) ผลลัพธ์การทำนายพลังงานไฟฟ้าที่ต้องการ
(หน่วย kWh, ตัวหนาหมายถึงผู้ชนะ)

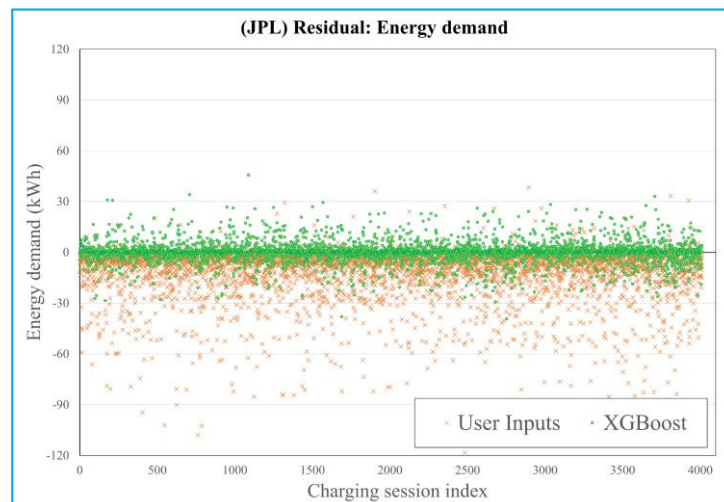
Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	19.53	12.34	26.91	-1.99
Baselines				
<i>Baseline1:</i> Mean of energy demand by user id	7.18	4.40	13.13	0.60
<i>Baseline2:</i> Mean of energy demand by user id and period	6.98	4.20	12.57	0.62
Proposed (ML models)				
XGBoost	6.36	3.82	11.85	0.68
RF	6.37	3.83	11.91	0.68
TabNet	6.56	4.03	12.81	0.66



รูปที่ 5-1 (JPL) Feature Importance จาก XGBoost ในการทำนายระยะเวลาในการเชื่อมต่อ (ซ้าย) และพลังงานไฟฟ้าที่ต้องการ (ขวา)



รูปที่ 5-2 (JPL) Residual ของระยะเวลาในการเชื่อมต่อ



รูปที่ 5-3 (JPL) Residual ของพลังงานไฟฟ้าที่ต้องการ

5.1.2 สถานี ACN: Caltech

ตารางที่ 5-3 และ ตารางที่ 5-4 แสดงผลการเปรียบเทียบความต้องการของผู้ใช้รถยนต์ไฟฟ้า ระหว่าง (I) User Inputs, (II) Baselines , และ (III) ML models ของสถานี Caltech ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามที่ได้อธิบายไปในหัวข้อ 4.1 โดยที่ ตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการทำนาย ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2019

เช่นเดียวกันกับกรณีของสถานี JPL ผลลัพธ์จากตารางที่ 5-3 และ ตารางที่ 5-4 แสดงให้เห็นว่า Baseline2 มีความแม่นยำกว่า Baseline1 ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการ ซึ่งสามารถสื่อได้ว่าการนำค่าช่วงเวลามามีส่วนร่วมในการสร้างข้อมูลทางสถิติจะทำให้จับพฤติกรรมความต้องการของผู้ใช้ได้ดีขึ้น โดยที่รูปที่ 5-4 ช่วยยืนยันข้อสันนิษฐานนี้จากการแสดงให้เห็นว่า Feature ที่มีความสำคัญนั้นจะมีช่วงเวลาหรือ Period เป็นส่วนประกอบเช่นเดียวกัน

อย่างไรก็ตามในกรณีของสถานี Caltech นั้นพบว่าโมเดลการเรียนรู้เฉพาะ XGBoost และ RF มีความแม่นยำที่เหนือกว่า Baselines โดยที่ RF เป็นโมเดลการเรียนรู้ที่แม่นยำที่สุด ในระหว่างที่ TabNet มีความแม่นยำที่แย่และน้อยกว่า Baseline2 เสียอีก ซึ่งสื่อได้ว่าโมเดลการเรียนรู้ในรูปแบบต้นไม้ยังคงมีประสิทธิภาพที่ดีกว่าในข้อมูลประเภทตาราง ในขณะที่เดียวกันการใช้ความต้องการจากที่ผู้ใช้เป็นคนป้อนข้อมูลหรือ User Inputs นั้นมีความแม่นยำน้อยที่สุดในทุกค่าวัดผลประสิทธิภาพเช่นเดิม

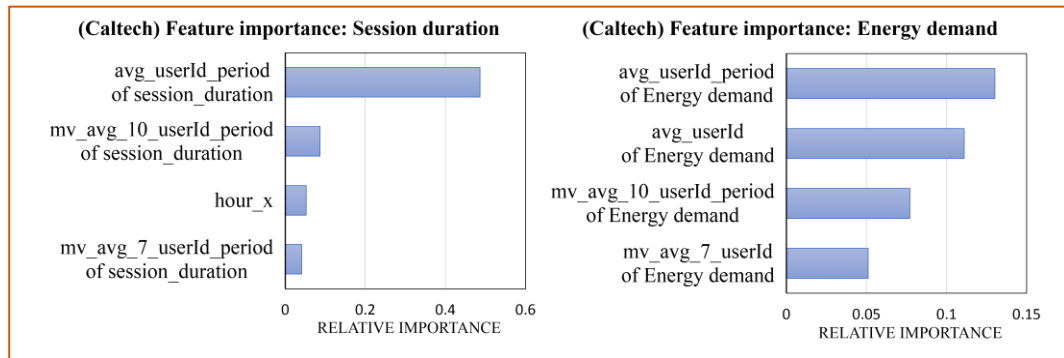
นอกจากนี้ได้มีการแสดงการวิเคราะห์ของผลลัพธ์ในรูปแบบของ Residual plot ระหว่างความต้องการจาก User Inputs กับความต้องการจากโมเดลการเรียนรู้ที่ชนะอันได้แก่ RF แสดงดังรูปที่ 5-5 และรูปที่ 5-6 และแจกเช่นเดียวกับกรณีของสถานี JPL พบว่าความต้องการจากที่ผู้ใช้เป็นผู้ป้อนนั้นมีแนวโน้มเอนเอียงไปในทิศทางระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการสูงกว่าความเป็นจริง ซึ่งความเอนเอียงนี้จะส่งผลเป็นอย่างมากกับการหาค่าที่เหมาะสมที่สุดในหัวข้อ 5.2.2 ให้ทำการยกค่ากระแสฟิคเพื่อรับรองรับความต้องการปลอม ในขณะเดียวกันทางฝั่ง RF พบว่า จะไม่มีความเอนเอียงดังกล่าวและค่าการทำนายจะผิดพลาดอยู่ระหว่าง -5 – 5 ชั่วโมง กับ -30 – 30 kWh สำหรับระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ

ตารางที่ 5-3 (Caltech) ผลลัพธ์การทำนายระยะเวลาในการเชื่อมต่อ
(หน่วยนาที, ตัวหนาหมายถึงผู้ชนะ)

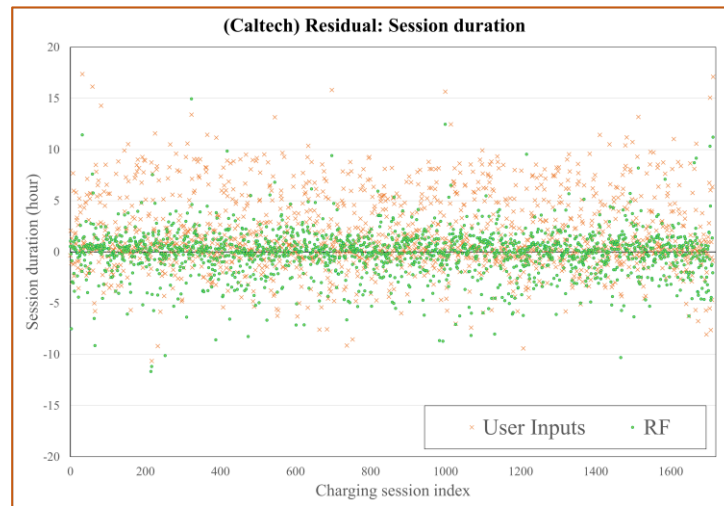
Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	265.10	169.20	29.50	-0.18
Baselines				
<i>Baseline1:</i> Mean of session duration by user id	157.32	112.56	17.82	0.45
<i>Baseline2:</i> Mean of session duration by user id and period	142.32	95.68	15.52	0.55
Proposed (ML models)				
XGBoost	137.43	92.34	15.13	0.58
RF	137.54	92.16	15.04	0.58
TabNet	145.57	97.05	16.11	0.53

ตารางที่ 5-4 (Caltech) ผลลัพธ์การทำนายพลังงานไฟฟ้าที่ต้องการ
(หน่วย kWh, ตัวหนาหมายถึงผู้ชนะ)

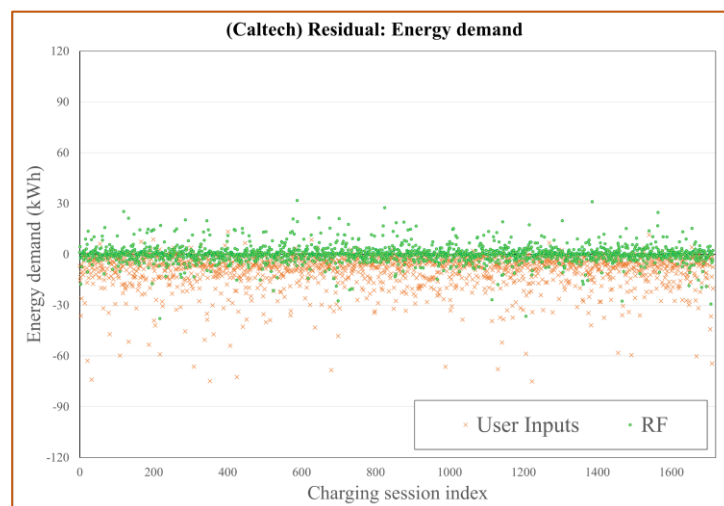
Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	15.13	9.81	33.64	-1.49
Baselines				
<i>Baseline1:</i> Mean of energy demand by user id	5.66	3.44	17.36	0.64
<i>Baseline2:</i> Mean of energy demand by user id and period	5.61	3.34	16.67	0.65
Proposed (ML models)				
XGBoost	5.60	3.39	17.21	0.65
RF	5.46	3.33	16.64	0.67
TabNet	5.73	3.44	17.46	0.63



รูปที่ 5-4 (Caltech) Feature Importance จาก XGBoost ในการทำนายระยะเวลาในการเชื่อมต่อ (ชั่วโมง) และพลังงานไฟฟ้าที่ต้องการ (กWh)



รูปที่ 5-5 (Caltech) Residual ของระยะเวลาในการเชื่อมต่อ



รูปที่ 5-6 (Caltech) Residual ของพลังงานไฟฟ้าที่ต้องการ

5.1.3 สถานี MEA: Mall

ตารางที่ 5-5 และ ตารางที่ 5-6 แสดงผลการเปรียบเทียบความต้องการของผู้ใช้รถยนต์ไฟฟ้า ระหว่าง (I) User Inputs, (II) Baselines , และ (III) ML models ของสถานี Mall ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามที่ได้อธิบายไปในหัวข้อ 4.1 โดยที่ตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการทำนาย ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และ ธันวาคมของปี ค.ศ. 2022

ผลลัพธ์จากตารางที่ 5-5 และ ตารางที่ 5-6 แสดงให้เห็นว่า *Baseline2* มีความแม่นยำกว่า *Baseline1* ในการทำนายระยะเวลาในการเชื่อมต่อ และจากรูปที่ 5-7 (ซ้าย) แสดงให้เห็นว่า Feature ที่มีความสำคัญนั้นจะมีช่วงเวลาหรือ Period เป็นส่วนประกอบ แต่ในกรณีของการทำนายพลังงานไฟฟ้าที่ต้องการความแม่นยำของทั้งสอง *Baselines* จะไม่ต่างกันมากนัก

ในกรณีของสถานี Mall นั้นพบว่าโมเดลการเรียนรู้ที่ทำนายระยะเวลาในการเชื่อมต่อที่ดีที่สุด ได้แก่ RF ซึ่งมีค่าความแม่นยำที่สูงกว่า *Baselines*

โมเดลการเรียนรู้ที่ดีที่สุดจากทั้งสามโมเดลในกรณีของการทำนายพลังงานไฟฟ้าที่ต้องการจะ ได้แก่ RF เช่นเดียวกัน แต่อย่างไรก็ตามการใช้ค่าเฉลี่ยพลังงานไฟฟ้าที่ต้องการของผู้ใช้หรือ *Baseline1* มีความแม่นยำกว่าโมเดลการเรียนรู้ทั้งหมด ทั้งนี้จะทำการวิเคราะห์ถึงสาเหตุดังกล่าวในหัวข้อ 5.3.2


นอกจากนี้ได้มีการแสดงการวิเคราะห์ของผลลัพธ์ในรูปแบบของ Residual plot จากโมเดลการเรียนรู้ที่ดีที่สุดจากโมเดลการเรียนรู้ทั้งหมด อันได้แก่ RF แสดงดังรูปที่ 5-8 และรูปที่ 5-9 จากรูปพบว่าในส่วนใหญ่ข้อมูลจะไม่มีเอนเอียงไปในการทำนายมากไปหรือน้อยไปมากนัก และจะมีค่าการทำนายผิดพลาดกระจายอยู่ระหว่าง -4 -4 ชั่วโมง กับ -20 - 20 kWh สำหรับระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ

ตารางที่ 5-5 (Mall) ผลลัพธ์การทำนายระยะเวลาในการเชื่อมต่อ
(หน่วยนาที, ตัวหนาหมายถึงผู้ชนะ)


Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	-	-	-	-
Baselines				
Baseline1: Mean of session duration by user id	95.61	57.13	16.56	0.33
Baseline2: Mean of session duration by user id and period	94.01	54.65	15.92	0.35
Proposed (ML models)				
XGBoost	95.44	58.70	17.45	0.33
RF	90.43	54.49	15.91	0.40
TabNet	98.75	58.04	16.80	0.28

ตารางที่ 5-6 (Mall) ผลลัพธ์การทำนายพลังงานไฟฟ้าที่ต้องการ
(หน่วย kWh, ตัวหนาหมายถึงผู้ชนะ)


Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	-	-	-	-
Baselines				
Baseline1: Mean of energy demand by user id	5.38	3.32	13.55	0.65
Baseline2: Mean of energy demand by user id and period	5.44	3.34	13.43	0.65
Proposed (ML models)				
XGBoost	5.55	3.38	13.61	0.63
RF	5.42	3.41	13.59	0.65
TabNet	6.18	3.57	14.46	0.54



รูปที่ 5-7 (Mall) Feature Importance จาก RF ในการทำนายระยะเวลาในการเชื่อมต่อ (ซ้าย) และพลังงานไฟฟ้าที่ต้องการ (ขวา)



รูปที่ 5-8 (Mall) Residual ของระยะเวลาในการเชื่อมต่อ



รูปที่ 5-9 (Mall) Residual ของพลังงานไฟฟ้าที่ต้องการ

5.1.4 สถานี MEA: **University**

ตารางที่ 5-7 และ ตารางที่ 5-8 แสดงผลการเปรียบเทียบความต้องการของผู้ใช้รถยนต์ไฟฟ้า ระหว่าง (I) User Inputs, (II) Baselines , และ (III) ML models ของสถานี **University** ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามที่ได้อธิบายไปในหัวข้อ 4.1 โดยที่ ตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำกรทำนาย ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2022

ผลลัพธ์จากตารางที่ 5-7 และ ตารางที่ 5-8 แสดงให้เห็นว่า *Baseline2* มีความแม่นยำกว่า *Baseline1* ในการทำนายระยะเวลาในการเชื่อมต่อ และจากรูปที่ 5-10 (ซ้าย) แสดงให้เห็นว่า Feature ที่มีความสำคัญนั้นจะมีช่วงเวลาหรือ Period เป็นส่วนประกอบ แต่ในกรณีของการทำนาย พลังงานไฟฟ้าที่ต้องการความแม่นยำของ *Baseline1* จะมากกว่า *Baseline2*

ในกรณีของสถานี **University** นั้นพบว่าในการทำนายระยะเวลาในการเชื่อมต่อ การใช้ ค่าเฉลี่ยระยะเวลาในการเชื่อมต่อของผู้ใช้หรือ *Baseline1* มีความแม่นยำที่ดีที่สุด และเหนือกว่าการใช้โมเดลการเรียนรู้ ทั้งนี้จะทำการวิเคราะห์ถึงสาเหตุดังกล่าวในหัวข้อ 5.3.2

ในกรณีของการทำนายพลังงานไฟฟ้าที่ต้องการพบว่าโมเดลการเรียนรู้ที่ดีที่สุดได้แก่ RF ซึ่งมี ค่าความแม่นยำที่เหนือกว่า *Baselines*


นอกจากนี้ได้มีการแสดงการวิเคราะห์ของผลลัพธ์ในรูปแบบของ Residual plot จากโมเดล การเรียนรู้ที่ โดยในที่นี้ได้เลือกผลจาก RF มาใช้ในการแสดงแสดง ดังรูปที่ 5-11 และรูปที่ 5-12 จากรูปพบว่าในส่วนใหญ่ข้อมูลจะไม่มีเอนเอียงไปในการทำนายมากไปหรือน้อยไปมากนัก และจะมีค่า การทำนายผิดพลาดกระจายอยู่ระหว่าง -4 -4 ชั่วโมง กับ -20 – 20 kWh สำหรับระยะเวลาในการ เชื่อมต่อและพลังงานไฟฟ้าที่ต้องการตามลำดับ

ตารางที่ 5-7 (University) ผลลัพธ์การทำนายระยะเวลาในการเชื่อมต่อ
(หน่วยนาที, ตัวหนาหมายถึงผู้ชนะ)


Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	-	-	-	-
Baselines				
<i>Baseline1:</i> Mean of session duration by user id	92.43	59.26	18.94	0.37
<i>Baseline2:</i> Mean of session duration by user id and period	77.80	55.76	18.30	0.56
Proposed (ML models)				
XGBoost	85.24	57.86	18.71	0.47
RF	83.19	58.87	19.14	0.49
TabNet	114.97	68.84	20.78	0.03

ตารางที่ 5-8 (University) ผลลัพธ์การทำนายพลังงานไฟฟ้าที่ต้องการ
(หน่วย kWh, ตัวหนาหมายถึงผู้ชนะ)


Regression Model	RMSE	MAE	SMAPE (%)	R ²
User Inputs	-	-	-	-
Baselines				
<i>Baseline1:</i> Mean of energy demand by user id	5.50	4.08	18.44	0.34
<i>Baseline2:</i> Mean of energy demand by user id and period	5.65	4.07	18.33	0.30
Proposed (ML models)				
XGBoost	5.69	4.11	18.29	0.29
RF	5.46	4.03	18.08	0.35
TabNet	5.98	4.27	18.59	0.22



รูปที่ 5-10 (*University*) Feature Importance จาก RF ในการทำนายระยะเวลาในการเชื่อมต่อ (ซ้าย) และพลังงานไฟฟ้าที่ต้องการ (ขวา)



รูปที่ 5-11 (*University*) Residual ของระยะเวลาในการเชื่อมต่อ



รูปที่ 5-12 (*University*) Residual ของพลังงานไฟฟ้าที่ต้องการ

5.2 ผลลัพธ์การ Simulation การหาค่าที่เหมาะสมที่สุด

5.2.1 สถานี ACN: JPL

ตารางที่ 5-9 แสดงผลลัพธ์ของการ Simulation ของสถานี JPL ระหว่างสามตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า: True demand, User inputs และ ML model กับสองอัลกอริทึมในการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุ: baseline ASA-PM และ ASA-PM-Feedback ตามที่ได้อธิบายไปในหัวข้อ 4.2 .ในกรณีของตัวประเมินความต้องการจาก True demand ที่เป็นความต้องการที่เกิดขึ้นจริงจะไม่มีค่าจำเป็นที่ต้องรองรับความไม่แน่นอนดังนั้นแล้ว จะจับคู่กับ baseline ASA-PM เท่านั้นและผลลัพธ์จะเป็นตัวแทนถึง best-case scenario ที่สามารถเกิดขึ้นได้ นอกจากนี้ตัวประเมินความต้องการจาก User inputs จะนับว่าเป็น baseline ของตัวประเมินความต้องการ ตัวประเมินความต้องการจาก ML model ของสถานี JPL จะใช้ XGBoost จากผลลัพธ์ของหัวข้อ 5.1.1 ทุกสถานการณ์ของสถานี JPL จะใช้ค่า Peak hint 500A ตามที่ได้ อธิบายไปในหัวข้อ 4.2.1 ผลลัพธ์ในตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการ Simulation ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2019

รายได้, ต้นทุนพลังงานค่าไฟฟ้าต่อหน่วย, ต้นทุนค่าความต้องการพลังงานไฟฟ้า และผลกำไรของ สถานีอัดประจุจะแสดงดังรูปที่ 5-13


ตามที่ได้คาดการณ์ไว้ ความเอนเอียงของผู้ใช้รถยนต์ไฟฟ้าทำให้การหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึมทำการยกค่ากระแสพิคเพื่อรองรับความต้องการในลักษณะระยะเวลาสั้นและพลังงานสูงปลอมจากผู้ใช้ ในทางตรงกันข้ามตัวประเมินความต้องการจาก XGBoost และจาก True demand จะไม่มีความเอนเอียงและไม่ทำให้กระแสพิคยกตัวสูงขึ้นทั้งสองอัลกอริทึม ส่งผลให้ในกรณีของตัวประเมินความต้องการจากผู้ใช้รถยนต์ไฟฟ้าหรือ User inputs นั้นเจอกับค่าต้นทุนความต้องการพลังงานไฟฟ้าที่สูงกว่า จึงมีผลกำไรที่น้อยลง

นอกจากนี้เมื่อเปรียบเทียบการหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึม พบว่าความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นส่งผลให้สถานีอัดประจุจ่ายพลังงานไฟฟ้าโดยรวมได้น้อยลงในอัลกอริทึม baseline ASA-PM โดยผลที่ว่ามันสามารถตรวจสอบได้จากรูปที่ 5-14 ซึ่งจะเห็นได้ว่าเส้นการอัดประจุของ ASA-PM User Inputs และ ASA-PM XGBoost ค่อยๆลดลงก่อนกำหนดเมื่อเทียบกับเส้นการอัดประจุของ ASA-PM True demand แต่ในกรณีของอัลกอริทึมที่นำเสนอ ASA-PM-Feedback นั้นพบว่าผลจากความไม่แน่นอนส่งผลน้อยลง ทำให้เส้นการอัดประจุมีความต่อเนื่องและสามารถจ่ายพลังงานไฟฟ้าได้มากขึ้น การที่สามารถจ่ายพลังงานไฟฟ้าได้มากขึ้น ส่งผลดีทำให้ผู้ใช้รถยนต์ไฟฟ้าได้รับพลังงานมากขึ้นและสถานีอัดประจุก็ได้รับรายได้มากขึ้น ซึ่งสามารถพิจารณาได้จากรูปที่ 5-15


สรุปโดยรวมแล้วสำหรับสถานี JPL หากทำการใช้ความต้องการจากผู้ใช้โดยตรงกับ อัลกอริทึมที่ไม่รองรับความไม่แน่นอนจะทำให้สถานีอัดประจุได้กำไรอยู่ที่ประมาณ \$2,267.34 ต่อเดือน แต่ถ้าหากทำการใช้ความต้องการจากโมเดลการเรียนรู้กับอัลกอริทึมที่รองรับความไม่แน่นอน หรือก็คือ End-to-end framework จะทำให้สถานีอัดประจุได้กำไรที่มากขึ้นเป็น \$2,883.62 ต่อเดือน ซึ่งเพิ่มขึ้นถึง 27.18%

ตารางที่ 5-9 (JPL) ผลลัพธ์การ Simulation (BL หมายถึง Baseline)

Demand Estimators	Algorithms	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Profit (\$)
True demand	ASA-PM (BL)	20,784.06	98.12	500.00	2,942.25
Baseline: User inputs	ASA-PM (BL)	20,784.06	91.78	621.82	2,267.34
	ASA-PM-Feedback (ours)	20,784.06	98.63	628.90	2,572.49
Proposed: XGBoost	ASA-PM (BL)	20,784.06	86.17	500.00	2,400.74
	ASA-PM-Feedback (ours)	20,784.06	96.84	500.00	2,883.62



รูปที่ 5-13 (JPL) Revenue breakdown ของสถานีอัดประจุ




รูปที่ 5-14 (JPL) Actual charge on Wednesday 2 Oct, 2019

(ในรูปจะแสดงถึงพลังงานซึ่งมีค่าเท่ากับแรงดันคูณด้วยกระแส หรือ

$$Power (W) = Voltage (V) \times Current (A)$$

โดยที่ในที่นี่ Voltage = 208V หรือคือย่านแรงดันจ่ายไฟโดยทั่วไป)



รูปที่ 5-15 (JPL) Percentage of demand met

5.2.2 สถานี ACN: Caltech

ตารางที่ 5-10 แสดงผลลัพธ์ของการ Simulation ของสถานี Caltech ระหว่างสามตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า: True demand, User inputs และ ML model กับสองอัลกอริทึมในการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุ: baseline ASA-PM และ ASA-PM-Feedback ตามที่ได้อธิบายไปในหัวข้อ 4.2 .ในกรณีของตัวประเมินความต้องการจาก True demand ที่เป็นความต้องการที่เกิดขึ้นจริงจะไม่มีค่าจำเป็นที่ต้องรองรับความไม่แน่นอนดังนั้นแล้วจะจับคู่กับ baseline ASA-PM เท่านั้นและผลลัพธ์จะเป็นตัวแทนถึง best-case scenario ที่สามารถเกิดขึ้นได้ นอกจากนี้ตัวประเมินความต้องการจาก User inputs จะนับว่าเป็น baseline ของตัวประเมินความต้องการ ตัวประเมินความต้องการจาก ML model ของสถานี Caltech จะใช้ RF จากผลลัพธ์ของหัวข้อ 5.1.2 ทุกสถานการณ์ของสถานี Caltech จะใช้ค่า Peak hint 160A ตามที่ได้อธิบายไปในหัวข้อ 4.2.1 ผลลัพธ์ในตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการ Simulation ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2019

รายได้, ต้นทุนพลังงานค่าไฟฟ้าต่อหน่วย, ต้นทุนค่าความต้องการพลังงานไฟฟ้า และผลกำไรของสถานีอัดประจุจะแสดงดังรูปที่ 5-16


