รายงานโครงงานวิศวกรรมไฟฟ้า วิชา 2102499 ปีการศึกษา 2567

การจำลองระบบบริหารจัดการพลังงานในสภาวะใกล้เวลาจริงของ สภาพแวดล้อม ณ อาคารเกเวอร์ต สแควร์

Simulation of near-real-time energy management system in Gewertz Square environment

นายพรพิพัฒน์ แก้วเขียว เลขประจำตัวนิสิต 6430255221 นายภูวดล ดำนิล เลขประจำตัวนิสิต 6432136621 อาจารย์ที่ปรึกษา ศ. ดร. จิตโกมุท ส่งศิริ

> ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ลงชื่ออาจารย์ที่ปรึกษาหลัก	ลงชื่ออาจารย์ที่ปรึกษาร่วม (ถ้ามี)	ลงชื่อตัวแทนบริษัท (เฉพาะ นิสิตในโปรแกรมความเชื่อมโยง อุตสาหกรรม)
()	()	()
วันที่	วันที่	วันที่

บทคัดย่อ

โครงงานนี้นำเสนอระบบจัดการพลังงานของสภาพแวดล้อม ณ อาคารเกเวอร์ต สแควร์ ซึ่งนำไปใช้ในงานจัดการ พลังงานของระบบที่มีการเชื่อมต่อกับพลังงานหมุนเวียน เพื่อทำให้การใช้พลังงานในระบบมีประสิทธิภาพมากที่สุด อาคารเกเวอร์ต สแควร์ประกอบไปด้วย 3 องค์ประกอบหลัก คือ โหลดไฟฟ้าที่มีกำลังไฟฟ้าสูงสุด 35 กิโลวัตต์, แผงโซลาร์ที่มีค่ากำลังติดตั้ง 50 กิโลวัตต์ และแบตเตอรี่ 215 กิโลวัตต์-ชั่วโมง จำนวน 2 ลูก โครงงานนี้ได้ใช้ได้ ใช้การหาค่าเหมาะที่สุดด้วยเทคนิคโปรแกรมเชิงเส้นในการวางแผนการอัดและคายประจุของแบตเตอรี่ 3 วันล่วง หน้าและ 1 ชั่วโมงล่วงหน้า และใช้การควบคุมเชิงทำนายแบบจำลอง ในการวางแผนแบบต่อเนื่อง ซึ่งช่วยให้ระบบ สามารถตัดสินใจตามสถานการณ์ที่เปลี่ยนแปลงได้ดีขึ้น เพื่อบรรลุฟังก์ชันจุดประสงค์เชิงเศรษฐศาสตร์และเชิงการ ทำงานของระบบจัดการพลังงาน ซึ่งประกอบไปด้วยฟังก์ชันการประหยัดพลังงาน, การประหยัดค่าไฟที่ต้องจ่าย, กำไรที่เกิดจากการซื้อและขายพลังงานจากกริด และฟังก์ชันจุดประสงค์ของแบตเตอรี่ โดยข้อมูลที่ใช้ในการทดลอง ประกอบด้วยข้อมูลจริงและข้อมูลพยากรณ์ ในส่วนของข้อมูลพยากรณ์จะใช้แบบจำลอง LSTM เพื่อสร้างแบบจำลอง ของโหลดไฟฟ้าและพลังงานโซลาร์สำหรับการพยากรณ์ 3 วันล่วงหน้าและ 1 ชั่วโมงล่วงหน้า ในโครงงานนี้ได้แบ่ง กรณีศึกษาทั้งหมด 4 กรณี ได้แก่ ค่าใช้จ่ายในอุดมคติ (Ideal), ค่าใช้จ่ายที่มีการวางแผนจากระบบจัดการพลังงาน (EMS), ค่าใช้จ่ายที่เกิดขึ้นจริง (Actual) และ ค่าใช้จ่ายเมื่อไม่มีระบบจัดการพลังงาน (NoEMS) ผลการทดลอง พบว่าเมื่อเปรียบเทียบกรณี Actual ที่มีการติดตั้งระบบจัดการพลังงานกับกรณี No EMS พบว่ากรณีของ Actual มีค่าไฟที่น้อยกว่าและมีกำไรสุทธิทีมากกว่าในกรณีของ No EMS ซึ่งกำไรสุทธิ เกิดจากกำไรที่ได้จากการขาย พลังงานคืนให้กับกรด หักล้างกับค่าใช้จ่ายเมื่อดึงพลังานจากกริด

คำสำคัญ: ระบบจัดการพลังงาน, การหาค่าเหมาะที่สุดด้วยเทคนิคโปรแกรมเชิงเส้น, การควบคุมเชิงทำนายแบบ จำลอง, แบบจำลอง LSTM

Abstract

This project presents an energy management system (EMS) implemented in the environment of Gewertz Square to manage energy in a system connected to renewable energy sources, aiming to maximize energy efficiency. Gewertz Square consists of three main components: an electrical load with a peak demand of 35 kW, a solar panel system with an installed capacity of 50 kW, and two batteries each with a capacity of 215 kWh.

The project applies linear programming techniques to determine the optimal charging and discharging schedules of the batteries for both Day-ahead and Hour-ahead planning horizons. Model Predictive Control (MPC) is also employed for continuous real-time planning, allowing the system to respond effectively to changing conditions. The EMS is designed to achieve both economic and operational objectives, including energy savings, electricity cost reduction, profit from energy trading with the grid, and efficient battery management.

The study uses both real and forecasted data. The forecasted data are generated using a Long Short-Term Memory (LSTM) model for predicting electrical load and solar generation for both three-day and one-hour ahead scenarios.

The four cases analyzed include the ideal expense, the planned expense using the EMS, the actual expense, and the expense without an EMS (No EMS). Experimental results show that when comparing the actual case, where the EMS is implemented, with the No EMS case, the actual case yields lower electricity costs and higher net profit. The net profit is calculated by selling surplus energy back to the grid, offsetting the cost of drawing energy from the grid.

Keywords: Energy Management System, Linear Programming Optimization, Model Predictive Control, LSTM Forecasting Model

สารบัญ

1	บทนำ 1.1	ที่มาและความสำคัญของโครงงาน	8 8
2	ภาพรว	มของโครงงา _ั น	10
	2.1	วัตถุประสงค์ของโครงงาน	10
	2.2 2.3	ขอบเขตของโครงงาน	10 10
3	หลักกา	ารและทฤษฎีที่เกี่ยวข้อง	11
	3.1	ระบบจัดการพลังงาน (Energy Management System, EMS)	11
		3.1.1 แบตเตอรี่	12
		3.1.2 โหลดไฟฟ้า	14
		3.1.3 แผงโซลาร์	15
		3.1.4 เงื่อนไขบังคับของ EMS	16
		3.1.5 Windugadusean and S	17
	3.2	การพยากรณ์ข้อมูลโดยโช้แบบจำลอง Long Short-Term Memory (LSTM)	22
		3.2.1 กลไกการควบคุมข้อมูลภายในหน่วยความจ้าของ LSTM	23
		3.2.2 สถาปัตยกรรมของแบบจำลองพยากรณ์	25
	3.3	การควบคุมเชิงท้านายแบบจำลอง (Model Predictive Control, MPC)	26
4	การเตรี	รี่ยมข้อมูล (Data Preparation)	28
	4.1	การปรับค่ากำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์	28
	4.2	การเตรียมข้อมูลสำหรับการพยากรณ์ (Forecasting Data)	29
		4.2.1 ข้อมูลโหลด	30
		4.2.2 ข้อมูลความเข้มแสง (Irradiance)	31
		4.2.3 ข้อมูลอณหภูมิโดยรอบ (Ambient Temperature)	32
		424 ข้อมูลดัชนีแมฆ (Cloud Index)	32
	43	การเตรียมข้อมูลสำหรับระบบจัดการพลังงาน (FMS Data)	33
	4.5		24
		4.5.1 แบทเทยว	24 25
		4.3.2 100 La 1 100 La 2 1 101 I LWW I	25 25
		4.5.5 ขอมูลสาหรบระบบงตการพลงจำนระยะหลายวันสางหนา (Day-Anead, DA)	35
		4.3.4 ข้อมูลสำหรับระบบจัดการพลังงานระยะหลายชั่วไม่งล่วงหน้า (Hour-Ahead,	~ ~
		ΗΑ)	39
5	แบบจำ	าลองการพยากรณ์ (Forecasting Model)	41
	5.1	แบบจำลองการพยากรณ์ระยะหลายวันล่วงหน้า (Day-Ahead, DA Forecasting Model)	41
		5.1.1 การพยากรณ์ใหลดไฟฟ้า (Load Forecasting)	41
		5.1.2 การพยากรณความเขมแสง (Irradiance Forecasting)	46
	5.2	แบบจำลองการพยากรณ์ระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA Forecasting	
		Model)	55
		5.2.1 การพยากรณเหลด (Load Forecasting) 5.2.2 ออสพยากรณ์เคอออน ขั้นและ (Inclusion)	55
		5.2.2 การพยากรณความเขมแสง (Irradiance Forecasting)	57

6	ผลการท	เดลองของร	ะบบจัดการพลังงาน	67
	6.1	ระบบจัดกา	เรพลังงานภายใต้กรอบ Day-Ahead	70
		6.1.1	ตัวอย่างชุดข้อมูลย่อย (Batch)	70
		6.1.2	การควบคุ่มเชิงทำนายแบบจำลอง (MPC)	74
	6.2	ระบบจัดกา	เรพลังงานภายใต้กรอบ Hour-Ahead	80
		6.2.1	ตัวอย่างชุดข้อมูลย่อย (Batch)	80
		6.2.2	การควบคุ่มเชิงทำนายแบบจำลอง (MPC)	89
7	บทสรุป			96

8 กิตติกรรมประกาศ

สารบัญรูป

1	ภาพรวมระบบจัดการพลังงาน [1]	8
2	ระบบ EMS ณ อาคารเกเวอร์ต สูแควร์	11
3	วตถุประสงคของระบบจดการพลงงาน	11
4	แผนภาพของอาคารเกเวอรต จุฬาลงกรณมหาวทยาลย	14
5	แผนภาพระบบของแผงเซลารบนอาคารบุญรอด บณฑสนต จุฬาลงกรณมหาวทยาลย	15
6	แผนภาพแสดงกำลังไฟฟ้าสุทธิที่ต้องการจากกรีด	16
7	แผนภาพแสดงพลังงานไฟฟ้าที่ดึงจากกริด	19
8	แผนภาพแสดงค่าไฟที่ต้องจ่ายเมื่อดึงไฟฟ้าจากกรีด	20
9	แผนภาพแสดงกำไรทิได้จากการซื้อและขายไฟจากกรีด	20
10	แบบข้าสองเครงข้ายประสาทเทยมแบบ RNN และ LSTM [2]	23
11 12	แผนมา เพ่นธุตุเงสถา เปตุเวกา มาของแบบงาเธอง พยาการแก่ก่านการทำการการการการการการการการการการการการการก	25
12	ขั้นต่อนอารทำ MDC ของแมตตลรี่	20 27
14	กราฟเปรียบเทียบค่าเฉลี่ย α ก่อนและหลังวันที่ 2 สิงหาคม 2566	28
15	กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ P _{DV} และ P _{DV.corr}	29
16	แผนภาพการเตรียมข้อมูลสำหรับการพยากรณ์	29
17	กราฟอนกรมเวลาของโห้ลดไฟฟ้า	30
18	กราฟอนุกรมเวลาของความเข้มแสง I, I _{NWP} , และI _{clr}	31
19	กราฟอนุกรมเวลาของอุณหภูมิโดยรอบ T และ T_{NWP}	32
20	กราฟอนกรมเวลาของดั้ชนีเมฆ CI_{CM} และ CI_{R}	33
21	แผนภาพการเตรียมข้อมูลสำหรับระบบจัดการพลังงาน	33
22	แบตเตอรี่ Jinko ความจุ๋ 215 kWh [3]	34
23	กราฟแสดงราคาซื้อและขายไฟฟ้าในแต่ละชั่วโมงที่สมมติขึ้น	35
24	การจัดกลุ่มข้อมูลกำลังไฟฟ้าของโหลดรายวัน	36
25	การจัดกลุ่มข้อมู [้] ลกำลังไฟฟ้าของแผงโซลาร์และความเข้มแสงรายวัน	37
26	กราฟอนุกรมเวลาของโหลดไฟฟ้าและการผลิตไฟฟ้าจากโซลาร์ภายใต้กรอบเวลา Hour-	
	Ahead	40
27	กราฟเปรียบเทียบผลเฉลยของ Day-Ahead ที่ถูกปรับความละเอียดจาก 15 นาที เป็น	
0.0	5 นาที	40
28	แบบจาลองการพยากรณเหลดภายเตกรอบ Day-Ahead	41
29	(1) โพแสพงพี โพ่ง เมื่อเมื่องของแบบง เสยงเนิงที่ขอมูลตั้งง่างสยบ	45
2U 21	การ เพียนการมหารถายของเหตุดเพพา เจริงและค่าพยาการณเพิลต์เพพา เรา เยเตการยบ Day-Anead	44 1
51	าาว เพ่าซุลพอพรออสอง	ן אר
20	เนขุตพย่อมูลต่าว เปลี่ยบ	45
5Z 33	แบบงาเสียงการพยากรณฑรามเซิมแสงภายเท่ารอบ Day-Anead	46
55	สาหรับขอต้อนอยือแอยือนอย่างเยี่ยงแบบงายองการพบการแบบการแบบการยบ Day-Aneau สำหรับขอต้อนอยือแอยตราอสอน (1)	18
31	ถาทรับบุทบอมู่แผกแมะพรรรมอบ (1)	40
54	สาหรับขอข้อบอยื่อแอยือนอย่างเยี่ยงแบบงายองการพบการแบบการแบบการยบ Day-Aneau สำหรับขอข้อบอยื่อแอยือแอย (2)	10
25	ถาทรับบุทบอมู่เพาแขตรรงแอบ (Z)	47
))	สาหรับขอข้อบอยื่อแอยื่อนอย่างเยี่ยงแบบงายองการพบการแบบการแบบการยบ Day-Aneau สำหรับขอข้อบอยื่อแอยื่อแอยู่เราอสอบ (3)	50
27		50
30	าราพแสตเงคาคา เมลูญแลยของแบบงาเลองการพยาการณเซลารระยะพลายามนลางหนาท ขล่าง ข	_
	นอยทสุดในชุดขอมูลตรวจสอบ	51
31	กราพอนุกรมเวลาของความเขมแสงคาจรงและคาแบบจาลองพยากรณภายโตกรอบ Day- Abaad	гэ
	AIIEdU	23

38	กราฟแสดงค่า MAE และ RMSE ของผลการพยากรณ์ความเข้มแสงอาทิตย์ล่วงหน้า 1,	
	2, และ 3 วัน สำหรับแต่ละชั่วโมง _.	54
39	กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ค่าจริงและค่าพยากรณ์ระยะหลาย	
	วันล่วงหน้า	54
40	แบบจำลองการพยากรณ์โหลดภายใต้กรอบ Hour-Ahead	55
41	กราฟแสดงค่าความสูญเสียของแบบจำลองในชุดข้อมูลตรวจสอบ	57
42	กราฟอนุกรมเวลาของโหลดไฟฟ้าจริงและค่าพยากรณ์โหลดไฟฟ้าภายใต้กรอบ Hour-Ahead	57
43	แบบจำลองการพยากรณ์ความเข้มแสงภายใต้กรอบ Hour-Ahead	58
44	กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายไต์กรอบ Hour-Ahead	
	สำหรับชุดข้อมูลฝึกและตรวจสอบ (1)	60
45	กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead	
	สำหรับชุดข้อมูลฝึกและตรวจสอบ (2)	61
46	กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead	
	สำหรับชุดข้อมูลฝึกและตรวจสอบ (3)	62
47	กราฟแส [่] ดงค่า [้] ความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead	
	ที่น้อยที่สุดในชุดข้อมูลตรวจสอบ	63
48	กระเพลงแนน (การณ์สาขายงความเข้มแสงค่าจริงและค่าแบบจำลองพยากรณ์ภายใต้กรอบ Hour-	00
10	Ahead	64
49	กราฟแสดงค่า MAE และ RMSE ของผลการพยากรณ์ความเข้มแสงอาทิตย์ล่วงหน้า 5	
	นาที และ 1 ชั่วโมง สำหรับแต่ละชั่วโมง	65
50	กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ค่าจริงและค่าพยากรณ์ภายใต้กรอบ	
E 4	Hour-Ahead	66
51	กราพผลเฉลยการทางานของระบบ EMS แบบ Day-Ahead เดยเช ขอมูลจรง เพอ บระหยด	
F 0	คาเพพา	70
52	กราพผลเฉลยการทางานของระบบ EMS แบบ Day-Anead เดยเข ขอมูลพยากรเน เพอ บระหย น้ำเมือ	มต
52	คาเพพา	(2
22	กว่าพพลเฉลยกาวทางานของระบบ EMS แบบ Day-Anead เพียเข ขอมูลงวง เพอ เนน อำไวสาวอิ	70
	กาเรลุพอ	13
54	กราฟผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยไซ ข้อมูลพยากรณ์ เพื่อ เน้น	
	ก้าไรสุทธิ์	74
55	กราฟแสดงค่าไข้จ่ายสะสมของปี 2024 ภายไต้กรอบ Day-Ahead	76
56	กราฟแสดง ค่าใช้จ่ายสุทธ์หลงการขายไฟฟ้า สะสมของป 2024 ภายโตกรอบ Day-Ahead	79
57	กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ ข้อมูลจริง เพื่อ ประหยัด	
	ค่าไฟฟ้า	82
58	กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ ข้อมูลพยากรณ์ เพื่อ ประห	เย็ด
	ค่าไฟฟ้า	84
59	กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยไซ ์ข้อมูลจริง เพื่อ ลด	
	รายจ่ายสุทธิหลังการขายไฟฟ้า	86
60	กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ ข้อมูลพยากรณ์ เพื่อ ลด	
	รายจ่ายสุทธิหลังการขายไฟฟ้า	88
61	กราฟแสดง ค่าใช้จ่าย สะสมของปี 2024 ภายใต้กรอบ Hour-Ahead	90
62	กราฟพฤติกรรมการตัดสินใจของระบบ EMS ตามช่วงเวลาของวัน	93
63	กราฟแสดง ค่าใช้จ่ายสุทธิหลังการขายไฟฟ้า สะสมของปี 2024 ภายใต้กรอบ Hour-Ahead	94

สารบัญตาราง

พารามิเตอร์ในระบบจัดการพลังงาน	12
ค่าพารามิเตอร์ของแบตเตอรี่ Jinko [3]	34
จำนวนกลุ่มข้อมูลที่ได้จากการจัดกลุ่มแบบ 3 วันต่อเนื่อง	39
ค่า MAE และ RMSE โดยรวมสำหรับการพยากรณ์ความเข้มแสงล่วงหน้า 1, 2 และ 3	
วัน (06:00-18:00)	53
ค่า MAE และ RMSE โดยรวมของการพยากรณ์ความเข้มแสงล่วงหน้า 1 ชั่วโมง (06:00–	
18:00)	66
รายละเอียดการทดลองของระบบจัดการพลังงาน	67
ค่าพารามิเตอร์ของการทดลองภายใต้กรอบ Day-Ahead	69
ค่าพารามิเตอร์ของการทดลองภายใต้กรอบ Hour-Ahead	69
ิสรุป รายจ่าย รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ การประหยั ด	9
ค่าไฟ	77
สรุป รายจ่ายสุทธิ รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ การ	
เน้นกำไร	78
สรุป รายจ่าย รายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ ประหยัด	
ค่าไฟ	91
สรุป รายจ่ายสุทธิ รายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ การ	
เน้นกำไร	93
	 พารามิเตอร์ในระบบจัดการพลังงาน ท่าพารามิเตอร์ของแบตเตอรี่ Jinko [3] จำนวนกลุ่มข้อมูลที่ได้จากการจัดกลุ่มแบบ 3 วันต่อเนื่อง ท่า MAE และ RMSE โดยรวมสำหรับการพยากรณ์ความเข้มแสงล่วงหน้า 1, 2 และ 3 วัน (06:00–18:00) ค่า MAE และ RMSE โดยรวมของการพยากรณ์ความเข้มแสงล่วงหน้า 1 ชั่วโมง (06:00– 18:00) รายละเอียดการทดลองของระบบจัดการพลังงาน ท่าพารามิเตอร์ของการทดลองภายใต้กรอบ Day-Ahead ค่าพารามิเตอร์ของการทดลองภายใต้กรอบ Hour-Ahead สรุปรายจ่ายรายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือการ เน้นกำไร สรุปรายจ่ายรายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือการ เน้นกำไร สรุปรายจ่ายสุทธิรายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือการ เน้นกำไร สรุปรายจ่ายสุทธิรายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือการ เน้นกำไร

1 บทนำ

1.1 ที่มาและความสำคัญของโครงงาน



รูป 1: ภาพรวมระบบจัดการพลังงาน [1]

ระบบจัดการพลังงาน (Energy Management System: EMS) เป็นระบบที่ช่วยในการควบคุมและบริหาร การใช้พลังงานให้มีประสิทธิภาพสูงสุด EMS มีบทบาทสำคัญในการเพิ่มประสิทธิภาพการใช้พลังงานหมุนเวียน เช่น พลังงานแสงอาทิตย์, พลังงานลม เป็นต้น เพื่อควบคุมการผลิตและการใช้งานพลังงานให้เหมาะสมกับความต้องการ ในแต่ละช่วงเวลา และสามารถจัดเก็บพลังงานส่วนเกินในระบบกักเก็บพลังงาน (Energy Storage System: ESS) เพื่อรองรับการใช้งานในช่วงเวลาที่มีพลังงานไม่เพียงพอหรือในช่วงที่มีความต้องการพลังงานสูง EMS สามารถแบ่ง หน้าที่ตามระดับการจัดการในโครงข่ายไฟฟ้าออกเป็น 2 ระดับหลักตาม*รูปที่* 1 ได้แก่ TSO-EMS (Transmission System Operator EMS) และ DSO-EMS (Distribution System Operator EMS) โดย TSO-EMS เน้น การบริหารจัดการในระดับการส่งกำลังไฟฟ้าจากแหล่งผลิตไปยังระบบจ่ายไฟ เช่น การรักษาสมดุลพลังงานและ ความถี่ของระบบ ขณะที่ DSO-EMS เน้นการจัดการพลังงานในระดับการจ่ายไฟฟ้าสู่ผู้ใช้ไฟฟ้าและไม่รักษาสมดุล ความถี่ของระบบ ในระดับ DSO-EMS ยังครอบคลุมระบบจัดการพลังงานในพื้นที่ที่แตกต่างกัน เช่น ระบบจัดการ พลังงานในโรงงาน (Factory Energy Management System: FEMS) ช่วยเพิ่มประสิทธิภาพการใช้พลังงานใน การผลิตและเครื่องจักรในโรงงาน, ระบบจัดการพลังงานในอาคาร (Building Energy Management System: BEMS) ช่วยจัดการพลังงานในอาคารให้เหมาะสมกับพฤติกรรมการใช้งาน, และระบบจัดการพลังงานในบ้าน (Home Energy Management System: HEMS) ช่วยควบคุมการใช้พลังงานในครัวเรือน

อาคารเกเวอร์ต สแควร์ ภายใต้การดูแลของภาควิช่าวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย มีแผนดำเนินการติดตั้งระบบผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ขนาด 50 กิโลวัตต์ บนหลังคาอาคาร และแบตเตอรี่ สำหรับกักเก็บพลังงานขนาด 215 กิโลวัตต์-ชั่วโมง จำนวน 2 ลูก เพื่อเพิ่มสัดส่วนการใช้พลังงานหมุนเวียนในระบบ ไฟฟ้าของอาคาร ทั้งนี้ เมื่อเพิ่มแหล่งผลิตพลังงานที่ไม่ต่อเนื่อง ทำให้เกิดความจำเป็นในการพัฒนาระบบจัดการ พลังงาน เพื่อบริหารจัดการการผลิต การใช้ และการจัดเก็บพลังงานภายในอาคารให้เกิดประสิทธิภาพสูงสุด

ในโครงงานนี้มีวัตถุประสงค์เพื่อจำลองการทำงานของระบบจัดการพลังงานในอาคารภายใต้สภาวะใกล้เคียงกับ เวลาจริง (Near Real-Time Simulation) ที่มีฟังก์ชันจุดประสงค์สำหรับการลดค่าไฟฟ้าและเพิ่มประสิทธิภาพ การทำงานของแบตเตอรี่ รวมทั้งใช้การควบคุมเชิงทำนายจำลองเพื่อทำให้หาค่าเหมาะที่สุดได้ค่าที่ดีขึ้น โดยพื้นที่ ศึกษาคือ อาคารเกเวอร์ต สแควร์ มีองค์ประกอบหลัก ได้แก่ โหลดไฟฟ้า, ระบบผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ บนหลังคา (Solar Rooftop), ระบบกักเก็บพลังงาน, และโครงข่ายไฟฟ้า องค์ประกอบเหล่านี้คล้ายกับงานวิจัย [4] ที่มีองค์ประกอบหลัก ได้แก่ โครงข่ายไฟฟ้า, โหลดไฟฟ้า, และระบบกักเก็บพลังงาน แต่งานวิจัย [4] มีฟังก์ชัน จุดประสงค์ในการประหยัดค่าไฟฟ้าเพียงอย่างเดียว และโครงงานนี้ได้พัฒนามาจากโครงงานปี 2566 [5] ที่มีรูป แบบปัญหาเชิงเส้นผสมจำนวนเต็ม (Mixed-Integer Linear Programming, MILP) เนื่องจากมีตัวแปรที่เป็นสถานะ การชาร์จหรือคายประจุของแบตเตอรี่ที่มีค่าเป็น 0 หรือ 1 โดยที่ 0 หมายถึง ไม่มีการชาร์จหรือคายประจุของ แบตเตอรี่ และ 1 หมายถึง มีการชาร์จหรือคายประจุของแบตเตอรี่ ทำให้ตัวแปรสถานะการชาร์จหรือคายประจุ เป็นตัวแปรฐานสอง (binary) จากโครงงาน [5] พบว่าค่าน้ำหนักของฟังก์ชันจุดประสงค์นั้นขึ้นกลับขนาดของระบบ ซึ่งส่งผลให้เมื่อเปลี่ยนขนาดของระบบจะไม่สามารถใช้ค่าน้ำหนักของฟังก์ชันวัตุประสงค์เดิมได้ และต้องปรับค่าน้ำ หนักใหม่ทุกครั้ง, เนื่องจากเป็นรูปแบบปัญหาเชิงเส้นผสมจำนวนเต็ม ทำให้การแก้หาค่าเหมาะที่สุดมีความซับซ้อน สูงและใช้เวลานาน

ในโครงงานนี้ได้มีการปรับปรุงแนวทางการแก้ปัญหาสำหรับระบบการจัดการพลังงานจากโครงงานวิศวกรรมปี 2566 [5] แบ่งเป็นประเด็นสำคัญดังนี้

- การเปลี่ยนวิธีการหาค่าเหมาะที่สุดที่มีรูปแบบปัญหา MILP เป็นรูปแบบปัญหาเชิงเส้น (Linear Programming, LP) ทำให้การแก้ปัญหาเชิงเลขมีประสิทธิภาพมากขึ้น
- การปรับค่าฟังก์ชันวัตถุประสงค์ให้เป็นแบบไร้หน่วยเพื่อให้การคำนวณค่าถ่วงน้ำหนักของตัวแปรต่างๆ มีความ เหมาะสมมากยิ่งขึ้นโดยไม่ขึ้นกับขนาดของพารามิเตอร์ เช่น ความจุของแบตเตอรี่หรือปริมาณการใช้โหลด สูงสุด
- การจัดรูปแบบของปัญหาโดยมีฟังก์ชันจุดประสงค์เป็นกำไรจากการซื้อขายพลังงานกับกริด ให้อยู่ในรูปของ ปัญหาเชิงเส้น

โครงงานนี้ยังได้นำเสนอการจำลองระบบที่ใกล้เคียงกับสภาวะจริง เพื่อเพิ่มประสิทธิภาพการทำงานของระบบ EMS ในสถานการณ์ที่เปลี่ยนแปลงตามเวลา การจำลองแบบนี้จะช่วยให้ระบบ EMS สามารถตอบสนองต่อสภาพ การใช้งานที่ไม่แน่นอน และให้ผลลัพธ์ที่สอดคล้องกับสภาวะการใช้งานจริง การทดลองในโครงงานนี้มุ่งเน้นการหา ค่าเหมาะที่สุด 2 ระยะเวลาคือหลายวันล่วงหน้า (Day-Ahead, DA) และหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA) ตามฟังก์ชันจุดประสงค์ที่ต้องการ โดยได้ทำการเปรียบเทียบประสิทธิภาพของระบบบริหารจัดการพลังงาน (EMS) ภายใต้ 4 กรณี ได้แก่ ค่าใช้จ่ายในอุดมคติ (Ideal), ค่าใช้จ่ายที่มีการวางแผนจากระบบจัดการพลังงาน (EMS), ค่าใช้จ่ายที่เกิดขึ้นจริง (Actual) และ ค่าใช้จ่ายเมื่อไม่มีระบบจัดการพลังงาน (NoEMS) เมื่อพิจารณากรณี Actual และ Ideal และใช้ฟังก์ชันจุดประสงค์คือการประหยัดค่าไฟพบว่าความต่างของค่าไฟในกรณี HA จะมี ค่าน้อยกว่า DA เนื่องจากการพยากรณ์ของ HA มีค่าดีกว่า DA และเมื่อพิจารณาผลต่างค่าไฟในกรณี Actual กับ NoEMS ในระยะเวลาของ HA และมีฟังก์ชันจุดประสงค์คือการประหยัดค่าไฟ พบว่าค่าไฟที่ต้องจ่ายในกรณี NoEMS สูงกว่ากรณี Actual 60,734 บาท และเมื่อใช้ฟังก์ชันจุดประสงค์คือการประหยัดค่าไฟ พบว่าค่าไฟที่ต้องจ่ายในกรณี พบว่าค่าไฟที่ต้องจ่ายในกรณี NoEMS มากกว่ากรณี Actual 35,126 บาท จากการทดลองในโครงงานแสดงถึง ความสำคัญในการพัฒนาระบบ EMS ในสภาวะใกล้เวลาจริง และความสำคัญของการติดตั้งระบบ เนื่องจาก EMS จะสามารถจัดการพลังงานให้มีประสิทธิภาพสูงสุด ส่งผลให้สามารถลดค่าใช้จ่ายและสร้างกำไรจากการซื้อขายไฟ จากกริดได้ดีกว่ากรณีไม่ติดตั้ง EMS

2 ภาพรวมของโครงงาน

2.1 วัตถุประสงค์ของโครงงาน

 เพื่อพัฒนาระบบการจัดการพลังงานสำหรับอาคารเกเวอร์ต สแควร์ โดยใช้การจำลองในสภาวะเสมือนจริง เพื่อประเมินประสิทธิภาพของ EMS ที่ได้รับการปรับปรุงจากโครงงานปี 2566 [5]

2.2 ขอบเขตของโครงงาน

- 1. ทำระบบการจัดการพลังงานสำหรับอาคารเกเวอร์ต สแควร์ ภาควิชาวิศวกรรมไฟฟ้า จุฬาลงกรณ์มหาวิทยาลัย
- 2. จำลองการทำงานของ EMS ในสภาวะใกล้เคียงกับเวลาจริงที่คำนวณทุก 5 นาที
- มีฟังก์ชันจุดประสงค์ที่หลากหลาย ได้แก่ การประหยัดค่าไฟ, การประหยัดพลังงาน, หรือการสร้างผลกำไร ในส่วนฟังก์ชันจุดประสงค์ของแบตเตอรี่จะรวมถึงการชาร์จแบตเตอรี่ให้เป็นไปตามรูปแบบที่ปรับเรียบ, การ ทำให้การชาร์จแบตเตอรี่หลายลูกทำงานคล้ายกัน, และการสนับสนุนการชาร์จแบตเตอรี่

2.3 ผลลัพธ์ที่คาดหวังจากโครงงาน

- ชุดคำสั่ง MATLAB และ Python ที่ช่วยในการแก้ปัญหาการหาค่าเหมาะที่สุดของ EMS ซึ่งสามารถปรับ ใช้ได้กับอาคารหรือระบบอื่นๆ ที่มีลักษณะการใช้งานใกล้เคียงกัน
- ผลการจำลองการทำงานของ EMS ในสภาวะใกล้เวลาจริง โดยแสดงถึงประสิทธิภาพและความสามารถใน การจัดการพลังงานในสถานการณ์การใช้พลังงานจริง

3 หลักการและทฤษฎีที่เกี่ยวข้อง

3.1 ระบบจัดการพลังงาน (Energy Management System, EMS)



รูป 2: ระบบ EMS ณ อาคารเกเวอร์ต สแควร์

รูปที่ 2 ระบบจัดการพลังงาน ณ อาคารเกเวอร์ต สแควร์เชื่อมกับองค์ประกอบหลักที่สำคัญ 3 องค์ประกอบ ได้แก่ โหลดไฟฟ้า แผงโซลาร์ และแบตเตอรี่ ระบบจะเก็บค่าพยากรณ์ของโหลดและกำลังไฟฟ้าแสงอาทิตย์ไว้ที่ ฐานข้อมูลและจะนำค่าพยากรณ์เหล่านี้ไปทำกับหาค่าเหมาะที่สุดตามจุดประสงค์ของ EMS โดยในการหาค่าเหมาะ ที่สุดนั้นจะต้องประกอบไปด้วยข้อมูลพยากรณ์ของโหลดไฟฟ้า, กำลังไฟฟ้าแสงอาทิตย์ และพารามิเตอร์ของระบบ เช่น คุณลักษณะของแบตเตอรี่ เมื่อหาค่าเหมาะที่สุดสำเร็จแล้วระบบจะส่งแผนการดำเนินงานไปที่ระบบควบคุม กริดเพื่อไปควบคุมแบตเตอรี่ โดยพารามิเตอร์ของระบบแสดงดัง*ตารางที่* 1





รูปที่ 3 แสดงถึงวัตถุประสงค์ของระบบจัดการพลังงานซึ่งสามารถแบ่งได้หลายแง่มุม ดังนี้

ช่วงเวลาวางแผนของ EMS (Time Horizon) ในโครงงานนี้จะพิจารณากรอบเวลาในการวางแผนล่วงหน้า ของระบบจัดการพลังงาน 2 กรอบเวลา นั่นคือ 3 วันล่วงหน้าสำหรับการวางแผนดำเนินการ (Day-Ahead, DA) และ 1 ชั่วโมงล่วงหน้า (Hour-Ahead, HA) เนื่องจากในช่วงเวลาที่สั้นลงของ 1 ชั่วโมงล่วงหน้าจะมีค่าพยากรณ์ ที่มีความคลาดเคลื่อนน้อยกว่าช่วงเวลา 3 วันล่วงหน้า ทำให้เราใช้ข้อมูลในการวางแผนดำเนินการ 1 ชั่วโมงล่วง หน้ามาพิจารณาร่วมกับการวางแผนดำเนินการ 3 วันล่วงหน้า

การจำลองผลของ EMS สามารถเลือกที่จะใช้ข้อมูลที่รู้ล่วงหน้าอยู่แล้ว (prescient data) ในการทำงานแบบ ออฟไลน์ จะเหมาะกับการวางแผนล่วงหน้า แต่ข้อมูลที่รู้ล่วงหน้าอยู่แล้วไม่สามารถทำได้จริงในการจำลองใกล้เวลา จริง เนื่องจากไม่สามารถรู้ข้อมูลของโหลดและพลังงานที่ผลิตได้ของแผงโซลาร์ จึงต้องใช้ข้อมูลพยากรณ์ในการจำลอง ใกล้เวลาจริง เพื่อให้ได้ข้อมูลของโหลดและพลังงานที่ผลิตได้ของแผงโซลาร์ในอนาคต

ฟังก์ชันจุดประสงค์ของระบบจัดการพลังงาน นั้นประกอบไปด้วย ฟังก์ชันจุดประสงค์ที่เกี่ยวข้องกับแบตเตอรี่ และ ฟังก์ชันการประหยัดค่าไฟของ EMS ซึ่งจะกล่าวในหัวข้อที่ 3.1.5