เช่นเดียวกับกรณีของสถานี JPL ความเอนเอียงของผู้ใช้รถยนต์ไฟฟ้าทำให้การหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึมทำการยกค่ากระแสไฟขึ้นไปสูงเพื่อรองรับความต้องการในลักษณะระยะเวลาสั้นและพลังงานสูงปลอมจากผู้ใช้ ในทางตรงกันข้ามตัวประเมินความต้องการจาก RF และจาก True demand จะไม่มีความเอนเอียงและไม่ทำให้กระแสไฟยกตัวสูงขึ้นมากนักทั้งสองอัลกอริทึม ส่งผลให้ในกรณีของตัวประเมินความต้องการจากผู้ใช้รถยนต์ไฟฟ้าหรือ User inputs นั้นเจอกับค่าต้นทุนความต้องการพลังงานไฟฟ้าที่สูงกว่า จึงมีผลกำไรที่น้อยลง

นอกจากนี้เมื่อเปรียบเทียบการหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึม พบว่าความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นส่งผลให้สถานีอัดประจุจ่ายพลังงานไฟฟ้าโดยรวมได้น้อยลงในอัลกอริทึม baseline ASA-PM โดยผลที่ว่านี้สามารถตรวจสอบได้จากรูปที่ 5-17 ซึ่งจะเห็นว่าเส้นการอัดประจุของ ASA-PM User Inputs และ ASA-PM RF ค่อยๆลดลงก่อนกำหนดเมื่อเทียบกับเส้นการอัดประจุของ ASA-PM True demand แต่ในกรณีของอัลกอริทึมที่นำเสนอ ASA-PM-Feedback นั้นพบว่าผลจากความไม่แน่นอนส่งผลน้อยลง ทำให้เส้นการอัดประจุมีความต่อเนื่องและสามารถจ่ายพลังงานไฟฟ้าได้มากขึ้น การที่สามารถจ่ายพลังงานไฟฟ้าได้มากขึ้นส่งผลดีทำให้ผู้ใช้รถยนต์ไฟฟ้าได้รับพลังงานมากขึ้นและสถานีอัดประจุก็ได้รับรายได้มากขึ้น ซึ่งสามารถพิจารณาได้จากรูปที่ 5-18

สรุปโดยรวมแล้วสำหรับสถานี **Caltech** หากทำการใช้ความต้องการจากผู้ใช้โดยตรงกับ อัลกอริทึมที่ไม่รองรับความไม่แน่นอนจะทำให้สถานีอัดประจุได้กำไรอยู่ที่ประมาณ \$471.79 ต่อเดือน แต่ถ้าหากทำการใช้ความต้องการจากโมเดลการเรียนรู้กับอัลกอริทึมที่รองรับความไม่แน่นอนหรือก็คือ End-to-end framework จะทำให้สถานีอัดประจุได้กำไรที่มากขึ้นเป็น \$739.46 ต่อเดือน ซึ่งเพิ่มขึ้นถึง 56.73%


ตารางที่ 5-10 (**Caltech**) ผลลัพธ์การ Simulation (BL หมายถึง Baseline)

Demand Estimators	Algorithms	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Profit (\$)
True demand	ASA-PM (BL)	5,934.73	98.45	172.04	742.00
Baseline: User inputs	ASA-PM (BL)	5,934.73	90.45	223.77	471.79
	ASA-PM-Feedback (ours)	5,934.73	98.61	217.94	597.34
Proposed: RF	ASA-PM (BL)	5,934.73	81.87	160.00	563.80
	ASA-PM-Feedback (ours)	5,934.73	96.37	164.13	739.46



รูปที่ 5-16 (**Caltech**) Revenue breakdown ของสถานีอัดประจุ

d




รูปที่ 5-17 (Caltech) Actual charge on Wednesday, 2 Oct, 2019

(ในรูปจะแสดงถึงพลังงานซึ่งมีค่าเท่ากับแรงดันคูณด้วยกระแส หรือ

$$Power (W) = Voltage (V) \times Current (A)$$

โดยที่ในที่นี่ Voltage = 208V หรือคือย่านแรงดันจ่ายไฟโดยทั่วไป)



รูปที่ 5-18 (Caltech) Percentage of demand met

5.2.3 สถานี MEA: Mall

ตารางที่ 5-11 แสดงผลลัพธ์ของการ Simulation ของสถานี Mall ระหว่างสองตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า: True demand และ ML model กับสองอัลกอริทึมในการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุ: baseline ASA-PM และ ASA-PM-Feedback ตามที่ได้อธิบายไปในหัวข้อ 4.2 ในกรณีของตัวประเมินความต้องการจาก True demand ที่เป็นความต้องการที่เกิดขึ้นจริงจะไม่มีค่าจำเป็นที่ต้องรองรับความไม่แน่นอนดังนั้นแล้วจะจับคู่กับ baseline ASA-PM เท่านั้นและผลลัพธ์จะเป็นตัวแทนถึง best-case scenario ที่สามารถเกิดขึ้นได้ นอกจากนี้จะมีการเพิ่มเติมสถานการณ์การอัดประจุที่ไม่มีการควบคุมด้วยเพื่อให้เป็นตัวเปรียบเทียบ ในกรณีที่แย่ที่สุดของสถานีนี้ ตัวประเมินความต้องการจาก ML model ของสถานี Mall จะใช้ RF จากผลลัพธ์ของหัวข้อ 5.1.3 ทุกสถานการณ์ของสถานี Mall จะใช้ค่า Peak hint 62 A ตามที่ได้ อธิบายไปในหัวข้อ 4.2.1 ผลลัพธ์ในตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการ Simulation ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2022

ทั้งนี้ เนื่องจากเครื่องมือ Simulation ที่ใช้มีข้อจำกัดรองรับกับเฉพาะเครื่องอัดประจุหนึ่งเฟส แต่ในชุดข้อมูลของการไฟฟ้านครหลวงจะมีรถยนต์ไฟฟ้าสามเฟสรวมอยู่ด้วยตามที่ได้กล่าวในหัวข้อ 4.2.1 ดังนั้นแล้วผลการ Simulation จะมีบางธุรกรรมการอัดประจุที่ไม่สามารถอัดประจุได้อย่างเต็มที่ ส่งผลให้ปริมาณพลังงานไฟฟ้าที่จ่ายโดยรวมทั้งหมดของสถานีจะมีค่าน้อยกว่าความเป็นจริง

รายได้, ต้นทุนพลังงานค่าไฟฟ้าต่อหน่วย, ต้นทุนค่าความต้องการพลังไฟฟ้า และผลกำไรของ สถานีอัดประจุจะแสดงดังรูปที่ 5-19


จากผลการ Simulation ตัวประเมินความต้องการจาก RF และจาก True demand จะไม่มี ความเอนเอียงจึงไม่ทำให้กระแสพิคกตัวสูงขึ้นมากนักในทั้งสองอัลกอริทึมการหาค่าที่เหมาะสม และ เมื่อเปรียบเทียบการหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึม พบว่าความไม่แน่นอนของความต้องการ ของผู้ใช้รถยนต์ไฟฟ้านั้นส่งผลให้สถานีอัดประจุจ่ายพลังงานไฟฟ้าโดยรวมได้น้อยลงในอัลกอริทึม baseline ASA-PM โดยผลที่ว่านี้สามารถตรวจสอบได้จากรูปที่ 5-20 ซึ่งจะเห็นได้ว่าเส้นการอัดประจุ ของ ASA-PM RF ค่อยๆลดลงก่อนกำหนดเมื่อเทียบกับเส้นการอัดประจุของ ASA-PM True demand แต่ในกรณีของอัลกอริทึมที่นำเสนอ ASA-PM-Feedback นั้นพบว่าผลจากความไม่แน่นอน ส่งผลน้อยลง ทำให้เส้นการอัดประจุมีความต่อเนื่องและสามารถจ่ายพลังงานไฟฟ้าได้มากขึ้น การที่ สามารถจ่ายพลังงานไฟฟ้าได้มากขึ้นส่งผลดีทำให้ผู้ใช้รถยนต์ไฟฟ้าได้รับพลังงานมากขึ้นและสถานีอัด ประจุก็ได้รับรายได้มากขึ้น ซึ่งสามารถพิจารณาได้จากรูปที่ 5-21

ในกรณีของผลลัพธ์ที่แย่ที่สุดอันได้แก่การที่ไม่มีการควบคุมการอัดประจุนั้น จะเห็นได้ว่า ค่ากระแสพิคกค่าที่สูงกว่ากรณีการหาค่าที่เหมาะสมที่สุด เป็นเหตุให้ค่าต้นทุนความต้องการพลังไฟฟ้า สูงจึงมีผลกำไรที่น้อยลง


สรุปโดยรวมแล้วสำหรับสถานี Mall หากไม่ทำการควบคุมการอัดประจุจะทำให้สถานีอัดประจุได้กำไรอยู่ที่ประมาณ \$100.06 ต่อเดือน แต่ถ้าหากทำการใช้ความต้องการจากโมเดลการความไม่เรียนรู้กับอัลกอริทึมที่รองรับความไม่แน่นอนหรือก็คือ End-to-end framework จะทำให้สถานีอัดประจุได้กำไรที่มากขึ้นเป็น \$132.50 ต่อเดือน ซึ่งเพิ่มขึ้นถึง 32.42%

ตารางที่ 5-11 (Mall) ผลลัพธ์การ Simulation (BL หมายถึง Baseline)


Demand Estimators	Algorithms	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Profit (\$)
True demand	ASA-PM (BL)	2,343.82	91.66	63.88	140.10
-	Uncontrol	2,343.82	92.76	96.00	100.06
Proposed: RF	ASA-PM (BL)	2,343.82	78.42	63.51	108.02
	ASA-PM-Feedback (ours)	2,343.82	89.24	64.17	132.50



รูปที่ 5-19 (Mall) Revenue breakdown ของสถานีอัดประจุ



รูปที่ 5-20 (Mall) Actual charge on Friday, 7 Oct, 2022
 (ในรูปจะแสดงถึงพลังงานซึ่งมีค่าเท่ากับแรงดันคูณด้วยกระแส หรือ
 $Power (W) = Voltage (V) \times Current (A)$
 โดยที่ในที่นี่ Voltage = 208V หรือคือย่านแรงดันจ่ายไฟโดยทั่วไป)



รูปที่ 5-21 (Mall) Percentage of demand met

5.2.4 สถานี MEA: **University**

ตารางที่ 5-12 แสดงผลลัพธ์ของการ Simulation ของสถานี **University** ระหว่างสองตัวประเมินความต้องการของผู้ใช้รถยนต์ไฟฟ้า: True demand และ ML model กับสองอัลกอริทึมในการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุ: baseline ASA-PM และ ASA-PM-Feedback ตามที่ได้อธิบายไปในหัวข้อ 4.2 ในกรณีของตัวประเมินความต้องการจาก True demand ที่เป็นความต้องการที่เกิดขึ้นจริงจะไม่มีค่าจำเป็นที่ต้องรองรับความไม่แน่นอนดังนั้นแล้วจะจับคู่กับ baseline ASA-PM เท่านั้นและผลลัพธ์จะเป็นตัวแทนถึง best-case scenario ที่สามารถเกิดขึ้นได้ นอกจากนี้จะมีการเพิ่มเติมสถานการณ์การอัดประจุที่ไม่มีการควบคุมด้วยเพื่อให้เป็นตัวเปรียบเทียบในกรณีที่แย่ที่สุดของสถานีนี้ ตัวประเมินความต้องการจาก ML model ของสถานี **University** จะใช้ RF จากผลลัพธ์ของหัวข้อ 5.1.4 ทุกสถานการณ์ของสถานี **University** จะใช้ค่า Peak hint 53 A ตามที่ได้อธิบายไปในหัวข้อ 4.2.1 ผลลัพธ์ในตารางจะแสดงถึงค่าเฉลี่ยของผลลัพธ์ของเดือนที่ทำการ Simulation ซึ่งได้แก่เดือน ตุลาคม, พฤศจิกายน และธันวาคมของปี ค.ศ. 2022

ทั้งนี้ เนื่องจากเครื่องมือ Simulation ที่ใช้มีข้อจำกัดรองรับกับเฉพาะเครื่องอัดประจุหนึ่งเฟส แต่ในชุดข้อมูลของการไฟฟ้านครหลวงจะมีรถยนต์ไฟฟ้าสามเฟสรวมอยู่ด้วยตามที่ได้กล่าวในหัวข้อ 4.2.1 ดังนั้นแล้วผลการ Simulation จะมีบางธุรกรรมการอัดประจุที่ไม่สามารถอัดประจุได้อย่างเต็มที่ ส่งผลให้ปริมาณพลังงานไฟฟ้าที่จ่ายโดยรวมทั้งหมดของสถานีจะมีค่าน้อยกว่าความเป็นจริง

รายได้, ต้นทุนพลังงานค่าไฟฟ้าต่อหน่วย, ต้นทุนค่าความต้องการพลังงานไฟฟ้า และผลกำไรของสถานีอัดประจุจะแสดงดังรูปที่ 5-22