ตัวแปร	ນີຍາມ	หน่วย
N_{Batt}	จำนวนของแบตเตอรี่ในระบบ	_{ຄູ} ິກ
BattCapacity	ความจุของแบตเตอรี่	กิ้โลวัตต์-ชั่วโมง (kWh)
SoC_{min}	สถานะแบตเตอรี่ต่ำสุด	%
SoC(1)	สถานะแบตเตอรี่เริ่มต้น	%
SoC_{max}	สถานะแบตเตอรี่สูงสุด	%
η_{C}	สัมประสิทธิ์การอัดประจุของแบตเตอรี่	-
η_{d}	สัมประสิทธิ์การคายประจุของแบตเตอรี่	-
MAX CHARGE RATE	อัตราการอัดประจุสูงสุดของแบตเตอรี่	กิโลวัตต์ (kW)
MAX DISCHARGE RATE	อัตราการคายประจุสูงสุดของแบตเตอรี่	กิโลวัตต์ (kW)
b(t)	อัตราราคาซื้อพลังงานไฟฟ้าจากกริด	บาท/กิโลวัตต์-ชั่วโมง (THB/kWh)
s(t)	อัตราราคาขายพลังงานไฟฟ้าให้กริด	บาท/กิโลวัตต์-ชั่วโมง (THB/kWh)
w_s	ค่าน้ำหนักของการชาร์จแบตเตอรี่	-
	ให้มีรูปแบบปรับเรียบ	
w_m	ค่าน้ำหนักของการชาร์จแบตเตอรี่	-
	หลายลูกให้ทำงานคล้ายกัน	
w_c	ค่าน้ำหนักของการส่งเสริมการชาร์จแบตเตอรี่	-

ตาราง 1: พารามิเตอร์ในระบบจัดการพลังงาน

3.1.1 แบตเตอรี่

ระบบกักเก็บพลังงาน (Energy Storage System, ESS) จะเข้ามามีบทบาทสำคัญในการกักเก็บพลังงานส่วนเกิน จากแหล่งผลิต และจ่ายพลังงานกลับเข้าสู่ระบบในช่วงที่มีความต้องการพลังงานไฟฟ้าสูงหรือแหล่งผลิตมีกำลังผลิต ไม่เพียงพอ ระบบกักเก็บพลังงานในโครงงานนี้คือระบบกักเก็บพลังงานด้วยแบตเตอรี่ (Battery Energy storage System, BESS) ซึ่งประกอบไปด้วยแบตเตอรี่หลายลูก แบตเตอรี่แต่ละลูกจะถูกระบุด้วยดัชนี $i = 1, 2, 3, \ldots, N_{Batt}$ เมื่อ N_{batt} แทนจำนวนแบตเตอรี่ทั้งหมดในระบบ สำหรับโครงงานนี้ กำหนดให้ $N_{Batt} = 2$ ซึ่งหมายความว่า ระบบประกอบด้วยแบตเตอรี่จำนวน 2 ลูก และความจุของแต่ละลูกคือ 215 กิโลวัตต์-ชั่วโมง โดยถ้ากำลังไฟฟ้าที่ โหลดไฟฟ้าต้องการมากกว่ากำลังไฟฟ้าที่ผลิตได้ แบตเตอรี่จะคายกำลังไฟฟ้าออกมาเพื่อทดแทนกำลังไฟฟ้าที่ไม่เพียง พอ ซึ่งส่งผลให้กำลังไฟฟ้าที่ต้องการจากกริดมีค่าลดลง หรือไม่ต้องการดึงกำลังไฟฟ้าจากกริดเลย ในขณะที่กำลัง ไฟฟ้าที่ผลิตได้มีค่ามากกว่ากำลังของโหลดไฟฟ้า แบตเตอรี่จะถูกชาร์จกำลังไฟฟ้าเก็บไว้ โดยสมการที่ใช้บรรยาย พลวัตและอสมการข้อกำหนด ณ เวลาหนึ่งๆสำหรับแบตเตอรี่แต่ละลูก แสดงได้ดังนี้

สมการบรรยายพลวัตสถานะของแบตเตอรี่

ในรายงานนี้มีตัวแปรที่ใช้อธิบายสมการพลวัตของแบตเตอรี่ คือ สถานะของแบตเตอรี่ (State of Charge, SoC) ซึ่งแสดงถึงสัดส่วนของพลังงานที่เหลืออยู่ของแบตเตอรี่ต่อพลังงานทั้งหมดที่แบตเตอรี่สามารถเก็บได้, กำลัง ไฟฟ้าที่ชาร์จเข้า ($P_{chg} \ge 0$) และ กำลังไฟฟ้าที่คายออกจากแบตเตอรี่ ($P_{dchg} \ge 0$) ในสภาวะทั่วไปเมื่อแบตเตอรี่ สั่งคายกำลังไฟฟ้าหรือถูกชาร์จกำลังไฟฟ้าเข้า จะมีการสูญเสียกำลังไฟฟ้าบางส่วนไปซึ่งแสดงได้ด้วยพจน์ η_d, η_c คือค่าคงตัวประสิทธิภาพขณะคายกำลังไฟฟ้าและถูกชาร์จกำลังไฟฟ้าเข้า และ $\eta_c > \eta_d$ โดยพลวัตสถานะของ แบตเตอรี่แสดงได้ดังสมการ

$$\operatorname{SoC}_{i}(t+1) = \operatorname{SoC}_{i}(t) + \frac{100}{\operatorname{BattCapacity}} \left(\eta_{c} P_{\operatorname{chg}}^{(i)}(t) \Delta t - \frac{P_{\operatorname{dchg}}^{(i)}(t) \Delta t}{\eta_{d}} \right)$$
(1)

- BattCapacity : ความจุไฟฟ้าของแบตเตอรี่ (kWh)
- Δt : ความละเอียดของเวลา
- + i : ดัชนีที่แสดงถึงแบตเตอรี่ตัวที่ $i=1,2,\ldots,N_{\rm Batt}$
- t: ดัชนีเวลา t=1,2,...,T

อสมการแสดงข้อจำกัดในการอัดและคายประจุของแบตเตอรี่

เมื่อแบตเตอรี่ทำงาน แบตเตอรี่ไม่สามารถอัดหรือคายประจุมากไปกว่าอัตราการคายและอัดประจุสูงสุดได้ สามารถ แสดงดังอสมการข้อจำกัดในการอัดและคายประจุของแบตเตอรี่ได้ดังนี้

$$P_{\rm chg}^{(i)}(t) \le {\sf MAX}$$
 CHARGE RATE, $t = 1, 2, \dots, T, \quad i = 1, 2, \dots, N_{\sf Batt}$ (2)

$$P_{\text{dchg}}^{(i)}(t) \leq \text{MAX DISCHARGE RATE}, \quad t = 1, 2, \dots, T, \quad i = 1, 2, \dots, N_{\text{Batt}}$$
 (3)

อสมการบรรยายข้อจำกัดสถานะของแบตเตอรี่

เงื่อนไขเพิ่มเติมสำหรับแบตเตอรี่คือการเสื่อมสภาพของแบตเตอรี่โดยพบว่าถ้าอัดประจุแบตเตอรี่จนเต็ม และ ให้แบตเตอรี่คายประจุจนหมดจะส่งผลให้แบตเตอรี่เสื่อมสภาพเร็ว ดังนั้นจึงจำกัดการทำงานของแบตเตอรี่ไว้ในช่วง ที่กำหนด

$$\operatorname{SoC}_{\min,i} \le \operatorname{SoC}_i(t) \le \operatorname{SoC}_{\max,i}$$
 (4)

สำหรับ $i=1,2,\ldots,N_{\mathsf{Batt}}$ และ $t=1,2,\ldots,T$

อสมการแสดงข้อจำกันสถานะการชาร์จ ณ ปลายวัน

เมื่อแบตเตอรี่ทำงานข้ามวัน เพื่อป้องกันให้สถานะแบตเตอรี่เพียงพอในวันถัดไป จึงมีข้อกำหนดสำหรับสถานะ ของแบตเตอรี่ ณ ปลายวันโดยต้องการให้สถานะแบตเตอรี่ ณ ปลายวันมีค่ามากกว่าค่าที่กำหนดแสดงได้ดังอสมการ ต่อไปนี้

$$\operatorname{SoC}_i(T) \ge 40$$
 (5)

สำหรับ $i=1,2,\ldots,N_{\mathsf{Batt}}$ และ T คือดัชนีเวลา ณ ปลายวัน

3.1.2 โหลดไฟฟ้า

ในการจำลองโหลดไฟฟ้าของอาคารเกเวอร์ต สแควร์ (Gewertz Square) จะใช้ข้อมูลการใช้พลังงานไฟฟ้าจริงจาก อาคารเกเวอร์ต องค์ประกอบของอาคารประกอบด้วยห้องต่าง ๆ ดังต่อไปนี้:

- ห้องที่ 1 : Professor's Rooms
- ห้องที่ 2 : Common Room
- ห้องที่ 3 : Student Club
- ห้องที่ 4 : Graduate Student office
- ห้องที่ 5 : Machine Lab
- ห้องที่ 6 : Power electronics Lab
- ห้องที่ 7 : Storage Room

โหลดไฟฟ้าส่วนใหญ่ของอาคารเกิดจากการใช้งานอุปกรณ์ไฟฟ้าภายในห้องปฏิบัติการ เครื่องปรับอากาศ และระบบ ไฟฟ้าส่องสว่าง โดยข้อมูลโหลดที่ใช้ในการวิเคราะห์เป็นข้อมูลจริงในช่วงระหว่างเดือนมีนาคม พ.ศ. 2566 ถึงเดือน ธันวาคม พ.ศ. 2567 ซึ่งจากข้อมูลดังกล่าวพบว่า ค่าโหลดไฟฟ้าสูงสุดอยู่ที่ประมาณ 35 kW



(a) อาคารเกเวอร์ต สแควร์

Professor's Rooms	Common Room	Graduate student office	Power elect	ronics Lab	
Student Club		Machi	ne Lab	Storage Room	

(b) แผนผังของอาคารเกเวอร์ต

รูป 4: แผนภาพของอาคารเกเวอร์ต จุฬาลงกรณ์มหาวิทยาลัย

3.1.3 แผงโซลาร์

แผงโซลาร์ที่วางแผนจะติดตั้งที่อาคารเกเวอร์ตมีกำลังการผลิตสูงสุดที่ 50 kW แต่เนื่องจากข้อมูลพลังงานแสงอาทิตย์ ที่มีอยู่ในปัจจุบันมาจากอาคารบุญรอด บิณฑสันต์ ซึ่งมีจำนวนทั้งหมด 49 แผง และกำลังผลิตรวมสูงสุดคือ 8 kW จึงได้มีการปรับสเกลข้อมูลดังกล่าวให้สอดคล้องกับขนาดของระบบที่อาคารเกเวอร์สแควร์ ทั้งนี้ การเลือกใช้ข้อมูล จากอาคารบุญรอด บิณฑสันต์ สามารถพิจารณาได้ว่าเหมาะสม เนื่องจากทั้งสองอาคารตั้งอยู่ในพื้นที่ใกล้เคียงกัน ทำให้ระดับความเข้มแสงอาทิตย์ที่ได้รับมีความใกล้เคียงกัน



(a) แผงโซลาร์ชนิด Frontier (8 kW)

(b) แผนภาพระบบของแผงโซลาร์ชนิด Frontier (8 kW) และคุณลักษณะ

รูป 5: แผนภาพระบบของแผงโซลาร์บนอาคารบุญรอด บิณฑสันต์ จุฬาลงกรณ์มหาวิทยาลัย

เงื่อนไขบังคับของ EMS 3.1.4

1. สมการแสดงกำลังไฟฟ้าสุทธิที่ต้องการจากกริด



รูป 6: แผนภาพแสดงกำลังไฟฟ้าสุทธิที่ต้องการจากกริด

$$P_{\text{net}}(t) = P_{\text{load}}(t) - P_{\text{pv}}(t) + \sum_{i=1}^{n} \left(P_{\text{chg}}^{(i)}(t) - P_{\text{dchg}}^{(i)}(t) \right), \quad t = 1, 2, \dots, T$$
(6)

เมื่อ P_{load} คือ โหลดไฟฟ้า (kW) และ P_{pv} คือ กำลังไฟฟ้าแสงอาทิตย์ (kW)

รูปที่ 6 แสดงถึงกำลังไฟฟ้าที่ต้องการจากกริด (Pnet) ซึ่งสามารถคำนวณได้จากกำลังของโหลดไฟฟ้า หักล[ั]บด้วยกำลังไฟฟ้าที่ผลิตได้ โดยถ้า

- P_{net} > 0 แสดงถึง กำลังไฟฟ้าที่โหลดในระบบต้องการมีมากกว่ากำลังไฟฟ้าที่ระบบผลิตได้ เพื่อตอบ สนองต่อความต้องการของโหลดจึงต้องดึงกำลังไฟฟ้าจากกริดเข้ามาในระบบ
- $P_{\rm net} < 0$ แสดงถึง กำลังไฟฟ้าที่โหลดในระบบต้องการมีค่าน้อยกว่ากำลังไฟฟ้าที่ระบบผลิตได้ ใน
- กรณีนี้ระบบไม่ต้องการดึงกำลังไฟฟ้าจากกริดและระบบสามารถขายกำลังไฟฟ้าคืนให้กับกริดได้ P_{net} = 0 แสดงถึง กำลังไฟฟ้าที่โหลดในระบบต้องการมีค่าเท่ากับกำลังไฟฟ้าที่ระบบผลิตได้ ดังนั้น ระบบจึงไม่ต้องการดึงไฟฟ้าจากกริด

จะได้ว่าสมการ (6) เป็นสมการเชิงเส้น เพราะมีความสัมพันธ์แบบเชิงเส้นในตัวแปร $P_{
m load},\,P_{
m pv},\,P_{
m chg}^{(i)},\,P_{
m deng}^{(i)}$ ตามลำดับ

- สมการบรรยายพลวัตสถานะของแบตเตอรี่ (1) จะได้ว่าสมการ (1) เป็นสมการเชิงเส้น เพราะมีความสัมพันธ์แบบเชิงเส้นในตัวแปร SoC_i, P⁽ⁱ⁾_{dchg}, P⁽ⁱ⁾_{chg}
- 3. อสมการแสดงข้อจำกัดในการอัดและคายประจุของแบตเตอรี่ (2)-(3) จะได้ว่าอสมการ (2)-(3) เป็นอสมการเชิงเส้น เพราะมีความสัมพันธ์แบบเชิงเส้นในตัวแปร $P_{
 m chg}^{(i)},\,P_{
 m dchg}^{(i)}$ ตาม ลำดับ
- อสมการบรรยายข้อจำกัดสถานะของแบตเตอรี่ (4) จะได้ว่าอสมการ (4) เป็นอสมการเชิงเส้น เพราะมีความสัมพันธ์แบบเชิงเส้นในตัวแปร SoC_i
- 5. อสมการบรรยายข้อกำกัดสถานะการชาร์จ ณ ปลายวัน จะได้ว่าอสมการ (5) เป็นอสมการเชิงเส้น เพราะมีความสัมพันธ์แบบเชิงเส้นในตัวแปร SoC,

ฟังก์ชันจุดประสงค์ของEMS 3.1.5

การหาค่าเหมาะที่สุดของ EMS จะต้องมีข้อกำหนดคือ ช่วงเวลาสำหรับการหาค่าเหมาะสุดซึ่งแสดงด้วยดัชนีแกน เวลา t=1,2,...,T , ความละเอียดของเวลา (resolution time) และพารามิเตอร์ของระบบจัดการพลังงานดัง ตารางที่ 1

ฟังก์ชันจุดประสงค์ของแบตเตอรี่

การชาร์จแบตเตอรี่ให้มีรูปแบบปรับเรียบ (smooth charging)

้เมื่อแบตเตอรี่สั่งอัดหรือคายประจุในเวลาหนึ่ง เมื่อพิจารณาในเวลาถัดไปที่อัดหรือคายประจุจะพบว่าต้องการ ้ให้กำลังของการอัดหรือคายประจุไม่ต่่างกันมาก เนื่องจากไม่อยากให้มีการกระชากของกระแสซึ่งจะส่งผลต่อการ เสื่อมสภาพของแบตเตอรี่ได้ ดังนั้นจึงต้องการให้ผลรวมของ ผลต่างระหว่างกำลังไฟฟ้าที่อัดหรือคายประจุในเวลา หนึ่งและเวลาถัดไปมีค่าน้อยที่สุด สำหรับแบตเตอรี่ทุกลูก

$$J_{\text{smoothcharge}} = \sum_{t=1}^{T-1} \sum_{i=1}^{N_{\text{Batt}}} \left(\frac{\left| P_{\text{chg}}^{(i)}(t+1) - P_{\text{chg}}^{(i)}(t) \right|}{\text{MAX CHARGE RATE}} + \frac{\left| P_{\text{dchg}}^{(i)}(t+1) - P_{\text{dchg}}^{(i)}(t) \right|}{\text{MAX DISCHARGE RATE}} \right)$$
(7)
เมื่อพิจารณาฟังก์ชัน $\sum_{t=1}^{T-1} \sum_{i=1}^{N_{\text{Batt}}} \left(\frac{\left| P_{\text{chg}}^{(i)}(t+1) - P_{\text{chg}}^{(i)}(t) \right|}{\text{MAX CHARGE RATE}} + \frac{\left| P_{\text{dchg}}^{(i)}(t+1) - P_{\text{dchg}}^{(i)}(t) \right|}{\text{MAX DISCHARGE RATE}} \right)$

 $\overline{t=1}$ $\overline{t=1}$ (MAA CHANGE NATE) จะพบว่าฟังก์ชันนี้เป็นฟังก์ชันไม่เชิงเส้น (Nonlinear function) แต่สามารถจัดรูปฟังก์ชันนี้ให้อยู่ในรูปแบบของ เอพิกราฟ (Epigraph form) ซึ่งสามารถแปลงจากปัญหาการหาค่าเหมาะสุดของฟังก์ชันไม่เชิงเส้นเป็นฟังก์ชันเชิง เส้นได้

จะใช้ตัวแปรเสริม $z_{
m chg}^{(i)}(t)$ และ $z_{
m dchg}^{(i)}(t)$ โดยที่กำหนดให้ $|\mathbf{p}(i)(i+1) = \mathbf{p}(i)(i)|$

$$\begin{aligned} \frac{\left|P_{\mathrm{chg}}^{(i)}(t+1) - P_{\mathrm{chg}}^{(i)}(t)\right|}{\mathrm{MAX \ CHARGE \ RATE}} &\leq z_{\mathrm{chg}}^{(i)}(t), \quad t = 1, 2, \dots, T-1 \\ & i = 1, 2, \dots, N_{\mathrm{Batt}} \\ \frac{\left|P_{\mathrm{dchg}}^{(i)}(t+1) - P_{\mathrm{dchg}}^{(i)}(t)\right|}{\mathrm{MAX \ DISCHARGE \ RATE}} &\leq z_{\mathrm{dchg}}^{(i)}(t), \quad t = 1, 2, \dots, T-1 \\ & i = 1, 2, \dots, N_{\mathrm{Batt}} \end{aligned}$$

จะได้ว่าปัญหา

minimize
$$J_{\text{smoothcharge}} = \sum_{t=1}^{T-1} \sum_{i=1}^{N_{\text{Batt}}} \left(\frac{\left| P_{\text{chg}}^{(i)}(t+1) - P_{\text{chg}}^{(i)}(t) \right|}{\text{MAX CHARGE RATE}} + \frac{\left| P_{\text{dchg}}^{(i)}(t+1) - P_{\text{dchg}}^{(i)}(t) \right|}{\text{MAX DISCHARGE RATE}} \right)$$

สมมูลกับ

minimize
$$\sum_{t=1}^{T-1} \sum_{i=1}^{N_{\text{Batt}}} \left(z_{\text{chg}}^{(i)}(t) + z_{\text{dchg}}^{(i)}(t) \right)$$

subject to
$$-z_{chg}^{(i)}(t) \le \frac{P_{chg}^{(i)}(t+1) - P_{chg}^{(i)}(t)}{MAX CHARGE RATE} \le z_{chg}^{(i)}(t), \qquad t = 1, \dots, T-1, \ i = 1, \dots, N_{Batt}$$

 $-z_{dchg}^{(i)}(t) \le \frac{P_{dchg}^{(i)}(t+1) - P_{dchg}^{(i)}(t)}{MAX DISCHARGE RATE} \le z_{dchg}^{(i)}(t), \quad t = 1, \dots, T-1, \ i = 1, \dots, N_{Batt}$

จากการจัดให้อยู่รูปของ epigraph form จะพบว่าปัญหาใหม่มีฟังก์ชันจุดประสงค์และเงื่อนไขบังคับเป็นเชิงเส้น ในตัวแปร z^{(i)}_{chg}, z^{(i)}_{dchg}, P^{(i)}_{chg}, P^{(i)}_{dchg}

การชาร์จแบตเตอรี่หลายลูกให้ทำงานคล้ายกัน (managing multiple batteries)

ในระบบที่มีแบตเตอรี่หลายลูกทำงานร่วมกัน ถ้ามีแบตเตอรี่บางลูกรับภาระงานมากกว่าลูกอื่นอย่างต่อเนื่อง ส่ง ผลให้แบตเตอรี่นั้นเสื่อมสภาพเร็วกว่าปกติได้ จึงมีความต้องการที่จะควบคุมให้แบตเตอรี่ทุกลูกทำงานใกล้เคียงกัน เพื่อบรรลุวัตถุประสงค์ดังกล่าว จึงมีการใช้ตัวแปรเสริมที่เรียกว่า สถานะแบตเตอรี่อ้างอิง (SoC_c) ซึ่งทำหน้าที่เป็น ค่ากลางในการเปรียบเทียบกับสถานะของแบตเตอรี่แต่ละลูก (SoC_i) โดยประเมินค่าความแตกต่างระหว่างแบตเตอรี่ แต่ละลูกกับสถานะแบตเตอรี่อ้างอิง และต้องการให้ผลรวมของค่าความแตกต่างทั้งหมดมีค่าน้อยที่สุด ซึ่งการประเมิน ค่าความแตกต่างนี้จะใช้ค่าสัมบูรณ์ เพื่อทำให้รูปแบบของปัญหาเป็นโปรแกรมเชิงเส้น

สำหรับระบบที่มีแบตเตอรี่ที่มีมากกว่าหรือเท่ากับ 3 ลูก

$$J_{\text{multibatt}} = \sum_{t=1}^{T} \sum_{i=1}^{N_{\text{Batt}}} \frac{|\text{SoC}_{i}(t) - \text{SoC}_{\text{C}}(t)|}{100}$$
(8)

สำหรับระบบที่มีแบตเตอรี่ 2 ลูก สามารถลดตัวแปรเสริมสถานะแบตเตอรี่อ้างอิงได้ เนื่องจากสามารถประเมิน ความแตกต่างของสถานะแบตเตอรี่ได้โดยตรงจากค่าผลต่างระหว่างแบตเตอรี่ทั้งสองลูก ดังนั้น จึงลดรูปของฟังก์ชัน จุดประสงค์ได้ดังนี้

$$J_{\text{multibatt}} = \sum_{t=1}^{T} \frac{|\text{SoC}_1(t) - \text{SoC}_2(t)|}{100}$$
(9)

การส่งเสริมการชาร์จแบตเตอรี่ (encouragement to charge battery)

ฟังก์ชันนี้แสดงถึงความต้องการให้แบตเตอรี่สั่งชาร์จเมื่อสถานะของแบตเตอรี่ยังไม่ถึงค่าสูงสุด โดยจะเปรียบ เทียบสถานะแบตเตอรี่ปัจจุบันเทียบกับสถานะแบตเตอรี่สูงสุด

$$J_{\text{chargebatt}} = \sum_{t=1}^{T} \sum_{i=1}^{N_{\text{Batt}}} \frac{\text{SoC}_{\max,i} - \text{SoC}_i(t)}{\text{SoC}_{\max,i} - \text{SoC}_{\min,i}}$$
(10)

ฟังก์ชันการประหยัดค่าไฟของ EMS

พลังงานไฟฟ้าที่ดึงจากกริด (Energy Unit)



รูป 7: แผนภาพแสดงพลังงานไฟฟ้าที่ดึงจากกริด

ความต้องการไฟฟ้าจากกริดนั้นบ่งบอกด้วย *P*_{net} โดยถ้า *P*_{net} มีค่าเป็นบวกนั่นหมายความว่าความต้องการ โหลดไฟฟ้ามีมากกว่าพลังงานไฟฟ้าที่ผลิตได้ ดังนั้นจึงต้องดึงพลังงานจากกริดเพิ่มดัง*รูปที่* 7 ในที่นี้จึงใช้ฟังก์ชัน หาค่าสูงสุด ในการบ่งบอกพลังงานที่ต้องการจากกริด แสดงดังสมการต่อไปนี้

$$J_{\text{cost}} = \text{Energy unit} = \sum_{t=1}^{T} \max(0, P_{\text{net}}(t))\Delta t$$
(11)

จาก max(0, P_{net}(t)) จะพบว่าฟังก์ชันนี้เป็นฟังก์ชันไม่เชิงเส้น (Nonlinear function) แต่สามารถจัดรูปฟังก์ชัน นี้ให้อยู่ในรูปแบบของ Epigraph form ได้ดังนี้ จะใช้ตัวแปรเสริม z(t) โดยที่ กำหนดให้

$$z(t) \ge \max(0, P_{\mathsf{net}}(t)), \qquad t = 1, 2, \dots, T$$

จึงได้ว่าปัญหา

minimize $\sum_{t=1}^{T} \max(0, P_{\mathsf{net}}(t)) \Delta t$

สมมูลกับ

$$\begin{array}{ll} \text{minimize} & \sum_{t=1}^{T} z(t) \Delta t \\ \text{subject to} & z(t) \geq 0, \qquad t=1,2,\ldots,T \\ & z(t) \geq P_{\mathsf{net}}(t), \quad t=1,2,\ldots,T \end{array}$$

จากการจัดให้อยู่รูปของ epigraph form จะพบว่าปัญหาใหม่มีฟังก์ชันจุดประสงค์และเงื่อนไขบังคับเป็นเชิง เส้นในตัวแปร $Z(t), P_{\sf net}$ โดย $P_{\sf net}$ นั้นเป็นเชิงเส้นในตัวแปร $P_{\sf chg}, P_{\sf dchg}, P_{\sf load}, P_{\sf pv}$ ตาม (6) ค่าไฟที่ต้องจ่ายเมื่อดึงพลังงานจากกริด (Energy Cost)



รูป 8: แผนภาพแสดงค่าไฟที่ต้องจ่ายเมื่อดึงไฟฟ้าจากกริด

เมื่อ $P_{net}(t)$ มีค่าเป็นบวกจะบ่งบอกถึงความต้องการดึงพลังไฟฟ้าจากกริด ซึ่งต้องเสียค่าใช้จ่ายดัง*รูปที่* 8 ฟังก์ชัน นี้จึงคำนวณค่าใช้จ่ายที่ต่ำที่สุดเมื่อดึงพลังงานจากกริดมาใช้ ซึ่งค่าใช้จ่ายเกิดจากผลคูณระหว่างค่า $P_{net}(t)$ และ b(t) โดย b(t) เป็นค่าไฟที่ต้องจ่ายเพื่อดึงไฟฟ้าจากกริด

$$J_{\text{cost}} = \text{Energy cost} = \sum_{t=1}^{T} b(t) \max(0, P_{\text{net}}(t)) \Delta t$$
(12)

จาก $b(t) \max(0, P_{net}(t)) \Delta t$ จะพบว่าฟังก์ชันนี้เป็นฟังก์ชันไม่เชิงเส้น แต่สามารถแปลงจากปัญหาการหาค่า เหมาะสุดของฟังก์ชันไม่เชิงเส้นเป็นฟังก์ชันเชิงเส้นโดยเทคนิค Epigraph form เช่นเดียวกับฟังก์ชันพลังงานไฟฟ้า ที่ดึงจากกริด

กำไรที่ได้จากการซื้อและขายไฟจากกริด (Profit)



รูป 9: แผนภาพแสดงกำไรที่ได้จากการซื้อและขายไฟจากกริด

ในกรณีที่สามารถขายพลังงานคืนให้กับกริดได้ ฟังก์ชันนี้จะคำนวณกำไรสูงสุดที่ได้จากการซื้อและขายไฟจาก กริด ซึ่งสมมูลกับการหาค่าต่ำสุดของกำไรสุทธิ (negative profit) โดยกำไรสุทธิคือค่าใช้จ่ายทั้งหมดเมื่อดึงพลังงาน จากกริด หักล้างกับรายได้เมื่อสามารถขายพลังงานให้กับกริด และกำหนดให้ *s*(*t*) คือ อัตราการขายพลังงานให้ กริด

$$J_{\text{cost}} = \sum_{t=1}^{I} \left[b(t) \max(0, P_{\text{net}}(t)) - s(t) \max(0, -P_{\text{net}}(t)) \right] \Delta t$$

ฟังก์ชันดังกล่าวไม่เป็นเชิงเส้น เนื่องจากประกอบด้วยฟังก์ชัน $\max(\cdot)$ จึงได้ว่า:

$$\max(0, P_{\mathsf{net}}(t)(t)) = \frac{P_{\mathsf{net}}(t) + |P_{\mathsf{net}}(t)|}{2}$$
$$\max(0, -P_{\mathsf{net}}(t)) = \frac{-P_{\mathsf{net}}(t) + |P_{\mathsf{net}}(t)|}{2}$$

และ

$$J_{\text{cost}} = \sum_{t=1}^{T} \left[\frac{b(t) + s(t)}{2} \cdot P_{\text{net}}(t) + \frac{b(t) - s(t)}{2} \cdot |P_{\text{net}}(t)| \right] \Delta t$$
(13)

เนื่องจาก |P_{net}(t)| เป็นฟังก์ชันไม่เชิงเส้น จึงนิยามตัวแปร P_{net_abs}(t) ขึ้นมาเพื่อใช้เป็นค่าขอบบนของ |P_{net}(t)| โดยมีจุดประสงค์เพื่อผ่อนคลายข้อจำกัดของฟังก์ชัน |P_{net}(t)| และแปลงปัญหาไม่เชิงเส้นเป็นปัญหาเชิงเส้น โดย มีเงื่อนไขบังคับคือ

$$-P_{\mathsf{net_abs}}(t) \le P_{\mathsf{net}}(t) \le P_{\mathsf{net_abs}}(t), \quad \text{ for } t = 1, 2, \dots, T$$

ทำให้ฟังก์ชันวัตถุประสงค์สามารถเขียนใหม่ในรูปเชิงเส้นได้เป็น:

$$\begin{array}{ll} \text{minimize} & \sum_{t=1}^{T} \left[\frac{b(t) + s(t)}{2} \cdot P_{\mathsf{net}}(t) + \frac{b(t) - s(t)}{2} \cdot P_{\mathsf{net_abs}}(t) \right] \Delta t \\ \text{subject to} & -P_{\mathsf{net_abs}}(t) \leq P_{\mathsf{net}}(t) \leq P_{\mathsf{net_abs}}(t), \quad t = 1, 2, \dots, T \end{array}$$

้อย่างไรก็ตาม แม้จะมีการปรับรูปแบบของปัญหาให้เป็นเชิงเส้น แต่หากไม่มีการกำหนดข้อจำกัดเพิ่มเติมที่เหมาะ สม ปัญหารูปแบบใหม่นี้อาจนำไปสู่ปัญหาที่ไม่มีขอบเขตล่าง (unbounded solution)

พิจารณา

- กรณีที่ b(t) > s(t): จะได้ว่า $\frac{b(t)-s(t)}{2} > 0$ ทำให้พจน์ที่คูณกับ $P_{\text{net}_abs}(t)$ มีค่าเป็นบวก และระบบจะ ไม่มีแรงจูงใจที่จะเพิ่ม $P_{\text{net}_abs}(t)$ อย่างไม่มีที่สิ้นสุด เพราะทำให้ค่าฟังก์ชันวัตถุประสงค์มีค่าสูงขึ้น
- กรณีที่ b(t) < s(t): จะได้ว่า $\frac{b(t)-s(t)}{2} < 0$ ทำให้พจน์ที่คูณกับ $P_{\text{net}_abs}(t)$ มีค่ากลายเป็นลบ และหาก ไม่มีข้อจำกัดเพิ่มเติมใดๆ ระบบจะมีแรงจูงใจให้ $P_{\text{net}_abs}(t) \to \infty$ เพื่อทำให้ค่าฟังก์ชันวัตถุประสงค์ลดลง เรื่อยๆ ซึ่งจะทำให้ปัญหาต้นทุนไม่มีขอบเขตล่าง (unbounded)

ดังนั้น เพื่อให้ปัญหาต้นทุนมีขอบเขตล่างที่แน่นอน และสามารถหาคำตอบที่เหมาะสมได้ จำเป็นต้องกำหนด เงื่อนไข กล่วคือ อัตราการซื้อไฟฟ้า มากกว่าอัตราขายไฟฟ้า

$$b(t) \ge s(t)$$

ฟังก์ชันการติดตามผลเฉลยหลายวันล่วงหน้า (TrackDA)

เนื่องจากแผน Hour-Ahead มุ่งเน้นการตัดสินใจในระยะหลายชั่วโมงล่วงหน้า จึงมักละเลยผลกระทบที่อาจ เกิดขึ้นในอนาคตระดับหลายวันล่วงหน้า เช่น สถานะแบตเตอรี่ที่อาจไม่เพียงพอต่อความต้องการพลังงานในช่วง เวลาวันถัดไป ซึ่งอาจนำไปสู่การดำเนินงานที่ไม่มีประสิทธิภาพหรือขาดความต่อเนื่องในระบบ ดังนั้นเพื่อให้ผลลัพธ์ จากการหาค่าเหมาะที่สุดในกรอบ Hour-Ahead มีความสอดคล้องกับการวางแผน Day-Ahead จึงมีการใช้ฟังก์ชัน TrackDA เพื่อเปรียบเทียบผลลัพธ์จริงกับคำตอบจากการวางแผนในกรอบ Day-Ahead โดยฟังก์ชันนี้ต้องใช้ข้อมูล จากผลเฉลย Day-Ahead ล่วงหน้า ได้แก่ ค่ากำลังไฟฟ้าที่ต้องการจากกริด (*P*_{net, ref}), การอัดประจุแบตเตอรี่ (*P*_{chg, ref}), และการคายประจุ (*P*_{dchg, ref}) เพื่อคำนวณค่าความเบี่ยงเบนระหว่างการวางแผนระหว่าง Hour-Ahead และ Day-Ahead นอกจากนี้มีการทำ *normalization* เพื่อให้ค่าทั้งหมดอยู่ในสเกลเดียวกัน ได้แก่ การหารอัตรา การเปลี่ยนแปลงของค่ากำลังไฟฟ้าที่ต้องการจากกริดระหว่าง Hour-Ahead และ Day-Ahead ด้วยค่าสูงสุดระหว่าง ความสามารถในการผลิตพลังงานไฟฟ้าสูงสุดของระบบผลิตไฟฟ้าจากพลังงานแสงอาทิตย์กับปริมาณโหลดสูงสุดที่ ระบบต้องรองรับ, การหารอัตราการเปลี่ยนแปลงของกำลังการอัดประจุแบตเตอรี่ระหว่าง Hour-Ahead และ Day-Ahead ด้วยอัตราการอัดประจุสูงสุด, และการหารอัตราการเปลี่ยนแปลงของกำลังการคายประจุแบตเตอรี่ระหว่าง Hour-Ahead และ Day-Ahead ด้วยอัตราการคายประจุสูงสุด ซึ่งช่วยลดผลกระทบจากค่าที่มีขนาดใหญ่เกินไป ทำให้การเปรียบเทียบผลลัพธ์ระหว่างแผน Day-Ahead กับการดำเนินการแบบ Hour-Ahead มีความแม่นยำขึ้น

$$J_{\text{trackDA}} = \sum_{t=1}^{T} \left\{ w_{\text{net}} \frac{\left| P_{\text{net},\text{HA}}(t) - P_{\text{net},\text{ref}}(t) \right|}{\max(PV_{\text{capacity}}, PL_{\text{capacity}})} + w_{\text{chg}} \sum_{i=1}^{2} \frac{\left| P_{\text{chg},\text{HA}}^{(i)}(t) - P_{\text{chg},\text{ref}}^{(i)}(t) \right|}{\text{MAX CHARGE RATE}} + w_{\text{dchg}} \sum_{i=1}^{2} \frac{\left| P_{\text{dchg},\text{HA}}^{(i)}(t) - P_{\text{dchg},\text{ref}}^{(i)}(t) \right|}{\text{MAX DISCHARGE RATE}} \right\}$$
(14)