จากผลการ Simulation ตัวประเมินความต้องการจาก RF และจาก True demand จะไม่มีค่าความเอนเอียงจึงไม่ทำให้กระแสพิคกตัวสูงขึ้นมากนักในทั้งสองอัลกอริทึมการหาค่าที่เหมาะสม และเมื่อเปรียบเทียบการหาค่าที่เหมาะสมที่สุดทั้งสองอัลกอริทึม พบว่าความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้านั้นส่งผลให้สถานีอัดประจุจ่ายพลังงานไฟฟ้าโดยรวมได้น้อยลงในอัลกอริทึม baseline ASA-PM โดยผลที่ว่ามันสามารถตรวจสอบได้จากรูปที่ 5-23 ซึ่งจะเห็นได้ว่าเส้นการอัดประจุของ ASA-PM RF ค่อยๆลดลงก่อนกำหนดเมื่อเทียบกับเส้นการอัดประจุของ ASA-PM True demand แต่ในกรณีของอัลกอริทึมที่นำเสนอ ASA-PM-Feedback นั้นพบว่าผลจากความไม่แน่นอนส่งผลน้อยลง ทำให้เส้นการอัดประจุมีความต่อเนื่องและสามารถจ่ายพลังงานไฟฟ้าได้มากขึ้น การที่สามารถจ่ายพลังงานไฟฟ้าได้มากขึ้นส่งผลดีทำให้ผู้ใช้รถยนต์ไฟฟ้าได้รับพลังงานมากขึ้นและสถานีอัดประจุก็ได้รับรายได้มากขึ้น ซึ่งสามารถพิจารณาได้จากรูปที่ 5-24


ในกรณีของผลลัพธ์ที่แย่ที่สุดอันได้แก่การที่ไม่มีการควบคุมการอัดประจุนั้น จะเห็นได้ว่าค่ากระแสพิคกค่าที่สูงกว่ากรณีการหาค่าที่เหมาะสมที่สุด เป็นเหตุให้ค่าต้นทุนความต้องการพลังงานไฟฟ้าสูงเกินรายรับของสถานีถึงขั้นที่ว่าสถานี **University** ขาดทุน อย่างไรก็ตามจากที่ได้กล่าวไปในหัวข้อ

4.2.1 ในความเป็นจริงสถานี **University** จะไม่ได้มีการจ่ายค่าความต้องการพลังงานไฟฟ้าแต่อย่างใดจึงไม่ได้ขาดทุนจริง


สรุปโดยรวมแล้วสำหรับสถานี **University** หากไม่ทำการควบคุมการอัดประจุจะทำให้สถานีอัดประจุได้ขาดทุนอยู่ที่ประมาณ \$-4.86 ต่อเดือน แต่ถ้าหากทำการใช้ความต้องการจากโมเดลการความไม่เรียนรู้กับอัลกอริทึมที่รองรับความไม่แน่นอนหรือก็คือ End-to-end framework จะทำให้สถานีอัดประจุได้กำไรที่มากขึ้นเป็น \$67.10 ต่อเดือน ซึ่งเพิ่มขึ้นถึง 1,480.66%

ตารางที่ 5-12 (**University**) ผลลัพธ์การ Simulation (BL หมายถึง Baseline)

Demand Estimators	Algorithms	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Profit (\$)
True demand	ASA-PM (BL)	1,541.68	96.56	64.10	82.71
-	Uncontrol	1,541.68	98.94	136.18	-4.86
Proposed: RF	ASA-PM (BL)	1,541.68	81.00	63.57	58.72
	ASA-PM- Feedback (ours)	1,541.68	93.37	72.12	67.10



รูปที่ 5-22 (**University**) Revenue breakdown ของสถานีอัดประจุ




รูปที่ 5-23 (University) Actual charge on Friday, 28 Oct, 2022

(ในรูปจะแสดงถึงพลังงานซึ่งมีค่าเท่ากับแรงดันคูณด้วยกระแส หรือ

$$\text{Power (W)} = \text{Voltage (V)} \times \text{Current (A)}$$

โดยที่ในที่นี่ Voltage = 208V หรือคือย่านแรงดันจ่ายไฟโดยทั่วไป)



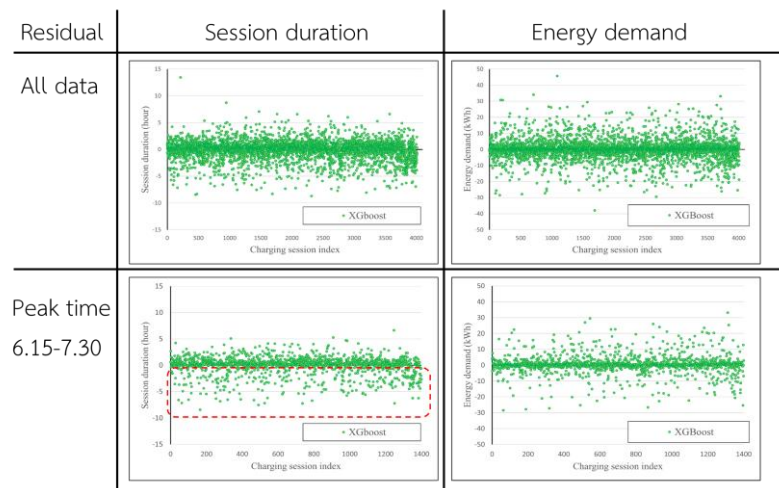
รูปที่ 5-24 (University) Percentage of demand met

5.3 วิเคราะห์ผลการทดลองเพิ่มเติม

5.3.1 วิเคราะห์ผลการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าของสถานี JPL ในช่วงเวลาที่มีผู้ใช้งานเป็นจำนวนมาก

จากรูปที่ 5-25 ที่แสดงถึง Residual ของการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าในช่วงเวลาทั้งหมดกับช่วงเวลาที่ผู้ใช้งานเป็นจำนวนมาก พบว่าในช่วงที่ผู้ใช้งานเป็นจำนวนมากนั้นการทำนายระยะเวลาในการเชื่อมต่อ (รูปที่ 5-25 (ล่างซ้าย)) จะมีแนวโน้มผิดพลาดไปในการทำนายมากเกินไปกว่าความเป็นจริง ในขณะที่การทำนายพลังงานไฟฟ้าที่ต้องการในช่วงที่ผู้ใช้งานเป็นจำนวนมากไม่ได้มีแนวโน้มไปในทิศทางหนึ่งมากนัก

จากนั้นจึงทำการพิจารณาถึงสาเหตุที่โมเดลทำนายระยะเวลามากเกินไปกว่าความเป็นจริงในช่วงเวลาที่ผู้ใช้เป็นจำนวนมาก โดยการพิจารณาจากค่าที่แท้จริงกับค่าจากการทำนายในช่วงเวลา 5 วันของผู้ใช้ทั้งหมดแสดงโดยรูปที่ 5-26 - รูปที่ 5-30 พบว่าในบางช่วงโมเดลมีการทำนายเกินอย่างมากในลักษณะครั้งต่อครั้ง กล่าวคือโมเดลทำนายระยะเวลาประมาณ 6-10 ชั่วโมงแต่ค่าระยะเวลาที่แท้จริงอยู่ที่ประมาณ 1-4 ชั่วโมง ซึ่งพิจารณาได้ว่าความต่างนี้มาจากการที่ผู้ใช้รถยนต์ออกจากที่ทำงานเวลาประมาณเที่ยงโดยที่เป็นไปได้ว่าอาจจะทำงานเพียงแค่วันหรือมีการนำรถออกไปรับประทานอาหารเที่ยง ซึ่งเพียงแค่อัฒนุสรกรรมการอัดประจุจะไม่สามารถระบุได้ ทำให้โมเดลไม่สามารถทำนายได้อย่างถูกต้อง




รูปที่ 5-25 Residual ของสถานี JPL

ของระยะเวลาในการเชื่อมต่อจากช่วงเวลาทั้งหมด (บนซ้าย)


ของระยะเวลาพลังงานไฟฟ้าที่ต้องการจากช่วงเวลาทั้งหมด (บนขวา)

ของระยะเวลาในการเชื่อมต่อจากช่วงเวลาที่ผู้ใช้งานสูง (ล่างซ้าย)


ของพลังงานไฟฟ้าที่ต้องการจากช่วงเวลาที่ผู้ใช้งานสูง (ล่างขวา)




รูปที่ 5-26 (JPL) ค่าที่แท้จริงกับค่าจากการทำนายของระยะเวลาในการเชื่อมต่อ
(Tuesday, 01 Oct, 2019)




รูปที่ 5-27 (JPL) ค่าที่แท้จริงกับค่าจากการทำนายของระยะเวลาในการเชื่อมต่อ
(Wednesday, 02 Oct, 2019)



รูปที่ 5-28 (JPL) ค่าที่แท้จริงกับค่าจากการทำนายของระยะเวลาในการเชื่อมต่อ
(Thursday, 03 Oct, 2019)



รูปที่ 5-29 (JPL) ค่าที่แท้จริงกับค่าจากการทำนายของระยะเวลาในการเชื่อมต่อ
(Friday, 04 Oct, 2019)

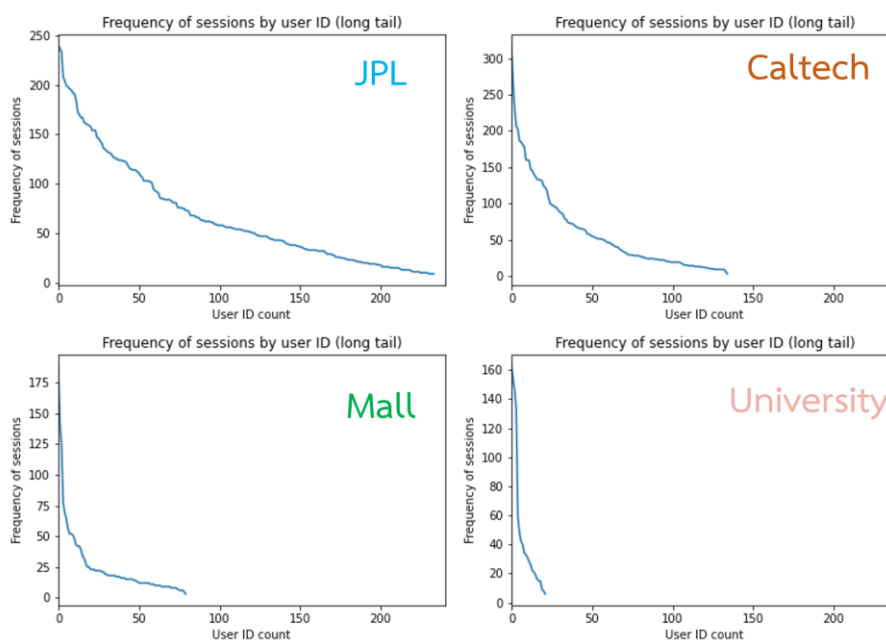


รูปที่ 5-30 (JPL) ค่าที่แท้จริงกับค่าจากการทำนายของระยะเวลาในการเชื่อมต่อ

5.3.2 วิเคราะห์ประสิทธิภาพของโมเดลการเรียนรู้ของสถานีการไฟฟ้านครหลวง

จากที่ผลลัพธ์ของโมเดลการเรียนรู้ในหัวข้อ 5.1.3 และหัวข้อ 5.1.4 มีความแม่นยำน้อยกว่าค่าเฉลี่ยจากธุรกรรมในอดีตของผู้ใช้ในการทำนายของสถานี **Mall** และ **University** นั้น พบว่าเมื่อทำการตรวจสอบข้อมูลจำนวนผู้ใช้กับจำนวนธุรกรรมของแต่ละคนออกมาเป็นกราฟ Long tail ดังแสดงตามรูปที่ 5-31

จากรูปพบว่าสถานี **Mall** และ **University** นั้นธุรกรรมการอัดประจุเกือบทั้งหมดเป็นของผู้ใช้รถยนต์ไฟฟ้าไม่กี่คน ดังนั้นแล้วจึงทำให้การใช้ค่าเฉลี่ยจากธุรกรรมในอดีตของผู้ใช้ในการทำนายความต้องการเพียงพอสำหรับสองสถานีนี้



รูปที่ 5-31 กราฟ Long tail ของผู้ใช้กับจำนวนธุรกรรมของแต่ละคนของสถานี **JPL** (บนซ้าย)

Caltech (บนขวา) **Mall** (ล่างซ้าย) **University** (ล่างขวา)

5.3.3 การทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าอย่างง่ายจากค่าสถิติ

นอกเหนือจากการใช้โมเดลการเรียนรู้ในการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าแล้ว ในอีกทางเลือกหนึ่งคือการใช้ค่าสถิติเช่นค่าเฉลี่ยในการทำนายแทน โดยในหัวข้อนี้จะใช้ค่าสถิติที่หลากหลายแทนในการทำนายและเปรียบเทียบกับผลจากโมเดลการเรียนรู้กับสถานี JPL ผลลัพธ์ในการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการโดยค่าสถิติเปรียบเทียบกับโมเดลการเรียนรู้จะแสดงดังตารางที่ 5-13 และตารางที่ 5-14 ตามลำดับ

จากผลลัพธ์ที่แสดงในตารางพบว่าค่าการทำนายระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการนั้น โมเดลการเรียนรู้มีความแม่นยำกว่าการใช้ค่าทางสถิติ



ตารางที่ 5-13 (JPL) ผลลัพธ์การทำนายระยะเวลาในการเชื่อมต่อด้วยค่าทางสถิติ
(หน่วยนาที, ตัวหนาหมายถึงผู้ชนะ)

Regression Model	RMSE	MAE	SMAPE(%)	R ²
ค่าสถิติ				
ค่าเฉลี่ยจากรยะเวลาในอดีตของผู้ใช้: Mean of session duration by user id	143.22	105.64	15.43	0.45
ค่าเฉลี่ยจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Mean of session duration by user id and period	120.68	81.63	11.79	0.61
ค่าเฉลี่ยเคลื่อนที่ 3 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้: Moving average 3 of session duration by user id	153.28	110.28	16.06	0.37
ค่าเฉลี่ยเคลื่อนที่ 3 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 3 of session duration by user id and period	129.79	89.17	12.72	0.55
ค่าเฉลี่ยเคลื่อนที่ 5 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้: Moving average 5 of session duration by user id	148.20	107.05	15.53	0.41
ค่าเฉลี่ยเคลื่อนที่ 5 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 5 of session duration by user id and period	124.15	85.49	12.23	0.59
ค่าเฉลี่ยเคลื่อนที่ 7 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้: Moving average 7 of session duration by user id	145.23	105.44	15.35	0.44
ค่าเฉลี่ยเคลื่อนที่ 7 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 7 of session duration by user id and period	122.54	83.96	12.02	0.60
ค่าเฉลี่ยเคลื่อนที่ 10 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้: Moving average 10 of session duration by user id	143.46	104.14	15.19	0.45
ค่าเฉลี่ยเคลื่อนที่ 10 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 10 of session duration by user id and period	121.55	82.90	11.91	0.60
ค่ามัธยฐานจากรยะเวลาในอดีตของผู้ใช้ Median of session duration by user id	151.45	100.27	14.62	0.39
ค่ามัธยฐานจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา Median of session duration by user id and period	178.08	117.19	17.75	0.15
ค่ามัธยฐานเคลื่อนที่ 3 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ Moving median 3 of session duration by user id	162.34	110.20	16.18	0.29
ค่ามัธยฐานเคลื่อนที่ 3 ครั้งล่าสุดจากรยะเวลาในอดีตของผู้ใช้ในแต่ละช่วงเวลา Moving median 3 of session duration by user id and period	152.66	102.05	14.88	0.38
Proposed (ML models)				
XGBoost	109.18	73.31	10.72	0.68
RF	111.44	75.03	10.86	0.67
TabNet	114.16	75.85	11.08	0.65

ตารางที่ 5-14 (JPL) ผลลัพธ์การทำนายพลังงานไฟฟ้าที่ต้องการด้วยค่าทางสถิติ
(หน่วย kWh, ตัวหนาหมายถึงผู้ชนะ)

Regression Model	RMSE	MAE	SMAPE(%)	R ²
ค่าสถิติ				
ค่าเฉลี่ยจากพลังงานในอดีตของผู้ใช้: Mean of energy demand by user id	7.18	4.40	13.13	0.60
ค่าเฉลี่ยจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Mean of energy demand by user id and period	6.98	4.20	12.57	0.62
ค่าเฉลี่ยเคลื่อนที่ 3 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้: Moving average 3 of energy demand by user id	7.44	4.44	13.60	0.57
ค่าเฉลี่ยเคลื่อนที่ 3 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 3 of energy demand by user id and period	7.18	4.22	12.88	0.60
ค่าเฉลี่ยเคลื่อนที่ 5 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้: Moving average 5 of energy demand by user id	7.22	4.33	13.25	0.59
ค่าเฉลี่ยเคลื่อนที่ 5 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 5 of energy demand by user id and period	6.89	4.05	12.46	0.63
ค่าเฉลี่ยเคลื่อนที่ 7 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้: Moving average 7 of energy demand by user id	7.11	4.25	12.98	0.60
ค่าเฉลี่ยเคลื่อนที่ 7 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 7 of energy demand by user id and period	6.78	3.98	12.26	0.64
ค่าเฉลี่ยเคลื่อนที่ 10 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้: Moving average 10 of energy demand by user id	7.02	4.19	12.82	0.61
ค่าเฉลี่ยเคลื่อนที่ 10 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา: Moving average 10 of energy demand by user id and period	6.69	3.94	12.16	0.65
ค่ามัธยฐานจากพลังงานในอดีตของผู้ใช้ Median of energy demand by user id	7.43	4.30	13.05	0.57
ค่ามัธยฐานจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา Median of energy demand by user id and period	8.36	4.72	14.77	0.45
ค่ามัธยฐานเคลื่อนที่ 3 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ Moving median 3 of energy demand by user id	7.72	4.45	13.57	0.53
ค่ามัธยฐานเคลื่อนที่ 3 ครั้งล่าสุดจากพลังงานในอดีตของผู้ใช้ในแต่ละช่วงเวลา Moving median 3 of energy demand by user id and period	7.79	4.44	13.56	0.52
Proposed (ML models)				
XGBoost	6.36	3.82	11.85	0.68
RF	6.37	3.83	11.91	0.68
TabNet	6.56	4.03	12.81	0.66

บทที่ 6

สรุปผลงานวิจัยและงานในอนาคต (Conclusion and future work)

6.1 สรุปผลงานวิจัย

ในงานวิจัยนี้ได้นำเสนอ End-to-end framework ที่เป็นการทำงานรวมกันของโมเดลการเรียนรู้ในการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้า กับการหาค่าที่เหมาะสมที่สุดในการจัดกำหนดการอัดประจุของรถยนต์ไฟฟ้า และทำการทดลองกับข้อมูลธุรกรรมจริงของสถานีอัดประจุสถานีด้วยกัน

ในการทำนายความต้องการของผู้ใช้รถยนต์ไฟฟ้าพบว่าข้อมูลช่วงเวลาเป็นส่วนประกอบที่สำคัญและมีความสมควรที่จะถูกรวมอยู่ในการสร้างอินพุต Feature ให้แก่โมเดลการเรียนรู้ เพื่อที่จะให้โมเดลจับพฤติกรรมของผู้ใช้รถยนต์ไฟฟ้าได้ดียิ่งขึ้น ผลลัพธ์การทำนายจากชุดข้อมูล ACN พบว่าโมเดลการเรียนรู้ทั้งหมดมีความแม่นยำที่เหนือกว่าความต้องการที่ผู้ใช้เป็นผู้ให้เอง โมเดลการเรียนรู้ที่ชนะในชุดข้อมูล ACN ยังคงเป็นโมเดลรูปแบบต้นไม้อันได้แก่ โมเดล XGBoost สำหรับสถานี **JPL** ด้วยค่า **SMAPE 10.72%** และ **11.85%** ในการทำนายระยะเวลาและพลังงานไฟฟ้าตามลำดับ และโมเดล RF สำหรับสถานี **Caltech** ด้วยค่า **SMAPE 15.04%** และ **16.64%** ในการทำนายระยะเวลาและพลังงานไฟฟ้าตามลำดับ อย่างไรก็ตามสำหรับสถานีจากการไฟฟ้านครหลวงนั้นในการทำนายบางค่าการใช้ค่าทางสถิติจะมีความแม่นยำที่เหนือกว่าโมเดลการเรียนรู้ เช่น สถานี **Mall** พบว่าโมเดล RF แม่นยำที่สุดในการทำนายระยะเวลาด้วยค่า **SMAPE 15.91%** แต่ค่าเฉลี่ยธุรกรรมในอดีตของผู้ใช้จะมีความแม่นยำกว่าในการทำนายพลังงานไฟฟ้า หรือสถานี **University** ที่พบว่าโมเดล RF จะแม่นยำเฉพาะการทำนายพลังงานไฟฟ้าด้วยค่า **SMAPE 18.08%** แต่ค่าเฉลี่ยธุรกรรมในอดีตของผู้ใช้ในแต่ละช่วงเวลาจะมีความแม่นยำกว่าในการทำนายระยะเวลา จากผลการวิเคราะห์เพิ่มเติมพบว่าสาเหตุที่โมเดลการเรียนรู้มีความแม่นยำที่น้อยกว่าในกรณีของสถานีจากการไฟฟ้านครหลวงนั้น พบว่าจำนวนธุรกรรมส่วนใหญ่นั้นเป็นของผู้ใช้จำนวนไม่กี่คน ดังนั้นแล้วจึงทำให้การใช้ค่าทางสถิติในการทำนายความต้องการเพียงพอสำหรับสองสถานีนี้ นอกจากนี้การวิเคราะห์ด้วย Residual plot พบว่า ความต้องการจากผู้ใช้โดยตรงมักมีความเอนเอียงเป็นอย่างมาก ในขณะที่โมเดลการเรียนรู้จะไม่มีค่าเอนเอียงดังกล่าว

ในงานวิจัยได้มีการวิเคราะห์ผลที่จะเกิดขึ้นจากความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ ผลที่ตามมาคือได้มีการพัฒนาอัลกอริทึมการหาค่าที่เหมาะสมที่สุดดั้งเดิมที่มีชื่อว่า Adaptive Scheduling Algorithm ให้รองรับความไม่แน่นอนของค่าความต้องการของผู้ใช้ โดยการใช้ข้อมูลป้อนกลับและใช้พฤติกรรมของระบบบริหารจัดการแบตเตอรี่ของรถยนต์ที่เรียกว่า CC-CV ให้เป็นประโยชน์


ผลลัพธ์ที่ได้ของ End-to-end framework นั้นพบว่าจะทำให้สถานีอัดประจุได้รับผลกำไรที่มากขึ้น โดยสำหรับสถานีจากชุดข้อมูล ACN เมื่อเปรียบเทียบกับกรณีที่ใช้ความต้องการจากผู้เข้าร่วมกับอัลกอริทึมดั้งเดิม พบว่า End-to-end framework จะทำให้มีผลกำไรมากขึ้น **\$616.28 (เพิ่มขึ้น 27.18%)** และ **\$267.67 (เพิ่มขึ้น 56.73%)** ต่อเดือนสำหรับสถานี **JPL** และ **Caltech** ตามลำดับ และสำหรับสถานีจากชุดข้อมูลการไฟฟ้านครหลวงเมื่อเปรียบเทียบกับกรณีที่ไม่มีการควบคุมการอัดประจุซึ่งเป็นการใช้งานในปัจจุบันและเป็นรูปแบบทั่วไปในส่วนใหญ่ของสถานีอัดประจุ พบว่า End-to-end framework จะทำให้มีผลกำไรมากขึ้น **\$32.44 (เพิ่มขึ้น 32.42%)** และ **\$71.96 (เพิ่มขึ้น 1480.66%)** ต่อเดือนสำหรับสถานี **Mall** และ **University** ตามลำดับ

6.2 แนวทางงานวิจัยในอนาคต

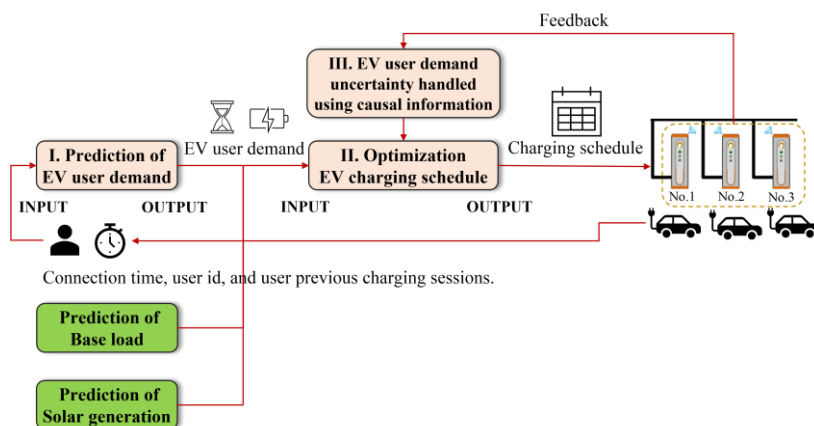
6.2.1 โหลดทั่วไป และพลังงานสะอาด

จากสมการ (3-5)-(3-6) ที่กล่าวถึงการค่า $L(t)$ โหลดไฟฟ้าทั่วไปในสถานี และ $G(t)$ ไฟฟ้าที่ผลิตได้จากโซลาร์เซลล์ ที่งานวิจัยนี้ได้ทำการละลายไว้เนื่องจากต้องการพิจารณาเฉพาะการใช้ไฟจากการอัดประจุรถยนต์ไฟฟ้าเท่านั้น แต่ทั้งนี้ในแง่ของสถานีอัดประจุที่ต้องการพิจารณาถึงค่าโหลดไฟฟ้าทั่วไปในสถานีและไฟฟ้าที่ผลิตได้จากโซลาร์เซลล์ร่วมด้วยซึ่งจะมีลักษณะดังรูปที่ 6-1

ซึ่งในกรณีนี้การหาค่าที่เหมาะสมที่สุดจะมีอุปสรรคเพิ่มเติมขึ้นมาได้แก่ โหลดไฟฟ้าทั่วไปในสถานีและไฟฟ้าที่ผลิตได้จากโซลาร์เซลล์ ซึ่งค่าทั้งสองค่านี้จะสามารถทราบได้จากมิเตอร์หรืออุปกรณ์วัดในเวลาปัจจุบันเท่านั้น แต่เนื่องจากว่าการหาค่าที่เหมาะสมที่สุดจะเป็นการหาค่ากำหนดการอัดประจุเวลาปัจจุบันจนถึงช่วงเวลาที่กำหนดในอนาคต ดังนั้นแล้วการหาค่าที่เหมาะสมที่สุดจะต้องทราบค่าในอนาคตของโหลดไฟฟ้าทั่วไปและค่าในอนาคตของไฟฟ้าที่ผลิตได้จากโซลาร์เซลล์ ซึ่งการที่จะทราบค่าในอนาคตได้นั้นจะต้องพึ่งการทำนายจากโมเดลการเรียนรู้ซึ่งแสดงได้ดังรูปที่ 6-2