กล่าวโดยสรุป ปัญหาการหาค่าเหมาะที่สุดของ EMS ภายใต้กรอบ Day-Ahead แสดงได้ดังนี้

minimize subject to	$J_{\text{cost}} + w_m J_{\text{multibatt}} + w_s J_{\text{smooth charge}} + w_c J_{\text{charge batt}}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's terminal SOC (5) Battery's SOC constraint (4)	(15)
------------------------	--	------

และปัญหาการหาค่าเหมาะที่สุดของ EMS ภายใต้กรอบ Hour-Ahead แสดงได้ดังนี้

minimize subject t	$J_{\text{cost}} + w_m J_{\text{multibatt}} + w_s J_{\text{smooth charge}} + w_c J_{\text{charge batt}} + J_{\text{trackDA}}$ To Power balance constraints (6)	
	Battery dynamic (1)	(16)
	Battery charge/discharge constraints (2) - (3)	(10)
	Battery's terminal SOC (5)	
	Battery's SOC constraint (4)	

3.2 การพยากรณ์ข้อมูลโดยใช้แบบจำลอง Long Short-Term Memory (LSTM)

การพยากรณ์ข้อมูลเป็นสิ่งที่จำเป็นสำหรับระบบการจัดการพลังงานเพื่อที่จะทำให้ระบบวางแผนจัดการพลังงานให้ มีประสิทธิภาพ ปัจจัยสำคัญที่ใช้การพยากรณ์ใน EMS ได้แก่ การพยากรณ์ความต้องการใช้ไฟฟ้าของผู้บริโภค (load forecasting) และการพยากรณ์พลังงานที่ผลิตได้จากแสงอาทิตย์ (solar forecasting) นอกจากนี้การพยากรณ์ มีการพยากรณ์ระยะหลายวันล่วงหน้า (Day-Ahead, DA) และการพยากรณ์ระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA) โดยทั้งสองแบบมีข้อแตกต่างที่เวลาที่ต้องการพยากรณ์ล่วงหน้า LSTM เป็นแบบจำลองที่เหมาะสมสำหรับข้อมูลแบบลำดับเวลา (Time Series) และข้อมูลเชิงลำดับ (Sequential Data) โดยแบบจำลอง LSTM พัฒนามาจากโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent neural network, RNN) ซึ่ง LSTM มีความสามารถในการจดจำบริบทจากข้อมูลในอดีตได้อย่างมีประสิทธิภาพกว่า เนื่องจาก โครงสร้างของ RNN จะมีเพียงเลเยอร์เดียว เช่น tanh layer ที่ใช้ประมวลผลข้อมูลในแต่ละช่วงเวลา ในขณะที่ LSTM มีโครงสร้างที่ซับซ้อนกว่า ซึ่งใน [6] ได้อธิบายกลไลหลักของ LSTM ว่าประกอบไปด้วยกลไกหลักสำคัญ 3 ส่วนหรือที่เรียกว่า ประตู (gate) ได้แก่ Forget Gate layer, Input Gate layer, และ Output Gate layer ซึ่ง ทำหน้าที่ควบคุมการไหลของข้อมูลเข้า-ออกจากหน่วยความจำอย่างเป็นระบบดัง *รูปที่* 10



รูป 10: แบบจำลองโครงข่ายประสาทเทียมแบบ RNN และ LSTM [2]

3.2.1 กลไกการควบคุมข้อมูลภายในหน่วยความจำของ LSTM

Forget Gate Layer Forget gate จะทำหน้าที่ในการตัดสินใจว่าข้อมูลใดจะถูกลบออกจาก cell state ซึ่ง cell state คือหน่วยความจำหลักของ LSTM ซึ่งเก็บข้อมูลที่ใช้ในการตัดสินใจในอนาคตและสามารถส่งผ่านไป ได้ตลอดทั้งลำดับ โดย Forget gate จะนำข้อมูลขาออกของโหนดก่อนหน้า (h_{t-1}) และข้อมูลขาเข้าที่โหนดนั้นๆ (x_t) ผ่านฟังก์ชัน sigmoid และแสดงผลลัพธ์ระหว่างค่า 0 และ 1 เมื่อมีค่าเป็น 0 จะลบข้อมูล cell state เดิม ออก แต่ถ้ามีค่าเป็น 1 จะเก็บ cell state เดิมต่อไป

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \tag{17}$$

- คือ เวกเตอร์ของค่า forget gate ณ เวลา t• f_t
- คือ ค่าน้ำหนักของ input x_t • W_f
- คือ ค่าน้ำหนักของ hidden state h_{t-1} • U_f
- คือ bias ของ forget gate • b_f
- คือ ฟังก์ชัน sigmoid ที่ให้ค่าอยู่ระหว่าง 0 ถึง 1 • σ

Input gate ใช้ตัดสินใจว่าข้อมูลใหม่ควรถูกเพิ่มเข้าไปใน cell state หรือไม่ โดยประกอบ Input Gate Layer ด้วยสองขั้นตอน คือการตัดสินใจเปิดรับข้อมูลใหม่ (i_t) และการสร้างข้อมูลใหม่ $(ilde{c}_t)$ ที่จะถูกเพิ่มเข้าไปใน cell state โดยใช้ฟังก์ชัน Hyperbolic Tangent

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \tag{18}$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \tag{19}$$

- คือ input gate ที่ควบคุมการเปิดรับข้อมูลใหม่ • i_t
- คือ candidate vector ที่จะถูกเพิ่มเข้า cell state • \tilde{c}_t
- คือ ค่าน้ำหนักของ input x_t ส้ำหรับ input gate และ cell update • W_i, W_c
- คือ ค่าน้ำหนักของ h_{t-1} สำหรับ input gate และ cell update • U_i, U_c
- คือ bias ของแต่ละ gate • b_i, b_c
- คือ ฟังก์ชัน sigmoid และ tanh ตามลำดับ • σ , tanh

หลังจากได้ f_t จาก forget gate i_t , และ \tilde{c}_t จาก input gate แล้ว cell state จะถูก Cell State Update ปรับค่าใหม่ดัง (20)

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \tag{20}$$

- คือ cell state หลังจากอัปเดต • c_t
- คือ Hadamard product • •

Output gate ทำหน้าที่ควบคุมว่าข้อมูลส่วนใดใน cell state ที่ควรถูกนำมาใช้เป็น Output Gate Layer ข้อมูลขาออกของโหนดปัจจุบัน โดยใช้ฟังก์ชัน sigmoid เพื่อพิจารณาและกำหนดว่าองค์ประกอบใดของ cell state จะแสดงออกมา จากนั้น cell state ที่ได้รับปรับค่าจะถูกส่งผ่านฟังก์ชัน Hyperbolic Tangent เพื่อควบคุมให้ อยู่ในช่วงค่าระหว่าง –1 ถึง 1 และคูณแบบจุดต่อจุด (Hadamard product) กับค่าที่ได้จากฟังก์ชัน sigmoid ก่อนหน้า ส่งออกมาเป็นผลลัพธ์ h_t

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \tag{21}$$

$$h_t = o_t \odot \tanh(c_t) \tag{22}$$

- คือ output gate ที่ควบคุมข้อมูลที่จะแสดงออก • o_t
- คือ ข้อมูลขาออกของ hidden state ณ เวลา t• h_t
- คือ ค่าน้ำหนักของ input และ hidden state ใน output gate คือ bias ของ output gate • W_o, U_o
- *b*_o

3.2.2 สถาปัตยกรรมของแบบจำลองพยากรณ์



รูป 11: แผนภาพแสดงสถาปัตยกรรมของแบบจำลองพยากรณ์

การออกแบบ แบบจำลอง LSTM เพื่อใช้สำหรับการพยากรณ์ จำเป็นต้องพิจารณาค่าไฮเปอร์พารามิเตอร์หลาย ค่า โดยในโครงงานนี้จะกล่าวถึง 3 ค่าที่สำคัญ ได้แก่ **จำนวนชั้นของ LSTM, ขนาดของ hidden state** และ **จำนวนชั้น Fully Connected (Dense Layers)** แสดงดัง *รูปที่* 11

จำนวนชั้นของ LSTM (num_layers) คือ จำนวนของเลเยอร์ LSTM ที่วางซ้อนกันในโครงสร้างของแบบ จำลอง เมื่อมีจำนวนเลเยอร์มาก แบบจำลองจะสามารถเรียนรู้ลักษณะลำดับของข้อมูลที่ซับซ้อนได้มากขึ้น แต่ถ้า มีจำนวนเลเยอร์ที่มากเกินไปจะเกิดการเรียนรู้มากเกิน (overfitting) และทำให้แบบจำลองมีความซับซ้อนมากเกิน ความจำเป็น นอกจากนี้การเพิ่มจำนวนชั้นยังส่งผลให้เวลาในการประมวลผลและการฝึกโมเดลเพิ่มสูงขึ้นด้วย

ขนาดของ Hidden State (hidden_size) แสดงถึงจำนวนของหน่วยประมวลผลภายในแต่ละ LSTM layer ซึ่งทำหน้าที่เก็บสถานะของระบบในแต่ละช่วงเวลา โดยภายในแต่ละหน่วยจะมีค่าน้ำหนักที่ถูกเรียนรู้จากข้อมูล ซึ่ง ใช้ในการประมวลผล input ปัจจุบันร่วมกับสถานะก่อนหน้า ผ่านการคำนวณที่เป็นการผลรวมเชิงเส้นของข้อมูล ขาเข้าและค่าน้ำหนัก เพื่อหารูปแบบของข้อมูล (temporal patterns)

จำนวนชั้นของ Fully Connected (fc_layers) หลังจากที่แบบจำลอง LSTM ประมวลผลข้อมูลในอดีต และเรียนรู้รูปแบบของข้อมูลได้แล้ว ผลลัพธ์ที่ได้จะถูกนำไปรวมกับข้อมูลคุณลักษณะภายนอกที่ทราบล่วงหน้า (เช่น ค่าพยากรณ์อุณหภูมิ หรือปฏิทินวันเปิดทำการ) เพื่อสร้างเวกเตอร์ข้อมูลขาเข้าสำหรับการพยากรณ์ ในการพยากรณ์ ค่าที่ตำแหน่งเวลา *t*+*k* แบบจำลองจะใช้ทั้งผลลัพธ์จาก LSTM และคุณลักษณะภายนอกที่สอดคล้องกับช่วงเวลา *t*+*k* เช่น อุณหภูมิ หรือปฏิทินวันเปิดทำการ เพื่อให้แบบจำลองสามารถเข้าใจบริบทของช่วงเวลานั้นได้อย่างเหมาะ สม ซึ่งถูกออกแบบให้ค่าทำนายในแต่ละ timestep มีชั้น Fully Connected ที่แตกต่างกัน เป็นฟังก์ชันของทั้ง สองส่วนดังกล่าว โดยเวกเตอร์ข้อมูลนี้จะถูกส่งเข้าสู่ชั้น Fully Connected ซึ่งทำหน้าที่รวมเชิงเส้นกับน้ำหนักของ แบบจำลอง และผ่านฟังก์ชันกระตุ้น (activation function) เพื่อให้ได้ค่าทำนายในอนาคต น้ำหนักของแบบจำลอง เหล่านี้จะถูกเรียนรู้ระหว่างกระบวนการฝึก เพื่อให้ผลลัพธ์ของการพยากรณ์มีความแม่นยำสูงขึ้น โดยเฉพาะในกรณี ที่ข้อมูลเป้าหมายมีความแปรผันตามเงื่อนไขภายนอกที่เปลี่ยนแปลงไปตามเวลา

3.3 การควบคุมเชิงทำนายแบบจำลอง (Model Predictive Control, MPC)

Model Predictive Control (MPC) หรือ Receding Horizon Control (RHC) เป็นวิธีการควบคุมแบบป้อน กลับ ซึ่งทำงานโดยอาศัยการวางแผนล่วงหน้าในช่วงเวลาจำกัด จากนั้นจึงใช้ข้อมูลล่าสุดในแต่ละช่วงเวลาในการ อัปเดตแผนอย่างต่อเนื่อง ในระบบจัดการพลังงานที่มีความไม่แน่นอนสูง เนื่องจากพฤติกรรมของโหลดไฟฟ้าและ พลังงานแสงอาทิตย์เปลี่ยนแปลงตามเวลา MPC จึงถูกนำมาประยุกต์ใช้กับระบบจัดการพลังงานเนื่องจากสามารถ พยากรณ์ล่วงหน้าและวางแผนควบคุมได้อย่างเหมาะสมภายใต้ข้อจำกัดของระบบ งานวิจัย [4] ได้เสนอระเบียบ วิธีของ MPC ทั้งหมด 3 ขั้นตอน คือ การพยากรณ์, การหาค่าเหมาะที่สุด, การดำเนินการ





พิจารณาระบบพลศาสตร์แบบไม่ต่อเนื่องในรูปแบบเชิงเส้นดังนี้:

$$x(t+1) = A(t)x(t) + B(t)u(t) + c(t)$$

โดยที่ $x(t) \in \mathbb{R}^n$ คือเวกเตอร์สถานะของระบบ, $u(t) \in \mathbb{R}^m$ คือเวกเตอร์ควบคุม และ c(t) คืออินพุต ภายนอกในช่วงเวลา t ทั้งนี้ระบบยังอยู่ภายใต้ข้อจำกัด $(x(t), u(t)) \in C(t)$ และมีฟังก์ชันต้นทุนแบบจุดเวลา $\ell(t, x(t), u(t))$ ซึ่งใช้ในการประเมินคุณภาพของการควบคุม

1. การพยากรณ์ (Prediction)

ในแต่ละช่วงเวลา t ระบบจะทำการประเมินค่าพารามิเตอร์ต่าง ๆ สำหรับช่วงเวลา t ถึง t + T ได้แก่ เมทริกซ์ พลศาสตร์ $\hat{A}(t|t)$, เมทริกซ์ควบคุม $\hat{B}(t|t)$, อินพุตภายนอก $\hat{c}(t|t)$, ข้อจำกัด $\hat{C}(t|t)$, ฟังก์ชันต้นทุน $\hat{\ell}(t|t, x, u)$ และสถานะเริ่มต้น $\hat{x}(t|t)$ ค่าประมาณเหล่านี้สามารถได้จากการประมาณเชิงสถิติ หรือการใช้แบบจำลองพยากรณ์

2. การหาค่าเหมาะที่สุด (Optimization)

ระบบจะใช้ค่าที่ประมาณไว้ในการแก้ปัญหาการเพิ่มประสิทธิภาพในช่วงเวลา t ถึง t+T เพื่อหาลำดับการควบคุม ที่เหมาะสม โดยมีรูปแบบดังนี้: $\begin{array}{ll} \text{minimize} & \displaystyle \frac{1}{T+1} \sum_{\tau=t}^{t+T} \hat{\ell}(\tau|t, \hat{x}(\tau), \hat{u}(\tau)) \\ \text{subject to} & \displaystyle \hat{x}(\tau+1) = \hat{A}(\tau|t) \hat{x}(\tau) + \hat{B}(\tau|t) \hat{u}(\tau) + \hat{c}(\tau|t) \\ & \displaystyle (\hat{x}(\tau), \hat{u}(\tau)) \in \hat{C}(\tau|t) \\ & \displaystyle \hat{x}(t) = \hat{x}(t|t) \end{array}$

ผลลัพธ์ที่ได้จากการหาค่าเหมาะที่สุดคือแผนดำเนินการควบคุมล่วงหน้า $\hat{u}^*(t),...,\hat{u}^*(t+T)$

3. การดำเนินการ (Execution)

เมื่อระบบได้แผนการควบคุมจากผลลัพธ์ของการหาค่าเหมาะที่สุดแล้ว ระบบจะเลือกนำคำสั่งควบคุมเฉพาะในช่วง เวลาปัจจุบันไปใช้งานจริงเท่านั้น โดยกำหนดให้ $u(t) = \hat{u}^*(t)$ ส่วนคำสั่งควบคุมในช่วงเวลาถัดไป t + 1 ถึง t + T จะยังไม่ถูกนำไปใช้ แต่มีหน้าที่เป็นแนวทางช่วยให้การเลือกคำสั่งควบคุมในช่วงเวลาปัจจุบันมีความเหมาะ สมที่สุด

เมื่อระบบดำเนินการควบคุมที่เวลา t แล้ว ระบบจะเข้าสู่ช่วงเวลา t+1 ซึ่งจะมีข้อมูลใหม่เข้ามา จากนั้นจะวนกลับ ไปเริ่มดำเนินการขั้นตอนการพยากรณ์อีกครั้ง และทำการวางแผนใหม่อย่างต่อเนื่องในลักษณะของวงรอบ (receding horizon)

การประยุกต์ใช้ MPC ในระบบจัดการพลังงาน



รูป 13: ขั้นตอนการทำ MPC ของแบตเตอรี่

ในโครงงานนี้มีวัตถุประสงค์เพื่อควบคุมการทำงานของแบตเตอรี่ โดยกระบวนการทั้งหมดแสดงไว้ใน *รูปที่* 13 ซึ่งสถานะของระบบที่ต้องการควบคุมคือ สถานะแบตเตอรี่ และคำสั่งควบคุมคือกำลังไฟฟ้าในการอัดและคายประจุ ในส่วน**การพยากรณ์** จะใช้แบบจำลองที่พัฒนามาจากแบบจำลอง LSTM ซึ่งผลลัพธ์ของการพยากรณ์คือค่าพยากรณ์ ของโหลดไฟฟ้าและกำลังไฟฟ้าที่ผลิตได้จากแสงอาทิตย์ ที่ความละเอียด 5 และ 15 นาที ค่าพยากรณ์ที่ได้จะถูก นำมาวิเคราะห์ร่วมกับสถานะของแบตเตอรี่ในช่วงเวลาปัจจุบัน (SoC) ซึ่งคำนวณจากสมการพลศาสตร์ของแบตเตอรี่ จากนั้นระบบจะดำเนินการคำนวณหาแผนควบคุมที่เหมาะสมผ่านกระบวน**การหาค่าเหมาะที่สุด** โดยอิงตามฟังก์ชัน จุดประสงค์หลายรูปแบบของ EMS เมื่อทำการหาค่าเหมาะที่สุดแล้วขั้นตอนถัดไป คือขั้นตอน**การดำเนินการ**โดย ผลลัพธ์ที่ได้จากกระบวนการหาค่าเหมาะที่สุด คือ รูปแบบสำหรับการชาร์จและการคายประจุของแบตเตอรี่ที่เหมาะ ที่สุด ซึ่งจะถูกคำนวณล่วงหน้าสำหรับหลายช่วงเวลา แต่ระบบจะเลือกใช้งานเฉพาะค่าควบคุมในช่วงเวลาปัจจุบัน เท่านั้น ซึ่งค่านี้จะเป็นค่ากำลังไฟฟ้าที่นำไปสั่งให้แบตเตอรี่ทำงานจริง หลังจากนั้น สถานะของแบตเตอรี่จะถูกปรับ ค่าใหม่ เพื่อใช้เป็นข้อมูลเริ่มต้นในการตัดสินใจรอบถัดไป และกระบวนการดังกล่าวจะถูกดำเนินซ้ำอย่างต่อเนื่อง ในแต่ละช่วงเวลา จนกว่าจะครบช่วงแผนควบคุมทั้งหมด

4 การเตรียมข้อมูล (Data Preparation)

4.1 การปรับค่ากำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์

ข้อมูลกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ (P_{pv}) และความเข้มแสง (I) ในโครงงานนี้ได้มาจากแพลตฟอร์ม CUEE และมิเตอร์ของ รศ. ดร.สุรพงศ์ สุวรรณกวิน จากการวิเคราะห์ข้อมูลกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ พบว่า ตั้งแต่วันที่ 2 สิงหาคม 2566 เป็นต้นมา ประสิทธิภาพของระบบมีแนวโน้มลดลง โดยเฉพาะในช่วงเวลาเที่ยงวันซึ่ง ควรเป็นช่วงที่ผลิตไฟฟ้าได้สูงสุด ปรากฏการณ์นี้สามารถตรวจสอบได้โดยการวิเคราะห์ความสัมพันธ์ระหว่างค่ากำลัง ไฟฟ้าที่ผลิตได้ กับค่าความเข้มแสผ่านพารามิเตอร์ α ตามสมการ (23)

$$P_{\rm pv}(t) = \alpha(t) \cdot I(t),$$
 โดยที่ $t \in$ ช่วงเวลา 07:00 ถึง 18:00 (23)

ค่าพารามิเตอร์ α แสดงถึงประสิทธิภาพของระบบพลังงานในช่วงเวลานั้นๆ ซึ่งในระบบที่เสถียรจะมีค่าคงที่ หรือใกล้เคียงกัน หากค่าดังกล่าวลดลงอย่างมีนัยสำคัญ แสดงถึงประสิทธิภาพที่ลดลงของระบบ



Efficiency vs. Time freq = 5min

รูป 14: กราฟเปรียบเทียบค่าเฉลี่ย lpha ก่อนและหลังวันที่ 2 สิงหาคม 2566

รูปที่ 14 พบว่าค่าของ α มีแนวโน้มลดลงอย่างชัดเจนหลังวันที่ 2 สิงหาคม 2566 แสดงถึงการลดลงของ ประสิทธิภาพระบบ ทำให้ในช่วงเวลาหลังวันที่ 2 สิงหาคม 2566 ปรับค่ากำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ให้ สะท้อนศักยภาพของระบบได้อย่างถูกต้อง จะมีการคำนวณตัวคูณปรับเทียบ k ซึ่งนิยามจากอัตราส่วนระหว่างค่า เฉลี่ยของ α ก่อน (α₁) และหลัง (α₂) วันที่ดังกล่าวตามสมการ (24)

$$k = \frac{\alpha_1}{\alpha_2} \tag{24}$$

โดยที่

- α_1 คือ ค่าเฉลี่ยของ α ก่อนวันที่ 2 สิงหาคม 2566
- α_2 คือ ค่าเฉลี่ยของ α หลังวันที่ 2 สิงหาคม 2566 (รายเดือน)

จากนั้นนำค่าตัวคูณ k ไปใช้ในการปรับค่าพลังงานให้ถูกต้องตามสมการ (25)

$$P_{\text{pv,corr}}(t) = P_{\text{pv}}(t) \cdot k \tag{25}$$

Solar power vs. Time (2023-08) freq = 15min



รูป 15: กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ $P_{
m pv}$ และ $P_{
m pv,corr}$

โดยค่าที่ได้จาก P_{pv,corr} นี้จะใช้แทนค่าที่วัดได้จริง เพื่อสะท้อนประสิทธิภาพของระบบในกรณีที่ไม่มีการลดลง ของ *a*

รูปที่ 15 แสดงกราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ *P*_{pv} และ *P*_{pv,corr} จะเห็นได้ว่าค่า กำลังไฟฟ้าที่ผลิตได้ (*P*_{pv}) มีแนวโน้มลดลงในช่วงหลังจากวันที่ 2 สิงหาคม พ.ศ. 2566 ซึ่งอาจเกิดจากผลกระทบ ของการเสื่อมสภาพของแผงโซลาร์หรืออุปกรณ์ประกอบอื่น หลังจากปรับค่าตาม (24) ค่ากำลังไฟฟ้าที่ปรับ (*P*_{pv,corr}) มีลักษณะอยู่ในระดับใกล้เคียงกับค่าก่อนเกิดความเสื่อม ซึ่งช่วยให้เห็นแนวโน้มพลังงานที่ควรจะได้ หากไม่มีการ เปลี่ยนแปลงของประสิทธิภาพระบบ โดยความแตกต่างระหว่าง *P*_{pv} และ*P*_{pv,corr} สามารถใช้เป็นตัวบ่งชี้ปริมาณ พลังงานที่สูญเสียไป



4.2 การเตรียมข้อมูลสำหรับการพยากรณ์ (Forecasting Data)

รูป 16: แผนภาพการเตรียมข้อมูลสำหรับการพยากรณ์

ในการดำเนินงานระบบจัดการพลังงานอย่างมีประสิทธิภาพ จำเป็นต้องอาศัยการพยากรณ์ข้อมูลล่วงหน้าใน

ช่วงเวลาต่างๆ โดยเฉพาะในระดับ 15 นาทีสำหรับการวางแผนระยะหลายวันล่วงหน้า (Day-Ahead) และระดับ 5 นาทีสำหรับการวางแผนระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead) การเตรียมข้อมูลเพื่อการพยากรณ์จึงเป็น ขั้นตอนที่สำคัญ เพื่อให้โมเดลการพยากรณ์สามารถเรียนรู้และประมวลผลล่วงหน้าได้อย่างแม่นยำ ข้อมูลที่ใช้ในการ พยากรณ์ครอบคลุมหลากหลายปัจจัย ทั้งด้านโหลดไฟฟ้า สภาพอากาศ และความเข้มแสงจากดวงอาทิตย์ ซึ่งล้วน มีอิทธิพลต่อพฤติกรรมการใช้พลังงานและการผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ โดยสามารถจำแนกเป็นหมวดหมู่ ได้แก่ ข้อมูลโหลด, ข้อมูลความเข้มแสง, ข้อมูลอุณหภูมิโดยรอบ, และข้อมูลดัชนีเมฆ แสดงใน*รูปที่* 16 เป็นก ระบวนการเตรียมข้อมูลที่ใช้สำหรับการพยากรณ์ โดยข้อมูลแต่ละประเภทผ่านกระบวนการต่างๆ เช่น การกรอง ข้อมูลที่ไม่สมบูรณ์, การเติมค่าที่ขาดหาย, และการปรับความถี่ของข้อมูลให้เหมาะสม ทั้งนี้ข้อมูลความเข้มแสง และ ข้อมูลพยากรณ์สภาพอากาศจะถูกประมวลผลให้มีความละเอียดในระดับ 5 และ 15 นาที ขณะที่ข้อมูลภาพถ่าย ดาวเทียมจะถูกใช้ในการคำนวณดัชนีเมฆในรูปแบบต่างๆ ก่อนนำมารวมและปรับความถี่ให้เหมาะสมเช่นกัน เพื่อ ให้ได้ชุดข้อมูลนำเข้าที่มีความครบถ้วน และสอดคล้องกับช่วงเวลาที่โมเดลต้องใช้ในการพยากรณ์

4.2.1 ข้อมูลโหลด

ข้อมูลโหลดได้มาจากแพลฟอร์ม CUBEM และมิเตอร์ของ รศ. ดร.สุรพงศ์ สุวรรณกวิน และได้ถูกปรับความละเอียด ข้อมูลให้เป็น 5 และ 15 นาทีตามลำดับ



Power Consumption

รูป 17: กราฟอนุกรมเวลาของโหลดไฟฟ้า

รูปที่ 17 แสดงถึงกำลังไฟฟ้าที่โหลดไฟ้าบริโภคระหว่างวันที่ 14 มกราคม 2567 ถึง 4 กุมภาพันธ์ 2567 พบว่ารูปแบบการใช้พลังงานของโหลดมีความสัมพันธ์กับเหตุการณ์เฉพาะ เช่น วันหยุด และวันที่มีการใช้งานห้อง ปฏิบัติการ ซึ่งมีผลให้ปริมาณการใช้ไฟฟ้ามีการเปลี่ยนแปลงอย่างมีนัยสำคัญในแต่ละช่วงเวลา จึงได้ว่าวันที่มีการ ใช้งานห้องปฏิบัติการ (*L*_d), ชั่วโมงที่มีการใช้งานห้องปฏิบัติการ (*L*_d), และวันเปิดทำการของมหาลัย (*W*_d) เป็น ข้อมูลคุณลักษณะของโหลดไฟฟ้า

โดยกำหนดให้

$$\begin{split} L_d(t) &= \begin{cases} 1, & \text{ido } t \text{ ifujuiniin} \text{shifts} \text{shifts}$$

4.2.2 ข้อมูลความเข้มแสง (Irradiance)

ข้อมูลความเข้มแสงในโครงงานนี้ได้มาจากแพลตฟอร์ม CUEE (I), แพลตฟอร์ม SoDa (Solar radiation Data) (I_{NWP}) [7], และความเข้มแสงภายใต้สภาวะท้องฟ้าแจ่มใส (I_{ctr}) ได้มาจากการคำนวณ Clear Sky Model [8] โดยได้ปรับความละเอียดเชิงเวลาของข้อมูลให้อยู่ในช่วง 5 และ 15 นาทีตามลำดับ



Time series of irradiance

รูป 18: กราฟอนุกรมเวลาของความเข้มแสง $I, I_{\rm NWP}$, และ $I_{\rm clr}$

ตัวอย่างข้อมูลในรูปที่ 18 แสดงกราฟอนุกรมเวลาของความเข้มแสง *I*, *I*_{NWP}, และ*I*_{clr} โดยจะเห็นว่าความเข้ม แสงมีลักษณะคล้ายคลึงกันในแต่ละวัน และมีค่าสูงสุดในช่วงเวลาประมาณ 12.00 น. นอกจากนี้ค่าความเข้มแสง จากมิเตอร์แสดงความผันผวนสูงเนื่องจากผลกระทบของสภาพอากาศ เช่น เมฆหรือหมอก ขณะที่ค่าความเข้มแสง จากแบบจำลองการพยากรณ์อากาศเชิงตัวเลขมีความผันผวนน้อยกว่า เนื่องจากเป็นค่าที่ได้มาจากการพยากรณ์เชิง ฟิสิกส์ และความเข้มแสงภายใต้สภาวะท้องฟ้าแจ่มใสมีค่ามากที่สุดและมีความต่อเนื่องสม่ำเสมอ เนื่องจากไม่มีสิ่ง บดบังแสงอาทิตย์และได้มาจากการคำนวณตามทฤษฎี กราฟนี้สะท้อนให้เห็นถึงความแตกต่างของข้อมูลจากแต่ละ แหล่ง และข้อมูลความเข้มแสงมีความสำคัญต่อการพัฒนาแบบจำลองการพยากรณ์พลังงานแสงอาทิตย์ที่แม่นยำ

4.2.3 ข้อมูลอุณหภูมิโดยรอบ (Ambient Temperature)

ข้อมูลอุณหภูมิโดยรอบในโครงงานนี้ได้มาจากแพลตฟอร์ม CUEE (T), และแพลตฟอร์ม SoDa (Solar radiation Data) (T_{NWP}) [7] โดยได้ปรับความละเอียดเชิงเวลาของข้อมูลให้อยู่ในช่วง 5 และ 15 นาทีตามลำดับ



Time series of temperature

รูป 19: กราฟอนุกรมเวลาของอุณหภูมิโดยรอบ T และ $T_{
m NWP}$

ตัวอย่างข้อมูลในรูปที่ 19 แสดงกราฟอนุกรมเวลาของอุณหภูมิโดยรอบ T, และ T_{NWP} โดยจะเห็นว่าอุณหภูมิ มีแนวโน้มเพิ่มขึ้นตั้งแต่ช่วงเช้า สูงสุดในช่วงบ่าย ลดลงในช่วงเย็น และมีลักษณะซ้ำกันในแต่ละวัน ข้อมูลจากมิเตอร์ แสดงความผันผวนสูงกว่าข้อมูลจากแบบจำลองการพยากรณ์ เนื่องจากได้รับอิทธิพลจากสภาพอากาศจริง ขณะ ที่ข้อมูลจากแบบจำลองเกิดจากการคำนวณเชิงฟิสิกส์ ดังนั้นอุณหภูมิโดยรอบจึงเป็นฟีเจอร์สำคัญที่สามารถนำไป ใช้ปรับปรุงความแม่นยำของแบบจำลองการพยากรณ์การผลิตพลังงานแสงอาทิตย์

4.2.4 ข้อมูลดัชนีเมฆ (Cloud Index)

ข้อมูลค่าดัชนีเมฆในงานวิจัยนี้ได้มาจากการสกัดค่าจากภาพถ่ายดาวเทียมฮิมาวาริ [9] ณ ตำแหน่งอาคารบุญรอด บิณฑสันต์ จุฬาลงกรณ์มหาวิทยาลัย โดยดัชนีเมฆเป็นตัวบ่งชี้ระดับความทึบของเมฆในแต่ละช่วงเวลา มีค่าตั้งแต่ 0 (ท้องฟ้าแจ่มใส) ถึง 255 (ท้องฟ้าครึ้มสนิท) ข้อมูลดัชนีเมฆประกอบด้วยภาพขาวดำ (*CI*_{CM}) และภาพสีจาก ช่องสัญญาณสีแดง (*CI*_{R)} นอกจากนี้ได้มีการปรับความละเอียดเชิงเวลาของข้อมูลให้อยู่ในช่วง 5 และ 15 นาที

ตัวอย่างข้อมูลในรูปที่ 20 แสดงกราฟอนุกรมเวลาของดัชนีเมฆ CI_{CM}, และ CI_R โดยจะเห็นว่าดัชนีเมฆแสดง ลักษณะการเปลี่ยนแปลงที่ผันผวนตลอดทั้งวัน และมีแนวโน้มสอดคล้องกับความผันผวนของค่าความเข้มแสงอาทิตย์ ใน*รูปที่* 18 ช่วงที่ดัชนีเมฆมีค่าสูงมักสัมพันธ์กับค่าความเข้มแสงอาทิตย์ที่ต่ำ และในทางกลับกันช่วงที่ดัชนีเมฆมี ค่าต่ำมักสัมพันธ์กับความเข้มแสงที่สูง การนำดัชนีเมฆมาใช้เป็นตัวแปรร่วมในแบบจำลองการพยากรณ์สามารถช่วย เพิ่มความแม่นยำของการประเมินพลังงานแสงอาทิตย์ได้อย่างมีนัยสำคัญ

Time series of cloud index



รูป 20: กราฟอนุกรมเวลาของดัชนี้เมฆ $CI_{\rm CM}$ และ $CI_{\rm R}$

4.3 การเตรียมข้อมูลสำหรับระบบจัดการพลังงาน (EMS Data)



รูป 21: แผนภาพการเตรียมข้อมูลสำหรับระบบจัดการพลังงาน

การเตรียมข้อมูลเป็นขั้นตอนพื้นฐานที่สำคัญสำหรับการดำเนินงานของระบบจัดการพลังงานทั้งในระดับ Day-Ahead (DA) และ Hour-Ahead (HA) ดังแสดงใน*รูปที่* 21 โดยระบบ DA ใช้ข้อมูลที่มีความละเอียดระดับ 15 นาที เช่น โหลดไฟฟ้า, และกำลังที่ผลิตได้จากแผงโซลาร์ เพื่อใช้วางแผนการจัดสรรพลังงานล่วงหน้า ข้อมูลเหล่านี้จะ ผ่านกระบวนการเตรียมให้พร้อมใช้งาน เช่น การปรับความถี่ของเวลา การจัดการค่าที่หายไป และการจัดรูปแบบ ให้เหมาะสมกับระบบ ส่วนระบบ HA ทำงานในช่วงเวลาสั้นและละเอียดกว่า (ระดับ 5 นาที) จะอาศัยข้อมูลจาก ระบบ DA ที่ถูกปรับขนาดความละเอียด (up-sampling) ให้เหมาะกับช่วงเวลาการคำนวณแบบ real-time โดย เฉพาะข้อมูลโหลดและโซลาร์ที่ใช้ประกอบกันเพื่อประเมินความต้องการพลังงานสุทธิของระบบ อีกทั้งยังรวมข้อมูล สถานะของแบตเตอรี่ (State of Charge: SoC) และพารามิเตอร์ของแบตเตอรี่ เพื่อให้การตัดสินใจเกี่ยวกับการ ชาร์จและดิสชาร์จพลังงานเป็นไปอย่างมีประสิทธิภาพและตอบสนองต่อความเปลี่ยนแปลงของสภาพแวดล้อมได้อย่าง แม่นยำ

4.3.1 แบตเตอรี่

ข้อมูลแบตเตอรี่ที่ใช้ในการทดลองเป็นข้อมูลแบตเตอรี่ของ Jinko [3] ทีมวิจัย CEPT วางแผนจัดซื้อแบตเตอรี่จำนวน 2 ลูก เมื่อเกิดกรณีที่แบตเตอรี่ลูกใดลูกหนึ่งเกิดปัญหาจะสามารถซ่อมแซมได้โดยไม่ส่งผลกระทบต่อการทำงานของ ระบบ และพารามิเตอร์ของแบตเตอรี่แสดงไว้ตาม*ตารางที่* 2 ค่าแรงดันไฟฟ้ามาตรฐานคำนวณมาจากค่าเฉลี่ยของ แรงดันสูงสุดและต่ำสุดของช่วงการทำงานแบตเตอรี่