รูปที่ 6-1 ตัวอย่างสถานีอัดประจุที่พิจารณาโหลดทั่วไปและโซลาร์เซลล์



รูปที่ 6-2 Framework ที่รวมการทำนายโหลดไฟฟ้าทั่วไปและการทำนายโซลาร์เซลล์

6.2.2 เครื่องอัดประจุรุ่นใหม่ และความสัมพันธ์ของเครื่องอัดประจุกับรถยนต์ไฟฟ้า

ในปัจจุบันเทคโนโลยีการออกแบบเครื่องอัดประจุได้มีการพัฒนาไปอย่างมาก จากเดิมเครื่องอัดประจुरुูปแบบ AC จะมีการออกแบบที่รองรับการจ่ายไฟเพียงแค่หนึ่งเฟสและกระแสสูงสุดที่จ่ายได้จะอยู่ที่ประมาณ 32 A ซึ่งในเครื่องมือ Simulation ACN Sim ที่ใช้งานในงานวิจัยนี้ได้ใช้เครื่องอัดประจุประเภทดังกล่าว อย่างไรก็ตามเครื่องอัดประจुरुูปแบบ AC ในปัจจุบันมีการพัฒนาให้รองรับการจ่ายไฟเพิ่มเติมในรูปแบบสามเฟส อีกทั้งยังมีการออกแบบที่เพิ่มความสามารถในการจ่ายไฟได้ถึง 64 A ซึ่งสามารถพิจารณาสรุปได้ตามตารางที่ 6-1

ความสัมพันธ์ของเครื่องอัดประจุกับรถยนต์ไฟฟ้าจะอยู่那儿จะมีลักษณะที่ว่า เครื่องอัดประจุเป็นอุปกรณ์ที่รองรับการจ่ายไฟ แต่กระแสที่ใช้งานจริงจะขึ้นอยู่กับการดึงกระแสของรถยนต์ไฟฟ้า พิจารณากรณีความสัมพันธ์ของเครื่องอัดประจุหนึ่งเฟสกับรถยนต์ไฟฟ้าได้ตามรูปที่ 6-3 เมื่อรถยนต์ไฟฟ้ามาทำการเชื่อมต่อกับเครื่องอัดประจุหนึ่งเฟสนี้จะได้ดึงกระแสได้เพียงแค่เฟสเดียวถึงแม้ว่ารถยนต์ไฟฟ้าจะเป็นประเภทสองเฟสหรือสามเฟสก็ตาม ในขณะที่เดียวกันถ้าหากเป็นเครื่องอัดประจุสามเฟสจะทำให้สามารถรองรับการดึงกระแสจากรถยนต์ไฟฟ้าได้ทั้งรูปแบบหนึ่ง, สอง หรือสามเฟสได้ดังแสดงดังรูปที่ 6-4 นอกจากนี้ถ้าเป็นกรณีที่เครื่องอัดประจุสามารถจ่ายกระแสสูงสุดได้ 64 A แต่รถยนต์ไฟฟ้าสามารถดึงกระแสได้เพียง 32 A จะทำให้เกิดกรณีดังรูปที่ 6-5 โดยรูปที่กล่าวมาทั้งหมดมาจากข้อมูลการอัดประจุจริงจากชุดข้อมูลของการไฟฟ้านครหลวง อนึ่งค่าสัญญาณควบคุมหรือ Pilot signal นั้นสำหรับเครื่องอัดประจุแบบสามเฟสจะไม่สามารถกำหนดแยกเฟสได้ หรือก็คือทุกเฟสจะต้องใช้ค่าเดียวกัน

จากที่กล่าวมาปัญหาที่พบจะมีดังนี้

1. จากรูปที่ 6-4 (กลาง) การอัดประจุของรถยนต์สองเฟสบางชนิดและรูปที่ 6-5 จะพบว่า มีช่องว่างระหว่างค่าสัญญาณควบคุมกับค่าดึงกระแสจริง หากการหาค่าที่เหมาะสมที่สุด

ไม่ทราบพฤติกรรมการดึงกระแสของรถยนต์ไฟฟ้าและทำการกำหนดให้ค่าสัญญาณควบคุมมีค่ามากเกินไปจะทำให้เกิดการสำรองกระแสไว้โดยเปล่าประโยชน์ กล่าวคือ ช่องว่างระหว่างค่าสัญญาณควบคุมกับค่าดึงกระแสจริง นี้ควรถูกโยกย้ายไปหารรถยนต์ไฟฟ้าคันอื่น


2. นอกจากที่ในกรณีทีกล่าวมาในข้อ 1 จะมีกรณีในรูปแบบที่คล้ายกันในตอนที่รถยนต์ไฟฟ้าเริ่มทำการอัดประจุในช่วง CV stage กล่าวคือหากพิจารณาจากรูปที่ 3-6 จะเห็นได้ว่าในช่วง CV stage นั้นจะมีช่องว่างระหว่างค่าสัญญาณควบคุมกับค่าดึงกระแสจริง เช่นเดียวกัน ซึ่งจะมีงานวิจัย [25] ที่เกี่ยวข้องกันกับช่องว่างระหว่างค่าสัญญาณควบคุมกับค่าดึงกระแสจริงนี้
3. สมการเงื่อนไขแสดงขอบข่ายที่เกี่ยวกับขีดจำกัดของอุปกรณ์ไฟฟ้าสมการที่ (3-12) จะพิจารณาขึ้นอยู่กับรูปแบบการเชื่อมต่อของเครื่องอัดประจุเนื่องจากเดิมเครื่องอัดประจุนั้นสามารถจ่ายไฟได้เฟสเดียว แต่ในกรณีที่เครื่องอัดประจุเป็นแบบสามเฟสจะทำให้สมการดังกล่าวใช้ไม่ได้เนื่องจากกระแสที่ดึงจริงจะขึ้นอยู่กับรถยนต์ไฟฟ้าว่าจะดึงหนึ่ง, สอง หรือสามเฟส
4. จากข้อ 3 ข้างบนทีกล่าวมานั้นจะพบว่าการหาค่าที่เหมาะสมที่สุดจะไม่ทราบได้ว่ารถยนต์ไฟฟ้าที่มาเชื่อมต่อนั้นจะดึงกระแสจริงในลักษณะหนึ่ง, สองหรือสามเฟส

แนวทางในการแก้ปัญหาทีกล่าวมาจะมีแนวคิดดังนี้


1. จะต้องทราบพฤติกรรมการดึงกระแสของรถยนต์ไฟฟ้าแต่ละรุ่น ทั้งค่ากระแสมากที่สุด, พฤติกรรมตอนอยู่ในช่วง CV stage และจำนวนเฟสที่รถยนต์ไฟฟ้าสามารถดึงกระแสเพื่อนำไปเป็นข้อมูลให้กับการหาค่าที่เหมาะสมที่สุด
2. ทำการเชื่อมโยงรุ่นของรถยนต์ไฟฟ้ากับ User id ของผู้ใช้รถยนต์ไฟฟ้า เมื่อผู้ใช้รถยนต์ไฟฟ้ารายนี้ทำการเชื่อมต่อกับเครื่องอัดประจุและทำการสั่งเริ่มอัดประจุผ่านแอปพลิเคชันมือถือ จะทำให้ระบบสามารถทราบได้ว่าเป็นผู้ใช้รถยนต์ไฟฟ้ารายใดซึ่งจะทำให้ทราบรุ่นของรถยนต์ไฟฟ้าและพฤติกรรมการดึงกระแสทันที
3. ทำการออกแบบสมการเงื่อนไขขอบข่ายที่เกี่ยวกับขีดจำกัดของอุปกรณ์ไฟฟ้าใหม่

ตารางที่ 6-1 เปรียบเทียบเครื่องอัดประจุในอดีตกับเครื่องอัดประจุในปัจจุบัน

List	Old (ACN)	New (MEA)
EV charger Supply phase (AC type)	1 phase	1 and 3 phase
EV charger Maximum supply current (AC type)	32 A	32 A and 64 A




รูปที่ 6-3 ความสัมพันธ์เครื่องอัดประจุหนึ่งเฟสกับรถยนต์ไฟฟ้า



รูปที่ 6-4 ความสัมพันธ์เครื่องอัดประจุสามเฟสกับรถยนต์ไฟฟ้าหนึ่งเฟส (บน)

ความสัมพันธ์เครื่องอัดประจุสามเฟสกับรถยนต์ไฟฟ้าสองเฟส (กลาง)

ความสัมพันธ์เครื่องอัดประจุสามเฟสกับรถยนต์ไฟฟ้าสามเฟส (ล่าง)




รูปที่ 6-5 ความสัมพันธ์เครื่องอัดประจุสามเฟสพิกัด 64 A กับรถยนต์ไฟฟ้าหนึ่งเฟสพิกัด 32 A

6.2.3 การประยุกต์ใช้กับการไฟฟ้า

การอัดประจุอัจฉริยะจากที่กล่าวมาในงานวิจัยนี้จะมองในมุมมองของผู้ให้บริการสถานีอัดประจุ แต่ถ้าหากมองในมุมมองของผู้ให้บริการไฟฟ้าอันได้แก่ การไฟฟ้านครหลวง และการไฟฟ้าภูมิภาคในประเทศไทย จะพบว่าการเติบโตของจำนวนผู้ใช้รถยนต์ไฟฟ้าที่กำลังเพิ่มขึ้นอย่างรวดเร็วจะส่งผลกระทบต่อระบบจำหน่ายเป็นอย่างมาก โดยที่พฤติกรรมการอัดประจุของที่อยู่อาศัยนั้นมักมีรูปแบบที่กระแสปีกสูงมากในช่วงเวลาประมาณ 18.00-20.00 ซึ่งเป็นช่วงเวลาที่ผู้คนเลิกงานแล้วกลับถึงบ้าน [26] เหตุการณ์จะทำให้หม้อแปลงจำหน่ายของการไฟฟ้าในปัจจุบันจะไม่สามารถรองรับความต้องการที่พร้อมกันนี้ได้และการลงทุนเพิ่มขนาดของหม้อแปลงจำหน่ายเพื่อรองรับความต้องการที่พร้อมกันนี้จะเป็นการลงทุนที่สูง ซึ่งการอัดประจุอัจฉริยะในงานวิจัยนี้สามารถนำมาประยุกต์ใช้ได้การแก้ปัญหาได้ กล่าวคือหากพิจารณาหมู่บ้านหนึ่งที่มีหม้อแปลงจำหน่ายจ่ายไฟฟ้าให้กับบ้านทุกหลังและลูกบ้านมีการติดตั้งเครื่องอัดประจุดังรูปที่ 6-6 จะพบว่ามัลักษณะรูปแบบคล้ายคลึงกับสถานีอัดประจุเลยทีเดียว แต่ทั้งนี้สิ่งที่จะแตกต่างกันและต้องพิจารณาเพิ่มเติมในการนำมาประยุกต์ใช้จะมีดังนี้

1. ข้อมูลพฤติกรรมการอัดประจุจะเป็นพฤติกรรมในรูปแบบของบ้านที่อยู่อาศัย จะต้องทำการหาและศึกษาข้อมูลดังกล่าว
2. การใช้ไฟฟ้าจะไม่ได้มีเพียงแค่การใช้ไฟของเครื่องอัดประจุ แต่จะมีการใช้ไฟปกติทั่วไปของบ้านที่อยู่อาศัยหรือเรียกว่าโหลดทั่วไปรวมอยู่ด้วย ซึ่งจะต้องนำมาพิจารณาร่วมกับการหาค่าที่เหมาะสมที่สุด ซึ่งได้อธิบายไปแล้วในหัวข้อ 6.2.1



รูปที่ 6-6 ตัวอย่างลักษณะของการจ่ายไฟของหมู่บ้าน

6.2.4 การทำนายความต้องการของผู้ใช้ให้ Underpredicted หรือ Overpredicted

ในงานวิจัยนี้ได้ทำการทำนายในลักษณะทั่วไปหรือคือ ให้น้ำหนักในการทำนายความต้องการของผู้ใช้ที่เท่ากัน ไม่ได้ทำไปในการทำนายในลักษณะ Underpredicted หรือ Overpredicted

ยกตัวอย่างเช่นค่าระยะเวลาในการเชื่อมต่อนั้น เราสามารถให้น้ำหนัก (weight) ของ Loss function ไปในลักษณะ Underpredicted ได้ เพื่อให้ผลลัพธ์เอนเอียงไปในการทำนายระยะเวลาที่น้อย แต่ทั้งนี้ทั้งนั้นจะต้องพิจารณาถึงผลลัพธ์ที่จะเกิดขึ้นและตามมาก่อนการออกแบบและเลือกจะให้ค่าระยะเวลาในการเชื่อมต่อและพลังงานไฟฟ้าที่ต้องการนั้นค่าไหนจะทำนายน้อยไปหรือมากไป

สิ่งที่ต้องพิจารณาเบื้องต้นได้แก่

1. การเลือกให้ทำนายน้อยไปหรือมากไปนั้นจะส่งผลกระทบต่อกลุ่มของความต้องการ ซึ่งสุดท้ายแล้วอาจจะไม่ได้สะท้อนถึงผลลัพธ์ที่ดีขึ้นของการหาค่าที่เหมาะสมที่สุด
2. การเลือกให้ทำนายค่าระยะเวลาที่น้อยไป หรือทำนายค่าพลังงานไฟฟ้าที่ต้องการมากไป อาจส่งผลให้การหาค่าที่เหมาะสมที่สุดยากขึ้นเพื่อรองรับพลังงานที่ต้องการที่เพิ่มขึ้นในเวลาที่สั้นลง
3. การเลือกให้ทำนายค่าความต้องการที่น้อยไป จะยังมีหัวข้อ 3.4 โมดูลรองรับความไม่แน่นอนของความต้องการของผู้ใช้รถยนต์ไฟฟ้าช่วยตรวจสอบในกรณีที่ทำนายน้อยไป เมื่อเวลาถึงค่าที่ทำนาย หรือพลังงานไฟฟ้าที่ได้รับถึงค่าที่ทำนาย