พารามิเตอร์	ค่า	หน่วย	ที่มา
η_{C}	0.95	-	กำหนดเอง
$\eta_{ m d}$	0.95*0.93	-	กำหนดเอง
อัตราการชาร์จประจุสูงสุด	100	kW	Jinko
อัตราการคายประจุสู่งสุด	100	kW	Jinko
ความจุแบตเตอรี่	215	kWh	Jinko
SoC(1)	50	%	กำหนดเอง
SoC _{min}	20	%	กำหนดเอง
SoC _{max}	80	%	กำหนดเอง
ค่าปลาย SoC	0	%	กำหนดเอง
แรงดันไฟฟ้ามาตรฐาน	$\frac{672+864}{2}$	V	Jinko

ตาราง 2: ค่าพารามิเตอร์ของแบตเตอรี่ Jinko [3]



รูป 22: แบตเตอรี่ Jinko ความจุ 215 kWh [3]

4.3.2 ข้อมูลราคาซื้อและขายค่าไฟฟ้า

ข้อมูลราคาซื้อและขายค่าไฟฟ้าถูกออกแบบให้เปลี่ยนแปลงตามเวลา (TOU) ตาม*รูปที่* 23 โดยราคาซื้อค่าไฟฟ้า แบ่งเป็นช่วงเวลาต่างๆ คือ เวลา 00:00 - 10:00 น. ราคา 2 บาท, เวลา 10:00 - 14:00 น. ราคา 3 บาท, เวลา 14:00 - 18:00 น. ราคา 5 บาท, เวลา 18:00 - 22:00 น. ราคา 7 บาท, และเวลา 22:00 - 24:00 น. ราคากลับ มาเป็น 2 บาท ส่วนราคาขายค่าไฟฟ้าจะมีราคา 2 บาทตลอดทั้งวัน ยกเว้นช่วงเวลา 18:00 - 22:00 น. ที่ปรับ ราคาเป็น 2.5 บาท สาเหตุที่ออกแบบราคาซื้อและขายค่าไฟฟ้าตาม*รูปที่* 23 เนื่องจากต้องการให้ค่าไฟฟ้ามีความ ผันผวนตามช่วงเวลาที่แตกต่างกัน ทำให้ EMS ตัดสินใจใช้พลังงานในช่วงเวลาที่มีค่าใช้จ่ายต่ำ และหลีกเลี่ยงการ ใช้พลังงานช่วงที่ราคาสูง



รูป 23: กราฟแสดงราคาซื้อและขายไฟฟ้าในแต่ละชั่วโมงที่สมมติขึ้น

4.3.3 ข้อมูลสำหรับระบบจัดการพลังงานระยะหลายวันล่วงหน้า (Day-Ahead, DA)

ระบบจัดการพลังงานระยะหลายวันล่วงหน้า (Day-Ahead: DA) ข้อมูลถูกจัดแบ่งเป็นกลุ่มละ 3 วัน เพื่อให้เพียง พอต่อการฝึกสอนและทดสอบโมเดลการวางแผนพลังงานล่วงหน้า โดยแต่ละกลุ่มจะเว้นระยะห่างกัน 1 วัน เพื่อ สร้างความหลากหลายของข้อมูลในมิติของเวลา ข้อมูลแต่ละกลุ่มจะถูกจัดเก็บแยกไฟล์อย่างเป็นระบบ เพื่อความ สะดวกในการเรียกใช้งานและจัดการในขั้นตอนการประมวลผลต่อไป

ข้อมูลโหลด

การจัดกลุ่มข้อมูลค่ากำลังไฟฟ้าของโหลดรายวัน



รูป 24: การจัดกลุ่มข้อมูลกำลังไฟฟ้าของโหลดรายวัน

ในการวิเคราะห์ข้อมูล ได้ทำการคำนวณค่ากำลังไฟฟ้าของโหลดรายวันจากข้อมูลอนุกรมเวลา โดยการรวมค่า กำลังไฟฟ้าของโหลดในแต่ละช่วงเวลาภายในวัน เพื่อให้ได้ค่ากำลังไฟฟ้ารวมของแต่ละวัน จากนั้นจึงทำการจัดกลุ่ม ข้อมูลรายวันโดยแบ่งออกเป็นหนึ่งแนวทางหลัก ดังนี้

• การจัดกลุ่มแบบหนึ่งมิติ (1-D Clustering):

ใช้ข้อมูลค่ำพลังงานแสงอาทิตย์รวมรายวัน (Daily Power Load) เป็นตัวแปรนำเข้าในการจัดกลุ่ม โดยอาศัย เทคนิคการจัดกลุ่มด้วยวิธี K-means เพื่อแบ่งข้อมูลออกเป็น 3 กลุ่ม ได้แก่ กลุ่มที่มีกำลังไฟฟ้าของโหลดสูง (high load), กลุ่มค่ากลาง (medium load), และกลุ่มที่มีค่าต่ำ (low load)

้ตัวอย่างผลการจัดกลุ่มแสดงไว้ใน*รูปที่* 24

ข้อมูลกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์

การจัดกลุ่มข้อมูลค่ากำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์และความเข้มแสงอาทิตย์

ในการวิเคราะห์ข้อมูล ได้ทำการคำนวณค่าพลังงานและค่าความเข้มแสงอาทิตย์รายวันจากข้อมูลอนุกรมเวลา โดยการรวมค่ากำลังไฟฟ้าและความเข้มแสงในแต่ละช่วงเวลาภายในวัน เพื่อให้ได้ค่ากำลังไฟฟ้าและค่าความเข้มแสง รวมของแต่ละวัน จากนั้นจึงทำการจัดกลุ่มข้อมูลรายวันโดยแบ่งออกเป็นสองแนวทางหลัก ดังนี้

• การจัดกลุ่มแบบสองมิติ (2-D Clustering):

ใช้ข้อมูลค่าพลังงานแสงอาทิตย์รวมรายวัน (Daily Power PV) ร่วมกับค่าความเข้มแสงรวมรายวัน (Daily Irradiance) เป็นตัวแปรนำเข้าในการจัดกลุ่ม โดยอาศัยเทคนิคการจัดกลุ่มด้วยวิธี K-means เพื่อแบ่งข้อมูล ออกเป็น 3 กลุ่ม ได้แก่ กลุ่มที่มีพลังงานและความเข้มแสงสูง (high solar), กลุ่มค่ากลาง (medium solar), และกลุ่มที่มีค่าต่ำ (low solar)

การจัดกลุ่มแบบ 2 มิติช่วยให้สามารถจำแนกประเภทของวันตามลักษณะสภาพอากาศได้อย่างชัดเจน โดย ลักษณะการกระจายตัวของข้อมูลในระนาบ 2 มิติแสดงให้เห็นถึงความสัมพันธ์ระหว่างพลังงานที่ผลิตได้กับ ความเข้มแสง ซึ่งมีประโยชน์อย่างมากต่อการประเมินความเสี่ยงของระบบผลิตไฟฟ้าจากแสงอาทิตย์


รูป 25: การจัดกลุ่มข้อมูลกำลังไฟฟ้าของแผงโซลาร์และความเข้มแสงรายวัน

้ตัวอย่างผลการจัดกลุ่มแสดงไว้ใน*รูปที่* 25(a)

• การจัดกลุ่มแบบหนึ่งมิติ (1-D Clustering):

ในกรณีที่ไม่สามารถใช้ข้อมูลความเข้มแสงร่วมในการจัดกลุ่มได้ เช่น ข้อมูลบางวันขาดหายหรือเซนเซอร์วัด ค่าทำงานผิดพลาด ได้มีการใช้เฉพาะค่าพลังงานรายวัน (Daily Power) เป็นตัวแปรในการจัดกลุ่ม โดยแบ่ง ออกเป็น 3 กลุ่มเช่นเดียวกัน คือ กลุ่มพลังงานสูง (high solar) ปานกลาง (medium solar) และต่ำ (low solar)

แม้ว่าการจัดกลุ่มแบบ 1 มิติจะไม่สามารถแยกความแตกต่างของสภาพอากาศได้ละเอียดเท่ากับแบบ 2 มิติ แต่ก็ยังสามารถสะท้อนความแปรผันของสภาพฟ้าในแต่ละวันได้พอสมควร และเหมาะสำหรับการใช้งานใน สภาพแวดล้อมจริงที่ข้อมูลอาจไม่สมบูรณ์อยู่เสมอ

ตัวอย่างผลการจัดกลุ่มแสดงไว้ใน*รูปที่* 25(b)

ในกรณีที่ผลการจัดกลุ่มจากข้อมูลแบบสองมิติไม่สามารถดำเนินการได้เนื่องจากข้อมูลไม่สมบูรณ์ ระบบจะเลือก ใช้ผลจากการจัดกลุ่มแบบหนึ่งมิติเข้ามาทดแทน เพื่อให้สามารถระบุประเภทของวันได้อย่างต่อเนื่องและครอบคลุม ทุกช่วงเวลา

การจัดกลุ่มข้อมูลแบบช่วงเวลา 3 วันต่อเนื่อง (Rolling 3-day Clustering)

ในการวิเคราะห์พฤติกรรมการใช้และการผลิตพลังงาน ได้ดำเนินการรวมข้อมูลโหลดไฟฟ้า (Load demand) และ ข้อมูลกำลังการผลิตของแผงโซลาร์ (PV generation) ตั้งแต่ปี ค.ศ. 2023 ถึง 2024 โดยมีขั้นตอนหลัก ดังนี้

- การรวมข้อมูล (Concatenation and Merging): ทำการรวมข้อมูลโหลดไฟฟ้า (Load) และข้อมูล กำลังการผลิตของแผงโซลาร์ (PV) ให้อยู่ในรูปแบบเดียวกันในระดับรายวัน เพื่อให้สามารถเปรียบเทียบและ วิเคราะห์ร่วมกันได้
- การแบ่งชุดข้อมูลเป็นช่วงเวลา 3 วันต่อเนื่อง (3-Day Rolling Batches): ข้อมูลที่ได้จะถูกแบ่งออก เป็นกลุ่มย่อยๆ แต่ละกลุ่มประกอบด้วยข้อมูลรายวันต่อเนื่องจำนวน 3 วัน เช่น กลุ่มที่ 1 คือข้อมูลของวัน ที่ 1–3 กลุ่มที่ 2 คือวันที่ 2–4 และดำเนินการต่อเนื่องไปเรื่อยๆ
- การคำนวณคลัสเตอร์แบบสะสม (Cluster Aggregation): สำหรับแต่ละช่วงเวลา 3 วัน จะนำค่าคลัสเตอร์ ของแต่ละวันมาหาค่าเฉลี่ย แล้วปัดค่าเป็นจำนวนเต็มเพื่อกำหนดคลัสเตอร์ของช่วงเวลา 3 วันนั้น ดังนี้

$$Cluster_{3-day} = round \left(\frac{Cluster_{day1} + Cluster_{day2} + Cluster_{day3}}{3}\right)$$
(26)

ตัวอย่างเช่น หากคลัสเตอร์ของวันที่ 1 ถึง 3 คือ 2, 1, 1 จะได้ค่าเฉลี่ยเป็น $rac{2+1+1}{3}=1.33$ ซึ่งจะถูกปัดลง เป็นคลัสเตอร์ 1 สำหรับช่วงนั้น

แนวทางนี้ช่วยให้สามารถวิเคราะห์แนวโน้มของข้อมูลในช่วงสั้นๆ ที่ต่อเนื่องกันได้ และมีประโยชน์อย่างยิ่งสำหรับ การจำแนกประเภทการใช้และการผลิตพลังงานของระบบ

ตารางที่ 3 แสดงผลการจัดกลุ่มข้อมูลจากการรวมชุดข้อมูลโหลดไฟฟ้าและกำลังไฟฟ้าจากแสงอาทิตย์ โดย พิจารณาเป็นช่วงเวลาต่อเนื่อง 3 วัน และทำการจัดกลุ่มตามระดับ (สูง กลาง ต่ำ) ของทั้งสองตัวแปร ผลลัพธ์ที่ได้ แสดงให้เห็นถึงการกระจายตัวของจำนวนกลุ่ม (Batch) ในแต่ละกรณี จากผลลัพธ์พบว่ากลุ่มที่มีจำนวนมากที่สุด คือ low load - medium solar ซึ่งมีจำนวนทั้งสิ้น 169 ชุดข้อมูล แสดงถึงความถี่ของช่วงที่ความต้องการใช้ พลังงานค่อนข้างต่ำ ขณะที่แสงอาทิตย์อยู่ในระดับปานกลาง รองลงมาคือ medium load - medium solar และ medium load - low solar ที่มีจำนวน 159 และ 89 ชุด ตามลำดับ ในทางกลับกันกลุ่มที่มีจำนวนข้อมูล น้อยที่สุดคือ high load - low solar มีเพียง 2 ชุดข้อมูล ซึ่งบ่งชี้ว่าเหตุการณ์ที่มีการใช้พลังงานสูงร่วมกับการ

Cluster Load	Cluster Solar	จำนวน Batch
high load	high solar	51
high load	medium solar	20
high load	low solar	2
medium load	high solar	81
medium load	medium solar	159
medium load	low solar	89
low load	high solar	39
low load	medium solar	169
low load	low solar	51

ตาราง 3: จำนวนกลุ่มข้อมูลที่ได้จากการจัดกลุ่มแบบ 3 วันต่อเนื่อง

ได้รับพลังงานแสงอาทิตย์ต่ำเกิดขึ้นน้อยมาก แนวโน้มที่สังเกตได้คือ ส่วนใหญ่ของข้อมูลจะอยู่ในกลุ่มโหลดระดับ กลางถึงต่ำ ประกอบกับค่าพลังงานแสงอาทิตย์ที่อยู่ในระดับปานกลางถึงต่ำ สะท้อนถึงรูปแบบการใช้งานพลังงาน ในชีวิตประจำวันของพื้นที่ศึกษาที่มีความผันผวนของแสงแดด และความต้องการโหลดที่อยู่ในช่วงไม่สูงมากนัก

4.3.4 ข้อมูลสำหรับระบบจัดการพลังงานระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA)

ในระบบจัดการพลังงานระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead: HA) ข้อมูลถูกจัดแบ่งเป็นกลุ่มย่อยรายชั่วโมง โดยมีการเว้นระยะห่างระหว่างแต่ละกลุ่มเพียง 5 นาที เพื่อให้สอดคล้องกับสถานการณ์จริงและการตัดสินใจในช่วง เวลาสั้นที่ระบบต้องรับมือ ข้อมูลเหล่านี้จะถูกรวบรวมและจัดเก็บต่อเนื่องตลอดทั้งปีในรูปแบบไฟล์เดี่ยวแบบยาว เพื่อให้สามารถเข้าถึงและอ้างอิงตามช่วงเวลาใดๆ ได้อย่างยืดหยุ่น อีกทั้งยังมีการนำผลลัพธ์จากระบบ DA มาใช้ เป็นข้อมูลอ้างอิง เพื่อสนับสนุนการคาดการณ์ในระบบ HA ให้มีความแม่นยำยิ่งขึ้น

ข้อมูลโหลด และกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์

ข้อมูลโหลดและกำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์เป็นชุดข้อมูลเดียวกับที่ได้นำเสนอไว้ก่อนหน้านี้สำหรับระบบ จัดการพลังงานระยะหลายวันล่วงหน้าแบบ Day-Ahead แต่ในที่นี้ได้ปรับความละเอียดของข้อมูลจากเดิมที่มีช่วง เวลา 15 นาที ให้เป็นช่วงเวลา 5 นาที เพื่อให้สอดคล้องกับระบบที่มีการตัดสินใจถี่ขึ้นในระดับเวลาที่สั้นลง

เวลา 15 นาที ให้เป็นช่วงเวลา 5 นาที เพื่อให้สอดคล้องกับระบบที่มีการตัดสินใจถี่ขึ้นในระดับเว[้]ลาที่สั้นลง *รูปที่* 26 แสดงกราฟอนุกรมเวลาะของโหลดไฟฟ้าและการผลิตไฟฟ้าจากโซลาร์ภายใต้กรอบเวลา Hour-Ahead พบว่าโหลดไฟฟ้ารวม (*P*_{Load}) มีลักษณะการเปลี่ยนแปลงที่สัมพันธ์กับพฤติกรรมการใช้งานของผู้บริโภค โดยมีค่า สูงในช่วงเข้าและเย็น และลดลงในช่วงกลางคืน สะท้อนถึงช่วงเวลาที่มีการใช้งานเครื่องใช้ไฟฟ้าสูง ขณะที่การผลิต ไฟฟ้าจากโซลาร์ (*P*_{pv}) มีรูปแบบชัดเจนเป็นโค้งระฆังในแต่ละวัน โดยเริ่มผลิตตั้งแต่ช่วงเช้า เพิ่มขึ้นจนถึงค่าสูงสุด ในช่วงกลางวัน และลดลงจนเป็นศูนย์ในช่วงเย็น ซึ่งสอดคล้องกับการมีหรือไม่มีแสงอาทิตย์ ข้อมูลนี้แสดงให้เห็น ถึงศักยภาพในการจัดการโหลดร่วมกับพลังงานแสงอาทิตย์ เพื่อเพิ่มประสิทธิภาพในการใช้พลังงานหมุนเวียนภายใน ระบบพลังงานท้องถิ่นหรือระบบไมโครกริดได้อย่างเหมาะสม

ข้อมูลผลเฉลยของ DA

ข้อมูลผลเฉลยจากกระบวนการวางแผนล่วงหน้าแบบ Day-Ahead (DA) เป็นผลลัพธ์ที่ได้จากการแก้ปัญหา การหาค่าเหมาะสมที่สุดในระดับเวลาที่มีความละเอียด 15 นาที หลังจากนั้นผลเฉลยของ DA ถูกปรับความละเอียด เป็น 5 นาที เพื่อให้สอดคล้องกับระบบจัดการพลังงานระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead) ที่มีความละเอียด ของข้อมูลทุก 5 นาที

P_Load and P_pv with Forecast Horizon 12



รูป 26: กราฟอนุกรมเวลาของโหลดไฟฟ้าและการผลิตไฟฟ้าจากโซลาร์ภายใต้กรอบเวลา Hour-Ahead



รูป 27: กราฟเปรียบเทียบผลเฉลยของ Day-Ahead ที่ถูกปรับความละเอียดจาก 15 นาที เป็น 5 นาที

รูปที่ 27 แสดงผลเฉลยจากการวางแผนล่วงหน้าแบบ Day-Ahead ซึ่งมีความละเอียดของช่วงเวลาทุก 15 นาที ได้ถูกนำมาปรับความละเอียดเป็นทุก 5 นาทีโดยใช้เทคนิคเชิงตัวเลขแบบการประมาณค่าในช่วงเชิงเส้น (linear interpolation) เพื่อให้สอดคล้องกับระบบควบคุมพลังงานระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead) ที่มี การตัดสินใจในระดับเวลา 5 นาที การปรับความละเอียดนี้ทำให้ค่าคำสั่งจ่ายพลังงานมีความต่อเนื่องมากขึ้น ส่ง ผลให้ระบบสามารถใช้งานข้อมูล DAref ได้อย่างราบรื่น ลดความไม่สอดคล้องระหว่างแผนและการควบคุมในระดับ เวลาจริง อีกทั้งยังช่วยให้การประเมินประสิทธิภาพของระบบในเชิงเวลาและพลังงานมีความแม่นยำยิ่งขึ้น

5 แบบจำลองการพยากรณ์ (Forecasting Model)

5.1 แบบจำลองการพยากรณ์ระยะหลายวันล่วงหน้า (Day-Ahead, DA Forecasting Model)

ข้อมูลพลังงานการใช้โหลดที่ใช้ในการฝึกแบบจำลองการพยากรณ์ระยะหลายวันล่วงหน้าจะมีความละเอียด 15 นาที และข้อมูลพลังงานแสงอาทิตย์ที่ใช้มีความละเอียด 15 นาที โดยจำกัดช่วงเวลาตั้งแต่ 06:00 น. ถึง 18:00 น. ของ แต่ละวัน

- ข้อมูลสำหรับการฝึกแบบจำลอง (Training Data) จะเป็นข้อมูลตั้งแต่วันที่ 10 มีนาคม 2566 ถึง 31 ธันวาคม 2566
- ข้อมูลสำหรับการตรวจสอบแบบจำลอง (Validation Data) จะใช้ช่วงเวลา 1 มกราคม 2567 ถึง 31 มีนาคม 2567
- ข้อมูลสำหรับการทดสอบแบบจำลอง (Test Data) จะใช้ช่วงเวลา 1 มกราคม 2567 ถึง 31 ธันวาคม 2567

5.1.1 การพยากรณ์โหลดไฟฟ้า (Load Forecasting)



รูป 28: แบบจำลองการพยากรณ์โหลดภายใต้กรอบ Day-Ahead

รูปที่ 28 แสดงถึงแบบจำลองพยากรณ์โหลดไฟฟ้าระยะหลายวันล่วงหน้า ซึ่งพัฒนามาจากแบบ LSTM ที่มี การปรับแต่งค่าไฮเปอร์พารามิเตอร์ โดยมีรายละเอียดการทำงานดังนี้ แบบจำลองจะรับข้อมูลโหลดไฟฟ้าในอดีต ย้อนหลังในรูปแบบของลำดับเวลา ข้อมูลดังกล่าวจะถูกป้อนเข้าสู่โครงข่าย LSTM ที่มีจำนวนชั้นตามที่กำหนด โดย ผลลัพธ์สุดท้ายจาก LSTM จะถูกนำมารวมกับข้อมูลคุณลักษณะภายนอกซึ่งรู้ล่วงหน้า ได้แก่ ค่าพยากรณ์อุณหภูมิ ในอนาคต ช่วงเวลาในการใช้งานห้องปฏิบัติการ วันที่มีการใช้งานห้องปฏิบัติการ และวันที่มหาวิทยาลัยเปิดทำการ ข้อมูลทั้งหมดจะถูกจัดรูปแบบใหม่ผ่านกระบวนการแยกตามช่วงเวลาการพยากรณ์ และรวมเป็นเวกเตอร์คุณลักษณะ x(t+k) สำหรับแต่ละ k ที่ต้องการพยากรณ์ ซึ่งจะถูกนำเข้าสู่โครงข่ายแบบ Dense-network โดยแยกตามช่วง เวลา และในช่วงเวลาที่ต้องการพยากรณ์จะมีโครงข่าย Fully Connected แยกกัน ซึ่งผลลัพธ์ของแบบจำลองนี้ คือค่าพยากรณ์โหลดไฟฟ้าในอนาคตแบบหลายช่วงเวลา

รายละเอียดพารามิเตอร์ของแบบจำลอง LSTM (LSTM Model Parameters)

- n_lags = 96 จำนวนข้อมูลในอดีตที่ใช้เป็นอินพุตเท่ากับ 96 ขั้นเวลา (24 ชั่วโมง)
- n_forecasts = 288 จำนวนข้อมูลในอนาคตที่ต้องการพยากรณ์ล่วงหน้าเท่ากับ 288 ขั้นเวลา (3 วันล่วง หน้า)
- batch_size = 64 จำนวนข้อมูลในแต่ละชุดที่ใช้ในการฝึก
- learning_rate = 1e-3 อัตราการเรียนรู้สำหรับตัวปรับน้ำหนัก
- n_epochs = 100 จำนวนรอบการฝึกสูงสุด
- n_patience = 100 จำนวนรอบสำหรับการหยุดการฝึกเมื่อประสิทธิภาพไม่ดีขึ้น
- loss_function = nn.L1Loss() ฟังก์ชันการสูญเสียเป็นค่า MAE (Mean Absolute Error)

ข้อมูลคุณลักษณะ (Input features)

- (1) กำลังไฟฟ้าของโหลดในอดีต 1 วัน, $P_{\text{load}}(t), \ P_{\text{load}}(t-1), \ \dots, \ P_{\text{load}}(t-95)$
- (2) อุณหภูมิพยากรณ์ล่วงหน้า 3 วัน $\hat{T}_{\sf NWP}(t+1), \ \hat{T}_{\sf NWP}(t+2), \ \dots, \ \hat{T}_{\sf NWP}(t+288)$
- (3) ช่วงเวลาในการใช้ห้องปฏิบัติการล่วงหน้า 3 วัน $\hat{L}_h(t+1), \ \hat{L}_h(t+2), \ \dots, \ \hat{L}_h(t+h_f)$
- (4) วันที่มีการใช้ห้องปฏิบัติการล่วงหน้า 3 วัน $\hat{L}_d(t+1), \ \hat{L}_d(t+2), \ \dots, \ \hat{L}_d(t+h_f)$
- (5) วันที่มหาวิทยาลัยเปิดทำการล่วงหน้า 3 วัน $\hat{W}_{\sf d}(t+1), \ \hat{W}_{\sf d}(t+2), \ \dots, \ \hat{W}_{\sf d}(t+288)$

ข้อมูลขาออก (Output feature)

กำลังไฟฟ้าของโหลดล่วงหน้า 3 วัน, $\hat{P}_{\text{load}}(t+1), \ \hat{P}_{\text{load}}(t+2), \ \dots, \ \hat{P}_{\text{load}}(t+288)$

ในการพัฒนาแบบจำลองพยากรณ์โหลดไฟฟ้าด้วยโครงข่ายประสาทเทียมแบบ LSTM ได้มีการทดลองปรับไฮ เปอร์พารามิเตอร์ในหลายด้านเพื่อหาโครงสร้างแบบจำลองที่ให้ผลการพยากรณ์ดีที่สุด โดยการทดลองแบ่งออกเป็น หัวข้อหลัก ดังนี้

- จำนวนเลเยอร์ของ LSTM (Number of LSTM Layers): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อศึกษาผลกระทบของจำนวนชั้นของแบบจำลองต่อความแม่นยำในการพยากรณ์
- จำนวนหน่วยซ่อนในแต่ละเลเยอร์ (Number of Hidden Sizes per Layer): ทดลองค่าต่าง ๆ ได้แก่
 10, 20, 50, 100 และ 200 หน่วย เพื่อวิเคราะห์ความสามารถในการเรียนรู้รูปแบบข้อมูลที่ซับซ้อน
- จำนวนเลเยอร์แบบเชื่อมต่อเต็มภายหลังแบบจำลอง LSTM (Number of Fully Connected Layers after LSTM, FC Layer Dim.): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อเสริม ความสามารถของแบบจำลองในการประมวลผลลักษณะของข้อมูลที่ได้จาก LSTM

ค่าความสูญเสียของแบบจำลองที่น้อยที่สุดในชุดข้อมูลตรวจสอบ

เมื่อพิจารณาจำนวนเลเยอร์ของ LSTM ใน*รูปที่* 29 พบว่าเมื่อจำนวนเลเยอร์แบบเชื่อมต่อเต็มภายหลังแบบ จำลองเพิ่มขึ้นจาก 1 ถึง 5 จะทำให้ค่าความสูญเสียลดลง และที่จำนวนเลเยอร์แบบเชื่อมต่อเต็มภายหลังแบบจำลอง เท่ากับ 5 ส่งผลให้เกิดค่าความสูญเสียต่ำสุด จากกราฟจะเห็นได้ชัดว่าเมื่อเพิ่มค่าจำนวนเลเยอร์แบบเชื่อมต่อเต็ม ภายหลังแบบจำลองเป็น 10 และ 20 ค่าความความสูญเสียจะมีค่าสูงขึ้นนั่นหมายว่าจำนวนชั้นเลเยอร์มีจำนวน มากเกินความต้องการ ดังนั้นจึงเลือก FC Layer Dim. = 5 จากการเปรียบเทียบทั้งหมด พบว่าแบบจำลองที่มี LSTM Layers = 2, Hidden Sizes = 10, และ FC Layer Dim. = 5 ให้ผลลัพธ์ดีที่สุด จึงเลือกใช้แบบจำลอง นี้เป็น แบบจำลองที่ดีที่สุดของการพยากรณ์โหลดไฟฟ้าระยะหลายวันล่วงหน้า



Trade-off: Future Layers vs Validation Loss

รูป 29: กราฟแสดงค่าความสูญเสียของแบบจำลองในชุดข้อมูลตรวจสอบ

แบบจำลองที่ดีที่สุดของการพยากรณ์โหลดไฟฟ้าระยะหลายวันล่วงหน้า

แบบจำลอง LSTM ที่มี LSTM Layers = 2, Hidden Sizes = 10, และ FC Layer Dim. = 5 ได้ถูกนำมาใช้ใน การพยากรณ์โหลดไฟฟ้าระยะหลายวันล่วงหน้า



รูป 30: กราฟอนุกรมเวลาของโหลดไฟฟ้าจริงและค่าพยากรณ์โหลดไฟฟ้าภายใต้กรอบ Day-Ahead

รูปที่ 30 แสดงการเปรียบเทียบระหว่างโหลดไฟฟ้าค่าจริงและค่าพยากรณ์ของโหลดไฟฟ้า พบว่าแบบจำลอง สามารถติดตามแนวโน้มของโหลดไฟฟ้าค่าจริงได้ดีในภาพรวม แต่ในช่วงเวลาที่มีการเปลี่ยนแปลงค่าโหลดไฟฟ้าแบบ ทันทีทันใด ค่าพยากรณ์จะไม่สามารถติดตามค่าโหลุดไฟฟ้าจริงได้ทัน

รูปที่ 31 แสดงค่า MAE และ sMAPE ในแต่ละชั่วโมงของวัน จะเห็นได้ว่าค่า MAE มีแนวโน้มเพิ่มสูงขึ้นในช่วง เวลา 09.00–16.00 น. ซึ่งเป็นช่วงเวลาที่มีโหลดไฟฟ้าสูง โดยค่าสูงสุดจะอยู่ระหว่างช่วง 12.00–14.00 น. และ ค่า MAE สูงถึงประมาณ 3.5 kW แสดงถึงความคลาดเคลื่อนของการพยากรณ์ที่เพิ่มขึ้นเมื่อโหลดไฟฟ้ามีค่ามาก แต่เมื่อเปรียบเทียบกับค่าโหลดสูงสุดที่ 35 kW พบว่าค่า MAE ดังกล่าวมีค่าประมาณร้อยละ 10 ของโหลดสูงสุด ซึ่งแสดงถึงแบบจำลองพยากรณ์มีประสิทธิภาพที่ดี เมื่อพิจารณาค่า sMAPE พบว่าสูงที่สุดในช่วงเวลา 07.00–09.00 น. และ 22.00–23.00 น. โดยมีค่าสูงถึงร้อยละ 60–70 ซึ่งอาจเกิดจากผลกระทบของโหลดที่อยู่ในระดับต่ำ ทำให้ค่าความคลาดเคลื่อนสัมพัทธ์เพิ่มสูงขึ้นแม้มีค่าคลาดเคลื่อนจริงไม่มากนัก ทั้งนี้ ค่า sMAPE ในช่วงกลางวัน จะลดต่ำลง เนื่องจากฐานของโหลดสูงขึ้นและการพยากรณ์มีความแม่นยำมากขึ้น



(a) กราฟแสดงค่า MAE ในแต่ละชั่วโมง



Hourly sMAPE by Prediction Day

(b) กราฟแสดงค่า sMAPE ในแต่ละชั่วโมง



5.1.2 การพยากรณ์ความเข้มแสง (Irradiance Forecasting)



รูป 32: แบบจำลองการพยากรณ์ความเข้มแสงภายใต้กรอบ Day-Ahead

รายละเอียดพารามิเตอร์ของแบบจำลอง LSTM (LSTM Model Parameters)

แบบจำลองการเรียนรู้ด้วยโครงข่ายประสาทเทียมแบบ LSTM (Long Short-Term Memory) ถูกนำมาใช้ในการ พยากรณ์พลังงานแสงอาทิตย์ล่วงหน้า โดยใช้ข้อมูลอดีตและข้อมูลพยากรณ์ของตัวแปรสภาพอากาศในอนาคตเป็น ปัจจัยร่วมในการพยากรณ์ตาม*รูปที่* 32 แบบจำลองนี้ถูกกำหนดค่าพารามิเตอร์ต่างๆ ดังนี้

- n_lags = 49 จำนวนข้อมูลในอดีตที่ใช้เป็นอินพุตเท่ากับ 49 ขั้นเวลา (เวลา 1 วันของช่วงเวลาตั้งแต่ 06:00 น. ถึง 18:00 น.)
- n_forecasts = 147 จำนวนข้อมูลในอนาคตที่ต้องการพยากรณ์ล่วงหน้าเท่ากับ 147 ขั้นเวลา (เวลา 3 วันของช่วงเวลาตั้งแต่ 06:00 น. ถึง 18:00 น.)
- batch_size = 64 จำนวนข้อมูลในแต่ละชุดที่ใช้ในการฝึก
- learning_rate = 1e-3 อัตราการเรียนรู้สำหรับตัวปรับน้ำหนัก
- n_epochs = 100 จำนวนรอบการฝึกสูงสุด
- n_patience = 100 จำนวนรอบสำหรับการหยุดการฝึกเมื่อประสิทธิภาพไม่ดีขึ้น
- loss_function = nn.L1Loss() ฟังก์ชันการสูญเสียเป็นค่า MAE (Mean Absolute Error)
- ข้อมูลนำเข้า (Input)
 - 1. ความเข้มแสงในอดีต 1 วัน: $I(t), I(t-1), \dots, I(t-48)$
 - 2. ความเข้มแสงจาก NWP ใน 3 วันถัดไป: $\hat{I}_{\text{NWP}}(t+1), \hat{I}_{\text{NWP}}(t+2), \dots, \hat{I}_{\text{NWP}}(t+147)$
 - 3. อุณหภูมิจาก NWP ใน 3 วันถัดไป: $\hat{T}_{NWP}(t+1), \hat{T}_{NWP}(t+2), \dots, \hat{T}_{NWP}(t+147)$
 - 4. ความเข้มแสงในสภาพท้องฟ้าใสใน 3 วันถัดไป: $\hat{I}_{clr}(t+1), \hat{I}_{clr}(t+2), \dots, \hat{I}_{clr}(t+147)$

• ข้อมูลส่งออก (Output)

1. ผลลัพธ์ของการพยากรณ์ของความเข้มแสงใน 3 วันถัดไป: $\hat{I}(t+1), \hat{I}(t+2), \dots, \hat{I}(t+147)$

ในการพัฒนาแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์ด้วยโครงข่ายประสาทเทียมแบบ LSTM ได้มีการทดลอง ในหลายด้านเพื่อหาโครงสร้างแบบจำลองที่ให้ผลการพยากรณ์ดีที่สุด โดยการทดลองแบ่งออกเป็นหัวข้อหลัก ดังนี้

- จำนวนเลเยอร์ของ LSTM (Number of LSTM Layers): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อศึกษาผลกระทบของความลึกของแบบจำลองต่อความแม่นยำในการพยากรณ์
- จำนวนหน่วยซ่อนในแต่ละเลเยอร์ (Number of Hidden Sizes per Layer): ทดลองค่าต่าง ๆ ได้แก่
 10, 20, 50, 100 และ 200 หน่วย เพื่อวิเคราะห์ความสามารถในการเรียนรู้รูปแบบข้อมูลที่ซับซ้อน
- จำนวนชั้นการเชื่อมโยงเต็มรูปแบบภายหลังแบบจำลอง LSTM (Dimension of Fully Connected Layers after LSTM, FC Layer Dim.): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 ชั้น เพื่อเสริม ความสามารถของแบบจำลองในการประมวลผลลักษณะของข้อมูลที่ได้จาก LSTM

ค่าความสูญเสียของแบบจำลองสำหรับชุดข้อมูลฝึกและตรวจสอบ

รูปที่ 33, *รูปที่* 34, และ*รูปที่* 35 แสดงกราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ระยะ หลายวันล่วงหน้า สำหรับชุดข้อมูลฝึกและตรวจสอบ แสดงให้เห็นถึงการลดลงของค่าความสูญเสียในแต่ละจำนวน เลเยอร์ LSTM ดังนี้:

- จำนวนเลเยอร์ LSTM = 1, 2, 5, 10, และ 20 เลเยอร์
 - การทดลองในแต่ละกรณีพบว่าค่าความสูญเสียลดลงในทิศทางเดียวกัน ซึ่งหมายความว่าจำนวนเลเยอร์ LSTM ที่แตกต่างกันไม่ส่งผลกระทบอย่างมีนัยสำคัญต่อประสิทธิภาพของแบบจำลองในแง่ของการลด ค่าความสูญเสีย ไม่ว่าจะเป็นข้อมูลการฝึกหรือการตรวจสอบ
- ข้อสังเกต
 - การเพิ่มจำนวนเลเยอร์ไม่ได้ทำให้เกิดการพัฒนาอย่างชัดเจนในการลดค่าความสูญเสียในชุดข้อมูลการ ฝึกและตรวจสอบ อาจเนื่องมาจากว่าแบบจำลองสามารถจับข้อมูลที่ซับซ้อนได้ดีในทุกจำนวนเลเยอร์ หรืออาจเป็นไปได้ว่าแบบจำลองไม่จำเป็นต้องมีจำนวนเลเยอร์ที่สูงเพื่อให้ได้ผลลัพธ์ที่ดี
 - ค่าความสูญเสียในชุดข้อมูลการตรวจสอบต่ำกว่าชุดข้อมูลการฝึก เนื่องจากข้อมูลในชุดการฝึกและการ ตรวจสอบอาจมีความแตกต่างกันในลักษณะหรือความยากง่าย โดยชุดข้อมูลการฝึกอาจมีลักษณะที่ซับ ช้อนหรือไม่สม่ำเสมอมากกว่าชุดข้อมูลการตรวจสอบ ซึ่งอาจทำให้แบบจำลองเรียนรู้ได้ดีในชุดข้อมูล การตรวจสอบมากกว่า นอกจากนี้การแบ่งข้อมูลยังมีความสำคัญเนื่องจาก มีจำนวนข้อมูลที่น้อย และ LSTM ต้องการการจัดเรียงข้อมูลตามลำดับเวลา การแบ่งข้อมูลจึงจำเป็นเพื่อรักษาความต่อเนื่องของ ข้อมูลตามลำดับเวลาและป้องกันไม่ให้ข้อมูลลำดับเวลาผิดเพี้ยน ซึ่งอาจทำให้ผลลัพธ์จากการฝึกฝนและ ทดสอบแบบจำลองมีความแตกต่างกัน
- จากการเปรียบเทียบผลการทดลองในแต่ละกรณีพบว่า
 - ไม่พบความแตกต่างที่ชัดเจนในประสิทธิภาพของแบบจำลองที่มีจำนวนเลเยอร์ LSTM ต่างกัน กล่าว คือ แบบจำลองที่มีจำนวนเลเยอร์น้อยหรือมากก็สามารถให้ผลลัพธ์ที่ใกล้เคียงกันได้
 - ดังนั้น อาจสรุปได้ว่า จำนวนเลเยอร์ที่มากขึ้นไม่จำเป็นต้องเป็นปัจจัยที่สำคัญในการปรับปรุงประสิทธิภาพ ของแบบจำลองในกรณีนี้



รูป 33: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Day-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (1)



รูป 34: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Day-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (2)



รูป 35: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Day-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (3)



รูป 36: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ระยะหลายวันล่วงหน้าที่น้อยที่สุดในชุด ข้อมูลตรวจสอบ

ค่าความสูญเสียของแบบจำลองที่น้อยที่สุดในชุดข้อมูลตรวจสอบ

รูปที่ 36 แสดงผลการทดลองเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM ที่มีจำนวนเลเยอร์แตกต่างกัน ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ โดยในแต่ละกรณีได้มีการปรับค่า Hidden Size และขนาดของ FC Layer Dim. ให้เหมาะสมเพื่อให้ได้ค่าความสูญเสียบนชุดตรวจสอบต่ำที่สุด ผลการวิเคราะห์สามารถสรุปได้ดังนี้:

- LSTM = 1 เลเยอร์: แบบจำลองที่มี Hidden Size เท่ากับ 150 และ FC Layer Dim. เท่ากับ 1 ให้ ค่าความสูญเสียบนชุดตรวจสอบเท่ากับ 0.2919 ซึ่งแม้จะสามารถเรียนรู้ข้อมูลได้ในระดับหนึ่ง แต่ยังไม่ใช่ ค่าที่ต่ำที่สุดเมื่อเทียบกับแบบจำลองที่มีจำนวนเลเยอร์มากขึ้น
- LSTM = 2 เลเยอร์: แบบจำลองที่มี Hidden Size เท่ากับ 200 และ FC Layer Dim. เท่ากับ 1 ให้ค่าความสูญเสียต่ำที่สุดที่ 0.2868 สะท้อนถึงความสามารถในการเรียนรู้ที่ดีของโครงสร้างแบบจำลองใน ระดับความลึกนี้
- LSTM = 5 เลเยอร์: แบบจำลองที่มี Hidden Size เท่ากับ 150 และ FC Layer Dim. เท่ากับ 1 ให้ ค่าความสูญเสียเท่ากับ 0.2905 ซึ่งแม้ไม่ใช่ค่าต่ำที่สุด แต่ยังอยู่ในระดับที่ยอมรับได้ และแสดงความเสถียร ระหว่างกระบวนการฝึกและตรวจสอบ
- LSTM = 10 เลเยอร์: มีการลดขนาด Hidden Size ต่อเลเยอร์ลงเหลือ 100 และเพิ่ม FC Layer Dim.
 เป็น 5 เพื่อควบคุมความซับซ้อนของแบบจำลอง ส่งผลให้ได้ค่าความสูญเสียอยู่ที่ 0.2898
- LSTM = 20 เลเยอร์: แม้ใช้พารามิเตอร์ที่ใกล้เคียงกับกรณี 10 เลเยอร์ (Hidden Size = 100, FC Layer Dim. = 5) แต่ค่าความสูญเสียกลับเพิ่มขึ้นเป็น 0.2920 สะท้อนว่าแบบจำลองอาจมีความลึกมากเกินไป เมื่อเทียบกับปริมาณข้อมูล ส่งผลต่อประสิทธิภาพในการเรียนรู้

จากการเปรียบเทียบทั้งหมด พบว่าแบบจำลองที่มี LSTM Layers = 2, Hidden Sizes = 200, และ FC Layer Dim. = 1 ให้ผลลัพธ์ดีที่สุด โดยสามารถลดค่าความสูญเสียในชุดตรวจสอบได้ต่ำที่สุด และรักษา เสถียรภาพระหว่างค่าความสูญเสียในชุดฝึกและชุดตรวจสอบได้ดี จึงเลือกใช้แบบจำลองนี้เป็น **แบบจำลองที่เหมาะ** สมที่สุดของการพยากรณ์โซลาร์ระยะหลายวันล่วงหน้า

แบบจำลองที่เหมาะสมที่สุดของการพยากรณ์โซลาร์ระยะหลายวันล่วงหน้า

แบบจำลอง LSTM ที่มี LSTM Layers = 2, Hidden Sizes = 200, และ FC Layer Dim. = 1 ได้ถูกนำมา ประยุกต์ใช้ในการพยากรณ์ความเข้มแสงระยะหลายวันล่วงหน้า

รูปที่ 37 แสดงการเปรียบเทียบระหว่างความเข้มแสงค่าจริงและค่าที่แบบจำลองพยากรณ์ได้ โดยจะเห็นว่าแบบ จำลองสามารถติดตามแนวโน้มของข้อมูลได้ค่อนข้างแม่นยำในหลายช่วงเวลา แต่อาจมีบางช่วงที่ค่าพยากรณ์เบี่ยง เบนจากค่าจริงอย่างเห็นได้ชัด โดยเฉพาะในช่วงที่มีความผันผวนสูงของค่าความเข้มแสง

รูปที่ 38 แสดงค่า Mean Absolute Error (MAE) และ Root Mean Squared Error (RMSE) สำหรับการ พยากรณ์ความเข้มแสงอาทิตย์รายชั่วโมงในช่วงเวลา 06:00–18:00 น. โดยเปรียบเทียบผลลัพธ์ของการพยากรณ์ ล่วงหน้า 1, 2 และ 3 วัน ซึ่งสามารถสรุปผลการวิเคราะห์ได้ดังนี้:

- แนวโน้มโดยรวม: ค่าความคลาดเคลื่อน (ทั้ง MAE และ RMSE) มีแนวโน้มเพิ่มขึ้นเมื่อระยะเวลาการพยากรณ์ ยาวขึ้น (จาก 1 วัน → 3 วัน) ซึ่งเป็นไปตามความไม่แน่นอนของสภาพอากาศที่เพิ่มขึ้นเมื่อทำนายระยะยาว
- ช่วงเช้า (06:00-09:00): ค่า MAE และ RMSE อยู่ในระดับต่ำ เนื่องจากความเข้มแสงอาทิตย์ยังไม่สูง ทำให้แบบจำลองสามารถพยากรณ์ได้แม่นยำขึ้น



รูป 37: กราฟอนุกรมเวลาของความเข้มแสงค่าจริงและค่าแบบจำลองพยากรณ์ภายใต้กรอบ Day-Ahead

- ช่วงกลางวัน (10:00–14:00): เป็นช่วงที่มีค่าความคลาดเคลื่อนสูงสุด โดยเฉพาะกรณีการพยากรณ์ล่วง หน้า 3 วัน ซึ่งอาจเกิดจากความผันแปรของสภาพอากาศ เช่น เมฆ ฝน หรือลักษณะการกระจายพลังงาน ที่เปลี่ยนแปลงรวดเร็ว
- ช่วงบ่าย (15:00–18:00): ค่าความคลาดเคลื่อนเริ่มลดลงอีกครั้ง โดยเฉพาะในกรณีล่วงหน้า 1 วัน แสดง ให้เห็นถึงความสามารถของแบบจำลองในการพยากรณ์ในช่วงปลายวันได้ดีขึ้น
- การเปรียบเทียบ MAE และ RMSE: ค่าความคลาดเคลื่อน RMSE สูงกว่า MAE เสมอ แสดงว่าอาจมีบาง ช่วงที่แบบจำลองพยากรณ์ผิดพลาดมากกว่าปกติ โดยเฉพาะในการพยากรณ์ระยะยาว (3 วัน)

นอกจากนี้ได้มีการคำนวณค่าเฉลี่ยของ MAE และ RMSE ตลอดช่วงเวลาที่สนใจ เพื่อใช้เป็นตัวแทนความแม่นยำ ของแบบจำลองโดยรวมสำหรับแต่ละช่วงเวลาการพยากรณ์ ผลการคำนวณสรุปได้ใน*ตารางที่* 4 สามารถสังเกต ได้ว่า เมื่อระยะเวลาการพยากรณ์เพิ่มขึ้น ความคลาดเคลื่อนของการพยากรณ์ก็เพิ่มขึ้นเช่นกัน โดยเฉพาะค่า RMSE ที่แสดงถึงการกระจายตัวของความผิดพลาดที่เพิ่มขึ้นในกรณีการพยากรณ์ระยะยาว สอดคล้องกับแนวโน้มที่พบใน กราฟรายชั่วโมง

ตาราง 4: ค่า MAE และ RMSE โดยรวมสำหรับการพยากรณ์ความเข้มแสงล่วงหน้า 1, 2 และ 3 วัน (06:00– 18:00)

ระยะเวลาพยากรณ์ล่วงหน้า	MAE (W/m^2)	RMSE (W/m^2)
1 วัน	101.77	145.60
2 วัน	102.06	146.02
3 วัน	102.18	145.85

การแปลงค่าความเข้มแสงเป็นกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์

ในการนำค่าความเข้มแสงที่ได้จากการพยากรณ์มาใช้ในระบบบริหารจัดการพลังงานจำเป็นต้องมีการแปลงให้ เป็นค่ากำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ โดยใช้แบบจำลองเชิงเส้นอย่างง่ายดังสมการ (27)

$$P_{\mathsf{pv}} = \alpha(t) \cdot I(t) \tag{27}$$



Model Performance: n_lstm_layers=2, hidden_units=200, dim_future_layers=1

รูป 38: กราฟแสดงค่า MAE และ RMSE ของผลการพยากรณ์ความเข้มแสงอาทิตย์ล่วงหน้า 1, 2, และ 3 วัน สำหรับแต่ละชั่วโมง

โดยที่ α เป็นพารามิเตอร์ที่สะท้อนแสดงถึงประสิทธิภาพของระบบพลังงานในช่วงเวลานั้นๆ แต่เพื่อให้ค่ากำลัง ไฟฟ้าที่ผลิตได้ของแผงโซลาร์ถูกต้อง จึงมีการปรับเทียบเพิ่มเติมด้วยค่าสเกล k ดังสมการ (25)



รูป 39: กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ค่าจริงและค่าพยากรณ์ระยะหลายวันล่วงหน้า

รูปที่ 39 แสดงผลการเปรียบเทียบระหว่างค่ากำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์จริงกับค่าที่ได้จากการพยากรณ์ ในกรณี Day-Ahead โดยค่าพยากรณ์ได้จากการแปลงค่าความเข้มแสงที่ได้จากแบบจำลองพยากรณ์ด้วยสมการ เชิงเส้น (27) และสมการปรับเทียบ (25) จะเห็นว่าแบบจำลองสามารถประมาณค่ากำลังไฟฟ้าได้ใกล้เคียงกับค่า จริงในหลายช่วงเวลา โดยเฉพาะในช่วงเวลาที่ค่ากำลังมีความราบเรียบ แต่มีบางช่วงที่ค่าพยากรณ์เบี่ยงเบนจากค่า จริง โดยเฉพาะในช่วงที่มีการเปลี่ยนแปลงของกำลังไฟฟ้าอย่างรวดเร็ว ซึ่งแสดงถึงข้อจำกัดของแบบจำลอง DA ที่ อิงอยู่กับข้อมูลในอดีตที่ห่างไกลกว่า

5.2 แบบจำลองการพยากรณ์ระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA Forecasting Model)

ข้อมูลพลังงานการใช้โหลดและข้อมูลพลังงานแสงอาทิตย์ที่ใช้ในการฝึกแบบจำลองการพยากรณ์ระยะหลายชั่วโมง ล่วงหน้าจะมีความละเอียด 5 นาที

- ข้อมูลสำหรับการฝึกแบบจำลอง (Training Data) จะเป็นข้อมูลตั้งแต่วันที่ 10 มีนาคม 2566 ถึง 31 ธันวาคม 2566
- ข้อมูลสำหรับการตรวจสอบแบบจำลอง (Validation Data) จะใช้ช่วงเวลา 1 มกราคม 2567 ถึง 31 มีนาคม 2567
- ข้อมูลสำหรับการทดสอบแบบจำลอง (Test Data) จะใช้ช่วงเวลา 1 มกราคม 2567 ถึง 31 ธันวาคม 2567



5.2.1 การพยากรณ์โหลด (Load Forecasting)

รูป 40: แบบจำลองการพยากรณ์โหลดภายใต้กรอบ Hour-Ahead

รูปที่ 40 แสดงถึงแบบจำลองพยากรณ์โหลดไฟฟ้าระยะหลายชั่วโมงล่วงหน้า ซึ่งใช้การปรับแต่งพารามิเตอร์ จากแบบจำลอง LSTM มีรายละเอียดดังนี้

รายละเอียดพารามิเตอร์ของแบบจำลอง LSTM (LSTM Model Parameters)

- n_lags = 12 จำนวนข้อมูลในอดีตที่ใช้เป็นอินพุตเท่ากับ 12 ขั้นเวลา (1 ชั่วโมงก่อนหน้า)
- n_forecasts = 12 จำนวนข้อมูลในอนาคตที่ต้องการพยากรณ์ล่วงหน้าเท่ากับ 12 ขั้นเวลา (1 ชั่วโมงล่วง หน้า)
- batch_size = 4096 จำนวนข้อมูลในแต่ละชุดที่ใช้ในการฝึก

- learning_rate = 1e-3 อัตราการเรียนรู้สำหรับตัวปรับน้ำหนัก
- n_epochs = 100 จำนวนรอบการฝึกสูงสุด
- n_patience = 100 จำนวนรอบสำหรับการหยุดการฝึกเมื่อประสิทธิภาพไม่ดีขึ้น
- loss_function = nn.L1Loss() ฟังก์ชันการสูญเสียเป็นค่า MAE (Mean Absolute Error)

ข้อมูลคุณลักษณะ (Input features)

- (1) กำลังไฟฟ้าของโหลดในอดีต 1 ชั่วโมง, $P_{\text{load}}(t), \ P_{\text{load}}(t-1), \ \dots, \ P_{\text{load}}(t-11)$
- (2) อุณหภูมิพยากรณ์ล่วงหน้า 1 ชั่วโมง $\hat{T}_{\sf NWP}(t+1), \ \hat{T}_{\sf NWP}(t+2), \ \dots, \ \hat{T}_{\sf NWP}(t+12)$
- (3) ช่วงเวลาในการใช้ห้องปฏิบัติการล่วงหน้า 1 ชั่วโมง $\hat{L}_h(t+1), \ \hat{L}_h(t+2), \ \dots, \ \hat{L}_h(t+12)$
- (4) วันที่มีการใช้ห้องปฏิบัติการล่วงหน้า 1 ชั่วโมง $\hat{L}_d(t+1), \ \hat{L}_d(t+2), \ \dots, \ \hat{L}_d(t+12)$
- (5) วันที่มหาวิทยาลัยเปิดทำการล่วงหน้า 1 ชั่วโมง $\hat{W}_{d}(t+1), \ \hat{W}_{d}(t+2), \ \dots, \ \hat{W}_{d}(t+12)$

ข้อมูลขาออก (Output feature)

กำลังไฟฟ้าของโหลดล่วงหน้า 1 ชั่วโมง, $\hat{P}_{\text{load}}(t+1), \ \hat{P}_{\text{load}}(t+2), \ \dots, \ \hat{P}_{\text{load}}(t+12)$

ในการพัฒนาแบบจำลองพยากรณ์โหลดไฟฟ้าด้วยโครงข่ายประสาทเทียมแบบ LSTM ได้มีการทดลองปรับไฮ เปอร์พารามิเตอร์ในหลายด้านเพื่อหาโครงสร้างแบบจำลองที่ให้ผลการพยากรณ์ดีที่สุด โดยการทดลองแบ่งออกเป็น หัวข้อหลัก ดังนี้

- จำนวนเลเยอร์ของ LSTM (Number of LSTM Layers): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อศึกษาผลกระทบของจำนวนชั้นของแบบจำลองต่อความแม่นยำในการพยากรณ์
- จำนวนหน่วยซ่อนในแต่ละเลเยอร์ (Number of Hidden Sizes per Layer): ทดลองค่าต่าง ๆ ได้แก่
 10, 20, 50, 100 และ 200 หน่วย เพื่อวิเคราะห์ความสามารถในการเรียนรู้รูปแบบข้อมูลที่ซับซ้อน
- จำนวนเลเยอร์แบบเชื่อมต่อเต็มภายหลังแบบจำลอง LSTM (Number of Fully Connected Layers after LSTM, FC Layer Dim.): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อเสริม ความสามารถของแบบจำลองในการประมวลผลลักษณะของข้อมูลที่ได้จาก LSTM

ค่าความสูญเสียของแบบจำลองที่น้อยที่สุดในชุดข้อมูลตรวจสอบ

เมื่อพิจารณาจำนวนเลเยอร์ของ LSTM ใน*รูปที่* 41 พบว่าเมื่อจำนวนเลเยอร์เพิ่มขึ้นจาก 1 ถึง 2 จะทำให้ ค่าความสูญเสียลดลง และที่จำนวนเลเยอร์เท่ากับ 2 ส่งผลให้เกิดค่าความสูญเสียต่ำสุด จากกราฟจะเห็นได้ชัดว่า เมื่อเพิ่มค่าจำนวนเลเยอร์เป็นค่าอื่น ค่าความความสูญเสียจะมีค่าคงที่ และจะสูงขึ้นในภายหลังนั่นหมายว่าจำนวน ชั้นเลเยอร์มีจำนวนมากเกินความต้องการ ดังนั้นจึงเลือก LSTM Layers = 2 จากการเปรียบเทียบทั้งหมด พบ ว่าแบบจำลองที่มี LSTM Layers = 2, Hidden Sizes = 50, และ FC Layer Dim. = 1 ให้ผลลัพธ์ดีที่สุด จึง เลือกใช้แบบจำลองนี้เป็น **แบบจำลองที่ดีที่สุดของการพยากรณ์โหลดไฟฟ้าระยะหลายชั่วโมงล่วงหน้า**

Trade-off: LSTM layers vs Validation Loss



รูป 41: กราฟแสดงค่าความสูญเสียของแบบจำลองในชุดข้อมูลตรวจสอบ

แบบจำลองที่ดีที่สุดของการพยากรณ์โหลดไฟฟ้าระยะหลายชั่วโมงล่วงหน้า

แบบจำลอง LSTM ที่มี LSTM Layers = 2, Hidden Sizes = 50 และ FC Layer Dim. = 1 ได้ถูกนำมาใช้ใน การพยากรณ์โหลดไฟฟ้าระยะหลายชั่วโมงล่วงหน้า



รูป 42: กราฟอนุกรมเวลาของโหลดไฟฟ้าจริงและค่าพยากรณ์โหลดไฟฟ้าภายใต้กรอบ Hour-Ahead

5.2.2 การพยากรณ์ความเข้มแสง (Irradiance Forecasting)

รายละเอียดพารามิเตอร์ของแบบจำลอง LSTM (LSTM Model Parameters)

แบบจำลองการเรียนรู้ด้วยโครงข่ายประสาทเทียมแบบ LSTM (Long Short-Term Memory) ถูกนำมาใช้ในการ พยากรณ์พลังงานแสงอาทิตย์ล่วงหน้า โดยใช้ข้อมูลอดีตและข้อมูลพยากรณ์ของตัวแปรสภาพอากาศในอนาคตเป็น





้ ปัจจัยร่วมในการพยากรณ์ตาม*รูปที่* 43 แบบจำลองนี้ถูกกำหนดค่าพารามิเตอร์ต่างๆ ดังนี้

- n_lags = 12 จำนวนข้อมูลในอดีตที่ใช้เป็นอินพุตเท่ากับ 12 ขั้นเวลา (เวลา 1 ชั่วโมงในอดีต)
- n_forecasts = 12 จำนวนข้อมูลในอนาคตที่ต้องการพยากรณ์ล่วงหน้าเท่ากับ 12 ขั้นเวลา (เวลา 1 ชั่วโมง ล่วงหน้า)
- batch_size = 64 จำนวนข้อมูลในแต่ละชุดที่ใช้ในการฝึก
- learning_rate = 1e-3 อัตราการเรียนรู้สำหรับตัวปรับน้ำหนัก
- n_epochs = 100 จำนวนรอบการฝึกสูงสุด
- n_patience = 100 จำนวนรอบสำหรับการหยุดการฝึกเมื่อประสิทธิภาพไม่ดีขึ้น
- loss_function = nn.L1Loss() ฟังก์ชันการสูญเสียเป็นค่า MAE (Mean Absolute Error)
- ข้อมูลนำเข้า (Input)
 - 1. ความเข้มแสงในอดีต 1 ชั่วโมง: $I(t), I(t-1), \dots, I(t-11)$
 - 2. ความเข้มแสงจาก NWP ใน 1 ชั่วโมงถัดไป: $\hat{I}_{\text{NWP}}(t+1), \hat{I}_{\text{NWP}}(t+2), \dots, \hat{I}_{\text{NWP}}(t+12)$
 - 3. อุณหภูมิจาก NWP ใน 1 ชั่วโมงถัดไป: $\hat{T}_{\sf NWP}(t+1), \hat{T}_{\sf NWP}(t+2), \dots, \hat{T}_{\sf NWP}(t+12)$
 - 4. ความเข้มแสงในสภาพท้องฟ้าใสใน 1 ชั่วโมงถัดไป: $\hat{I}_{clr}(t+1), \hat{I}_{clr}(t+2), \dots, \hat{I}_{clr}(t+12)$

- 5. ดัชนีเมฆของภาพขาวดำใน 1 ชั่วโมงถัดไป: $\hat{CI}_{\mathsf{CM}}(t+1), \hat{CI}_{\mathsf{CM}}(t+2), \dots, \hat{CI}_{\mathsf{CM}}(t+12)$
- 6. ดัชนีเมฆของภาพสีจากช่องสัญญาณสีแดงใน 1 ชั่วโมงถัดไป: $\hat{CI}_{\mathsf{R}}(t+1), \hat{CI}_{\mathsf{R}}(t+2), \dots, \hat{CI}_{\mathsf{R}}(t+1)$

• ข้อมูลส่งออก (Output)

1. ผลลัพธ์ของการพยากรณ์ของความเข้มแสงใน 1 ชั่วโมงถัดไป: $\hat{I}(t+1), \hat{I}(t+2), \dots, \hat{I}(t+12)$

ในการพัฒนาแบบจำลองพยากรณ์ความเข้มแสงอาทิตย์ด้วยโครงข่ายประสาทเทียมแบบ LSTM ได้มีการทดลอง ในหลายด้านเพื่อหาโครงสร้างแบบจำลองที่ให้ผลการพยากรณ์ดีที่สุด โดยการทดลองแบ่งออกเป็นหัวข้อหลัก ดังนี้

- จำนวนเลเยอร์ของ LSTM (Number of LSTM Layers): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อศึกษาผลกระทบของความลึกของแบบจำลองต่อความแม่นยำในการพยากรณ์
- จำนวนหน่วยซ่อนในแต่ละเลเยอร์ (Number of Hidden Sizes per Layer): ทดลองค่าต่าง ๆ ได้แก่
 10, 20, 50, 100 และ 200 หน่วย เพื่อวิเคราะห์ความสามารถในการเรียนรู้รูปแบบข้อมูลที่ซับซ้อน
- จำนวนเลเยอร์แบบเชื่อมต่อเต็มภายหลังแบบจำลอง LSTM (Number of Fully Connected Layers after LSTM, FC Layer Dim.): ทดลองค่าต่าง ๆ ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ เพื่อเสริม ความสามารถของแบบจำลองในการประมวลผลลักษณะของข้อมูลที่ได้จาก LSTM

ค่าความสูญเสียของแบบจำลองสำหรับชุดข้อมูลฝึกและตรวจสอบ

รูปที่ 44, *รูปที่* 45, และ*รูปที่* 46 แสดงกราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ระยะ หลายชั่วโมงล่วงหน้า สำหรับชุดข้อมูลฝึกและตรวจสอบ แสดงให้เห็นถึงการลดลงของค่าความสูญเสียในแต่ละจำนวน เลเยอร์ LSTM ดังนี้:

- จำนวนเลเยอร์ LSTM = 1, 2, 5, 10, และ 20 เลเยอร์
 - การทดลองในแต่ละกรณีพบว่าค่าความสูญเสียของชุดข้อมูลฝึกสามารถลดลงได้อย่างต่อเนื่อง โดยเฉพาะ ในกรณีที่จำนวนเลเยอร์ไม่มากนัก เช่น 1 หรือ 2 เลเยอร์ ขณะที่บางแบบจำลอง เช่น กรณีที่มีเลเยอร์ มากขึ้น (เช่น 10 หรือ 20 เลเยอร์) ค่าความสูญเสียของชุดข้อมูลตรวจสอบมีแนวโน้มคงที่ แสดงถึง ภาวะ underfitting หรือ model saturation ได้ในบางกรณี
- ข้อสังเกต
 - ถึงแม้ว่าค่าความสูญเสียของชุดข้อมูลฝึกจะลดลงได้มากขึ้นเมื่อใช้แบบจำลองที่ซับซ้อนขึ้น แต่ค่าความ สูญเสียของชุดข้อมูลตรวจสอบในบางกรณีไม่ได้ลดลงตาม แสดงให้เห็นว่าแบบจำลองอาจเรียนรู้เฉพาะ ข้อมูลฝึกได้ดี แต่ไม่สามารถเรียนรู้ข้อมูลทั่วไปได้ดีในชุดข้อมูลที่ไม่เคยเห็น
 - ค่าความสูญเสียของชุดข้อมูลตรวจสอบในบางช่วงเวลาอาจต่ำกว่าค่าความสูญเสียของชุดข้อมูลฝึก ซึ่ง อาจสะท้อนถึงความแตกต่างเชิงลักษณะของข้อมูลทั้งสองชุด เช่น ความซับซ้อน ความไม่สมดุล หรือ noise ที่อาจมีมากในชุดข้อมูลฝึก
- จากการเปรียบเทียบผลการทดลองในแต่ละกรณีพบว่า
 - แบบจำลองที่มีจำนวนเลเยอร์แตกต่างกันไม่ได้แสดงความแตกต่างอย่างมีนัยสำคัญในด้านค่าความสูญ เสียของชุดข้อมูลตรวจสอบ
 - ดังนั้นอาจสรุปได้ว่า การเพิ่มจำนวนเลเยอร์ LSTM ในกรณีนี้ไม่ได้ส่งผลให้ประสิทธิภาพของแบบจำลอง
 ดีขึ้นอย่างมีนัยสำคัญ และจำนวนเลเยอร์ที่มากเกินไปอาจนำไปสู่ความซับซ้อนที่ไม่จำเป็น



รูป 44: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (1)



รูป 45: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (2)



รูป 46: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead สำหรับชุด ข้อมูลฝึกและตรวจสอบ (3)

ค่าความสูญเสียของแบบจำลองที่น้อยที่สุดในชุดข้อมูลตรวจสอบ



รูป 47: กราฟแสดงค่าความสูญเสียของแบบจำลองการพยากรณ์โซลาร์ภายใต้กรอบ Hour-Ahead ที่น้อยที่สุด ในชุดข้อมูลตรวจสอบ

รูปที่ 47 แสดงผลการทดลองเปรียบเทียบประสิทธิภาพของแบบจำลอง LSTM สำหรับการพยากรณ์พลังงาน แสงอาทิตย์ระยะหลายชั่วโมงล่วงหน้า โดยพิจารณาจำนวนเลเยอร์ของ LSTM ที่แตกต่างกัน ได้แก่ 1, 2, 5, 10 และ 20 เลเยอร์ ในแต่ละกรณีได้มีการปรับค่า Hidden Size และขนาดของ FC Layer Dim. ให้เหมาะสมเพื่อ ให้ค่าความสูญเสียบนชุดตรวจสอบต่ำที่สุด ผลการวิเคราะห์สามารถสรุปได้ดังนี้:

- LSTM = 1 เลเยอร์: แบบจำลองที่มี Hidden Size เท่ากับ 50 และ FC Layer Dim. เท่ากับ 1 ให้ค่า ความสูญเสียบนชุดตรวจสอบเท่ากับ 0.1239 ซึ่งแสดงให้เห็นว่าโครงสร้างที่เรียบง่ายสามารถเรียนรู้ข้อมูล ลักษณะระยะหลายวันล่วงหน้าได้ในระดับหนึ่ง
- LSTM = 2 เลเยอร์: แบบจำลองที่มีพารามิเตอร์เท่ากับกรณี LSTM 1 เลเยอร์ (Hidden Size = 50, FC

Layer Dim. = 1) ให้ค่าความสูญเสียต่ำที่สุดที่ 0.1227 สะท้อนถึงการเพิ่มความสามารถในการเรียนรู้เมื่อ ลึกขึ้นเพียงเล็กน้อย

- LSTM = 5 เลเยอร์: แม้จะลดขนาด Hidden Size ลงเหลือ 20 และ FC Layer Dim. เท่ากับ 1 เพื่อควบคุม จำนวนพารามิเตอร์รวม แต่ยังให้ค่าความสูญเสียอยู่ในระดับต่ำที่ 0.1228 ซึ่งใกล้เคียงกับค่าที่ดีที่สุด
- LSTM = 10 เลเยอร์: การใช้ Hidden Size เท่ากับ 50 และ FC Layer Dim. เท่ากับ 1 ยังสามารถ รักษาค่าความสูญเสียให้อยู่ในระดับใกล้เคียงกับแบบจำลองที่ตื้นกว่า ซึ่งมีค่าเท่ากับ 0.1228 แต่ไม่ได้ส่งผล ให้เกิดการปรับปรุงที่มีนัยสำคัญ
- LSTM = 20 เลเยอร์: แม้จะใช้ Hidden Size เท่ากับ 100 และ FC Layer Dim. เท่ากับ 1 เพื่อรองรับ โครงสร้างที่ลึกขึ้น แต่ค่าความสูญเสียกลับเพิ่มขึ้นเป็น 0.1364 แสดงให้เห็นว่าแบบจำลองอาจมีความซับ ซ้อนเกินความจำเป็นเมื่อเทียบกับขนาดของข้อมูลที่ใช้ในการฝึก

จากการเปรียบเทียบทั้งหมด พบว่าแบบจำลองที่มี LSTM Layers = 2, Hidden Sizes = 50, และ FC Layer Dim. = 1 ให้ผลลัพธ์ดีที่สุด โดยสามารถลดค่าความสูญเสียในชุดตรวจสอบได้ต่ำที่สุด และรักษาเสถียรภาพ ระหว่างค่าความสูญเสียในชุดฝึกและชุดตรวจสอบได้ดี จึงเลือกใช้แบบจำลองนี้เป็น แบบจำลองที่เหมาะสมที่สุด ของการพยากรณ์โซลาร์ระยะหลายชั่วโมงล่วงหน้า

แบบจำลองที่เหมาะสมที่สุดของการพยากรณ์โซลาร์ระยะหลายชั่วโมงล่วงหน้า

แบบจำลอง LSTM ที่มี LSTM Layers = 2, Hidden Sizes = 50, และ FC Layer Dim. = 1 ได้ถูกนำมาประยุกต์ ใช้ในการพยากรณ์ความเข้มแสงระยะหลายชั่วโมงล่วงหน้า





รูป 48: กราฟอนุกรมเวลาของความเข้มแสงค่าจริงและค่าแบบจำลองพยากรณ์ภายใต้กรอบ Hour-Ahead

รูปที่ 48 แสดงการเปรียบเทียบระหว่างค่าความเข้มแสงอาทิตย์จริงและค่าที่ได้จากการพยากรณ์ล่วงหน้า 5 นาที และ 1 ชั่วโมงของแบบจำลอง LSTM สำหรับกรณีการพยากรณ์ระยะหลายชั่วโมงล่วงหน้า ในการพยากรณ์ ล่วงหน้า 5 นาทีจะเห็นได้ว่าแบบจำลองสามารถติดตามแนวโน้มของข้อมูลได้อย่างแม่นยำในหลายช่วงเวลา แม้ว่า จะมีบางช่วงที่ค่าพยากรณ์เบี่ยงเบนจากค่าจริง โดยเฉพาะช่วงที่ความเข้มแสงมีความผันผวนสูง แต่เมื่อเปรียบเทียบ กับผลการพยากรณ์ล่วงหน้า 1 ชั่วโมง พบว่าแบบจำลองที่พยากรณ์ล่วงหน้า 5 นาที สามารถติดตามการเปลี่ยนแปลง ของข้อมูลได้แม่นยำกว่า โดยเฉพาะในช่วงที่ความเข้มแสงเปลี่ยนแปลงอย่างรวดเร็ว นอกจากนี้เมื่อเปรียบเทียบกับ ผลการพยากรณ์ของกรณี DA ใน*รูปที่* 37 พบว่าแบบจำลองในกรณี HA ใน*รูปที่* 48 สามารถติดตามการเปลี่ยนแปลง ของข้อมูลได้แม่นยำกว่าอย่างชัดเจน ทั้งในด้านของแนวโน้มและระดับของค่าที่พยากรณ์ได้ โดยเฉพาะในช่วงที่มี ความเปลี่ยนแปลงอย่างรวดเร็วของความเข้มแสง ซึ่งแสดงให้เห็นถึงความได้เปรียบของกรอบเวลาการพยากรณ์ที่ สั้นกว่าในการรักษาความแม่นยำของแบบจำลอง



Model Performance Comparison: yhat1 vs yhat12

รูป 49: กราฟแสดงค่า MAE และ RMSE ของผลการพยากรณ์ความเข้มแสงอาทิตย์ล่วงหน้า 5 นาที และ 1 ชั่วโมง สำหรับแต่ละชั่วโมง

รูปที่ 49 แสดงค่า Mean Absolute Error (MAE) และ Root Mean Squared Error (RMSE) รายชั่วโมง สำหรับการพยากรณ์ค่าความเข้มแสงอาทิตย์ล่วงหน้า 5 นาที และ 1 ชั่วโมง (HA) ในช่วงเวลา 06:00–18:00 น. ซึ่งสามารถวิเคราะห์ได้ดังนี้:

- แนวโน้มโดยรวม: ค่าความคลาดเคลื่อน (ทั้ง MAE และ RMSE) มีแนวโน้มอยู่ในระดับต่ำตลอดช่วงเวลา 06:00–18:00 ซึ่งสอดคล้องกับลักษณะของการพยากรณ์ระยะหลายวันล่วงหน้า (โดยเฉพาะการพยากรณ์ ล่วงหน้า 5 นาที) ที่แบบจำลองสามารถติดตามแนวโน้มของข้อมูลได้ดี เนื่องจากข้อมูลในอนาคตมีความสัมพันธ์ ใกล้ชิดกับข้อมูลในอดีต
- ช่วงเช้า (06:00–09:00): ค่า MAE และ RMSE อยู่ในระดับต่ำ แสดงให้เห็นว่าแบบจำลองสามารถพยากรณ์ ได้แม่นยำในช่วงที่ค่าความเข้มแสงยังไม่ผันผวนมาก โดยเฉพาะในกรณี 5 นาทีที่สามารถตอบสนองต่อการ เปลี่ยนแปลงได้รวดเร็วกว่า
- ช่วงกลางวัน (10:00–14:00): เป็นช่วงที่ค่าความคลาดเคลื่อนมีแนวโน้มสูงขึ้น เนื่องจากเป็นช่วงเวลาที่ ค่าความเข้มแสงมีการเปลี่ยนแปลงอย่างรวดเร็ว หรือได้รับอิทธิพลจากปัจจัยภายนอก เช่น การเคลื่อนผ่าน ของเมฆ ซึ่งส่งผลให้ความแม่นยำลดลงในทั้งสองกรณี โดยกรณี 1 ชั่วโมงจะได้รับผลกระทบมากกว่า
- ช่วงบ่าย (15:00–18:00): ค่าความคลาดเคลื่อนลดลงอีกครั้ง โดยเฉพาะในช่วงหลัง 16:00 เป็นต้นไป ซึ่ง เป็นช่วงที่ความเข้มแสงลดลงอย่างต่อเนื่อง แบบจำลองสามารถคาดการณ์ได้แม่นยำยิ่งขึ้น โดยเฉพาะในกรณี 5 นาที
- การเปรียบเทียบระหว่างการพยากรณ์ล่วงหน้า 5 นาทีและ 1 ชั่วโมง: พบว่าการพยากรณ์ล่วงหน้า 5 นาทีมีค่าความคลาดเคลื่อนต่ำกว่าการพยากรณ์ล่วงหน้า 1 ชั่วโมงในเกือบทุกช่วงเวลา ซึ่งสะท้อนให้เห็นถึง ความแม่นยำที่สูงขึ้นของระยะพยากรณ์ที่สั้นกว่า โดยเฉพาะในช่วงเวลาที่ค่าความเข้มแสงเปลี่ยนแปลงรวดเร็ว

• การเปรียบเทียบ MAE และ RMSE: ค่าความคลาดเคลื่อน RMSE สูงกว่า MAE ในทุกช่วงเวลา แสดงให้ เห็นว่ามีบางช่วงที่เกิดความผิดพลาดขนาดใหญ่ (outlier) ซึ่งส่งผลต่อค่า RMSE มากกว่า MAE

จากการคำนวณค่าความคลาดเคลื่อนเฉลี่ยตลอดช่วงเวลา 06:00–18:00 สำหรับการพยากรณ์ล่วงหน้า 5 นาที และ 1 ชั่วโมง สามารถสรุปได้ใน*ตารางที่* 5 นอกจากนี้ค่าความคลาดเคลื่อนโดยรวมแสดงให้เห็นว่าแบบจำลองมี ความสามารถในการพยากรณ์ความเข้มแสงระยะหลายชั่วโมงล่วงหน้าได้อย่างแม่นยำ โดยมีค่าผิดพลาดเฉลี่ยในระดับ ต่ำ ซึ่งสอดคล้องกับลักษณะของข้อมูลในกรณี HA ที่มีการเปลี่ยนแปลงของข้อมูลค่อนข้างต่อเนื่องและไม่ซับซ้อน เท่าการพยากรณ์ระยะหลายวันล่วงหน้าใน*ตารางที่* 4

ตาราง 5: ค่า MAE และ RMSE โดยรวมของการพยากรณ์ความเข้มแสงล่วงหน้า 1 ชั่วโมง (06:00-18:00)

ระยะเวลาพยากรณ์ล่วงหน้า	MAE (W/m^2)	RMSE (W/m^2)
5 นาที	60.62	106.69
1 ชั่วโมง	80.01	123.75

การแปลงค่าความเข้มแสงเป็นกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์

Time series PV power for model: n_lstm_layers = 2, hidden_units = 50, dim_future_layers = 1



รูป 50: กราฟอนุกรมเวลาของกำลังไฟฟ้าที่ผลิตได้ของแผงโซลาร์ค่าจริงและค่าพยากรณ์ภายใต้กรอบ Hour-Ahead

รูปที่ 50 แสดงผลการเปรียบเทียบระหว่างค่ากำลังไฟฟ้าจริงและค่าที่ได้จากการพยากรณ์ของแบบจำลอง Hour-Ahead ซึ่งได้จากการแปลงค่าความเข้มแสงพยากรณ์แบบระยะหลายชั่วโมงล่วงหน้าผ่านสมการ (27) และ (25) ผลการพยากรณ์แสดงให้เห็นว่าแบบจำลองสามารถติดตามแนวโน้มของกำลังไฟฟ้าได้อย่างแม่นยำกว่ากรณี Day-Ahead ใน*รูปที่* 39 โดยเฉพาะในช่วงที่ค่ากำลังไฟฟ้ามีการเปลี่ยนแปลงอย่างรวดเร็วหรือมีความผันผวนสูง ซึ่งบ่ง บอกถึงข้อได้เปรียบของการพยากรณ์ในกรอบเวลาที่สั้นกว่าในการสะท้อนการเปลี่ยนแปลงของสภาพแวดล้อมที่เกิด ขึ้น ณ ใกล้เคียงเวลาจริงได้ดีกว่า

6 ผลการทดลองของระบบจัดการพลังงาน

เพื่อประเมินประสิทธิภาพของระบบจัดการพลังงาน (Energy Management System: EMS) ได้มีการดำเนิน การทดลองในสองระดับเวลา ได้แก่ ระยะหลายวันล่วงหน้า (Day-Ahead, DA) และระยะหลายชั่วโมงล่วงหน้า (Hour-Ahead, HA) โดยแต่ละระดับมีการเปรียบเทียบทั้งในรูปแบบการคำนวณแบบตัวอย่างชุดข้อมูลย่อย (Batch) และ การควบคุมเชิงทำนายแบบจำลอง (MPC) โดยมีวัตถุประสงค์หลักคือการลดต้นทุนพลังงาน หรือเพิ่มกำไรจาก การดำเนินงาน รวมถึงในกรณี HA มีการติดตามผลจากการวางแผนล่วงหน้าในระดับ DA ผ่านวัตถุประสงค์ J_{trackDA} แสดงรายละเอียดของการทดลองที่ดำเนินการตาม*ตารางที่* 6

การทดลอง	ระดับเวลา (HA/DA)	วัตถุประสงค์	ลักษณะข้อมูลโหลดและโซลาร์
1	DA	$J_{\text{energycost}} + J_{\text{battery}}$	actual
2	DA	$J_{\text{energycost}} + J_{\text{battery}}$	forecast
3	DA	$J_{\text{profit}} + J_{\text{battery}}$	actual
4	DA	$J_{\text{profit}} + J_{\text{battery}}$	forecast
5	HA	$J_{\text{energycost}} + J_{\text{battery}} + J_{\text{track,DA}}$	actual
6	HA	$J_{\text{energycost}} + J_{\text{battery}} + J_{\text{track,DA}}$	forecast
7	HA	$J_{\text{profit}} + J_{\text{battery}} + J_{\text{track,DA}}$	actual
8	HA	$J_{\text{profit}} + J_{\text{battery}} + J_{\text{track,DA}}$	forecast

ตาราง 6: รายละเอียดการทดลองของระบบจัดการพลังงาน

ทมายแหตุ: $J_{
m battery} = w_{
m m} J_{
m multibatt} + w_{
m S} J_{
m smooth\ charge} + w_{
m c} J_{
m charge\ batt}$

ในการทดลองมีการประเมินค่าใช้จ่ายจากการใช้พลังงานไฟฟ้าในระบบพลังงานแบบไมโครกริด กำลังไฟฟ้าสุทธิ (P_{net}) หมายถึงปริมาณพลังงานที่ระบบจำเป็นต้องซื้อจากกริดภายนอก หลังจากหักลบพลังงานที่ผลิตได้ในระบบ และการอัดประจุหรือคายประจุของแบตเตอรี่ในช่วงเวลานั้นๆ โดยสามารถคำนวณได้แตกต่างกันตามกรณีที่พิจารณา ได้แก่

 กรณี Ideal: เป็นกรณีอ้างอิงที่สมมุติให้ระบบสามารถรู้ข้อมูลโหลดและโซลาร์ล่วงหน้าอย่างแม่นยำ ทำให้ สามารถวางแผนการอัดประจุหรือคายประจุแบตเตอรี่ได้อย่างเหมาะสมในแต่ละช่วงเวลา ส่งผลให้สามารถ ลดการพึ่งพาพลังงานจากกริดได้อย่างมีประสิทธิภาพสูงสุด และนำไปสู่ต้นทุนรวมที่ต่ำที่สุดเมื่อเทียบกับกรณี อื่นๆ โดยสามารถนิยามกำลังไฟฟ้าสุทธิที่เกิดขึ้นจริงได้ตาม (28) ซึ่งเป็นค่าใช้จ่ายที่เกิดขึ้นในการทดลอง 1, 3, 5, และ 7

$$P_{\text{net, ideal}}(t) = P_{\text{load}}(t) - P_{\text{pv}}(t) + \sum_{i=1}^{n} \left(P_{\text{chg}}^{(i)}(t) - P_{\text{dchg}}^{(i)}(t) \right) \qquad t = 1, 2, \dots, T$$
(28)

 กรณี EMS: เป็นกรณีที่ใช้ข้อมูลพยากรณ์โหลดและโซลาร์ในการวางแผนล่วงหน้า ทำให้แผนการอัดประจุ หรือคายประจุแบตเตอรี่ที่ได้จึงสามารถลดการซื้อไฟจากกริดได้ในระดับหนึ่ง แม้จะไม่แม่นยำเท่า Ideal เนื่องจาก มีข้อจำกัดจากความคลาดเคลื่อนของข้อมูลพยากรณ์ โดยสามารถนิยามกำลังไฟฟ้าสุทธิที่เกิดขึ้นจริงได้ตาม (29) ซึ่งเป็นค่าใช้จ่ายที่เกิดขึ้นในการทดลอง 2, 4, 6, และ 8

$$P_{\text{net, ems}}(t) = \hat{P}_{\text{load}}(t) - \hat{P}_{\text{pv}}(t) + \sum_{i=1}^{n} \left(\hat{P}_{\text{chg}}^{(i)}(t) - \hat{P}_{\text{dchg}}^{(i)}(t) \right) \qquad t = 1, 2, \dots, T$$
(29)

 กรณี Actual: เป็นผลลัพธ์จากการนำแผนการอัดประจุหรือคายประจุแบตเตอรี่จาก EMS ไปใช้กับข้อมูล โหลดและโซลาร์จริง หากการพยากรณ์มีความคลาดเคลื่อน เช่น โซลาร์จริงต่ำกว่าที่คาด หรือโหลดสูงกว่า คาด จะทำให้ไม่สามารถอัดประจุหรือคายประจุจากแบตเตอรี่ได้อย่างมีประสิทธิภาพ ส่งผลให้ต้องซื้อไฟเพิ่ม ขึ้นจากกริด โดยสามารถนิยามกำลังไฟฟ้าสุทธิที่เกิดขึ้นจริงได้ตาม (30)

$$P_{\text{net, actual}}(t) = P_{\text{load}}(t) - P_{\text{pv}}(t) + \sum_{i=1}^{n} \left(\hat{P}_{\text{chg}}^{(i)}(t) - \hat{P}_{\text{dchg}}^{(i)}(t) \right) \qquad t = 1, 2, \dots, T$$
(30)

 กรณี No EMS: เป็นกรณีที่ไม่มีการบริหารจัดการด้วยแบตเตอรี่ พลังงานทั้งหมดต้องซื้อจากกริดเมื่อโหลด มากกว่าการผลิต โดยสามารถนิยามกำลังไฟฟ้าสุทธิที่เกิดขึ้นจริงได้ตาม (31)

$$P_{\text{net, noems}}(t) = P_{\text{load}}(t) - P_{\text{pv}}(t) \quad t = 1, 2, \dots, T$$
 (31)

นิยามตัวแปรที่ใช้ในสมการ

- $P_{\mathsf{net},x}(t)$: กำลังไฟฟ้าสุทธิของกรณี $x \in \{\mathsf{ideal}, \mathsf{ems}, \mathsf{actual}, \mathsf{noems}\}$
- $\hat{P}_{\text{load}}(t)$ คือ กำลังโหลดที่พยากรณ์ไว้ในช่วงเวลา t
- $P_{\rm pv}(t)$ คือ กำลังไฟฟ้าที่ผลิตได้จริงจากโซลาร์ในช่วงเวลา t
- $\hat{P}_{\mathrm{pv}}(t)$ คือ กำลังไฟฟ้าที่พยากรณ์จากโซลาร์ในช่วงเวลา t
- $P_{
 m chg}^{(i)}(t)$ คือ กำลังที่ใช้อัดประจุแบตเตอรี่ก้อนที่ i ในช่วงเวลา t เมื่อใช้ข้อมูลโหลดและโซลาร์จริง
- $P_{
 m dchg}^{(i)}(t)$ คือ กำลังที่คายประจุจากแบตเตอรี่ก้อนที่ i ในช่วงเวลา t เมื่อใช้ข้อมูลโหลดและโซลาร์จริง
- $\hat{P}_{
 m chg}^{(i)}(t)$ คือ กำลังที่ใช้อัดประจุแบตเตอรี่ก้อนที่ i ในช่วงเวลา t เมื่อใช้ข้อมูลโหลดและโซลาร์พยากรณ์
- $\hat{P}_{
 m dchg}^{(i)}(t)$ คือ กำลังที่คายประจุจากแบตเตอรี่ก้อนที่ i ในช่วงเวลา t เมื่อใช้ข้อมูลโหลดและโซลาร์พยากรณ์
- n คือ จำนวนแบตเตอรี่ทั้งหมดในระบบ
- T คือ จำนวนช่วงเวลาทั้งหมดที่ใช้ในการวิเคราะห์

จากการวิเคราะห์ผลลัพธ์ พบว่าลำดับของค่าใช้จ่ายสุทธิ (ซื้อไฟฟ้า - ขายไฟฟ้า) ในแต่ละกรณี เรียงจาก **น้อย ไปมาก** ได้แก่

Ideal, EMS < Actual < No EMS

โดยกรณี Ideal หรือ EMS มีค่าใช้จ่ายต่ำที่สุด ขึ้นอยู่กับความแม่นยำในการพยากรณ์ข้อมูลโหลดและพลังงาน จากโซลาร์ ซึ่งมีผลต่อปริมาณพลังงานที่เหลือ หากพลังงานที่เหลือจากค่าพยากรณ์มากกว่าค่าจริง ทำให้กรณี EMS จะมีค่าใช้จ่ายต่ำสุด แต่หากพลังงานที่เหลือจากค่าพยากรณ์น้อยกว่าค่าจริง ทำให้กรณี Ideal จะมีค่าใช้จ่ายต่ำ สุด เนื่องจากทั้งสองกรณีสามารถวางแผนการใช้พลังงานได้อย่างมีประสิทธิภาพสูงสุด ในขณะที่กรณี No EMS มี ค่าใช้จ่ายสูงที่สุด เนื่องจากไม่มีการใช้แบตเตอรี่เพื่อช่วยลดภาระการซื้อไฟฟ้าจากกริด

พารามิเตอร์	ค่า	หน่วย
η_c	0.95	-
η_d	0.95*0.93	-
อัตราการอัดประจุประจุสูงสุด	100	kW
อัตราการคายประจุสูงสุด	100	kW
ความจุแบตเตอรี่	215	kWh
$SoC_1(1)$	50	%
$SoC_2(1)$	50	%
SoC _{min}	20	%
SoC _{max}	80	%
ค่าปลาย SoC	0	%
แรงดันไฟฟ้ามาตรฐาน	$\frac{672+864}{2}$	V
จำนวนแบตเตอรี่	2	ลูก
w_{s}	3	-
w_{m}	10^{-4}	-
wc	0.05	-
wnet	0	-
w_{Chg}	0	-
$w_{\sf dchg}$	0	-

ตาราง 7: ค่าพารามิเตอร์ของการทดลองภายใต้กรอบ Day-Ahead

ตาราง 8: ค่าพารามิเตอร์ของการทดลองภายใต้กรอบ Hour-Ahead

พารามิเตอร์	ค่า	หน่วย
η_c	0.95	-
η_d	0.95 * 0.93	-
อัตราการอัดประจุประจุสูงสุด	100	kW
อัตราการคายประจุสูงสุด	100	kW
ความจุแบตเตอรี่	215	kWh
$SoC_1(1)$	50	%
$SoC_2(1)$	50	%
SoC _{min}	20	%
SoC _{max}	80	%
ค่าปลาย SoC	0	%
แรงดันไฟฟ้ามาตรฐาน	$\frac{672 + 864}{2}$	V
จำนวนแบตเตอรี่	2	ູລູກ
w_{s}	3	-
w _m	10^{-4}	-
w _c	0.05	-
wnet	0	-
w _{chg}	5	-
wdchg	5	-

6.1 ระบบจัดการพลังงานภายใต้กรอบ Day-Ahead

6.1.1 ตัวอย่างชุดข้อมูลย่อย (Batch)

การทดลองในส่วนนี้มุ่งเน้นการประเมินประสิทธิภาพของ EMS ภายใต้กรอบการวางแผนแบบ Day-Ahead และ ใช้ชุดข้อมูลย่อยทั้งโหลดและการผลิตไฟฟ้าจากโซลาร์ ซึ่งข้อมูลทั้งหมดถือว่าเป็นที่ทราบล่วงหน้าในช่วงเวลาการ วางแผนทั้งหมด แนวทางนี้เหมาะสำหรับการทดสอบประสิทธิภาพของอัลกอริทึมในสภาพแวดล้อมที่มีความไม่แน่นอน ต่ำหรือในเชิงวิเคราะห์ เพื่อดูว่า EMS สามารถตัดสินใจจัดสรรพลังงานได้อย่างมีประสิทธิภาพเพียงใด

การทดลองที่ 1

minimize subject to	$J_{cost} + w_m J_{multibatt} + w_s J_{smooth charge} + w_c J_{charge batt}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(32)
------------------------	--	------

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Day-Ahead โดยใช้ข้อมูล จริง (actual data) และตั้งค่าพารามิเตอร์ตาม*ตารางที่* 7 และใช้ฟังก์ชันวัตถุประสงค์เป็นการประหยัดค่าไฟฟ้า ตาม (12) ส่วนฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์ จากการทดลองแสดงให้เห็นว่าการใช้ EMS สามารถลดต้นทุนค่าไฟฟ้าได้ และแนวโน้มการอัดประจุและคายประจุ ของแบตเตอรี่เป็นไปอย่างมีประสิทธิภาพตามแผนที่วางไว้



รูป 51: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้**ข้อมูลจริง**เพื่อ**ประหยัดค่าไฟฟ้า**

รูปที่ 51 แสดงโหลด, โซลาร์, และผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้ข้อมูลจริง เพื่อประหยัดค่าไฟฟ้า มีรายละเอียดของกราฟย่อยในแต่ละตำแหน่งดังนี้

 กราฟย่อยที่ (1,1): กราฟอนุกรมเวลาของโหลด, กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์, และพลังงานสุทธิ แสดง การเปลี่ยนแปลงตามเวลา และเปรียบเทียบการใช้พลังงานของโหลดกับการผลิตกำลังไฟฟ้าจากโซลาร์ในแต่ละ ช่วง พบว่าในช่วงเวลากลางวัน กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์มีปริมาณมากกว่าความต้องการของโหลด ส่งผลให้มีพลังงานส่วนเกินที่สามารถนำไปจัดเก็บในแบตเตอรี่ได้ ในทางตรงกันข้ามช่วงเวลาเย็น ปริมาณความ ต้องการใช้พลังงานของโหลดสูงกว่ากำลังผลิตจากโซลาร์ ทำให้จำเป็นต้องดึงพลังงานจากแบตเตอรี่มาใช้งาน

- กราฟย่อยที่ (1,2): แสดงผลเฉลยการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} พบว่าผลเฉลยของ SoC มีแนวโน้มเพิ่มขึ้นในช่วงเวลาที่ P_{chg} > 0 kW และลดลงในช่วงเวลาที่ P_{dchg} > 0 kW ซึ่งสะท้อนให้ เห็นถึงความสอดคล้องของผลเฉลยกับพลวัตของระบบแบตเตอรี่ตามข้อจำกัดและกลไกการควบคุมที่กำหนด ไว้
- กราฟย่อยที่ (2,1): แสดงผลเฉลย P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU แสดงให้เห็นว่าระบบมีแนว โน้มเลือกดำเนินการอัดประจุเข้าสู่แบตเตอรี่ในช่วงเวลาที่อัตราค่าไฟฟ้า TOU อยู่ในระดับต่ำ และดำเนิน การคายประจุในช่วงที่อัตราค่าไฟฟ้า TOU อยู่ในระดับสูง เพื่อให้เกิดการลดต้นทุนค่าไฟฟ้ารวมอย่างมีประสิทธิภาพ
- กราฟย่อยที่ (2,2): แสดงค่าไฟฟ้าในแต่ละช่วงเวลา (15 นาที) และค่าไฟฟ้าสะสมตลอดช่วงเวลาการทดลอง แสดงให้เห็นว่าระบบจัดการพลังงานสามารถช่วยลดค่าไฟฟ้ารวมได้

การทดลองที่ 2

$\begin{array}{llllllllllllllllllllllllllllllllllll$	(33)
--	------

ในการทดลองนี้ใช้ข้อมูลพยากรณ์ (forecast data) เพื่อจำลองสภาวะการวางแผนล่วงหน้าแบบ Day-Ahead โดยตั้งค่าพารามิเตอร์ตาม*ตารางที่* 7 และใช้ฟังก์ชันวัตถุประสงค์เป็นการประหยัดค่าไฟฟ้าตาม (12) ส่วนฟังก์ชัน วัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จากการทดลองแสดง ให้เห็นว่าผลกระทบของความคลาดเคลื่อนจากการพยากรณ์ต่อประสิทธิภาพของ EMS เมื่อเปรียบเทียบกับการทดลอง ที่ 1 และช่วยเน้นย้ำความสำคัญของแบบจำลองการการพยากรณ์ที่แม่นยำ

รูปที่ 52 แสดงโหลด, โซลาร์, และผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้ข้อมูลพยากรณ์ เพื่อประหยัดค่าไฟฟ้า มีรายละเอียดของกราฟย่อยในแต่ละตำแหน่งดังนี้

- กราฟย่อยที่ (1,1): กราฟอนุกรมเวลาของโหลดพยากรณ์, กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์พยากรณ์, และ พลังงานสุทธิจากการพยากรณ์ แสดงการเปลี่ยนแปลงตามเวลา และเปรียบเทียบการใช้พลังงานของโหลด กับการผลิตกำลังไฟฟ้าจากโซลาร์ในแต่ละช่วง พบว่าในช่วงเวลากลางวัน ค่าพยากรณ์ของกำลังไฟฟ้าที่ผลิต ได้จากแผงโซลาร์มีแนวโน้มมากกว่าค่าพยากรณ์ของโหลด ส่งผลให้ระบบคาดการณ์ว่าจะมีพลังงานส่วนเกิน เพียงพอสำหรับจัดเก็บในแบตเตอรี่ แต่ในช่วงเวลาเย็น ค่าพยากรณ์ของโหลดมีแนวโน้มสูงกว่ากำลังผลิตจาก โซลาร์ ส่งผลให้ระบบคาดการณ์ว่าจำเป็นต้องดึงพลังงานจากแบตเตอรี่มาใช้งาน
- กราฟย่อยที่ (1,2): แสดงผลเฉลยการควบคุมแบตเตอรี่จากการใช้ข้อมูลพยากรณ์ ได้แก่ SoC, P_{chg}, และ P_{dchg} พบว่าผลเฉลยของ SoC มีแนวโน้มเพิ่มขึ้นในช่วงที่ P_{chg} > 0 kW และลดลงเมื่อ P_{dchg} > 0 kW เช่น เดียวกับกรณีข้อมูลจริง แต่ความคลาดเคลื่อนของการพยากรณ์อาจส่งผลให้เกิดการเปลี่ยนแปลงของการควบคุม แบตเตอรี่ เช่น การอัดประจุหรือคายประจุไม่เหมือนกับกรณีข้อมูลจริง
- กราฟย่อยที่ (2,1): แสดงผลเฉลย P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU พบว่าระบบมีแนวโน้ม ดำเนินการอัดประจุในช่วงที่ค่าไฟ TOU ต่ำ และคายประจุในช่วงที่ค่าไฟ TOU สูง เพื่อพยายามลดค่าไฟ รวม แต่ความไม่แน่นอนจากการใช้ข้อมูลพยากรณ์อาจทำให้รูปแบบการดำเนินการไม่แม่นยำเท่ากับกรณีข้อมูล จริง



รูป 52: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้**ข้อมูลพยากรณ์**เพื่อ**ประหยัดค่า ไฟฟ้า**

 กราฟย่อยที่ (2,2): แสดงค่าไฟฟ้ารายช่วงเวลา (15 นาที) และค่าไฟฟ้าสะสมจากผลลัพธ์ที่ได้จากการใช้ ข้อมูลพยากรณ์ พบว่าระบบยังคงสามารถลดค่าไฟฟ้ารวมได้ในระดับหนึ่ง แต่ประสิทธิภาพในการลดค่าไฟฟ้า มีแนวโน้มดีกว่ากรณีที่ใช้ข้อมูลจริงเล็กน้อย สาเหตุหนึ่งอาจมาจากความแม่นยำของการพยากรณ์โหลดที่ต่ำ กว่าค่าจริง ส่งผลให้การประมาณโหลดมีค่าน้อยกว่า ทำให้กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์เพียงพอต่อความ ต้องการโหลด และลดความจำเป็นในการซื้อไฟฟ้าจากกริดเพิ่มเติม

การทดลองที่ 3

minimize subject to	$J_{cost} + w_m J_{multibatt} + w_s J_{smooth charge} + w_c J_{charge batt}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(34)
------------------------	--	------

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Day-Ahead โดยใช้ข้อมูล จริง และตั้งค่าพารามิเตอร์ตาม*ตารางที่* 7 และใช้ฟังก์ชันวัตถุประสงค์เป็นการเน้นกำไรสุทธิตาม (13) ส่วนฟังก์ชัน วัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จากการทดลองแสดง ให้เห็นว่า EMS ไม่เพียงแต่ช่วยลดต้นทุนแต่ยังสามารถเพิ่มกำไรให้กับระบบได้ โดยพฤติกรรมของแบตเตอรี่และ โหลดมีผลต่อแนวทางการดำเนินการของ EMS อย่างมีนัยสำคัญ

รูปที่ 53 แสดงโหลด, โซลาร์, และผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้ข้อมูลจริง เพื่อเน้นกำไรสุทธิ มีรายละเอียดของกราฟย่อยในแต่ละตำแหน่งดังนี้

 กราฟย่อยที่ (1,1): กราฟอนุกรมเวลาของโหลด, กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์, และพลังงานสุทธิ แสดง ให้เห็นพฤติกรรมของแหล่งผลิตและโหลดในแต่ละช่วงเวลา โดยในช่วงเวลากลางวัน แผงโซลาร์ผลิตไฟฟ้า ได้มากกว่าความต้องการโหลด ส่งผลให้มีพลังงานส่วนเกินสามารถจัดเก็บในแบตเตอรี่เพื่อใช้ในช่วงเวลาอื่น


รูป 53: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้**ข้อมูลจริง**เพื่อ**เน้นกำไรสุทธิ**

หรือจำหน่ายคืนเข้าสู่กริดเพื่อสร้างรายได้เพิ่มเติม ในทางกลับกันช่วงเย็นความต้องการโหลดเพิ่มสูงสูงกว่า กำลังการผลิตจากโซลาร์ ทำให้ต้องดึงพลังงานจากแบตเตอรี่มาใช้งานเพื่อรองรับภาระโหลด

- กราฟย่อยที่ (1,2): แสดงผลเฉลยการควบคุมแบตเตอรี่ ได้แก่ SoC, $P_{\rm chg}$, และ $P_{\rm dchg}$ ซึ่งพบว่า SoC เพิ่ม ขึ้นในช่วงที่ $P_{\rm chg} > 0$ kW และลดลงในช่วงที่ $P_{\rm dchg} > 0$ kW แสดงถึงการดำเนินการอัดประจุและคาย ประจุอย่างเหมาะสมตามสถานการณ์
- กราฟย่อยที่ (2,1): แสดงผลเฉลย P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU พบว่าระบบมีแนวโน้ม ดำเนินการอัดประจุแบตเตอรี่ในช่วงที่ TOU ต่ำ และคายประจุในช่วงที่ TOU สูง โดยเฉพาะในช่วงวันสุดท้าย จะมีการคายประจุในปริมาณมาก เพื่อเพิ่มผลตอบแทนกำไรสุทธิจากการซื้อ–ขายไฟฟ้าให้ได้มากที่สุด
- กราฟย่อยที่ (2,2): แสดงผลกำไรในแต่ละช่วงเวลา (15 นาที) และผลกำไรรวมตลอดช่วงเวลาการทดลอง แสดงให้เห็นว่าการมีระบบจัดการพลังงานช่วยเพิ่มผลตอบแทนสุทธิจากการดำเนินงาน โดยคำนึงถึงทั้งราย ได้จากการขายไฟฟ้าและต้นทุนจากการซื้อไฟจากกริด

การทดลองที่ 4

subject to Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)
--

ในการทดลองนี้ใช้ข้อมูลพยากรณ์ เพื่อจำลองสภาวะการวางแผนล่วงหน้าแบบ Day-Ahead โดยตั้งค่าพารามิเตอร์ ตาม*ตารางที่* 7 และใช้ฟังก์ชันวัตถุประสงค์เป็นการเน้นกำไรสุทธิตาม (13) ส่วนฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จากการทดลองแสดงให้เห็นว่าแม้จะมีความคลาด เคลื่อนจากการคาดการณ์ แต่ระบบ EMS ยังคงสามารถปรับตัวได้ในระดับหนึ่ง



รูป 54: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้**ข้อมูลพยากรณ์**เพื่อ**เน้นกำไรสุทธิ**

รูปที่ 54 แสดงโหลด, โซลาร์, และผลเฉลยการทำงานของระบบ EMS แบบ Day-Ahead โดยใช้ข้อมูลพยากรณ์ โดยมีวัตถุประสงค์เพื่อเพิ่มกำไรสุทธิจากการซื้อ–ขายไฟฟ้า มีรายละเอียดของกราฟย่อยในแต่ละตำแหน่งดังนี้

- กราฟย่อยที่ (1,1): กราฟอนุกรมเวลาของโหลด, กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์, และพลังงานสุทธิ แสดง ให้เห็นพฤติกรรมของแหล่งผลิตและโหลดในแต่ละช่วงเวลา โดยแม้จะใช้ข้อมูลพยากรณ์ซึ่งมีความไม่แน่นอน แต่ระบบยังสามารถบริหารจัดการพลังงานได้ใกล้เคียงกับสภาพการณ์จริง กล่าวคือในช่วงกลางวันมีพลังงาน ส่วนเกินจากโซลาร์ที่สามารถจัดเก็บในแบตเตอรี่หรือจำหน่ายคืนเข้าสู่กริดได้ ส่วนในช่วงเย็นต้องดึงพลังงาน จากแบตเตอรี่มาใช้งานเพื่อลดภาระจากการซื้อไฟฟ้า
- กราฟย่อยที่ (1,2): แสดงผลเฉลยการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} ซึ่งพบว่า SoC มีการ เปลี่ยนแปลงตามลักษณะการอัดประจุและคายประจุในแต่ละช่วงเวลา แม้อาจมีความคลาดเคลื่อนเล็กน้อย จากการพยากรณ์โหลดและโซลาร์ที่ไม่แม่นยำ
- กราฟย่อยที่ (2,1): แสดงผลเฉลย P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU พบว่าระบบยังคงมีแนวโน้ม อัดประจุแบตเตอรี่ในช่วง TOU ต่ำ และคายประจุในช่วง TOU สูง โดยเฉพาะในช่วงวันสุดท้ายมีการคาย ประจุมากขึ้น เพื่อสร้างผลตอบแทนกำไรสุทธิสูงสุดแม้อยู่ภายใต้ข้อจำกัดของข้อมูลพยากรณ์
- กราฟย่อยที่ (2,2): แสดงผลกำไรในแต่ละช่วงเวลา (15 นาที) และผลกำไรรวมตลอดช่วงเวลาการทดลอง โดยพบว่าการใช้ข้อมูลพยากรณ์ยังคงทำให้ระบบสามารถสร้างผลตอบแทนได้ดี แม้ผลกำไรรวมอาจต่ำกว่า กรณีใช้ข้อมูลจริงเล็กน้อย เนื่องจากความคลาดเคลื่อนในการพยากรณ์ส่งผลต่อการตัดสินใจควบคุมระบบ

6.1.2 การควบคุมเชิงทำนายแบบจำลอง (MPC)

การทดลองแบบการควบคุมเชิงทำนายแบบจำลองออกแบบมาเพื่อให้ EMS สามารถตอบสนองต่อความเปลี่ยนแปลง ของสภาวะแวดล้อมแบบเรียลไทม์มากขึ้น ซึ่งเป็นวิธีการที่ระบบจะวางแผนล่วงหน้าใน 24 ชั่วโมงล่วงหน้า แล้ว ปรับแผนใหม่ทุก 15 นาที โดยในการทดลองนี้ใช้กรอบการวางแผนแบบ Day-Ahead และปรับแผนแบบ MPC ไปพร้อมกับการอัปเดตข้อมูลใหม่ในแต่ละช่วงเวลา

การเปรียบเทียบค่าไฟฟ้าระหว่างข้อมูลจริงและค่าพยากรณ์ภายใต้กรอบ Day-Ahead

minimize subject to	$J_{\text{cost}} + w_{\text{m}}J_{\text{multibatt}} + w_{\text{s}}J_{\text{smooth charge}} + w_{\text{c}}J_{\text{charge batt}}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(36)
------------------------	--	------

การทดลองในรูปแบบ MPC ถูกนำมาใช้เพื่อเปรียบเทียบค่าใช้จ่าย ระหว่างกรณีที่ใช้ข้อมูลจริง และข้อมูลพยากรณ์ โดยสมมุติให้การตัดสินใจล่วงหน้าในแต่ละช่วงเวลาขึ้นอยู่กับข้อมูลพยากรณ์ จากนั้นจึงประเมินผลลัพธ์ย้อนหลังด้วย ข้อมูล actual เพื่อสะท้อนถึงความสามารถของระบบ EMS ในการควบคุมค่าใช้จ่ายภายใต้ความไม่แน่นอนของ สภาวะแวดล้อม การทดลองนี้อิงจากการจำลองการวางแผนล่วงหน้าแบบ Day-Ahead โดยใช้พารามิเตอร์ตาม*ตาราง ที่* 7 และฟังก์ชันวัตถุประสงค์หลักเป็นการลดค่าใช้จ่ายรวมตาม (12) พร้อมกับฟังก์ชันเสริมสำหรับการบริหารจัดการ แบตเตอรี่ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลการทดลองแสดงให้เห็นว่า แม้มีความคลาด เคลื่อนจากการพยากรณ์ ระบบ EMS ยังคงสามารถจำกัดค่าใช้จ่ายให้อยู่ในระดับที่เหมาะสม และแสดงประสิทธิภาพ ที่ดีเมื่อเปรียบเทียบกับกรณีไม่ใช้ EMS

รูปที่ 55 แสดงผลการเปรียบเทียบค่าใช้จ่ายสะสมรายเดือนในปี 2024 สำหรับแต่ละกรณีการดำเนินงาน ได้แก่ กรณีอุดมคติ (Ideal), การใช้ระบบจัดการพลังงาน (EMS), กรณีที่ใช้ผลจริง (Actual) และกรณีไม่มีระบบจัดการ พลังงาน (No EMS) โดยมีข้อสังเกตที่สำคัญดังนี้

- ค่าใช้จ่ายในกรณี Ideal (สีน้ำเงิน) มีค่าน้อยที่สุดตลอดทั้งปี สะท้อนถึงขอบเขตล่างของต้นทุนที่สามารถทำได้ เมื่อมีข้อมูลล่วงหน้าอย่างสมบูรณ์
- ค่าใช้จ่ายในกรณี EMS (สีแดง) มีแนวโน้มใกล้เคียงกับกรณี Ideal ในหลายเดือน แสดงให้เห็นถึงความสามารถ ของระบบ EMS ในการตัดสินใจที่มีประสิทธิภาพภายใต้ข้อจำกัดของการพยากรณ์
- ค่าใช้จ่ายในกรณี Actual (สีเขียว) มักสูงกว่ากรณี Ideal ซึ่งสะท้อนถึงความคลาดเคลื่อนการอัดประจุหรือ คายประจุแบตเตอรี่จาก EMS ไม่สอดคล้องกับข้อมูลโหลดและโซลาร์จริง
- ค่าใช้จ่ายในกรณี No EMS (สีดำ) สูงที่สุดในทุกช่วงเวลา แสดงให้เห็นถึงผลเสียของการไม่มีระบบการจัดการ พลังงาน

จากการวิเคราะห์เพิ่มเติม พบว่าช่วงเดือนมิถุนายนถึงสิงหาคม ค่าใช้จ่ายในกรณี Actual และ No EMS เพิ่ม ขึ้นอย่างรวดเร็ว ซึ่งอาจเกิดจากภาระโหลดที่สูงขึ้นหรือการผลิตพลังงานจากแผงโซลาร์ที่ลดลงในช่วงฤดูฝน สถานการณ์ ดังกล่าวส่งผลต่อความสามารถของระบบ EMS ในการควบคุมต้นทุนพลังงาน

จาก*ตารางที่* 9 แสดง**รายจ่าย**รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**การประหยัด** ค่าไฟ สามารถวิเคราะห์ได้ดังนี้

พิจารณารายจ่ายแต่ละเดือน

- มีนาคม: ความแตกต่างระหว่าง Actual (5,297 บาท) กับ NoEMS (10,252 บาท) สูงกว่า 4,900 บาท แสดงให้เห็นถึงประสิทธิภาพของ EMS ในการลดค่าใช้จ่ายได้อย่างชัดเจน เมื่อเปรียบเทียบกับ กรณีที่ไม่มีการใช้งาน EMS
- พฤษภาคม: รายจ่าย Actual สูงถึง 5,443 บาท ขณะที่ EMS อยู่เพียง 4 บาท และ Ideal เพียง 439 บาท แสดงให้เห็นถึงความเบี่ยงเบนอย่างมีนัยสำคัญในการใช้งานจริง ซึ่งอาจเกิดจากการคาดการณ์การ ใช้แบตเตอรี่ไม่สอดคล้องกับความต้องการโหลดจริง
- มิถุนายนและกรกฎาคม: Ideal และ EMS มีรายจ่ายใกล้ศูนย์ แต่ Actual ยังมีรายจ่ายระดับพัน บาท แสดงถึงศักยภาพสูงของระบบภายใต้การควบคุมล่วงหน้า แต่เมื่อมีการใช้แบตเตอรี่ไม่สอดคล้อง กับความต้องการโหลดจริง ทำให้รายจ่ายกลับเพิ่มขึ้นอย่างชัดเจน









รูป 55: กราฟแสดง**ค่าใช้จ่าย**สะสมของปี 2024 ภายใต้กรอบ Day-Ahead

Month	Ideal (THB)	EMS (THB)	Actual (THB)	NoEMS (THB)	Actual – Ideal (THB)	Actual – NoEMS (THB)
มกราคม	1,074	479	4,022	8,109	2,948	-4,087
กุมภาพันธ์	1,053	849	4012	9120	2959	-5,108
์มีนาคม	1,283	441	5,297	10,252	4,014	-4,955
เมษายน	1,057	484	3,805	10,644	2,749	-6,838
พฤษภาคม	439	4	5,443	9,576	5,004	-4,133
มิถุนายน	7	0	2,717	6,295	2,710	-3,577
กรกฎาคม	335	0	3,373	6,274	3,038	-2,901
สิงหาคม	466	4	4,173	8,799	3,707	-4,626
กันยายน	1,450	3	4,735	8,319	3,285	-3,585
ตุลาคม	126	2	3,570	8,099	3,444	-4,529
พฤตจิกายน	28	2	2,825	7,243	2,798	-4,418
ธันวาคม	3	0	1,036	3,782	1,033	-2,746
Total	7,321	2,270	45,009	96,512	37,688	-51,504

ิ ตาราง 9: สรุป**รายจ่าย**รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**การประหยัดค่าไฟ**

- ตุลาคมและพฤศจิกายน: แม้ EMS จะมีรายจ่ายเพียง 2 บาท แต่ Actual ยังสูงเกิน 2,800 บาท แสดงให้เห็นว่าการพยากรณ์ในช่วงปลายปีอาจมีความคลาดเคลื่อนสูง และควรปรับปรุงการวางแผน ให้สอดคล้องกับฤดูกาล
- ธันวาคม: ทุกกรณีมีรายจ่ายต่ำ โดยเฉพาะ Ideal และ EMS ต่ำกว่า 5 บาท สะท้อนถึงโหลดที่น้อย และความเสถียรของการควบคุมระบบในช่วงสิ้นปี
- พิจารณารายจ่ายรวมทั้งปี
 - Ideal: มีรายจ่ายรวมเพียง 7,321 บาท ซึ่งต่ำที่สุด สะท้อนถึงประสิทธิภาพสูงสุดของระบบเมื่อมีข้อมูล ล่วงหน้าที่แม่นยำ
 - EMS: มีรายจ่ายรวม 2,270 บาท ซึ่งน้อยกว่า Ideal เป็นผลมาจากข้อมูลโหลดที่พยากรณ์ได้น้อยกว่า ความเป็นจริง หรือข้อมูลโซลาร์ที่พยากรณ์ได้มากกว่าความเป็นจริงในบางเดือน ทำให้ EMS มีพลังงาน จากโซลาร์เหลือมากกว่า Ideal จึงต้องซื้อไฟจากกริดน้อยลง ส่งผลให้รายจ่ายรวมลดลง
 - Actual: มีรายจ่ายรวม 45,009 บาท แสดงถึงผลลัพธ์จากการนำแผนการอัดประจุหรือคายประจุ แบตเตอรี่จาก EMS ไม่สอดคล้องกับข้อมูลโหลดและโซลาร์จริง ส่งผลให้มีรายจ่ายสูงขึ้น นอกจากนี้ ค่าใช้จ่าย Actual ยังสูงกว่าค่าใช้จ่าย Ideal โดยมีผลต่างเป็นจำนวนเงิน 37,688 บาท
 - NoEMS: มีรายจ่ายรวมสูงถึง 96,512 บาท ซึ่งสูงที่สุด เนื่องจากไม่มีการใช้แบตเตอรี่เลย ทำให้ต้อง ซื้อพลังงานจากกริดในทุกกรณีที่โหลดมากกว่าการผลิต โดยเมื่อเปรียบเทียบกับกรณี Actual พบว่าการ ไม่ใช้ EMS ส่งผลให้มีรายจ่ายสูงขึ้น 51,504 บาท

ดังนั้นระบบ EMS มีประสิทธิภาพในการลดค่าใช้จ่ายรวมประจำปีได้อย่างมีนัยสำคัญ โดยสามารถควบคุมต้นทุน ให้อยู่ใกล้เคียงกับกรณีอุดมคติ แม้ต้องดำเนินงานภายใต้ความไม่แน่นอนของข้อมูลจริง แสดงถึงศักยภาพของระบบ EMS ในการบริหารจัดการพลังงานภายใต้สภาพแวดล้อมที่เปลี่ยนแปลงได้อย่างเหมาะสม

การเปรียบเทียบผลกำไรระหว่างข้อมูลจริงและค่าพยากรณ์ภายใต้กรอบ Day-Ahead

minimize subject to	$J_{\text{cost}} + w_{\text{m}}J_{\text{multibatt}} + w_{\text{s}}J_{\text{smooth charge}} + w_{\text{c}}J_{\text{charge batt}}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(37)
	battery's SOC constraint (4)	

การทดลองในรูปแบบ MPC ถูกนำมาใช้เพื่อเปรียบเทียบผลกำไร ระหว่างกรณีที่ใช้ข้อมูลจริง และข้อมูลพยากรณ์ โดยสมมุติให้การตัดสินใจล่วงหน้าในแต่ละช่วงเวลาขึ้นอยู่กับข้อมูลพยากรณ์ จากนั้นจึงประเมินผลจริงย้อนหลังด้วย ข้อมูล actual เพื่อสะท้อนความสามารถของระบบ EMS ในการปรับตัวและวางแผนภายใต้สภาวะข้อมูลที่ไม่สมบูรณ์ การทดลองนี้ใช้การจำลองแบบ Day-Ahead โดยตั้งค่าพารามิเตอร์ตาม *ตารางที่* 7 และใช้ฟังก์ชันวัตถุประสงค์ หลักในการลดค่าใช้จ่ายตาม (13) พร้อมฟังก์ชันเสริมของแบตเตอรี่ตาม (7), (9), และ (10) ภายใต้อัตราค่าไฟฟ้า แบบ TOU ผลลัพธ์แสดงให้เห็นว่าระบบสามารถรักษาประสิทธิภาพในการตัดสินใจได้ แม้จะมีความคลาดเคลื่อน จากการพูยากรณ์

รูปที่ 56 แสดงผลการเปรียบเทียบกำไรสะสมรายเดือนในปี 2024 สำหรับแต่ละกรณีการดำเนินงาน ได้แก่ กรณีอุดมคติ (Ideal), การใช้ระบบจัดการพลังงาน (EMS), กรณีที่ใช้ผลจริง (Actual) และกรณีไม่มีระบบจัดการ พลังงาน (No EMS) โดยมีข้อสังเกตที่สำคัญดังนี้

- กำไรในกรณี Ideal (สีน้ำเงิน) มีค่าสูงที่สุดตลอดทั้งปี สะท้อนถึงขอบเขตบนของผลกำไรที่สามารถทำได้เมื่อ มีข้อมูลล่วงหน้าอย่างสมบูรณ์
- กำไรในกรณี EMS (สีแดง) มีแนวโน้มใกล้เคียงกับกรณี Ideal ในหลายเดือน แสดงให้เห็นถึงความสามารถ ของระบบ EMS ในการตัดสินใจที่มีประสิทธิภาพภายใต้ข้อจำกัดของการพยากรณ์
- กำไรในกรณี Actual (สีเขียว) มักต่ำกว่ากรณี Ideal ซึ่งสะท้อนถึงความคลาดเคลื่อนของการอัดประจุหรือ คายประจุแบตเตอรี่จาก EMS ที่ไม่สอดคล้องกับข้อมูลโหลดและโซลาร์จริง
- กำไรในกรณี No EMS (สีดำ) ต่ำที่สุดในทุกช่วงเวลา แสดงให้เห็นถึงผลเสียของการไม่มีระบบการจัดการ พลังงาน

จากการวิเคราะห์เพิ่มเติม พบว่าช่วงเดือนมิถุนายนถึงสิงหาคม กำไรในกรณี Actual และ No EMS เพิ่มขึ้น น้อยกว่าช่วงอื่นอย่างมีนัยสำคัญ ซึ่งอาจเกิดจากภาระโหลดที่สูงขึ้นหรือการผลิตพลังงานจากแผงโซลาร์ที่ลดลงใน ช่วงฤดูฝน ส่งผลต่อความสามารถของระบบ EMS ในการเพิ่มกำไร

ิตาราง 10: สรุป**รายจ่ายสุทธิ**รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**การเน้นกำไร**

Month	Ideal (THB)	EMS (THB)	Actual (THB)	NoEMS (THB)	Actual – Ideal (THB)	Actual – NoEMS (THB)
มกราคม	214	-667	1,216	4,407	1,003	-3,191
กุมภาพันธ์	834	-342	1,597	5,807	763	-4,209
์ มีนาคม	933	-940	2,516	6,470	1,584	-3,954
เมษายน	-911	-919	277	5,039	1,188	-4,762
พฤษภาคม	-14	-2,419	1,798	5,091	1,812	-3,293
มิถุนายน	-2,287	-3,502	-1,307	1,103	980	-2,410
กรกฎาคม	-524	-3,438	544	2,890	1,068	-2,347
สิงหาคม	-69	-1,833	1,115	4,618	1,184	-3,503
กันยายน	1,098	-1,660	2,128	5,454	1,030	-3,327
ตุลาคม	-677	-1,943	388	3,614	1,065	-3,226
พฤศจิกายน	-1,500	-2,205	-803	2,217	697	-3,020
ธั้นวาคม	-3,463	-3,213	-3,201	-1,511	262	-1,690
Total	-6.367	-23.081	6.267	45,199	12.635	-38,932

หมายเหตุ: รายจ่ายสุทธิ = รายจ่ายจากการซื้อไฟฟ้า – รายได้จากการขายไฟฟ้า

จากตาราง 10 แสดง**รายจ่ายสุทธิ**รายเดือนภายใต้กรอบเวลา Day-Ahead เมื่อฟังก์ชันวัตถุประสงค์มุ่งเน้น ไปที่**การเพิ่มกำไร** สามารถวิเคราะห์ได้ดังนี้











- พิจารณารายจ่ายสุทธิแต่ละเดือน
 - มกราคมถึงมีนาคม: รายจ่ายในกรณี EMS มีค่าเป็นลบ แสดงถึงการทำกำไรจากระบบ ขณะที่กรณี Actual ยังแสดงรายจ่ายสูง เช่น ในเดือนมีนาคม EMS ทำกำไรได้ถึง 940 บาท ในขณะที่ Actual มีรายจ่ายถึง 2,516 บาท ผลต่างดังกล่าวสะท้อนความคลาดเคลื่อนในการใช้งานจริง ซึ่งอาจเกิดจาก การคาดการณ์การใช้พลังงานจากแบตเตอรี่ที่ไม่สอดคล้องกับความต้องการโหลดที่เกิดขึ้นจริง
 - เมษายนถึงกันยายน: ความแตกต่างระหว่าง EMS กับ Actual ยังคงเด่นชัด เช่น ในเดือนพฤษภาคม EMS ทำกำไร 2,419 บาท แต่ Actual ยังเสียเงินถึง 1,798 บาท บ่งบอกถึงผลกระทบจากการใช้ พลังงานจากแบตเตอรี่ของข้อมูลพยากรณ์ที่ไม่สอดคล้องกับความต้องการโหลดที่เกิดขึ้นจริง
 - กรกฎาคม: กรณี Ideal และ EMS ทำกำไรเกินประมาณพันบาท ในขณะที่ Actual กลับมีรายจ่าย เป็นบวก แสดงให้เห็นถึงผลกระทบจากข้อจำกัดในการนำระบบไปใช้งานจริง ซึ่งส่งผลให้ไม่สามารถ สร้างกำไรได้ตามศักยภาพของระบบที่ประเมินจาก EMS
 - ตุลาคมและพฤศจิกายน: EMS ทำกำไรประมาณ 2,000 บาท ในขณะที่ Actual มีรายจ่ายหลัก ร้อย แสดงให้เห็นว่าการดำเนินการจริงในบางช่วงเวลาเริ่มมีแนวโน้มใกล้เคียงกับแผนที่วางไว้ แต่ยังมี โอกาสในการปรับปรุงเพิ่มเติม

พิจารณารายจ่ายสุทธิรวมทั้งปี

- Ideal: มีผลกำไรรวม 6,367 บาท ซึ่งเป็นผลลัพธ์ที่ดีที่สุดภายใต้สมมติฐานว่ามีข้อมูลโหลดและโซลาร์ ที่รู้ล่วงหน้าที่แม่นยำ
- EMS: มีผลกำไรรวม 23,081 บาท เนื่องจากระบบ EMS อาจใช้กลยุทธ์แบบอนุรักษ์นิยมที่ช่วยเพิ่ม โอกาสในการทำกำไร โดยเฉพาะในสถานการณ์ที่ข้อมูลพยากรณ์แตกต่างจากข้อมูลจริง ทำให้มีพลังงาน ส่วนเกินจากโซลาร์ที่สามารถนำไปขายได้
- Actual: มีรายจ่ายรวม 6,267 บาท แม้ว่าจะดีกว่ากรณี NoEMS อย่างชัดเจน แต่ยังไม่สามารถสร้าง กำไรได้เช่นเดียวกับแผน EMS เนื่องจากการนำแผนการอัดประจุหรือคายประจุแบตเตอรี่จาก EMS ไม่สอดคล้องกับข้อมูลโหลดและโซลาร์ที่เกิดขึ้นจริง นอกจากนี้ค่าใช้จ่าย Actual ยังสูงกว่าค่าใช้จ่าย Ideal โดยมีผลต่างเป็นจำนวนเงิน 12,635 บาท
- NoEMS: มีรายจ่ายรวม 45,199 บาท ซึ่งเป็นรายจ่ายที่สูงที่สุด โดยสะท้อนต้นทุนที่เกิดจากการไม่ใช้ แบตเตอรี่เลย และต้องพึ่งพาการซื้อพลังงานจากกริดทั้งหมดในช่วงที่โหลดมากกว่าการผลิต โดยเมื่อ เปรียบเทียบกับกรณี Actual พบว่าการไม่ใช้ EMS ส่งผลให้มีรายจ่ายสูงขึ้น 38,932 บาท

ดังนั้นระบบ EMS มีประสิทธิภาพในการเพิ่มกำไรรวมประจำปีได้อย่างมีนัยสำคัญ โดยสามารถรักษาระดับกำไร ให้อยู่ใกล้เคียงกับกรณีอุดมคติ แม้ต้องดำเนินงานภายใต้ความไม่แน่นอนของข้อมูลจริง แสดงถึงศักยภาพของระบบ EMS ในการบริหารจัดการพลังงานเพื่อเพิ่มผลตอบแทนในสภาพแวดล้อมที่เปลี่ยนแปลงได้อย่างเหมาะสม

6.2 ระบบจัดการพลังงานภายใต้กรอบ Hour-Ahead

6.2.1 ตัวอย่างชุดข้อมูลย่อย (Batch)

การ<u>ทดลองที่ 5</u>

minimize subject to	$J_{\text{cost}} + w_{\text{m}}J_{\text{multibatt}} + w_{\text{s}}J_{\text{smooth charge}} + w_{\text{c}}J_{\text{charge batt}} + J_{\text{trackDA}}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3)	(38)
	Battery's SOC constraint (4)	

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Hour-Ahead โดยใช้ข้อมูล จริง (actual data) และตั้งค่าพารามิเตอร์ตาม*ตารางที่* 8 และใช้ฟังก์ชันวัตถุประสงค์เป็นการประหยัดค่าไฟฟ้า ตาม (12) ส่วนฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) และฟังก์ชันวัตถุประสงค์ของการติดตาม ผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จากการทดลองแสดงให้เห็นว่าการ ใช้ EMS สามารถลดต้นทุนค่าไฟฟ้าได้ แนวโน้มการอัดประจุและคายประจุของแบตเตอรี่เป็นไปอย่างมีประสิทธิภาพ และสามารถปรับผลเฉลยการอัดประจุและคายประจุของแบตเตอรี่ให้สอดคล้องกับแผน Day-Ahead ได้อย่างมี ประสิทธิภาพ

รูปที่ 57 แสดงผลการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ข้อมูลจริงในแต่ละชั่วโมง เพื่อให้ ระบบสามารถวางแผนและตัดสินใจการจัดการพลังงานได้ใกล้เคียงกับสถานการณ์จริงยิ่งขึ้น โดยมุ่งเน้นไปที่การลด ต้นทุนค่าไฟฟ้า รายละเอียดของกราฟย่อยในแต่ละตำแหน่งมีดังนี้

- รูปที่ 57(a) แสดงโหลด กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์ และผลเฉลยของการควบคุมในระบบ EMS แบบ Hour-Ahead โดยมีรายละเอียดของกราฟย่อยดังนี้
 - กราฟย่อยที่ (1,1): กราฟอนุกรมเวลาของโหลด, กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์, และพลังงาน สุทธิ แสดงการเปลี่ยนแปลงตามเวลา และเปรียบเทียบการใช้พลังงานของโหลดกับการผลิตกำลังไฟฟ้า จากโซลาร์ในแต่ละช่วง พบว่าช่วงเวลาส่วนใหญ่ กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์มีปริมาณมากกว่า ความต้องการของโหลด ส่งผลให้มีพลังงานส่วนเกินที่สามารถนำไปจัดเก็บในแบตเตอรี่ได้ และบางช่วง เวลา ปริมาณความต้องการใช้พลังงานของโหลดสูงกว่ากำลังผลิตจากโซลาร์ ทำให้จำเป็นต้องดึงพลังงาน จากแบตเตอรี่มาใช้งาน
 - กราฟย่อยที่ (1,2): แสดงผลเฉลยการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} พบว่า SoC เพิ่มขึ้นในช่วงที่ P_{chg} > 0 kW และลดลงในช่วงที่ P_{dchg} > 0 kW ซึ่งสะท้อนให้เห็นถึงกลไกการ ควบคุมแบตเตอรี่ที่ตอบสนองต่อโหลดสุทธิ แต่เนื่องจากขอบเขตการวางแผนของระบบ HA มีเพียง 1 ชั่วโมงล่วงหน้า การวางแผน SoC จึงอยู่ในช่วงแคบ และไม่สามารถใช้กลยุทธ์การเก็บ/ปล่อยพลังงาน ล่วงหน้าได้อย่างมีประสิทธิภาพ
 - กราฟย่อยที่ (2,1): แสดงผลเฉลย P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU พบว่าเมื่อ P_{net} > 0 kW แสดงว่าระบบมีความต้องการพลังงานสุทธิเพิ่มขึ้น จึงเกิดการคายประจุจากแบตเตอรี่เพื่อเสริม พลังงานให้โหลด ขณะที่เมื่อ P_{net} < 0 kW ระบบมีพลังงานส่วนเกิน ทำให้เกิดการอัดประจุพลังงาน เข้าสู่แบตเตอรี่ นอกจากนี้ระยะเวลาการวางแผนแบบ Hour-Ahead ไม่เพียงพอให้วางกลยุทธ์เชิง TOU ที่ซับซ้อนได้อย่างเต็มที่
 - กราฟย่อยที่ (2,2): แสดงค่าไฟฟ้าในแต่ละช่วงเวลา (5 นาที) และค่าไฟฟ้าสะสมตลอดช่วงเวลาการ ทดลอง แสดงให้เห็นว่าระบบ EMS แบบ Hour-Ahead สามารถช่วยลดค่าใช้จ่ายได้ระดับหนึ่งจาก การจัดสรรพลังงานจากแบตเตอรี่ แต่เมื่อเปรียบเทียบกับแผน Day-Ahead ที่สามารถวางกลยุทธ์ข้าม ช่วงเวลา TOU ได้ จะพบว่าศักยภาพในการลดต้นทุนของ Hour-Ahead ยังมีข้อจำกัด
- รูปที่ 57(b) แสดงการเปรียบเทียบผลเฉลยของระบบ EMS แบบ Hour-Ahead กับแผนอ้างอิงจาก Day-Ahead โดยเปรียบเทียบพฤติกรรมของ P_{net}, P_{chg}, และ P_{dchg} พบว่าผลเฉลยของ Hour-Ahead มีลักษณะ ตอบสนองตามสถานการณ์จริงได้ดี แต่ไม่สามารถวางแผนล่วงหน้าตาม TOU ได้อย่างมีประสิทธิภาพเท่า ระบบ Day-Ahead ทำให้ไม่สามารถอัดประจุ/คายประจุแบตเตอรี่เพื่อให้ได้ต้นทุนต่ำสุดในภาพรวมได้เท่า กัน



รูป 57: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้**ข้อมูลจริง**เพื่อ**ประหยัดค่าไฟฟ้า**

การ<u>ทดลองที่ 6</u>

minimiz subiect	ze to	$J_{\text{cost}} + w_{\text{m}}J_{\text{multibatt}} + w_{\text{s}}J_{\text{smooth charge}} + w_{\text{c}}J_{\text{charge batt}} + J_{\text{trackDA}}$ Power balance constraints (6)	
,		Battery dynamic (1)	(39)
		Battery charge/discharge constraints (2) - (3)	
		Battery's SOC constraint (4)	

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Hour-Ahead โดยใช้ข้อมูล พยากรณ์ (forecast data) สำหรับโหลดและการผลิตจากโซลาร์ เพื่อให้ระบบสามารถวางแผนและตัดสินใจการ จัดการพลังงานได้ล่วงหน้าในแต่ละชั่วโมง โดยมีการตั้งค่าพารามิเตอร์ตาม*ตารรางที่* 8 และใช้ฟังก์ชันวัตถุประสงค์ ในการประหยัดค่าไฟฟ้าตาม (12) รวมถึงฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) และฟังก์ชัน วัตถุประสงค์ของการติดตามผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จาก การทดลองแสดงให้เห็นว่าระบบ EMS สามารถช่วยลดต้นทุนค่าไฟฟ้าได้ในระดับหนึ่ง แม้ว่าจะมีความไม่แน่นอน จากการพยากรณ์ก็ตาม แนวโน้มการอัดประจุและคายประจุของแบตเตอรี่ยังคงมีความสอดคล้องกับโหลดสุทธิ โดย ระบบสามารถปรับผลเฉลยการอัดประจุและคายประจุให้ใกล้เคียงกับแผน Day-Ahead ได้ แม้ประสิทธิภาพโดย รวมจะลดลงเล็กน้อยเมื่อเทียบกับกรณีที่ใช้ข้อมูลจริง

รูปที่ 58 แสดงผลการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ข้อมูลพยากรณ์โหลดและกำลังผลิต จากโซลาร์ในแต่ละชั่วโมง เพื่อให้ระบบสามารถวางแผนและตัดสินใจการจัดการพลังงานล่วงหน้าได้ใกล้เคียงสถานการณ์ จริง โดยมีเป้าหมายในการลดต้นทุนค่าไฟฟ้า รายละเอียดของกราฟย่อยในแต่ละตำแหน่งมีดังนี้

- รูปที่ 58(a) แสดงโหลดที่พยากรณ์ไว้ กำลังผลิตจากโซลาร์ที่พยากรณ์ และผลเฉลยของการควบคุมในระบบ
 EMS แบบ Hour-Ahead ภายใต้ความไม่แน่นอนของข้อมูล โดยมีรายละเอียดของกราฟย่อยดังนี้
 - กราฟย่อยที่ (1,1): แสดงอนุกรมเวลาของโหลด, พลังงานจากแผงโซลาร์, และพลังงานสุทธิที่ได้จาก ข้อมูลพยากรณ์ พบว่าระบบสามารถประเมินแนวโน้มโหลดและการผลิตได้ใกล้เคียงกับสถานการณ์จริง ในบางช่วง แต่ในบางช่วงมีความคลาดเคลื่อนของข้อมูล ซึ่งอาจส่งผลให้เกิดการควบคุมที่ไม่เหมาะสม เช่น อัดประจุเกินหรือคายประจุน้อยกว่าความเป็นจริง
 - กราฟย่อยที่ (1,2): แสดงผลการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} โดยพบว่าระบบ สามารถควบคุม SoC ได้ตามข้อจำกัด แต่ลักษณะการเปลี่ยนแปลงของ SoC มีความระมัดระวังมาก ขึ้นเมื่อเทียบกับกรณีใช้ข้อมูลจริง เนื่องจากต้องเผื่อค่าความไม่แน่นอนไว้ในกระบวนการตัดสินใจ
 - กราฟย่อยที่ (2,1): แสดง P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU ซึ่งพบว่าแนวโน้มของ P_{net} สัมพันธ์กับผลพยากรณ์ของโหลดและโซลาร์ โดยระบบ EMS ยังคงตอบสนองต่อ TOU ได้ในระดับ หนึ่ง แต่ความไม่แน่นอนของข้อมูลพยากรณ์ทำให้ไม่สามารถตัดสินใจอัดประจุหรือคายประจุได้อย่าง แม่นยำเสมอไป
 - กราฟย่อยที่ (2,2): แสดงค่าไฟฟ้าในแต่ละช่วงเวลา (5 นาที) และค่าไฟฟ้าสะสมตลอดช่วงเวลาการ ทดลอง พบว่าการใช้ข้อมูลพยากรณ์ไม่ได้ทำให้ค่าใช้จ่ายสะสมเพิ่มขึ้นเมื่อเทียบกับกรณีใช้ข้อมูลจริง เนื่องจาก การทดลองในรูปแบบ Hour-Ahead มีการวางแผนล่วงหน้าในทุกๆ 1 ชั่วโมง จึงไม่ก่อให้เกิดการเปลี่ยนแปลง ที่ชัดเจน
- รูปที่ 58(b) แสดงการเปรียบเทียบผลเฉลยของระบบ EMS แบบ Hour-Ahead ที่ใช้ข้อมูลพยากรณ์กับ แผนอ้างอิงจาก Day-Ahead โดยพบว่า EMS แบบ Hour-Ahead ยังคงมีความยืดหยุ่นและสามารถตอบ สนองต่อสถานการณ์ได้ดีในระยะหลายวันล่วงหน้า แม้จะมีข้อจำกัดด้านความแม่นยำของข้อมูล



รูป 58: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้**ข้อมูลพยากรณ์**เพื่อ**ประหยัดค่า ไฟฟ้า**

การ<u>ทดลองที่ 7</u>

minimize subject to	$J_{ m cost} + w_{ m m} J_{ m multibatt} + w_{ m s} J_{ m smooth \ charge} + w_{ m c} J_{ m charge \ batt} + J_{ m trackDA}$ Power balance constraints (6)	
	Battery dynamic (1)	(40)
	Battery charge/discharge constraints (2) - (3)	
	Battery's SOC constraint (4)	

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Hour-Ahead โดยใช้ข้อมูล จริง และตั้งค่าพารามิเตอร์ตาม*ตารางที่* 8 โดยฟังก์ชันวัตถุประสงค์มุ่งเน้นไปที่ การลดรายจ่ายสุทธิหลังการขาย ไฟฟ้าเข้าสู่ระบบ ตาม (13) รวมถึงฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) และฟังก์ชันวัตถุประสงค์ ของการติดตามผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จากการทดลอง แสดงให้เห็นว่าการใช้ระบบ EMS ช่วยลดรายจ่ายสุทธิจากพลังงานไฟฟ้าได้อย่างมีนัยสำคัญ โดยแนวโน้มการอัด ประจุและคายประจุของแบตเตอรี่เป็นไปอย่างมีประสิทธิภาพ และสามารถปรับผลเฉลยให้สอดคล้องกับแผน Day-Ahead ได้อย่างเหมาะสม

รูปที่ 59 แสดงผลการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ข้อมูลจริงในแต่ละชั่วโมง เพื่อให้ ระบบสามารถวางแผนและตัดสินใจการจัดการพลังงานได้ใกล้เคียงกับสถานการณ์จริงมากยิ่งขึ้น โดยมีเป้าหมายเพื่อ ลดรายจ่ายสุทธิหลังการขายไฟฟ้าเข้าสู่ระบบ รายละเอียดของกราฟย่อยในแต่ละตำแหน่งมีดังนี้

- รูปที่ 59(a) แสดงโหลด กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์ และผลเฉลยของการควบคุมในระบบ EMS แบบ Hour-Ahead โดยมีรายละเอียดของกราฟย่อยดังนี้
 - กราฟย่อยที่ (1,1): แสดงอนุกรมเวลาของโหลด, กำลังไฟฟ้าที่ผลิตจากแผงโซลาร์ และพลังงานสุทธิ พบว่าช่วงเวลาส่วนใหญ่กำลังผลิตจากโซลาร์มีปริมาณมากกว่าความต้องการของโหลด ส่งผลให้เกิดพลังงาน ส่วนเกินที่สามารถส่งกลับเข้าสู่ระบบหรือเก็บในแบตเตอรี่ได้ ในขณะที่บางช่วงต้องดึงพลังงานจากแบตเตอรี่ มาใช้งาน
 - กราฟย่อยที่ (1,2): แสดงผลเฉลยของการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} โดยพบว่า SoC มีแนวโน้มเพิ่มขึ้นเมื่อมีการอัดประจุและลดลงเมื่อมีการคายประจุ ซึ่งสะท้อนกลยุทธ์การควบคุม ที่ตอบสนองตามโหลดสุทธิ แต่ขอบเขตของการวางแผนที่จำกัดภายใน 1 ชั่วโมง ส่งผลให้ไม่สามารถ วางแผนล่วงหน้าเพื่อใช้ประโยชน์เชิงกลยุทธ์จาก TOU ได้อย่างเต็มที่
 - กราฟย่อยที่ (2,1): แสดงผลเฉลยของ P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU ซึ่งแสดงถึงพฤติกรรม ของระบบ EMS ในการตัดสินใจอัดประจุหรือคายประจุแบตเตอรี่เพื่อลดรายจ่ายสุทธิ โดยระบบมีแนว โน้มในการอัดประจุแบตเตอรี่ในช่วงมีพลังงานส่วนเกิน หรืออัตราค่าไฟฟ้าต่ำ และคายประจุในช่วงที่ มีความต้องการพลังงานสุทธิ หรือต้องการขายพลังงานคืนสู่กริด
 - กราฟย่อยที่ (2,2): แสดงรายจ่ายสุทธิแบบละเอียด (5 นาที) และรายจ่ายสุทธิสะสมในช่วงการทดลอง ซึ่งสะท้อนให้เห็นถึงความสามารถของระบบ EMS แบบ Hour-Ahead ในการลดรายจ่ายสุทธิหลังการ ขายไฟฟ้า แม้ว่าจะยังมีข้อจำกัดเมื่อเทียบกับระบบ Day-Ahead ที่สามารถวางกลยุทธ์ล่วงหน้าได้ใน ระยะยาวกว่า
- รูปที่ 59(b) แสดงการเปรียบเทียบผลเฉลยของระบบ EMS แบบ Hour-Ahead กับแผน Day-Ahead โดย พบว่าผลเฉลยของ Hour-Ahead สามารถตอบสนองต่อสถานการณ์จริงได้ดีในเชิงปรับตามโหลดสุทธิ แต่ ผลเฉลยของระบบ Hour-Ahead ยังมีความคลาดเคลื่อนจากแผน Day-Ahead ในบางช่วงเวลา



รูป 59: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้**ข้อมูลจริง**เพื่อ**ลดรายจ่ายสุทธิหลัง** การขายไฟฟ้า

การ<u>ทดลองที่ 8</u>

minimize subiect to	$J_{\text{cost}} + w_{\text{m}}J_{\text{multibatt}} + w_{\text{s}}J_{\text{smooth charge}} + w_{\text{c}}J_{\text{charge batt}} + J_{\text{trackDA}}$ Power balance constraints (6)	
	Battery dynamic (1)	(41)
	Battery charge/discharge constraints (2) - (3)	
	Battery's SOC constraint (4)	

การทดลองนี้มีวัตถุประสงค์เพื่อประเมินผลการทำงานของระบบ EMS ภายใต้กรอบ Hour-Ahead โดยใช้ข้อมูล พยากรณ์ และตั้งค่าพารามิเตอร์ตาม*ตารางที่* 8 โดยฟังก์ชันวัตถุประสงค์มุ่งเน้นไปที่ การลดรายจ่ายสุทธิหลังการ ขายไฟฟ้าเข้าสู่ระบบตาม (13) รวมถึงฟังก์ชันวัตถุประสงค์ของแบตเตอรี่ตาม (7), (9), และ (10) และฟังก์ชัน วัตถุประสงค์ของการติดตามผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้อัตราค่าไฟฟ้าแบบ TOU ผลลัพธ์จาก การทดลองแสดงให้เห็นว่าการใช้ระบบ EMS ช่วยลดรายจ่ายสุทธิจากพลังงานไฟฟ้าได้อย่างมีนัยสำคัญ โดยแนว โน้มการอัดประจุและคายประจุของแบตเตอรี่เป็นไปอย่างมีประสิทธิภาพ และสามารถปรับผลเฉลยให้สอดคล้อง กับแผน Day-Ahead ได้อย่างเหมาะสม แม้ว่าจะมีความคลาดเคลื่อนในบางช่วงเนื่องจากข้อจำกัดของการพยากรณ์

รูปที่ 60 แสดงผลการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้ข้อมูลพยากรณ์ในแต่ละชั่วโมง เพื่อ ให้ระบบสามารถวางแผนและเป็นสถานการณ์ที่สอดคล้องกับการใช้งานจริงในเชิงปฏิบัติ โดยมีเป้าหมายเพื่อลดราย จ่ายสุทธิหลังการขายไฟฟ้าเข้าสู่ระบบ รายละเอียดของกราฟย่อยในแต่ละตำแหน่งมีดังนี้

- รูปที่ 60(a) แสดงโหลด กำลังไฟฟ้าที่ผลิตได้จากแผงโซลาร์ และผลเฉลยของการควบคุมในระบบ EMS แบบ Hour-Ahead โดยมีรายละเอียดของกราฟย่อยดังนี้
 - กราฟย่อยที่ (1,1): แสดงโหลดที่พยากรณ์ไว้ กำลังผลิตจากโซลาร์ และพลังงานสุทธิ โดยตลอดทั้งช่วง พลังงานจากโซลาร์มีแนวโน้มสูงกว่าความต้องการของโหลด ระบบสามารถบริหารจัดการพลังงานส่วน เกินได้ผ่านการเก็บในแบตเตอรี่หรือขายคืนสู่กริด
 - กราฟย่อยที่ (1,2): แสดงผลเฉลยของการควบคุมแบตเตอรี่ ได้แก่ SoC, P_{chg}, และ P_{dchg} พบว่า แบตเตอรี่ไม่มีการอัดประจุไฟเลยตลอดช่วงเวลา เนื่องจากสถานการณ์ที่โซลาร์มีมากพอที่จะจ่ายโหลด โดยตรง และในขณะที่ SoC ลดลงในบางช่วงเวลา เนื่องจากแบตเตอรี่มีการคายประจุเพื่อนำพลังงาน ในแบตเตอรี่มาขาย สะท้อนการใช้แบตเตอรี่เพื่อวัตถุประสงค์ในการเพิ่มรายได้มากกว่าการสำรองพลังงาน
 - กราฟย่อยที่ (2,1): แสดงผลเฉลยของ P_{net}, P_{chg}, P_{dchg} และอัตราค่าไฟฟ้า TOU ซึ่งแสดงถึงพฤติกรรม ของระบบ EMS ในการตัดสินใจอัดประจุหรือคายประจุแบตเตอรี่เพื่อลดรายจ่ายสุทธิ โดยระบบมีแนว โน้มคายประจุในช่วงที่ต้องการขายพลังงานคืนสู่กริด
 - กราฟย่อยที่ (2,2): แสดงรายจ่ายสุทธิแบบละเอียด (ทุก 5 นาที) และรายจ่ายสุทธิสะสมตลอดช่วง การทดลอง ซึ่งสะท้อนให้เห็นถึงประสิทธิภาพของระบบ EMS แบบ Hour-Ahead ในการลดรายจ่าย สุทธิผ่านการบริหารจัดการพลังงานส่วนเกิน แม้จะอยู่ภายใต้ข้อจำกัดของความคลาดเคลื่อนจากข้อมูล พยากรณ์ ระบบสามารถปรับตัวและวางกลยุทธ์การขายไฟฟ้าได้อย่างเหมาะสม โดยใช้แบตเตอรี่เพื่อ เพิ่มโอกาสในการจำหน่ายไฟฟ้า
- รูปที่ 60(b) แสดงการเปรียบเทียบผลลัพธ์ระหว่างแผน Hour-Ahead กับแผน Day-Ahead ซึ่งแผน Hour-Ahead สามารถใช้ข้อมูลพยากรณ์ที่อัปเดตได้ในการตัดสินใจขายไฟอย่างยืดหยุ่น แต่ผลเฉลยของระบบ Hour-Ahead ยังมีความคลาดเคลื่อนจากแผน Day-Ahead ในบางช่วงเวลา



รูป 60: กราฟผลเฉลยการทำงานของระบบ EMS แบบ Hour-Ahead โดยใช้**ข้อมูลพยากรณ์**เพื่อ**ลดรายจ่ายสุทธิ** หลังการขายไฟฟ้า

6.2.2 การควบคุมเชิงทำนายแบบจำลอง (MPC)

การทดลองแบบการควบคุมเชิงทำนายแบบจำลองสามารถปรับให้รองรับการวางแผนแบบ Hour-Ahead ได้โดย เปลี่ยนการวางแผนล่วงหน้าจาก 24 ชั่วโมงเป็นการวางแผนแบบ 1 ชั่วโมง โดยที่ EMS จะปรับแผนทุกๆ 5 นาที ตามข้อมูลที่ได้รับใหม่ในแต่ละช่วงเวลา ทำให้ระบบสามารถตอบสนองต่อความเปลี่ยนแปลงของสภาวะแวดล้อม ได้อย่างรวดเร็วและมีความยืดหยุ่นมากขึ้น

การเปรียบเทียบค่าไฟฟ้าระหว่างข้อมูลจริงและค่าพยากรณ์ภายใต้กรอบ Hour-Ahead

minimize subject ⁻	 J_{cost} + w_mJ_{multibatt} + w_sJ_{smooth charge} + w_cJ_{charge batt} + J_{trackDA} Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4) 	(42)
	Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(42)

การทดลองในรูปแบบ MPC ถูกนำมาใช้เพื่อเปรียบเทียบค่าใช้จ่ายระหว่างกรณีที่ใช้ข้อมูลจริง และข้อมูลพยากรณ์ โดยสมมุติให้การตัดสินใจล่วงหน้าในแต่ละช่วงเวลาขึ้นอยู่กับข้อมูลพยากรณ์ จากนั้นจึงประเมินผลลัพธ์ย้อนหลังด้วย ข้อมูลจริง เพื่อสะท้อนถึงความสามารถของระบบ EMS ในการควบคุมค่าใช้จ่ายภายใต้ความไม่แน่นอนของสภาวะ แวดล้อม การทดลองนี้อิงจากการจำลองสถานการณ์ที่ระบบต้องตัดสินใจซ้ำในทุกชั่วโมง โดยใช้พารามิเตอร์ตาม*ตาราง ที่* 8 และฟังก์ชันวัตถุประสงค์หลักคือการลดค่าใช้จ่ายรวมตาม (12) ควบคู่กับฟังก์ชันเสริมที่เกี่ยวข้องกับการควบคุม แบตเตอรี่ตาม (7), (9), และ (10) รวมถึงฟังก์ชันวัตถุประสงค์ของการติดตามผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้โครงสร้างอัตราค่าไฟฟ้าแบบ TOU ผลการทดลองแสดงให้เห็นว่า การปรับการตัดสินใจให้ถี่ขึ้นตาม แนวทาง Hour-Ahead ช่วยให้ระบบสามารถตอบสนองต่อความแปรปรวนของโหลดและพลังงานหมุนเวียนได้อย่าง มีประสิทธิภาพมากยิ่งขึ้น ส่งผลให้สามารถควบคุมค่าใช้จ่ายให้อยู่ในระดับที่ต่ำกว่าเมื่อเปรียบเทียบกับกรณีไม่ใช้ EMS หรือกรณีที่ใช้การวางแผนแบบ Day-Ahead

รูปที่ 61 แสดงผลการเปรียบเทียบค่าใช้จ่ายสะสมรายเดือนในปี 2024 สำหรับแต่ละกรณีการดำเนินงาน ได้แก่ กรณีอุดมคติ (Ideal), การใช้ระบบจัดการพลังงาน (EMS), กรณีที่ใช้ผลจริง (Actual) และกรณีไม่มีระบบจัดการ พลังงาน (No EMS) โดยมีข้อสังเกตที่สำคัญดังนี้

- ค่าใช้จ่ายในกรณี Ideal (สีน้ำเงิน) ทั่วไปถือเป็นขอบเขตล่างของต้นทุนที่สามารถบรรลุได้หากมีข้อมูลล่วง หน้าอย่างสมบูรณ์
- ค่าใช้จ่ายกรณี EMS (สีแดง) แสดงแนวโน้มค่าใช้จ่ายที่ใกล้เคียงกับ Ideal ในหลายเดือน และบางครั้ง EMS สามารถทำให้รายจ่ายน้อยกว่า Ideal ด้วยเหตุผลข้างต้น เนื่องจากความคลาดเคลื่อนในการพยากรณ์ เช่น การประเมินโหลดต่ำเกินไป หรือการคาดการณ์พลังงานแสงอาทิตย์สูงเกินจริง
- ค่าใช้จ่ายกรณี Actual (สีเขียว) มีค่าใช้จ่ายสูงกว่ากรณี EMS เนื่องจากความคลาดเคลื่อนการอัดประจุหรือ คายประจุแบตเตอรี่จาก EMS ไม่สอดคล้องกับข้อมูลโหลดและโซลาร์จริง
- ค่าใช้จ่ายกรณี No EMS (สีดำ) มีค่าใช้จ่ายสูงที่สุดในทุกช่วงเวลา แสดงให้เห็นถึงผลเสียของการไม่มีระบบ การจัดการพลังงาน

จาก*ตารางที่* 11 แสดง**รายจ่าย**รายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**การประหยัด ค่าไฟ** สามารถวิเคราะห์ได้ดังนี้









รูป 61: กราฟแสดง**ค่าใช้จ่าย**สะสมของปี 2024 ภายใต้กรอบ Hour-Ahead

Month	Ideal (THB)	EMS (THB)	Actual (THB)	NoEMS (THB)	Actual – Ideal (THB)	Actual – NoEMS (THB)
มกราคม	1,628	2,389	3,605	8,170	1,977	-4,565
กุมภาพันธ์	1,688	2,880	4,025	9,189	2,337	-5,164
์มีนาคม	2,051	3,409	5,222	10,308	3,171	-5,086
เมษายน	1,447	2,471	3,626	10,669	2,179	-7,043
พฤษภาคม	909	1,761	3,674	9,634	2,766	-5,959
มิถุนายน	319	1,289	2,258	6,337	1,939	-4,079
กรกฎาคม	1,188	1,782	2,916	6,321	1,727	-3,406
สิงหาคม	1,268	2,578	4,043	8,919	2,776	-4,875
กันยายน	2,075	2,032	4,058	8,406	1,983	-4,348
ตุลาคม	790	1,903	3,404	8,155	2,614	-4,752
พฤศจิกายน	576	1,530	2,426	7,290	1,850	-4,864
ธันวาคม	113	310	833	3,856	721	-3,023
Total	14,051	24,333	40,091	97,256	26,040	-57,164

ตาราง 11: สรุป**รายจ่าย**รายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**ประหยัดค่าไฟ**

• พิจารณารายจ่ายแต่ละเดือน

- มกราคม: Ideal มีรายจ่าย 1,628 บาท ซึ่งต่ำกว่า EMS ที่มีรายจ่ายเพียง 2,389 บาท เนื่องจาก พยากรณ์โหลดสูงกว่าความจริง หรือโซลาร์ต่ำกว่าความจริงในบางช่วง ทำให้ EMS เหลือพลังงานน้อย กว่า Ideal เลยซื้อไฟจากกริดมากขึ้น
- พฤษภาคม: รายจ่าย Actual สูงถึง 3,674 บาท ขณะที่ Ideal อยู่ที่ 909 บาท แสดงถึงความคลาด เคลื่อนจากสภาพอุดมคติ ซึ่งอาจมีสาเหตุมาจากการใช้พลังงานจากแบตเตอรี่ของข้อมูลพยากรณ์ที่ไม่ สอดคล้องกับความต้องการโหลดที่เกิดขึ้นจริง
- มิถุนายน: EMS มีรายจ่ายสูงถึง 1,289 บาท ซึ่งมากกว่า Ideal (319 บาท) อย่างมาก เนื่องจาก พยากรณ์โหลดสูงกว่าความจริง หรือโซลาร์ต่ำกว่าความจริงในบางช่วง ทำให้ EMS เหลือพลังงานน้อย กว่า Ideal เลยซื้อไฟจากกริดเพิ่มขึ้น
- ตุลาคมและพฤศจิกายน: แม้ EMS จะควบคุมรายจ่ายไว้ที่ 1,903 และ 1,530 บาทตามลำดับ แต่ Actual ยังคงสูงกว่า 1,000 บาท แสดงถึงข้อจำกัดของระบบในการรับมือกับฤดูกาลที่ความไม่แน่นอน ของโหลดและการผลิตพลังงานเพิ่มขึ้น
- ธันวาคม: รายจ่ายในทุกกรณีต่ำมาก โดย EMS มีค่าเท่ากับ 310 บาท และ Actual เพียง 833 บาท สะท้อนถึงช่วงโหลดต่ำที่ทำให้ความจำเป็นในการซื้อไฟจากกริดลดลง
- พิจารณารายจ่ายรวมทั้งปี
 - Ideal: มีรายจ่ายรวมเพียง 14,051 บาท ซึ่งต่ำที่สุด แสดงถึงประสิทธิภาพสูงสุดเมื่อมีข้อมูลล่วงหน้าที่ แม่นยำและครบถ้วน
 - EMS: มีรายจ่ายรวม 24,333, บาท ซึ่งแม้จะสูงกว่า Ideal แต่ยังต่ำกว่ารายจ่าย Actual เนื่องจาก พยากรณ์โหลดต่ำกว่าความจริง หรือโซลาร์สูงเกินจริงในบางช่วง ทำให้ EMS เหลือพลังงานมากกว่า Actual เลยซื้อไฟจากกริดน้อยลง
 - Actual: มีรายจ่ายรวม 40,091 บาท ซึ่งสูงกว่า Ideal ถึง 26,040 บาท สะท้อนผลกระทบจากการ ใช้พลังงานจากแบตเตอรี่ของข้อมูลพยากรณ์ที่ไม่สอดคล้องกับความต้องการโหลดที่เกิดขึ้นจริง
 - NoEMS: มีรายจ่ายรวมสูงสุดถึง 97,256 บาท แสดงให้เห็นว่าการไม่ใช้ระบบ EMS นำไปสู่ค่าใช้จ่าย ที่มากกว่าการใช้ EMS ถึง 57,164 บาท

ดังนั้นระบบ EMS แสดงให้เห็นถึงประสิทธิภาพที่โดดเด่นในการลดค่าใช้จ่ายรวมประจำปีภายใต้การดำเนินงาน แบบ Hour-Ahead ใน*ตารางที่* 11 โดยสามารถควบคุมต้นทุนให้อยู่ใกล้เคียงกับกรณี Ideal ได้มากกว่ากรณี Day-Ahead ใน*ตารางที่* 9 แม้ต้องเผชิญกับความไม่แน่นอนของข้อมูลจริง ความสามารถในการอัปเดตข้อมูลพยากรณ์ ในช่วงเวลาที่ใกล้เคียงกับการปฏิบัติจริงช่วยให้ระบบ EMS สามารถตัดสินใจได้แม่นยำและยืดหยุ่นมากขึ้น สะท้อน ถึงศักยภาพของ EMS ในการบริหารจัดการพลังงานภายใต้สภาพแวดล้อมที่เปลี่ยนแปลงได้อย่างมีประสิทธิภาพยิ่ง ขึ้น

การเปรียบเทียบรายจ่ายสุทธิหลังการขายไฟฟ้าระหว่างข้อมูลจริงและค่าพยากรณ์ภายใต้กรอบ Hour-Ahead

minimize subject to	$J_{cost} + w_m J_{multibatt} + w_s J_{smooth charge} + w_c J_{charge batt} + J_{trackDA}$ Power balance constraints (6) Battery dynamic (1) Battery charge/discharge constraints (2) - (3) Battery's SOC constraint (4)	(43)

การทดลองในรูปแบบ MPC ถูกนำมาใช้เพื่อเปรียบเทียบค่าใช้จ่ายสุทธิหลังการขายไฟฟ้าระหว่างกรณีที่ใช้ข้อมูล จริง และข้อมูลพยากรณ์ โดยสมมุติให้การตัดสินใจล่วงหน้าในแต่ละช่วงเวลาขึ้นอยู่กับข้อมูลพยากรณ์ จากนั้นจึง ประเมินผลลัพธ์ย้อนหลังด้วยข้อมูลจริง เพื่อสะท้อนถึงความสามารถของระบบ EMS ในการควบคุมค่าใช้จ่ายภาย ใต้ความไม่แน่นอนของสภาวะแวดล้อม การทดลองนี้อิงจากการจำลองสถานการณ์ที่ระบบต้องตัดสินใจซ้ำในทุกชั่วโมง โดยใช้พารามิเตอร์ตาม*ตารางที่* 8 และฟังก์ชันวัตถุประสงค์หลักคือการลดรายจ่ายสุทธิหลังการขายไฟฟ้าตาม (13) ควบคู่กับฟังก์ชันเสริมที่เกี่ยวข้องกับการควบคุมแบตเตอรี่ตาม (7), (9), และ (10) รวมถึงฟังก์ชันวัตถุประสงค์ของ การติดตามผลเฉลยของหลายวันล่วงหน้าตาม (14) ภายใต้โครงสร้างอัตราค่าไฟฟ้าแบบ TOU ผลการทดลองแสดง ให้เห็นว่า การปรับการตัดสินใจให้ถี่ขึ้นตามแนวทาง Hour-Ahead ช่วยให้ระบบสามารถตอบสนองต่อความแปรปรวน ของโหลดและพลังงานหมุนเวียนได้อย่างมีประสิทธิภาพมากยิ่งขึ้น ส่งผลให้สามารถลดรายจ่ายสุทธิหลังการขายไฟฟ้า

เพื่อให้เข้าใจพฤติกรรมการตัดสินใจของระบบ EMS ได้ชัดเจนยิ่งขึ้นตาม*รูปที่* 62 แสดงกราฟการเปลี่ยนแปลง ของกำลังอัดประจุ/คายประจุ โหลด การผลิตจากแผงโซลาร์ และการแลกเปลี่ยนพลังงานกับกริดในแต่ละช่วงเวลา โดยมีข้อสังเกตแต่ละช่วงเวลาดังนี้

- ตอนเช้าและกลางวัน (ประมาณ 06:00 16:00): โหลดเริ่มเพิ่มขึ้น ในขณะที่ระบบผลิตไฟฟ้าจากแสง อาทิตย์กำลังผลิตพลังงานได้และมีค่าสูง EMS จะขายพลังงานส่วนเกินคืนกริดเพื่อเพิ่มรายได้ และสำรอง ส่วนหนึ่งด้วยการอัดประจุแบตเตอรี่เพื่อเก็บสำรองไว้สำหรับช่วงเย็น
- ตอนเย็น (ประมาณ 16:00 22:00): โหลดเพิ่มขึ้นอีกครั้งในขณะที่การผลิตลดลง ระบบจึงใช้พลังงาน จากแบตเตอรี่เพื่อลดการซื้อไฟจากกริด ซึ่งช่วงนี้มักมีอัตราค่าไฟสูง
- กลางคืน (ประมาณ 22:00 06:00): EMS จะอัดประจุแบตเตอรี่ด้วยไฟจากกริดในช่วงที่ค่าไฟต่ำที่สุด เพื่อเตรียมพร้อมสำหรับการใช้งานในวันถัดไป ลดรายจ่ายสุทธิของระบบได้อย่างมีประสิทธิภาพ

รูปที่ 63 แสดงผลการเปรียบเทียบรายจ่ายสุทธิหลังการขายไฟฟ้าสะสมรายเดือนในปี 2024 สำหรับแต่ละกรณี การดำเนินงาน ได้แก่ กรณีอุดมคติ (Ideal), การใช้ระบบจัดการพลังงาน (EMS), กรณีที่ใช้ผลจริง (Actual) และ กรณีไม่มีระบบจัดการพลังงาน (No EMS) โดยมีข้อสังเกตที่สำคัญดังนี้

- รายจ่ายสุทธิกรณี Ideal (สีน้ำเงิน) โดยทั่วไปถือเป็นขอบเขตล่างสุดของต้นทุนที่สามารถบรรลุได้ หากรู้ข้อมูล ล่วงหน้าอย่างสมบูรณ์
- รายจ่ายสุทธิกรณี EMS (สีแดง) แสดงแนวโน้มใกล้เคียงกับ Ideal ในหลายเดือน และในบางช่วงยังต่ำกว่า Ideal ได้ เนื่องจากความคลาดเคลื่อนในการพยากรณ์ เช่น ประเมินโหลดต่ำเกินไป หรือคาดการณ์พลังงาน แสงอาทิตย์สูงเกินจริง



รูป 62: กราฟพฤติกรรมการตัดสินใจของระบบ EMS ตามช่วงเวลาของวัน

- รายจ่ายสุทธิกรณี Actual (สีเขียว) สูงกว่ากรณี EMS เนื่องจากแผนจาก EMS ไม่สอดคล้องกับโหลดและ โซลาร์จริง ส่งผลให้ขายไฟฟ้าได้น้อยกว่าที่คาดการณ์ไว้
- รายจ่ายสุทธิกรณี No EMS (สีดำ) สูงที่สุดในทุกช่วงเวลา แสดงถึงผลเสียจากการไม่ใช้ระบบจัดการพลังงาน

ตาราง 12: สรุป**รายจ่ายสุทธิ**รายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์คือ**การเน้นกำไร**

Month	Ideal (THB)	EMS (THB)	Actual (THB)	NoEMS (THB)	Actual – Ideal (THB)	Actual – NoEMS (THB)
มกราคม	156	-595	548	4,507	392	-3,958
กุมภาพันธ์	1,062	1,135	2,277	5,841	1,216	-3,563
์ มีนาคม	1,667	883	2,618	6,537	951	-3,919
เมษายน	-459	-389	608	5,072	1,067	-4,463
พฤษภาคม	176	111	2,032	5,129	1,856	-3,097
มิถุนายน	-1,948	-2,361	-1,103	1,130	845	-2,234
กรกฎาคม	-137	-554	745	2,949	882	-2,204
สิงหาคม	422	171	1,515	4,702	1,093	-3,187
กันยายน	1,566	176	2,389	5,529	822	-3,141
ตุลาคม	-178	-569	756	3,627	934	-2,871
พฤศจิกายน	-1,313	-1,378	-515	2,324	799	-2,838
ธันวาคม	-3,435	-4,654	-3,256	-1,605	178	-1,651
Total	-2,421	-8,025	8,615	45,743	11,036	-37,128

หมายเหตุ: รายจ่ายสุทธิ = รายจ่ายจากการซื้อไฟฟ้า – รายได้จากการขายไฟฟ้า

จากตาราง 12 แสดงรายจ่ายสุทธิรายเดือนภายใต้กรอบเวลา Hour-Ahead เมื่อฟังก์ชันวัตถุประสงค์มุ่งเน้น ไปที่การเพิ่มกำไร สามารถวิเคราะห์ได้ดังนี้

• พิจารณารายจ่ายสุทธิแต่ละเดือน









รูป 63: กราฟแสดง**ค่าใช้จ่ายสุทธิหลังการขายไฟฟ้า**สะสมของปี 2024 ภายใต้กรอบ Hour-Ahead

- มกราคมถึงมีนาคม: ร่ายจ่ายสุทธิในเดือนมกราคมของกรณี EMS สามารถทำกำไรได้ 595 บาท ขณะ ที่ Actual มีรายจ่าย 548 บาท และ NoEMS สูงถึง 4,507 บาท สะท้อนถึงความคลาดเคลื่อนจาก การพยากรณ์โหลดต่ำเกินไปหรือพลังงานแสงอาทิตย์สูงเกินจริง ทำให้ EMS มีกำไรมากกว่า Actual และแสดงถึงประสิทธิภาพของระบบ EMS ในการเพิ่มรายได้เมื่อเทียบกับ NoEMS
- เมษายนถึงมิถุนายน: แม้ในช่วงนี้จะมีเดือนที่ระบบ EMS มีกำไรสูง (เช่น เมษายนและพฤษภาคม) แต่ก็ยังดีกว่า Actual อย่างมาก เช่นในเดือนมิถุนายน EMS มีกำไร 2,361 บาท ขณะที่ Actual มีกำไรเพียง 1,103 บาท สะท้อนถึงความคลาดเคลื่อนจากการพยากรณ์โหลดต่ำเกินไปหรือพลังงาน แสงอาทิตย์สูงเกินจริง ทำให้ EMS มีพลังงานจากแสงอาทิตย์เหลือมากกว่า Actual เลยขายไฟคืน กริดได้มากกว่า
- กรกฎาคมถึงกันยายน: เดือนกรกฎาคม Ideal ได้กำไร 137 บาท ขณะที่ Actual ขาดทุนถึง 745 บาท แสดงถึงความคลาดเคลื่อนจากการใช้พลังงานจากแบตเตอรี่ของข้อมูลพยากรณ์ที่ไม่สอดคล้องกับ ความต้องการโหลดที่เกิดขึ้นจริง
- ตุลาคมถึงพฤศจิกายน: กรณี Actual ยังคงควบคุมกำไรได้ดี เช่นในเดือนพฤศจิกายน Actual มี กำไรเพียง 515 บาท ขณะที่ NoEMS ขาดทุน 2,324 บาท แสดงให้เห็นถึงความสำคัญของการมีระบบ จัดการพลังงาน
- ธันวาคม: ทั้ง EMS และ Ideal มีกำไรสูง โดยเฉพาะ EMS ที่ทำกำไรได้ 4,654 บาท มากกว่า NoEMS ที่กำไรได้แค่ 1,605 บาท แสดงว่าระบบ EMS ส่งผลทำให้ได้กำไรมากขึ้น
- พิจารณารายจ่ายสุทธิรวมทั้งปี
 - Ideal: ได้กำไรรวม 2,421 บาท แสดงถึงระดับประสิทธิภาพสูงสุดเมื่อมีข้อมูลล่วงหน้าและไม่มีความ ไม่แน่นอน
 - EMS: ได้กำไรรวม 8,025 บาท แม้จะดีกว่า Ideal สะท้อนถึงความคลาดเคลื่อนจากการพยากรณ์ โหลดต่ำเกินไปหรือพลังงานแสงอาทิตย์สูงเกินจริง ทำให้ EMS มีพลังงานจากแสงอาทิตย์เหลือมากกว่า Actual เลยขายไฟคืนกริดได้มากกว่า
 - Actual: มีรายจ่ายรวม 8,615 บาท ซึ่งมากกว่า Ideal ถึง 11,036 บาท แสดงถึงความคลาดเคลื่อน จากการใช้พลังงานจากแบตเตอรี่ของข้อมูลพยากรณ์ที่ไม่สอดคล้องกับความต้องการโหลดที่เกิดขึ้นจริง
 - NoEMS: มีรายจ่ายรวม 45,537 บาท ซึ่งสูงกว่าทุกกรณี และมากกว่า Actual ถึง 37,128 บาท แสดง ถึงผลเสียจากการไม่ใช้ระบบบริหารจัดการเลย

ดังนั้นระบบ Energy Management System (EMS) แสดงให้เห็นถึงศักยภาพในการลดรายจ่ายสุทธิประจำ ปีจากการซื้อขายไฟฟ้าภายใต้กรอบการดำเนินงานแบบ Hour-Ahead ใน*ตารางที่* 12 สามารถลดรายจ่ายสุทธิได้ ต่ำกว่ากรณี Day-Ahead ใน*ตารางที่* 10 และการดำเนินงานแบบ Hour-Ahead สามารถอัปเดตข้อมูลพยากรณ์ ให้ใกล้เคียงกับความเป็นจริงช่วยให้ระบบ EMS มีความยืดหยุ่นและแม่นยำในการตัดสินใจมากขึ้น สะท้อนถึงความ เหมาะสมของแนวทาง Hour-Ahead สำหรับการบริหารจัดการพลังงานในสภาวะแวดล้อมที่มีความไม่แน่นอนสูง

7 บทสรุป

โครงงานนี้มุ่งเน้นการพัฒนาและวิเคราะห์ระบบบริหารจัดการพลังงานด้วยแบตเตอรี่ (Energy Management System: EMS) สำหรับระบบผลิตไฟฟ้าด้วยพลังงานหมุนเวียน โดยมีวัตถุประสงค์เพื่อลดรายจ่ายด้านพลังงานหรือ เพิ่มผลกำไรจากการซื้อขายไฟฟ้า หนึ่งในองค์ประกอบสำคัญของระบบคือการเตรียมข้อมูลพยากรณ์ ทั้งในส่วนของ โหลดไฟฟ้าและการผลิตจากแสงอาทิตย์ เพื่อให้ระบบ EMS สามารถวางแผนการทำงานของแบตเตอรี่ล่วงหน้าได้ อย่างมีประสิทธิภาพ

ในการพยากรณ์ข้อมูล ได้พัฒนาโมเดลแบบลำดับเวลา Long Short-Term Memory (LSTM) เพื่อใช้ในการ ทำนายค่าโหลดไฟฟ้าและค่าความเข้มแสงอาทิตย์ โดยค่าความเข้มแสงที่ได้จะถูกแปลงเป็นค่ากำลังไฟฟ้าที่ผลิตได้ จากแผงโซลาร์เซลล์อย่างเหมาะสม การพยากรณ์ถูกแบ่งออกเป็น 2 ระดับ ได้แก่ แบบวันล่วงหน้า (Day-Ahead: DA) ซึ่งพยากรณ์ล่วงหน้า 1, 2 และ 3 วัน และแบบชั่วโมงล่วงหน้า (Hour-Ahead: HA) ซึ่งพยากรณ์ล่วงหน้า 1 ชั่วโมง

เพื่อประเมินประสิทธิภาพของ EMS ได้มีการเปรียบเทียบรายจ่ายด้านพลังงานใน 4 กรณี ได้แก่

- กรณี Ideal: เป็นกรณีอ้างอิงซึ่งสมมติว่าระบบสามารถทราบโหลดและการผลิตพลังงานล่วงหน้าได้ทั้งหมด ทำให้สามารถควบคุมแบตเตอรี่อย่างมีประสิทธิภาพสูงสุด
- กรณี EMS: เป็นกรณีที่ใช้การพยากรณ์โหลดและการผลิตพลังงานในการวางแผนการทำงานของแบตเตอรี่
- กรณี Actual: เป็นผลลัพธ์จากการนำแผนการจาก EMS มาประยุกต์ใช้กับข้อมูลจริงที่เกิดขึ้น
- กรณี No EMS: เป็นกรณีที่ไม่มีการบริหารจัดการด้วยแบตเตอรี่ พลังงานทั้งหมดต้องซื้อจากกริดเมื่อโหลด มากกว่าการผลิต

ฟังก์ชันวัตถุประสงค์ของการวางแผนมีอยู่สองรูปแบบหลัก ได้แก่ **การลดรายจ่ายค่าไฟฟ้า** และ **การเพิ่มผล**

กำไรจากการซื้อขายไฟฟ้า ผลการทดลองแส[้]ดงให้เห็นว่าในทั้งสองฟังก์ชัน การใช้แผนแบบ Hour-Ahead ซึ่งแสดง ใน*ตารางที่* 11 และ*ตารางที่* 12 มีประสิทธิภาพในการลดความคลาดเคลื่อน (error) ระหว่างผลลัพธ์จริง (Actual) และกรณีอ้างอิง (Ideal) ได้ดีกว่าแผนแบบ Day-Ahead ที่แสดงใน*ตารางที่* 9 และ*ตารางที่* 10 สาเหตุหลักมาจาก แผนแบบ Hour-Ahead มีการอัปเดตแผนในช่วงเวลาที่สั้นกว่า และใช้ข้อมูลพยากรณ์โหลดและโซลาร์ที่แม่นยำ กว่า จึงสามารถตอบสนองต่อความผันผวนของระบบได้อย่างทันท่วงทีและมีประสิทธิภาพ โดยเฉพาะในกรณีของ การลดค่าไฟฟ้า พบว่าความคลาดเคลื่อนลดลงอย่างเด่นชัด ขณะที่กรณีของการเพิ่มผลกำไร แม้จะมีแนวโน้มลด ลงเช่นกัน แต่ยังไม่เด่นชัดเท่ากรณีแรก อย่างไรก็ตามเมื่อพิจารณาค่าใช้จ่ายจริง (Actual) ของแต่ละฟังก์ชันวัตถุประสงค์ ภายใต้ทั้งแผน Day-Ahead และ Hour-Ahead พบว่าฟังก์ชันที่เน้น **การเพิ่มผลกำไร** ซึ่งแสดงใน*ตารางที่* 10 และ*ตารางที่* 12 กลับให้ค่าใช้จ่ายสุทธิจริงที่ต่ำกว่าฟังก์ชันที่เน้น **การเดิมผลกำไร** ซึ่งแสดงใน*ตารางที่* 11 อย่างชัดเจน ผลลัพธ์นี้สะท้อนให้เห็นว่าแผนที่เปิดโอกาสให้มีการค้าขายพลังงานอย่างยืดหยุ่นและชาญฉลาด อาจ ส่งผลให้รายจ่ายรวมลดลงได้ดีกว่าการมุ่งลดเฉพาะค่าไฟฟ้าเพียงอย่างเดียว นอกจากนี้การวิเคราะห์ยังแสดงให้เห็น ว่าระบบ EMS มีบทบาทสำคัญในการลดรายจ่ายด้านพลังงานอย่างมีนัยสำคัญ โดยเฉพาะในช่วงที่โหลดมีความ ผันผวนสูง เมื่อเปรียบเทียบกับกรณีที่ไม่มีการบริหารจัดการด้วยแบตเตอรี่ (No EMS) ซึ่งตอกย้ำถึงความสำคัญ ของการวางแนนควบคูมที่คำนึงถึงความไม่แน่นอนองระบบ

ผลการศึกษานี้สะท้อนให้เห็นถึงความสำคัญของการใช้ข้อมูลพยากรณ์ที่แม่นยำในการวางแผนการทำงานของ แบตเตอรี่ และศักยภาพของระบบ EMS ในการลดค่าใช้จ่ายหรือเพิ่มรายได้ในระบบพลังงานสมัยใหม่ ซึ่งสามารถ นำไปต่อยอดสู่การใช้งานจริงในระบบไมโครกริดหรืออาคารอัจฉริยะในอนาคต

8 กิตติกรรมประกาศ

โครงงานฉบับนี้สำเร็จลุล่วงได้ด้วยดี เนื่องด้วยความกรุณาเป็นอย่างดียิ่งจาก ศาสตราจารย์ ดร.จิตโกมุท ส่งศิริ ที่ ได้กรุณาสละเวลาอันมีค่าให้คำแนะนำและให้ความรู้แก่ผู้จัดทำด้วยความเอาใจใส่ตลอดระยะเวลาการดำเนินโครง งาน คำปรึกษาอันล้ำค่าของท่านมีความสำคัญอย่างยิ่งในการกำหนดทิศทางของโครงงานให้ก้าวหน้าและเป็นไปอย่าง มีระบบ ทางผู้จัดทำขอขอบพระคุณเป็นอย่างสูง ไว้ ณ ที่นี้

ขอขอบพระคุณ รศ. ดร.สุรพงศ์ สุวรรณกวิน ที่กรุณาให้ข้อมูลของโหลดไฟฟ้าและกำลังไฟฟ้าแสงอาทิตย์ที่ใช้ ในการทดลองทั้งหมด

ขอขอบคุณนาย ณฐนนท โตงามรักษ์ ที่ให้ความรู้ในด้านการเขียนโปรแกรม และช่วยสร้างแบบจำลองพยากรณ์ ซึ่งเป็นส่วนสำคัญของโครงงานนี้

สุดท้ายนี้ขอข[้]อบคุณศูนย์เชี่ยวชาญพิเศษเฉพาะด้านเทคโนโลยีไฟฟ้ากำลังที่ได้ให้ข้อมูลเกี่ยวกับการดำเนินงาน จริงของระบบจัดการพลังงานทำให้ผู้จัดทำได้มีความเข้าใจที่ถูกต้อง

เอกสารอ้างอิง

- [1] P. Assoc. Prof. Naebboon Hoonchareon, "Centralized and decentralized EMS," Course 2102559 Energy Management Systems in Smart Grids, Chapter 2 Centralized and Decentralized EMS, Faculty of Engineering, Chulalongkorn University, 2024, เข้าถึงเมื่อ 18 พฤศจิกายน 2567.
- [2] C. Olah. (2015) Understanding LSTM networks. เข้าถึงเมื่อ 16 เมษายน 2568. [Online]. Available: https://colah.github.io/posts/2015-08-Understanding-LSTMs/
- [3] Jinko Solar Energy Storage. Jks-215klaa-100plaa product page. เข้าถึงเมื่อ 12 พฤศจิกายน 2567. [Online]. Available: https://jinkosolarenergystorage.com.au/product/jks-215klaa-100plaa/
- [4] D. Pérez-Piñeiro, S. Skogestad, and S. Boyd, "Home energy management with dynamic tariffs and tiered peak power charges," 2023. [Online]. Available: https://arxiv.org/abs/2307.07580
- [5] N. Kongkaew and P. Chaowarak, "Energy management system for Gewertz square," 2566, CUEE Final-Year Project Report (2102499).
- [6] Wikipedia contributors, "Long short-term memory wikipedia, the free encyclopedia," 2022, เข้าถึงเมื่อ 4 กุมภาพันธ์ 2568. [Online]. Available: https://en.wikipedia.org/wiki/Long_short-term_memory
- [7] MINES ParisTech. SoDa: Solar radiation Data services. เข้าถึงเมื่อ 14 มกราคม 2568. [Online]. Available: https://www.soda-pro.com/web-services
- [8] N. Tongamrak, "Improved clear sky model," https://github.com/energyCUEE/improved_ clearsky model, 2023, เข้าถึงเมื่อ 28 มกราคม 2568.
- [9] Optemis. (2022) Himawari-8 satellite imagery archive. เข้าถึงเมื่อ 14 มกราคม 2568. [Online]. Available: https://himawari.optemis.space/archives