บทที่ 7 ภาคผนวก

7.1 ผลลัพธ์ของการ Offline Scheduling เพื่อหาค่า Peak hint

7.1.1 สถานี ACN: **JPL**

ตารางที่ 7-1 (**JPL**) ผลลัพธ์ของการ Offline scheduling เพื่อหาค่า Peak hint

Month	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Revenue (\$)	Demand charge (\$)	Energy cost (\$)	Profit (\$)
Jan	19,757.64	99.99	429.29	5,926.46	1,384.92	1,521.81	3,019.73
Feb	18,977.05	99.91	485.31	5,687.85	1,565.66	1,457.39	2,664.80
Mar	20,819.26	99.88	448.20	6,238.11	1,445.94	1,573.25	3,218.92
Apr	22,336.77	99.58	467.09	6,673.18	1,506.86	1,710.96	3,455.36
May	23,126.65	99.99	450.70	6,937.17	1,454.00	1,775.61	3,707.55
Jun	20,033.75	100.00	535.89	6,010.13	1,728.84	2,749.17	1,532.12
Jul	21,415.38	100.00	596.70	6,424.58	1,925.00	2,819.70	1,679.87
Aug	21,484.66	100.00	548.72	6,445.40	1,770.23	2,936.89	1,738.29
Sep	19,872.28	100.00	516.39	5,961.64	1,665.93	2,753.71	1,542.00
Average	20,869.27	99.93	497.59	6,256.06	1,605.26	2,144.28	2,506.52

7.1.2 สถานี ACN: **Caltech**

ตารางที่ 7-2 (**Caltech**) ผลลัพธ์ของการ Offline scheduling เพื่อหาค่า Peak hint

Month	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Revenue (\$)	Demand charge (\$)	Energy cost (\$)	Profit (\$)
Jan	10,210.99	99.19	184.32	3,038.50	594.64	754.14	1,689.72
Feb	9,296.84	99.79	183.47	2,783.10	591.90	693.64	1,497.56
Mar	8,900.52	99.77	153.97	2,663.92	496.72	651.79	1,515.41
Apr	8,801.33	99.57	149.63	2,629.01	482.70	651.94	1,494.36
May	8,433.20	99.19	148.94	2,509.39	480.49	627.54	1,401.35
Jun	7,191.65	99.89	152.02	2,155.17	490.42	951.23	7,13.52
Jul	6,607.18	99.95	145.95	1,981.12	470.85	874.73	6,35.53
Aug	7,300.74	99.87	160.00	2,187.36	516.17	1029.98	6,41.21
Sep	7,308.30	99.95	181.11	2,191.44	584.28	1023.60	5,83.56
Average	8,227.86	99.68	162.16	2,459.89	523.13	806.51	1,130.25

7.1.3 สถานี MEA: **Mall**

ตารางที่ 7-3 (**Mall**) ผลลัพธ์ของการ Offline scheduling เพื่อหาค่า Peak hint

Month	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Revenue (\$)	Demand charge (\$)	Energy cost (\$)	Profit (\$)
Jan	2,031.04	92.90	64.00	415.13	82.00	210.86	122.26
Feb	1,235.06	96.85	38.14	263.15	48.86	135.42	78.87
Mar	2,193.95	93.34	50.95	450.55	65.29	237.02	148.24
Apr	2,474.94	90.66	64.00	493.62	82.00	254.84	156.78
May	2,179.40	94.67	64.00	453.92	82.00	231.42	140.51
Jun	2,502.46	94.57	64.00	520.63	82.00	271.68	166.95
Jul	2,391.05	96.86	63.98	509.54	81.97	262.53	165.04
Aug	2,951.83	95.32	89.06	619.04	114.11	323.02	181.92
Sep	2,743.81	91.98	64.00	555.25	82.00	289.82	183.43
Average	2,300.39	94.13	62.46	475.65	80.03	246.29	149.33


7.1.4 สถานี MEA: **University**

ตารางที่ 7-4 (**University**) ผลลัพธ์ของการ Offline scheduling เพื่อหาค่า Peak hint


Month	Total energy requested (kWh)	%Energy delivered	Peak current (A)	Revenue (\$)	Demand charge (\$)	Energy cost (\$)	Profit (\$)
Jan	474.71	86.16	32.00	89.98	41.00	48.42	0.56
Feb	1081.16	98.88	62.34	235.20	79.88	122.86	32.46
Mar	1060.91	99.03	61.94	231.14	79.36	119.86	31.92
Apr	601.02	97.36	43.91	128.74	56.26	71.48	0.99
May	845.22	97.42	56.55	181.15	72.46	94.86	13.83
Jun	772.92	98.74	52.45	167.90	67.20	91.63	9.07
Jul	895.02	98.35	51.37	193.66	65.82	99.49	28.35
Aug	1240.48	97.15	54.41	265.14	69.71	127.33	68.09
Sep	1246.54	97.94	62.22	268.58	79.72	137.30	51.57
Average	913.11	96.78	53.02	195.72	67.93	101.47	26.32

7.2 การกระจายตัวของข้อมูลสถานี Caltech, Mall, และ University


7.2.1 สถานี ACN: Caltech



รูปที่ 7-1 (Caltech) เวลาในการเชื่อมต่อ (ซ้าย) เวลาในการเสร็จสิ้นการเชื่อมต่อ (ขวา)

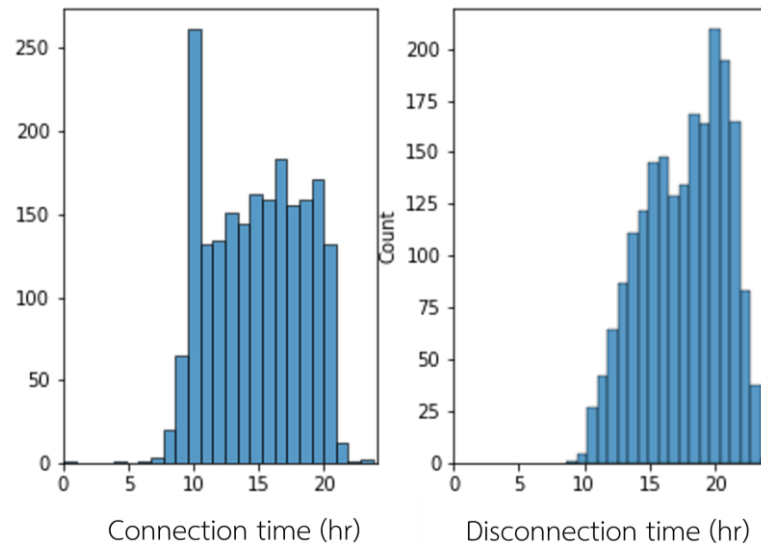


รูปที่ 7-2 (Caltech) ระยะเวลาในการเชื่อมต่อ (ซ้าย) พลังงานไฟฟ้าที่ต้องการ (ขวา)




รูปที่ 7-3 (Caltech) ระยะเวลาในการเชื่อมต่อในแต่ละช่วงเวลา (ซ้าย)
พลังงานไฟฟ้าที่ต้องการในแต่ละช่วงเวลา (ขวา)


7.2.2 สถานี MEA: Mall



รูปที่ 7-4 (Mall) เวลาในการเชื่อมต่อ (ซ้าย) เวลาในการเสร็จสิ้นการเชื่อมต่อ (ขวา)




รูปที่ 7-5 (Mall) ระยะเวลาในการเชื่อมต่อ (ซ้าย) พลังงานไฟฟ้าที่ต้องการ (ขวา)




รูปที่ 7-6 (Mall) ระยะเวลาในการเชื่อมต่อในแต่ละช่วงเวลา (ซ้าย)
พลังงานไฟฟ้าที่ต้องการในแต่ละช่วงเวลา (ขวา)


7.2.3 สถานี MEA: University



รูปที่ 7-7 (University) เวลาในการเชื่อมต่อ (ซ้าย) เวลาในการเสร็จสิ้นการเชื่อมต่อ (ขวา)



รูปที่ 7-8 (University) ระยะเวลาในการเชื่อมต่อ (ซ้าย) พลังงานไฟฟ้าที่ต้องการ (ขวา)



รูปที่ 7-9 (University) ระยะเวลาในการเชื่อมต่อในแต่ละช่วงเวลา (ซ้าย)
พลังงานไฟฟ้าที่ต้องการในแต่ละช่วงเวลา (ขวา)

7.3 ผลลัพธ์ของการปรับ Hyper parameter ของโมเดลการเรียนรู้

7.3.1 สถานี ACN: JPL

ตารางที่ 7-5 (JPL) ผลลัพธ์การปรับ Hyper parameter ของ XGBoost

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
XGBoost	Session duration	'model__ subsample': 0.6, 'model__ n_estimators': 1000, 'model__ max_depth': 6, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.8, 'model__ colsample_bylevel': 0.9	'model__ subsample': 0.7, 'model__ n_estimators': 1000, 'model__ max_depth': 5, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.8, 'model__ colsample_bylevel': 0.9	'model__ subsample': 0.8, 'model__ n_estimators': 1000, 'model__ max_depth': 6, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.8, 'model__ colsample_bylevel': 0.4
XGBoost	Energy demand	'model__ subsample': 0.7, 'model__ n_estimators': 1000, 'model__ max_depth': 6, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.5, 'model__ colsample_bylevel': 0.5	'model__ subsample': 0.6, 'model__ n_estimators': 1000, 'model__ max_depth': 6, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.7, 'model__ colsample_bylevel': 0.9	'model__ subsample': 0.7, 'model__ n_estimators': 1000, 'model__ max_depth': 15, 'model__ learning_rate': 0.01, 'model__ colsample_bytree': 0.9, 'model__ colsample_bylevel': 0.7

ตารางที่ 7-6 (JPL) ผลลัพธ์การปรับ Hyper parameter ของ RF

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
RF	Session duration	'model__n_estimators': 200, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True	'model__n_estimators': 100, 'model__max_features': 'auto', 'model__max_depth': None, 'model__bootstrap': True	'model__n_estimators': 600, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True
RF	Energy demand	'model__n_estimators': 700, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True	'model__n_estimators': 500, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True	'model__n_estimators': 900, 'model__max_features': 'sqrt', 'model__max_depth': None, 'model__bootstrap': True

ตารางที่ 7-7 (JPL) ผลลัพธ์การปรับ Hyper parameter ของ TabNet

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
TabNet	Session duration Energy demand	<pre>n_d=40, n_a=40, n_steps=4, gamma=1.0, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=2, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000359583874400 19246, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 3, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=77, output_dim=2, device_name='auto'</pre>	<pre>n_d=40, n_a=40, n_steps=4, gamma=1.0, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=1, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000614452817593 0551, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 7, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=77, output_dim=2, device_name='auto'</pre>	<pre>n_d=56, n_a=56, n_steps=3, gamma=1.0, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=2, epsilon=1e-15, momentum=0.02, lambda_sparse=1.401827129398187 8e-06, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 3, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=77, output_dim=2, device_name='auto'</pre>

7.3.2 สถานี ACN: Caltech

ตารางที่ 7-8 (Caltech) ผลลัพธ์การปรับ Hyper parameter ของ XGBoost

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
XGBoost	Session duration	'model__subsample': 0.9, 'model__n_estimators': 500, 'model__max_depth': 6, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.7, 'model__colsample_bylevel': 0.7	'model__subsample': 0.6, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.6, 'model__colsample_bylevel': 0.7	'model__subsample': 0.8, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.8, 'model__colsample_bylevel': 0.9
	Energy demand	'model__subsample': 0.5, 'model__n_estimators': 500, 'model__max_depth': 6, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.8, 'model__colsample_bylevel': 0.6	'model__subsample': 0.6, 'model__n_estimators': 1000, 'model__max_depth': 6, 'model__learning_rate': 0.1, 'model__colsample_bytree': 0.7, 'model__colsample_bylevel': 0.6	'model__subsample': 0.9, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.7, 'model__colsample_bylevel': 0.9

ตารางที่ 7-9 (Caltech) ผลลัพธ์การปรับ Hyper parameter ของ RF

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
RF	Session duration	model__n_estimators: 400, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True	model__n_estimators: 1000, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True	model__n_estimators: 600, 'model__max_features': 'auto', 'model__max_depth': 10, 'model__bootstrap': True
RF	Energy demand	model__n_estimators: 300, 'model__max_features': 'log2', 'model__max_depth': 10, 'model__bootstrap': True	model__n_estimators: 700, 'model__max_features': 'log2', 'model__max_depth': None, 'model__bootstrap': True	model__n_estimators: 900, 'model__max_features': 'auto', 'model__max_depth': None, 'model__bootstrap': True

ตารางที่ 7-10 (JPL) ผลลัพธ์การปรับ Hyper parameter ของ TabNet

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
TabNet	Session duration Energy demand	<pre>n_d=52, n_a=52, n_steps=5, gamma=1.2, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=1, epsilon=1e-15, momentum=0.02, lambda_sparse=5.854457111378371 4e-05, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 6, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=77, output_dim=2, device_name='auto'</pre>	<pre>n_d=52, n_a=52, n_steps=3, gamma=1.2, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=2, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000354324584219 3232, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 9, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=77, output_dim=2, device_name='auto'</pre>	<pre>n_d=36, n_a=36, n_steps=4, gamma=1.0, cat_idxs=[74, 75, 76], cat_dims=[2, 2, 6], cat_emb_dim=[2, 2, 6], n_independent=2, n_shared=3, epsilon=1e-15, momentum=0.02, lambda_sparse=8.51260653718941e- 05, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 9, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=77, output_dim=2, device_name='auto'</pre>

7.3.3 สถานการณ์ MEA: Mall

ตารางที่ 7-11 (Mall) ผลลัพธ์การปรับ Hyper parameter ของ XGBoost

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
XGBoost	Session duration	'model__subsample': 0.9, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.7, 'model__colsample_bylevel': 0.5	'model__subsample': 0.7, 'model__n_estimators': 500, 'model__max_depth': 10, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.9, 'model__colsample_bylevel': 0.6	'model__subsample': 0.8, 'model__n_estimators': 100, 'model__max_depth': 10, 'model__learning_rate': 0.3, 'model__colsample_bytree': 0.8, 'model__colsample_bylevel': 0.5
	Energy demand	'model__subsample': 0.5, 'model__n_estimators': 100, 'model__max_depth': 10, 'model__learning_rate': 0.1, 'model__colsample_bytree': 0.8, 'model__colsample_bylevel': 0.8	'model__subsample': 0.8, 'model__n_estimators': 100, 'model__max_depth': 6, 'model__learning_rate': 0.1, 'model__colsample_bytree': 0.5, 'model__colsample_bylevel': 0.8	'model__subsample': 0.8, 'model__n_estimators': 100, 'model__max_depth': 6, 'model__learning_rate': 0.1, 'model__colsample_bytree': 0.9, 'model__colsample_bylevel': 0.8

ตารางที่ 7-12 (Mall) ผลลัพธ์การปรับ Hyper parameter ของ RF

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
RF	Session duration	model__n_estimators: 600, 'model__max_features': 'auto', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 100, 'model__max_features': 'auto', 'model__max_depth': None, 'model__bootstrap': True	model__n_estimators: 300, 'model__max_features': 'auto', 'model__max_depth': None, 'model__bootstrap': True
RF	Energy demand	model__n_estimators: 200, 'model__max_features': 'sqrt', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 100, 'model__max_features': 'auto', 'model__max_depth': None, 'model__bootstrap': True	model__n_estimators: 200, 'model__max_features': 'log2', 'model__max_depth': 10, 'model__bootstrap': True

ตารางที่ 7-13 (Mall) ผลลัพธ์การปรับ Hyper parameter ของ TabNet

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
TabNet	Session duration Energy demand	<pre>n_d=44, n_a=44, n_steps=3, gamma=1.2, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=2, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000103395165469 00966, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 8, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=76, output_dim=2, device_name='auto'</pre>	<pre>n_d=48, n_a=48, n_steps=4, gamma=1.4, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=3, epsilon=1e-15, momentum=0.02, lambda_sparse=1.068302093874755 6e-05, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 7, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=76, output_dim=2, device_name='auto'</pre>	<pre>n_d=52, n_a=52, n_steps=3, gamma=1.0, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=3, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000322875065918 2916, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 10, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=76, output_dim=2, device_name='auto'</pre>

7.3.4 สถาบัน MEA: University

ตารางที่ 7-14 (University) ผลลัพธ์การปรับ Hyper parameter ของ XGBoost

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
XGBoost	Session duration	'model__subsample': 0.9, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.7, 'model__colsample_bylevel': 0.5	'model__subsample': 0.5, 'model__n_estimators': 500, 'model__max_depth': 6, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.6, 'model__colsample_bylevel': 0.4	'model__subsample': 0.8, 'model__n_estimators': 500, 'model__max_depth': 5, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.8, 'model__colsample_bylevel': 0.9
		'model__subsample': 0.8, 'model__n_estimators': 500, 'model__max_depth': 3, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.5, 'model__colsample_bylevel': 0.8	'model__subsample': 0.7, 'model__n_estimators': 500, 'model__max_depth': 20, 'model__learning_rate': 0.01, 'model__colsample_bytree': 0.5, 'model__colsample_bylevel': 0.7	'model__subsample': 0.7, 'model__n_estimators': 100, 'model__max_depth': 3, 'model__learning_rate': 0.1, 'model__colsample_bytree': 0.9, 'model__colsample_bylevel': 0.7
XGBoost	Energy demand			

ตารางที่ 7-15 (University) ผลลัพธ์การปรับ Hyper parameter ของ RF

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
RF	Session duration	model__n_estimators: 800, 'model__max_features': 'auto', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 200, 'model__max_features': 'log2', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 300, 'model__max_features': 'log2', 'model__max_depth': 10, 'model__bootstrap': True
RF	Energy demand	model__n_estimators: 700, 'model__max_features': 'auto', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 600, 'model__max_features': 'sqrt', 'model__max_depth': 5, 'model__bootstrap': True	model__n_estimators: 900, 'model__max_features': 'sqrt', 'model__max_depth': 10, 'model__bootstrap': True

ตารางที่ 7-16 (University) ผลลัพธ์การรับ Hyper parameter ของ TabNet

ML model	Target	Validation month: Sep.	Validation month: Oct.	Validation month: Nov.
TabNet	Session duration Energy demand	<pre>n_d=20, n_a=20, n_steps=3, gamma=1.2, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=3, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000880109245066 3109, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 10, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=76, output_dim=2, device_name='auto'</pre>	<pre>n_d=52, n_a=52, n_steps=4, gamma=1.2, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=3, epsilon=1e-15, momentum=0.02, lambda_sparse=0.000116107572190 93384, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 9, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='entmax', input_dim=76, output_dim=2, device_name='auto'</pre>	<pre>n_d=56, n_a=56, n_steps=3, gamma=1.2, cat_idxs=[74, 75], cat_dims=[2, 6], cat_emb_dim=[2, 6], n_independent=2, n_shared=2, epsilon=1e-15, momentum=0.02, lambda_sparse=2.727155833827392 e-06, seed=0, clip_value=1, verbose=0, optimizer_fn=<class 'torch.optim.adam.Adam'>, optimizer_params={'lr': 0.02, 'weight_decay': 1e-05}, scheduler_fn=<class 'torch.optim.lr_scheduler.ReduceLRO nPlateau'>, scheduler_params={'mode': 'min', 'patience': 7, 'min_lr': 1e-05, 'factor': 0.5}, mask_type='sparsemax', input_dim=76, output_dim=2, device_name='auto'</pre>



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บรรณานุกรม

- [3] K. Clement-Nyns, E. Haesen, and J. Driesen, "The Impact of Charging Plug-In Hybrid Electric Vehicles on a Residential Distribution Grid," *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 371-380, 2010, doi: 10.1109/TPWRS.2009.2036481.
- [4] J. Coignard, S. Saxena, J. Greenblatt, and D. Wang, "Clean vehicles as an enabler for a clean electricity grid," *Environmental Research Letters*, vol. 13, no. 5, p. 054031, 2018/05/01 2018, doi: 10.1088/1748-9326/aabe97.
- [5] J. D. Cross and R. Hartshorn, "My Electric Avenue: Integrating electric vehicles into the electrical networks," in *6th Hybrid and Electric Vehicles Conference (HEVC 2016)*, 2-3 Nov. 2016 2016, pp. 1-6, doi: 10.1049/cp.2016.0972.
- [6] A. S. Al-Ogaili *et al.*, "Review on Scheduling, Clustering, and Forecasting Strategies for Controlling Electric Vehicle Charging: Challenges and Recommendations," *IEEE Access*, vol. 7, pp. 128353-128371, 2019, doi: 10.1109/ACCESS.2019.2939595.
- [7] J. García-Villalobos, I. Zamora, J. I. San Martín, F. J. Asensio, and V. Aperribay, "Plug-in electric vehicles in electric distribution networks: A review of smart charging approaches," *Renewable and Sustainable Energy Reviews*, vol. 38, pp. 1500-1517, 2016.
- [8] Q. Wang, X. Liu, J. Du, and F. Kong, "Smart Charging for Electric Vehicles: A Survey From the Algorithmic Perspective," *IEEE Communications Surveys & Tutorials*, vol. 18, pp. 1500-1517, 2016.
- [9] Z. J. Lee *et al.*, "Adaptive Charging Networks: A Framework for Smart Electric Vehicle Charging," *IEEE Transactions on Smart Grid*, vol. 12, no. 5, pp. 4339-4350, 2021, doi: 10.1109/TSG.2021.3074437.
- [10] Z. J. Lee, T. Li, and S. H. Low, "ACN-Data: Analysis and Applications of an Open EV Charging Dataset," *Proceedings of the Tenth ACM International Conference on Future Energy Systems*, 2019.

- [11] S. Shahriar, A. R. Al-Ali, A. H. Osman, S. Dhou, and M. Nijim, "Prediction of EV Charging Behavior Using Machine Learning," *IEEE Access*, vol. 9, pp. 111576-111586, 2021, doi: 10.1109/ACCESS.2021.3103119.
- [12] K. Schwenk, K. Phipps, B. Briegel, V. Hagenmeyer, and R. Mikut, "A Benchmark for Parking Duration Prediction of Electric Vehicles for Smart Charging Applications," in *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*, 5-7 Dec. 2021 2021, pp. 1-8, doi: 10.1109/SSCI50451.2021.9660063.
- [13] A. Almaghrebi, F. Aljuheshi, M. Rafaie, K. James, and M. Alahmad, "Data-Driven Charging Demand Prediction at Public Charging Stations Using Supervised Machine Learning Regression Methods," *Energies*, vol. 13, no. 16, p. 4231, 2020. [Online].
- [14] Y.-W. Chung, B. Khaki, T. Li, C. Chu, and R. Gadh, "Ensemble machine learning-based algorithm for electric vehicle user behavior prediction," *Applied Energy*, vol. 254, p.
- [15] A. Lucas, R. Barranco, and N. Refa, "EV Idle Time Estimation on Charging Infrastructure, Comparing Supervised Machine Learning Regressions," *Energies*, vol. 12, no. 2, p. 269, 2019. [Online].
- [16] *SAE Electric Vehicle and Plug in Hybrid Electric Vehicle Conductive Charge Coupler*, SAE, 2017.
- [17] S. Ö. Arik and T. Pfister, "TabNet: Attentive Interpretable Tabular Learning," *ArXiv*, vol. abs/1908.07442, 2021.
- [18] O. Frendo, N. Gaertner, and H. Stuckenschmidt, "Improving Smart Charging Prioritization by Predicting Electric Vehicle Departure Time," *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, no. 10, pp. 6646-6653, 2021, doi: 10.1109/TITS.2020.2988648.
- [19] W. Tang, S. Bi, and Y. J. Zhang, "Online Charging Scheduling Algorithms of Electric Vehicles in Smart Grid: An Overview," *IEEE Communications Magazine*, vol. 54, no. 12, pp. 76-83, 2016, doi: 10.1109/MCOM.2016.1600346CM.
- [20] N. Chen, C. Kurniawan, Y. Nakahira, L. Chen, and S. H. Low, "Smoothed Least-Laxity-First Algorithm for Electric Vehicle Charging: Online Decision and Performance Analysis With Resource Augmentation," *IEEE Transactions on Smart*

- Grid*, vol. 13, no. 3, pp. 2209-2217, 2022, doi: 10.1109/TSG.2021.3138615.
- [21] C. Diaz, A. Mazza, F. Ruiz, D. Patino, and G. Chicco, "Understanding Model Predictive Control for Electric Vehicle Charging Dispatch," in *2018 53rd International Universities Power Engineering Conference (UPEC)*, 4-7 Sept. 2018 2018, pp. 1-6, doi: 10.1109/UPEC.2018.8542050.
- [22] W. Tang and Y. J. Zhang, "A Model Predictive Control Approach for Low-Complexity Electric Vehicle Charging Scheduling: Optimality and Scalability," *IEEE Transactions on Power Systems*, vol. 32, no. 2, pp. 1050-1063, 2017, doi: 10.1109/TPWRS.2016.2585202.
- [23] M. S. Lipu *et al.*, "Battery Management, Key Technologies, Methods, Issues, and Future Trends of Electric Vehicles: A Pathway toward Achieving Sustainable Development Goals," *Batteries*, vol. 8, no. 9, doi: 10.3390/batteries8090119.
- [24] Z. J. Lee, D. Johansson, and S. H. Low, "ACN-Sim: An Open-Source Simulator for Data-Driven Electric Vehicle Charging Research," in *2019 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*, 21-23 Oct. 2019 2019, pp. 1-6, doi: 10.1109/SmartGridComm.2019.8909765.
- [25] O. Frendo, J. Graf, N. Gaertner, and H. Stuckenschmidt, "Data-driven smart charging for heterogeneous electric vehicle fleets," *Energy and AI*, vol. 1, p.
- [26] T. Jonas, N. Daniels, and G. Macht, "Electric Vehicle User Behavior: An Analysis of Charging Station Utilization in Canada," *Energies*, vol. 16, no. 4, p. 1592, 2023. [Online].



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	Prachaya Udomparichatr
วัน เดือน ปี เกิด	02 July 1992
สถานที่เกิด	Bangkok, Thailand
วุฒิการศึกษา	Bachelor's degree in electrical engineering, Chulalongkorn university
ที่อยู่ปัจจุบัน	99/296 Alley 7 Supalaithani Latsawai, Moo 3, Lamlukka 71, Lamkukka



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY