

การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์  
วัลเลย์โดยใช้วิธีการเรียนรู้ของเครื่อง

ELECTRICITY CONSUMPTION FORECASTING IN  
WANGCHAN VALLEY SMART CITY USING MACHINE  
LEARNING METHOD



สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร  
ปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์)  
ภาควิชาสถิติ คณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ปีการศึกษา 2566  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ELECTRICITY CONSUMPTION FORECASTING IN  
WANGCHAN VALLEY SMART CITY USING MACHINE  
LEARNING METHOD



A COOPARATIVE EDUCATION SUBMITTED IN  
PARTIAL FULFILLMENT OF THE REQUIREMENT FOR  
THE DEGREE OF BACHELOR OF SCIENCE (APPLIED STATISTICS)  
DEPARTMENT OF STATISTICS, SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารทสงวนเวสสำหรับกรเซงานเพอการศกษาเท่านั้น ไมอนุญาตเหนาไปเซประยชนดานการค้ำ  
ไมว่ากรณใดๆ ทั้งสิ้น อกทั้งห้ามมิให้ดัดแและหรือสงเอกสารทุกคร้งที่มีการนำไปใช้  
ACADEMIC YEAR 2023

หัวข้อสหกิจศึกษา การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์โดย  
ใช้วิธีการเรียนรู้ของเครื่อง  
ELECTRICITY CONSUMPTION FORECASTING IN WANGCHAN  
VALLEY SMART CITY USING MACHINE LEARNING METHOD

ชื่อนักศึกษา นางสาวอารยา มิตรโษะมัน รหัสนักศึกษา 63050693

ปริญญา วิทยาศาสตร์บัณฑิต (สถิติประยุกต์)

ภาควิชา สถิติ

ปีการศึกษา 2566

อาจารย์ที่ปรึกษา ผู้ช่วยศาสตราจารย์ ดร.ยุวดี กล่อมวิเศษ

คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.) อนุมัติ  
ให้สหกิจศึกษานี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต (สถิติประยุกต์)  
ประจำปีการศึกษา 2566

คณะกรรมการสอบ	ลายมือชื่อ
ผศ.ดร.พรพิมล ชัยวุฒิศักดิ์ ประธานกรรมการ	<i>Pornpimol Chaiwuttisak</i>
ว่าที่ ร.ต.คมกฤษ มิสเกตุ กรรมการ	<i>ก.ก.</i>
ผศ.ดร.ยุวดี กล่อมวิเศษ กรรมการและอาจารย์ที่ปรึกษา	<i>ยุวดี</i>

ลิขสิทธิ์ของคณะวิทยาศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อสหกิจศึกษา	การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์โดยใช้วิธีการเรียนรู้ของเครื่อง		
ชื่อนักศึกษา	นางสาวอารยา มิตรโชะมัน	รหัสนักศึกษา	63050693
ปริญญา	วิทยาศาสตร์บัณฑิต (สถิติประยุกต์)		
ภาควิชา	สถิติ		
คณะ	วิทยาศาสตร์		
มหาวิทยาลัย	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.)		
ปีการศึกษา	2566		
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.ยุวดี กล่อมวิเศษ		

### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการประยุกต์ใช้การเรียนรู้ของเครื่องมาใช้ในการพยากรณ์ข้อมูลเกี่ยวกับค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และค่าพลังงานไฟฟ้าช่วง ON PEAK, OFF PEAK, และ HOLIDAY (kWh) ซึ่งได้รับการอนุเคราะห์ข้อมูลจากเมืองอัจฉริยะวังจันทร์วัลเลย์ โดยข้อมูลที่ใช้ คือ ข้อมูลตั้งแต่เดือน มกราคม พ.ศ. 2564 ถึง เดือน ธันวาคม 2566 จำนวน 36 เดือน ผู้วิจัยได้ทำการแบ่งข้อมูล 24 เดือน เป็น ชุดข้อมูลฝึกสอน และข้อมูล 12 เดือน เป็นชุดข้อมูลทดสอบ เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่องทั้ง 5 วิธี ได้แก่ แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน แบบจำลองการสุ่มป่าไม้ แบบจำลองเอ็กซ์ทรีมกาเดียนบูทดิ้ง แบบจำลองการถดถอยเชิงเส้น และแบบจำลองค่าเฉลี่ยเคลื่อนที่ โดยใช้รากที่สองของความคลาดเคลื่อนค่าเฉลี่ยเป็นเกณฑ์ในการเปรียบเทียบประสิทธิภาพแบบจำลองแต่ละวิธี

ผลการวิจัยพบว่า ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) มีแบบจำลองที่เหมาะสมที่สุด คือ แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK และ HOLIDAY (kWh) มีแบบจำลองที่เหมาะสมที่สุด คือ แบบจำลองค่าเฉลี่ยเคลื่อนที่ และข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) มีแบบจำลองที่เหมาะสมที่สุด คือ แบบจำลองการถดถอยเชิงเส้น จากนั้นผู้วิจัยได้นำแบบจำลองที่ดีที่สุดไปใช้ในการพยากรณ์ข้อมูลล่วงหน้า 12 เดือน ผู้วิจัยหวังเป็นอย่างยิ่งว่าผลการพยากรณ์ล่วงหน้าจะสามารถใช้เป็นข้อมูลเบื้องต้นในการวางแผนการจัดหาพลังงานไฟฟ้าให้เพียงพอต่อความต้องการ และใช้พลังงานไฟฟ้าในอนาคตอย่างมีประสิทธิภาพมากยิ่งขึ้น

**คำสำคัญ :** การพยากรณ์การใช้พลังงานไฟฟ้า การเรียนรู้ของเครื่อง รากที่สองของความคลาดเคลื่อนค่าเฉลี่ย ชุดข้อมูลฝึกสอนและทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ไม่ควรนำเอกสารนี้ไปเผยแพร่โดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

<b>Title</b>	ELECTRICITY CONSUMPTION FORECASTING IN WANGCHAN VALLEY SMART CITY USING MACHINE LEARNING METHOD
<b>Students</b>	Miss. Araya Mitsoman      Student ID 63050693
<b>Degree</b>	Bachelor of Science (Applied Statistics)
<b>Department</b>	Statistics
<b>School</b>	Science
<b>University</b>	King Mongkut's Institute of Technology Ladkrabang (KMITL)
<b>Academic</b>	2023
<b>Advisor</b>	Asst. Prof. Dr. Yuwadee Klomwises

### Abstract

The aim of this research is to explore the utilization of machine learning for forecasting electricity consumption. The study focuses on analyzing data pertaining to electricity demand during ON PEAK periods (kW) as well as ON PEAK, OFF PEAK, and HOLIDAY electricity usage (kWh). The data were sourced from the Intelligent Wangchan Valley, spanning from January 2021 to December 2023, totaling 36 months. We divided the data into 24 months for training datasets and 12 months for testing datasets. We employed five methods: Support Vector Machines, Random Forest, Extreme Gradient Boosting, Linear Regression, and Moving Average. In addition, the root means square error (RMSE) served as the measure for evaluating the performance of each forecasting model.

The research findings revealed that the data on the electricity demand during ON PEAK periods (kW) are best suited for the support vector machine model. Additionally, the data on electricity consumption during ON PEAK and HOLIDAY periods (kWh) are best modeled using moving averages. Furthermore, OFF PEAK electricity consumption (kWh) data are best modeled using linear regression. The aforementioned models have the smallest root mean square error calculated from the testing dataset. Subsequently, the best-performing model was used to forecast electricity usage for the next 12 months. Finally, we hope that the forecasting results can serve as preliminary data for planning an adequate electricity supply to meet demand and ensure more efficient electricity usage in the future.

**Keywords** : Electricity consumption forecasting, Machine learning, Root Mean Square Error, Training and testing datasets



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

การทำสหกิจศึกษาฉบับนี้สำเร็จได้ เนื่องจากได้รับความเมตตาจากอาจารย์ที่ปรึกษาสหกิจศึกษา ผู้ช่วยศาสตราจารย์ ดร.ยุวดี กล่อมวิเศษ ที่เมตตาให้คำปรึกษา สละเวลาอันมีค่าให้คำแนะนำ อีกทั้งยังช่วยแก้ไขข้อบกพร่องต่าง ๆ ด้วยความเอาใจใส่ จนกระทั่งสหกิจศึกษาสำเร็จลุล่วงไปด้วยดี ผู้วิจัยทราบบนซึ่งในความเมตตาจากท่านอาจารย์และกราบขอบพระคุณเป็นอย่างสูง ณ โอกาสนี้

ผู้วิจัยขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์ ที่ให้เกียรติเป็นประธานกรรมการสอบสหกิจที่เมตตาให้คำปรึกษา และสละเวลามาตรวจทานแก้ไขข้อบกพร่องต่าง ๆ ตลอดจนการทำสหกิจศึกษาฉบับนี้ อีกทั้งคุณอาจารย์ประจำภาคสถิติ คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (สจล.) ที่ให้คำแนะนำที่เป็นประโยชน์แก่ผู้วิจัย มอบวิชาความรู้และประสบการณ์การเรียนการสอนกับผู้วิจัย

รวมถึงขอขอบคุณ ว่าที่ ร.ต.คมกฤษ มิสเกตู จากบริษัท ปตท. จำกัด (มหาชน) ที่ให้โอกาสแก่ผู้วิจัยได้เข้าร่วมโครงการสหกิจศึกษา และให้ความอนุเคราะห์ข้อมูลผู้ปริมาณการใช้พลังงานไฟฟ้า เมืองอัจฉริยะวังจันทร์วัลเลย์ ในการศึกษาวิเคราะห์เพื่อให้เกิดประโยชน์กับผู้วิจัยและหน่วยงานที่เกี่ยวข้อง รวมทั้งขอบคุณพี่ ๆ ที่คอยดูแล ให้คำปรึกษา คอยมอบความรู้ และแบ่งปันประสบการณ์ เพื่อช่วยสร้างผลงานวิจัยที่มีคุณภาพ

สุดท้ายนี้ผู้วิจัยขอขอบพระคุณบิดา มารดา ที่สนับสนุนให้กำลังใจแก่ผู้วิจัยในการศึกษาระดับปริญญาตรี ตลอดจนการทำสหกิจศึกษาครั้งนี้สำเร็จลุล่วงไปด้วยดี ผู้วิจัยหวังเป็นอย่างยิ่งว่าสหกิจศึกษานี้จะเป็นประโยชน์และจะเป็นแนวทางในการพัฒนาต่อไป

อารยา มิตรไช้มนัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ข
กิตติกรรมประกาศ.....	ง
สารบัญ.....	จ
สารบัญตาราง.....	ช
สารบัญรูป.....	ฉ
<b>บทที่ 1 บทนำ.....</b>	<b>1</b>
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตของงานวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 นิยามศัพท์เฉพาะ.....	3
<b>บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>4</b>
2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้าวงจันท์วัลเลย์.....	4
2.1.1 ความหมายของโครงการวงจันท์วัลเลย์.....	4
2.1.2 ความหมายของพลังงานและพลังงานไฟฟ้า.....	5
2.1.3 ระบบบริหารจัดการพลังงานไฟฟ้า.....	6
2.1.4 อัตราค่าไฟฟ้าการไฟฟ้าส่วนภูมิภาค.....	7
2.1.5 ทฤษฎีเกี่ยวกับอินเทอร์เน็ตของทุกสรรพสิ่ง (Internet of things)...	9
2.2 การทำเหมืองข้อมูล (Data Mining).....	10
2.2.1 เหมืองข้อมูล.....	10
2.2.2 ประเภทของการทำเหมืองข้อมูล.....	10
2.2.3 ขั้นตอนการทำเหมืองข้อมูล.....	11
2.3 การเรียนรู้ของเครื่อง (Machine Learning).....	13
2.3.1 การเรียนรู้ของเครื่อง.....	13
2.3.2 อัลกอริทึมของ Machine Learning.....	13
2.4 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์.....	14
2.4.1 แบบจำลอง Support Vector Machine.....	14
2.4.2 แบบจำลอง Random Forest.....	15

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของโรงเรียนเพื่อการศึกษาเท่านั้น เมื่อเผยแพร่ให้ผู้ใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้เผยแพร่ไปยังสื่อและช่องทางอื่นใดของเอกสารทุกพริ้งที่มีกรนำไปใช้

## สารบัญ(ต่อ)

	หน้า
2.4.3 แบบจำลอง Extreme Gradient Boosting.....	16
2.4.4 แบบจำลอง Linear Regression.....	17
2.4.5 แบบจำลอง Moving Average.....	18
2.5 การปรับแต่งพารามิเตอร์ของแบบจำลองในการพยากรณ์.....	20
2.6 การวัดประสิทธิภาพของแบบจำลองในการพยากรณ์.....	23
2.7 งานวิจัยที่เกี่ยวข้อง.....	24
<b>บทที่ 3 วิธีการดำเนินงานวิจัย.....</b>	<b>26</b>
3.1 ขั้นตอนการดำเนินงาน.....	26
3.2 เครื่องมือที่ใช้ในการศึกษาวิจัย.....	28
3.3 การจัดเตรียมข้อมูล.....	29
3.4 การสร้างแบบจำลอง.....	35
3.5 การปรับแต่งพารามิเตอร์.....	45
3.6 การวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	53
3.7 การพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี.....	54
<b>บทที่ 4 ผลการวิจัยและการอภิปรายผล.....</b>	<b>58</b>
4.1 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าก่อนการปรับแต่งพารามิเตอร์.....	58
4.2 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าหลังการปรับแต่งพารามิเตอร์.....	85
4.3 ผลการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	101
4.4 ผลการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี.....	104
<b>บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....</b>	<b>107</b>
5.1 สรุปผลการวิจัย.....	107
5.2 ข้อเสนอแนะ.....	110
เอกสารอ้างอิง.....	111
ภาคผนวก.....	113
ภาคผนวก ก.....	114
ภาคผนวก ข.....	124
ภาคผนวก ค.....	134
ภาคผนวก ง.....	144
ภาคผนวก จ.....	154

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ทำซ้ำหรือเผยแพร่โดยไม่ได้รับอนุญาต  
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแบบลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง

ตารางที่		หน้า
2.1	ช่วงเวลาของการใช้ Time of Use Rater.....	8
3.1	ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566.....	29
3.2	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566.....	31
3.3	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566.....	32
3.4	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566.....	33
3.5	ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565.....	35
3.6	ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	36
3.7	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565.....	37
3.8	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	38
3.9	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565.....	38
3.10	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	39
3.11	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565.....	40
3.12	ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	41
4.1	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	57
4.2	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	59

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการขังนเพื่อการศึกษาเท่านั้น เมื่อผู้ยูเตให้หน้าไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น ยกเว้นที่มิได้เห็นแต่เพียงเนื้อหา และต้องยั้งยั้งใจของเอกสารที่พ่วงที่มีกาแนไป

## สารบัญตาราง(ต่อ)

ตารางที่		หน้า
4.3	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	60
4.4	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	61
4.5	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	63
4.6	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	64
4.7	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	65
4.8	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	66
4.9	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	68
4.10	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	69
4.11	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	70
4.12	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	72
4.13	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	73
4.14	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	74
4.15	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	76
4.16	ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	77

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการขังเพื่อการค้าเท่านั้น เมื่อผู้ยืมได้เห็นว่าเว็บไซต์หรือเนื้อหาการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง(ต่อ)

ตารางที่	หน้า
4.17 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	78
4.18 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	80
4.19 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	81
4.20 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	82
4.21 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	84
4.22 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	85
4.23 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	86
4.24 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	88
4.25 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	89
4.26 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	90
4.27 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	92
4.28 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	93
4.29 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	94
4.30 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	96

## สารบัญตาราง(ต่อ)

ตารางที่	หน้า
4.31 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	97
4.32 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	98
ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)	
4.33 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	100
4.34 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	100
4.35 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	101
4.36 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง.....	101
4.37 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้า ช่วง ON PEAK (kW) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567.....	102
4.38 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567.....	103
4.39 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567.....	104
4.40 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567.....	105
5.1 พยากรณ์ปริมาณการใช้พลังงานไฟฟ้า เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567	107

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูปภาพ

รูปที่	หน้า
2.1 เมืองอัจฉริยะ 7 ด้านโครงการวังจันทร์วัลเลย์.....	6
2.2 การจัดการพลังงานไฟฟ้าโครงการวังจันทร์วัลเลย์.....	8
2.3 ขั้นตอนอัตราค่าไฟฟ้าการไฟฟ้าส่วนภูมิภาค.....	10
2.4 ขั้นตอนการทำเหมืองข้อมูล.....	13
2.5 อัลกอริทึมของ Machine Learning.....	14
2.6 การจำแนกประเภทของข้อมูลของแบบจำลอง Support Vector Machine.....	16
2.7 การจำแนกประเภทของข้อมูลของแบบจำลอง Random Forest.....	17
2.8 การจำแนกประเภทของข้อมูลของแบบจำลอง Extreme Gradient Boosting.....	18
2.9 การจำแนกประเภทของข้อมูลของแบบจำลอง Linear Regression.....	19
2.10 เส้นแบบจำลอง Moving Average.....	20
2.11 การสร้างโมเดลการเรียนรู้ของเครื่อง.....	22
2.12 การทำ Hyperparameter Tuning.....	22
2.13 จำลองการทำงานของ Grid Search.....	23
2.14 จำลองการทำงานของ Random Search.....	24
3.1 ขั้นตอนการดำเนินงาน.....	27
3.2 Code สำหรับ Support Vector Machine.....	42
3.3 Code สำหรับ Random Forest.....	42
3.4 Code สำหรับ Extreme Gradient Boosting.....	43
3.5 Code สำหรับ Linear Regression.....	43
3.6 Code สำหรับ Moving Average.....	44
3.7 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine.....	45
3.8 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Random Forest.....	46
3.9 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Extreme Gradient Boosting.....	46
3.10 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine.....	47
3.11 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Random Forest.....	48

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการขังนเพื่อการศึกษาเท่านั้น เมื่อผู้ยู่ยู่เห็นหน้าไปใช้ประโยชน์ทางการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
3.12 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Extreme Gradient Boosting.....	48
3.13 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine.....	49
3.14 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Random Forest.....	50
3.15 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Extreme Gradient Boosting.....	50
3.16 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine.....	51
3.17 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Random Forest.....	52
3.18 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Extreme Gradient Boosting.....	52
3.19 Code สำหรับการวัดประสิทธิภาพของแบบจำลอง.....	53
3.20 Code สำหรับการสร้างข้อมูลเพื่อพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี.....	54
3.21 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Support Vector Machine.....	54
3.22 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Random Forest.....	55
3.23 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Extreme Gradient Boosting.....	55
3.24 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Linear Regression.....	56
3.25 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Moving Average.....	56
4.1 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	59
4.2 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	60

เอกสารนี้เป็นเอกสารลิขสิทธิ์สงวนสิทธิ์หรือการขังนเพื่อการค้าเท่านั้น เมื่อผู้ยู่ได้เห็นว่าใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
4.3 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	62
4.4 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	63
4.5 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	64
ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK	
4.6 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	66
4.7 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	67
4.8 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	68
4.9 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	70
4.10 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	71
ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)	
4.11 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	72
4.12 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	74
4.13 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	75
4.14 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	76
4.15 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	78

เอกสารนี้เป็นเอกสารลิขสิทธิ์ของสถาบันวิจัยและพัฒนาพลังงานทดแทนจันทบุรี เมื่อผู้ยืมได้เห็นว่าประโยชน์ที่เกินกว่าค่า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
4.16 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	79
4.17 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	80
4.18 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	82
4.19 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	83
4.20 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	84
4.21 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	86
4.22 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	87
4.23 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	88
4.24 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	90
4.25 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	91
4.26 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	92
4.27 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	94
4.28 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	95
4.29 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	96

เอกสารนี้เป็นเอกสารสงวนลิขสิทธิ์หรือการขังเพื่อการค้าภายใต้เงื่อนไขและข้อระเบียบอื่นหากมีค่า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูปภาพ(ต่อ)

รูปที่	หน้า
4.30 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	98
4.31 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	99
4.32 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566.....	100



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ประเทศไทยเผชิญกับความแปรปรวนด้านสภาพภูมิอากาศ ทั้งอุณหภูมิที่สูงขึ้น อากาศเย็นผิดปกติ เกิดภัยแล้งและน้ำท่วมฉับพลันหลายพื้นที่ สิ่งเหล่านี้สร้างความเสียหายรุนแรงต่อระบบเศรษฐกิจและสังคม สอดคล้องกับรายงานจาก Global Climate Risk Index ที่ประเมินว่าประเทศไทยจะได้รับผลกระทบสูงจากการเปลี่ยนแปลงสภาพภูมิอากาศ หากไม่ได้รับการแก้ไขอย่างเร่งด่วน ปัญหาเหล่านี้จะเกิดขึ้นซ้ำแล้วซ้ำเล่า และภัยธรรมชาติจะยิ่งทวีความรุนแรงมากขึ้นเรื่อยๆ” รวมถึงสัดส่วนการปล่อยก๊าซเรือนกระจกในประเทศไทยนั้นมาจากหลายภาคส่วน แต่โดยหลักแล้วจะมาจากภาคพลังงาน เช่น การผลิตพลังงานไฟฟ้า การใช้ฟอสซิลทำความร้อน ไปจนถึงการขนส่งทางบกทางอากาศ ซึ่งมีส่วนต่อการปล่อยก๊าซเรือนกระจกกว่า 60% ส่วนภาคการเกษตรและภาคอื่นๆ อยู่ที่ประมาณ 20% ดังนั้น ในฐานะที่บริษัท ปตท. จำกัด (มหาชน) เป็นองค์กรที่รับผิดชอบด้านความมั่นคงทางพลังงานของประเทศ จึงมีหลักและแนวคิดที่พยายามสร้าง Net Zero Emissions ที่ช่วยลดก๊าซเรือนกระจกในชั้นบรรยากาศให้มีความเท่าเทียม นอกจากนี้ทางบริษัท ปตท. จำกัด (มหาชน) มีการพัฒนาโครงการวังจันทร์วัลเลย์ ให้เป็นเมืองวิจัยนวัตกรรมของประเทศในรูปแบบ Smart Natural Innovation Platform (วรพงษ์ นาคฉัตรีย์, 2566)

โครงการนวัตกรรมระเบียงเศรษฐกิจภาคตะวันออก หรือ โครงการวังจันทร์วัลเลย์ เป็นโครงการที่เกิดจากความร่วมมือระหว่าง บริษัท ปตท. จำกัด (มหาชน) กับสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม ที่จะพัฒนาพื้นที่โครงการฯ ให้มีระบบนิเวศนวัตกรรม (Innovation Ecosystem) ในระดับชั้นนำของภูมิภาคเอเชียตะวันออกเฉียงใต้ เพื่อให้ประชาชนมีคุณภาพชีวิตที่ดี ซึ่งประเทศไทยพยายามผลักดัน Smart City ให้เกิดขึ้นจริงตามแผนพัฒนาเศรษฐกิจแห่งชาติฉบับที่ 12 และนโยบาย Thailand 4.0 โดย “วังจันทร์วัลเลย์” ถูกพัฒนาในรูปแบบ Smart Natural Innovation Platform

โครงการวังจันทร์วัลเลย์เป็นหนึ่งในโครงการที่เน้นการใช้พลังงานไฟฟ้าอย่างมีประสิทธิภาพเพื่อตอบสนองต่อความต้องการทางพลังงานที่เพิ่มสูงขึ้น โดยโครงการนี้ได้รับการสนับสนุนจากรัฐบาลและผู้สนับสนุนทางธุรกิจในการพัฒนาและใช้เทคโนโลยีใหม่ๆ โครงการวังจันทร์วัลเลย์เป็นหนึ่งในโครงการที่มุ่งเน้นการใช้พลังงานที่สะอาดและมีประสิทธิภาพ เพื่อสร้างการผลิตไฟฟ้าที่มีคุณภาพและเพียงพอต่อความต้องการของสังคมในปัจจุบันและอนาคต (วังจันทร์วัลเลย์, 2565)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดังนั้นผู้วิจัยจึงสนใจในการสำรวจปริมาณการใช้พลังงานไฟฟ้าในโครงการวังจันทร์วัลเลย์ โดยสังเกตเห็นความเปลี่ยนแปลงของการใช้พลังงานไฟฟ้าในแต่ละช่วงเวลา ข้อมูลที่ได้จากการเก็บข้อมูลพลังงานไฟฟ้านั้น จะนำข้อมูลมาวิเคราะห์โดยใช้แบบจำลอง Support Vector Machines, Random Forest, Extreme Gradient Boosting, Linear Regression และแบบจำลอง Moving Average จากนั้นทำการเปรียบเทียบประสิทธิภาพของวิธีพยากรณ์ เพื่อเลือกวิธีพยากรณ์ที่เหมาะสมที่สุด จากนั้นพยากรณ์ปริมาณการใช้ไฟฟ้าล่วงหน้า และสามารถนำค่าพยากรณ์ให้หน่วยงาน ใช้เป็นข้อมูลเบื้องต้นในการวางแผนการจัดการทรัพยากรในอนาคต

## 1.2 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อสร้างตัวแบบการเรียนรู้ของเครื่องสำหรับพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์
- 2) เพื่อเปรียบเทียบหาตัวแบบการเรียนรู้ของเครื่องที่เหมาะสมสำหรับการนำไปใช้พยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์

## 1.3 ขอบเขตของงานวิจัย

- 1) ขอบเขตเชิงเนื้อหา  
ข้อมูลที่ใช้วิจัยเป็นข้อมูลเกี่ยวกับค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh) ที่ใช้ในการศึกษาครั้งนี้เป็นข้อมูลปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์
- 2) ขอบเขตเชิงพื้นที่และเวลา  
ข้อมูลที่ใช้วิจัยตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566 ระยะเวลา 36 เดือน สำหรับใช้ในการสร้างแบบจำลองพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์
- 3) ขอบเขตเชิงเครื่องมือ  
เครื่องมือที่ใช้ในการสร้างแบบจำลองคือ โปรแกรม R

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ทราบตัวแบบที่เหมาะสมสำหรับการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์
- 2) วังจันทร์วัลเลย์สามารถนำค่าพยากรณ์ที่ได้ไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 1.5 นิยามศัพท์เฉพาะ

ในงานวิจัยครั้งนี้ ผู้วิจัยได้กำหนดความหมายของคำศัพท์ที่เกี่ยวข้องไว้ เพื่อให้ผู้ที่จะนำงานวิจัยนี้ไปศึกษาต่อได้เกิดความเข้าใจในแนวทางเดียวกัน ดังนี้

1) การเรียนรู้ของเครื่อง (Machine Learning) หมายถึง การทำให้คอมพิวเตอร์ สามารถเรียนรู้สิ่งต่างๆ และพัฒนาการทำงานให้ดีขึ้นได้ด้วยตัวเองจากข้อมูลและสภาพแวดล้อมที่ได้รับจากการเรียนรู้ของระบบ (Cyber Elite, 2022)

2) การปล่อยก๊าซเรือนกระจกสุทธิเป็นศูนย์ (Net Zero Emissions) หมายถึง การที่ปริมาณการปล่อยก๊าซเรือนกระจกมีความสมดุล เท่ากับก๊าซเรือนกระจกที่ถูกดูดซับออกจากชั้นบรรยากาศ ซึ่งในสภาวะสมดุลนี้ก็ไม่เพิ่มปริมาณก๊าซเรือนกระจกในบรรยากาศ (ธนินสา, 2565)

3) วังจันทร์วัลเลย์ (Wangchan Valley) หมายถึง โครงการเมืองนวัตกรรมอัจฉริยะของบริษัท ปตท. จำกัด (มหาชน) ที่ร่วมมือกับ สำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) ตั้งอยู่ที่อำเภอวังจันทร์ จังหวัดระยอง (วังจันทร์วัลเลย์, 2565)

4) เมืองอัจฉริยะ (Smart City) หมายถึง เมืองที่ใช้ประโยชน์จากเทคโนโลยีและนวัตกรรมที่ทันสมัยและชาญฉลาด เพื่อเพิ่มประสิทธิภาพของการให้บริการและการบริหารจัดการเมือง ลดค่าใช้จ่ายและการใช้ทรัพยากรของเมืองและประชากรเป้าหมาย (Depa, 2021)

5) อินเทอร์เน็ตของทุกสรรพสิ่ง (Internet of things) หมายถึง "สิ่ง" จำนวนมากมายที่เชื่อมต่อกับอินเทอร์เน็ตเพื่อให้พวกเขาสามารถแบ่งปันข้อมูลกับสิ่งอื่น ๆ - แอปพลิเคชัน IoT อุปกรณ์เชื่อมต่อเครื่องจักรอุตสาหกรรมและอื่น ๆ อุปกรณ์ที่เชื่อมต่ออินเทอร์เน็ตใช้เซ็นเซอร์ในตัวเพื่อรวบรวมข้อมูลและในบางกรณีก็ทำเช่นนั้น อุปกรณ์และเครื่องจักรที่เชื่อมต่อ IoT สามารถปรับปรุงวิธีการทำงานและการใช้ชีวิตของเรา (Sas, 2023)

6) พลังงานไฟฟ้า (Electrical Energy) หมายถึง พลังงานรูปแบบหนึ่งที่เกิดจากการแยกตัว หรือการเคลื่อนที่ของอิเล็กตรอน หรือโปรตอน ซึ่งการเดินทางของพลังงานดังกล่าวผ่านวัสดุนำไฟฟ้า ทำให้เกิดเป็นกระแสไฟฟ้าที่เราใช้กันอยู่ในการดำรงชีวิต คุณภาพชีวิต และการอำนวยความสะดวกในการดำรงชีวิต (NPS, 2023)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2

# ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การศึกษาวิจัยในครั้งนี้ผู้จัดทำได้ทำการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องกับการเปรียบเทียบตัวแบบการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวงจันท์วัลเลย์ โดยมีรายละเอียดประกอบด้วยหัวข้อ ดังต่อไปนี้

- 2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้าวงจันท์วัลเลย์
- 2.2 การทำเหมืองข้อมูล (Data Mining)
- 2.3 การเรียนรู้ของเครื่อง (Machine Learning)
- 2.4 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์และการวัดความผิดพลาดแบบจำลองในการพยากรณ์
- 2.5 การปรับแต่งพารามิเตอร์ของแบบจำลองในการพยากรณ์
- 2.6 การวัดประสิทธิภาพของแบบจำลองในการพยากรณ์
- 2.7 งานวิจัยที่เกี่ยวข้อง

### 2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้าวงจันท์วัลเลย์

#### 2.1.1 ความหมายของโครงการวงจันท์วัลเลย์

โครงการนวัตกรรมระเบียงเศรษฐกิจภาคตะวันออก หรือ โครงการวงจันท์วัลเลย์ ตั้งอยู่ที่ ต.ปายุบใน อ.วังจันท์ จ.ระยอง บนพื้นที่ 3,454 ไร่ เป็นโครงการที่เกิดจากความร่วมมือระหว่าง บริษัท ปตท. จำกัด (มหาชน) กับสำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) กระทรวงการอุดมศึกษา วิทยาศาสตร์ วิจัยและนวัตกรรม ที่จะพัฒนาพื้นที่โครงการฯ ให้มีระบบนิเวศนวัตกรรม (Innovation Ecosystem) ในระดับชั้นนำของภูมิภาคเอเชียตะวันออกเฉียงใต้ เพื่อให้ประชาชนมีคุณภาพชีวิตที่ดี ซึ่งประเทศไทยพยายามผลักดัน Smart City ให้เกิดขึ้นจริงตามแผนพัฒนาเศรษฐกิจแห่งชาติฉบับที่ 12 และนโยบาย Thailand 4.0 โดย “วงจันท์วัลเลย์” ถูกพัฒนาในรูปแบบ Smart Natural Innovation Platform แบ่งออกเป็น 3 โซน ดังนี้

- 1) พื้นที่เพื่อการศึกษา (Education Zone) ซึ่งมีพื้นที่ที่พัฒนาแล้ว ได้แก่ สถาบันวิทยสิริเมธี (VISTEC) โรงเรียนกำเนิดวิทย์ (KVIS) และศูนย์เรียนรู้ป่าวงจันท์
- 2) พื้นที่เพื่อการวิจัยและพัฒนานวัตกรรม (Innovation Zone) พื้นที่ที่จะพัฒนาเป็นศูนย์วิจัย พัฒนา และนวัตกรรม เพื่อยกระดับความสามารถด้านวิทยาศาสตร์ เทคโนโลยี และนวัตกรรมแบบก้าวกระโดด โดยออกแบบโครงสร้างพื้นฐานและบริการไว้อย่างครบวงจร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) พื้นที่เพื่ออำนวยความสะดวก ที่พักอาศัยและสันตนาการ (Community Zone) พื้นที่ ซึ่งจะพัฒนาให้เป็นพื้นที่สำหรับที่อยู่อาศัยและสันตนาการ รองรับความเป็นอยู่ของนักวิจัยและครอบครัว นักเรียน นักศึกษา และผู้ประกอบการ เช่น โรงเรียนนานาชาติ โรงแรมและที่พักอาศัย ศูนย์การค้าและนันทนาการ

“วังจันทร์วัลเลย์” เป็นพื้นที่ที่มีองค์ประกอบในการพัฒนา Smart City ครบทั้ง 7 ด้าน ตามหลักที่สำนักงานส่งเสริมเศรษฐกิจดิจิทัล (depa) ได้กำหนดไว้ นั่นคือ สิ่งแวดล้อมอัจฉริยะ (Smart Environment) การบริการภาครัฐอัจฉริยะ (Smart Governance) การเดินทางและขนส่งอัจฉริยะ (Smart Mobility) พลังงานอัจฉริยะ (Smart Energy) เศรษฐกิจอัจฉริยะ (Smart Economy) การดำรงชีวิตอัจฉริยะ (Smart Living) และพลเมืองอัจฉริยะ (Smart People) นอกจากนี้เมืองอัจฉริยะวังจันทร์วัลเลย์ ยังมีการพัฒนาระบบจัดเก็บและบริหารข้อมูลเมือง (City Data Platform) ในการวางโครงข่ายเชื่อมโยงข้อมูล การกำหนดชุดข้อมูล การรวบรวมและการใช้ประโยชน์จากข้อมูล การดูแลความมั่นคงปลอดภัยไซเบอร์ และการดูแลความปลอดภัยของข้อมูลส่วนบุคคล ทั้งหมดนี้คือสิ่งอัจฉริยะของวังจันทร์วัลเลย์ ที่เตรียมความพร้อมสู่การเป็นต้นแบบเมืองนวัตกรรมแห่งอนาคตตามที่ตั้งเป้าไว้ได้อย่างสมบูรณ์แบบ แสดงดังรูปที่ 2.1 เมืองอัจฉริยะ 7 ด้าน โครงการวังจันทร์วัลเลย์ (วังจันทร์วัลเลย์, 2565)



รูปที่ 2.1 เมืองอัจฉริยะ 7 ด้านโครงการวังจันทร์วัลเลย์

### 2.1.2 ความหมายของพลังงานและพลังงานไฟฟ้า

พลังงาน (Energy) หมายถึง ความสามารถซึ่งมีอยู่ในตัวของสิ่งนี้อาจให้แรงงานได้ เป็นผลจากการถ่ายเทหรือการเปลี่ยนแปลงสภาพของพลังงาน มีทรัพยากรหลายชนิดที่สามารถนำมาใช้ให้เป็นประโยชน์ในด้านพลังงานได้ สำหรับประเทศไทยแม้ว่าจะสามารถจัดหาได้จากแหล่งภายในประเทศ แต่ยังไม่เพียงพอ จำเป็นต้องนำเข้าเชื้อเพลิงและแหล่งพลังงานจากต่างประเทศ จากผลของวิกฤตการณ์พลังงานเชื้อเพลิงเมื่อ พ.ศ. 2516 แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ จึงได้ลดสัดส่วนการพึ่งพาเชื้อเพลิงจากต่างประเทศลง โดยเร่งรัดสำรวจและพัฒนาแหล่งพลังงาน

ภายในประเทศ รวมทั้งการใช้พลังงานอย่างประหยัดและมีประสิทธิภาพยิ่งขึ้น แหล่งพลังงานในประเทศได้แก่ พลังงานสมัยใหม่ เช่น ปิโตรเลียม (น้ำมันดิบ ก๊าซธรรมชาติ และคอนเดนเสท) ถ่านลิกไนต์ พลังน้ำ และวัสดุทางการเกษตร เช่น แสงอาทิตย์ ความร้อนใต้พิภพ และลม เป็นต้น สำหรับเชื้อเพลิงและพลังงานที่ต้องนำเข้าได้แก่ น้ำมันดิบ น้ำมันสำเร็จรูป ถ่านหิน ไฟฟ้า ฟืน และถ่าน ส่วนเชื้อเพลิงที่ประเทศไทยสามารถส่งออกได้คือ คอนเดนเสท น้ำมันเตา น้ำมันเครื่องบิน เป็นต้น แต่ละปีประเทศไทยได้สูญเสียเงินตราต่างประเทศเป็นจำนวนมาก ในการจัดหาเชื้อเพลิงและพลังงาน แม้ว่าความพยายามในการลดสัดส่วนการพึ่งพาพลังงานจากต่างประเทศจะประสบผลสำเร็จ แต่ก็ยังมีสัดส่วนที่สูงอยู่ ดังนั้นสถานการณ์พลังงานของโลกจะยังคงมีผลกระทบต่อเศรษฐกิจของไทยอยู่มาก ในขณะที่ความต้องการพลังงานรวมภายในประเทศเพิ่มขึ้นตลอดเวลา

พลังงานไฟฟ้าเกิดขึ้นได้หลายวิธี คือ

- 1) พลังงานไฟฟ้าที่เกิดขึ้นเองตามธรรมชาติ เกิดจากการเปลี่ยนพลังงานความร้อนเป็นพลังงาน
  - 2) พลังงานไฟฟ้าที่เกิดจากการเสียดสีของวัตถุต่างชนิดกัน เช่น แผ่นพลาสติกกับผ้า หวีกับผม
  - 3) พลังงานไฟฟ้าที่เกิดจากการเปลี่ยนแสงสว่างหรือพลังงานแสงอาทิตย์ให้เป็นพลังงานไฟฟ้า โดยการใช้เซลล์แสงอาทิตย์ (Solar Cell) หรือ โฟโตเซลล์ (Photo Cell)
  - 4) พลังงานไฟฟ้าที่เกิดจากการทำปฏิกิริยาเคมี เช่น แบตเตอรี่ ถ่านไฟฉาย เซลล์แห้งและเซลล์เชื้อเพลิง
  - 5) พลังงานไฟฟ้าที่เกิดจากการเหนี่ยวนำของอำนาจแม่เหล็กโดยเครื่องกำเนิดไฟฟ้า
- ได้แก่ ไฟฟ้าที่ใช้อยู่ตามอาคารบ้านเรือนในปัจจุบัน (NPS, 2023)

### 2.1.3 ระบบบริหารจัดการพลังงานไฟฟ้า

เมืองอัจฉริยะวังจันทร์วัลเลย์ สร้างเมืองที่มีโครงสร้างพื้นฐานระบบสาธารณูปโภคที่ทันสมัย เชื่อมโยงกับระบบอัจฉริยะต่างๆ เพื่อการบริหารจัดการเมืองอัจฉริยะได้อย่างมีประสิทธิภาพ โดยเฉพาะอย่างยิ่ง ระบบการจัดการพลังงานไฟฟ้า สำหรับรองรับการใช้ชีวิตของประชากรภายในพื้นที่ที่ช่วยอำนวยความสะดวกต่างๆ แสดงดังรูปที่ 2.2 การจัดการพลังงานไฟฟ้าโครงการวังจันทร์วัลเลย์ (วังจันทร์วัลเลย์, 2565)

1) Smart Meter ที่ Tie-in Building: ผู้ใช้ไฟฟ้า และเจ้าหน้าที่ที่อาคาร Intelligent Operation Center (IOC) สามารถดูข้อมูลการรับส่งไฟฟ้าได้แบบ Real-Time และนำข้อมูลพฤติกรรมการใช้ไฟฟ้ามาวิเคราะห์ เพื่อวางแผนการใช้พลังงานให้มีประสิทธิภาพในอนาคต รวมถึงแจ้งเตือนหากมีการใช้พลังงานเกินค่ามาตรฐานดัชนีชี้วัดการใช้พลังงาน


2) Energy Management System (EMS): ซอฟต์แวร์ที่ใช้บริหารจัดการระบบจำหน่ายไฟฟ้าภายในโครงการฯ รวมถึงการจับเก็บข้อมูลปริมาณและคุณภาพของไฟฟ้าที่รับ-ส่ง อีกทั้งยังสามารถคิดค่าไฟและออกบิลให้กับผู้ใช้ไฟฟ้า

3) SCADA System: ซอฟต์แวร์ที่ใช้ควบคุมและติดตามระบบ อุปกรณ์จำหน่ายไฟฟ้า ภายในโครงการฯ รวมถึงควบคุมการจัดสรรพลังงานไฟฟ้า กรณีไฟฟ้าเกินหรือดับในบางจุด

4) Substation Automation System: ตรวจสอบสถานะและควบคุมการทำงานของ อุปกรณ์ระบบจำหน่ายไฟฟ้าภายใน Substation

5) 500 kW Solar Farm: ติดตั้งโดย GPSC เพื่อเป็นแหล่งพลังงานสะอาด สำหรับใช้ เฉพาะภายในพื้นที่ Utility Center และพื้นที่ Innovation Zone เฟส 2 ในอนาคต โดย GPSC มี แผนที่จะขยายขนาดกำลังผลิตไฟฟ้ามากถึง 2 MW

6) Microgrid for IOC: ติดตั้งโดย GPSC ประกอบด้วย Solar Roof ขนาด 117 kW ระบบ Energy Storage System (ESS) ขนาด 50 kWh และซอฟต์แวร์บริหารจัดการพลังงาน โดย จะนำพลังงาน Solar Roof ที่เหลือจากการผลิตมาเก็บไว้ใน ESS เพื่อนำกลับมาใช้เป็นพลังงานเสริม ในช่วง Peak Load



รูปที่ 2.2 การจัดการพลังงานไฟฟ้าโครงการวังจันทร์วัลเลย์

#### 2.1.4 อัตราค่าไฟฟ้าการไฟฟ้าส่วนภูมิภาค

การคำนวณคิดค่าไฟฟ้านั้นจะมีองค์ประกอบของค่าไฟฟ้าประกอบด้วย 3 ส่วนหลัก ดังนี้

1) ค่าพลังงานไฟฟ้า (ค่าไฟฟ้าฐาน): การกำหนดค่าไฟฟ้าล่วงหน้าและเป็นอัตราคงที่ (เป็นแบบ Price Fixing) สำหรับการใช้ประกาศเรียกเก็บค่าไฟฟ้าจากผู้ใช้ไฟฟ้าในระยะเวลา 3 - 5 ปี ข้างหน้า เพื่อให้สะท้อนต้นทุนในการก่อสร้างโรงไฟฟ้า ระบบสายส่ง ระบบจำหน่าย ค่าใช้จ่ายในการดำเนินงานที่มีประสิทธิภาพ ผลตอบแทนการดำเนินงานที่เหมาะสมของการไฟฟ้าทั้ง 3 แห่ง และ ต้นทุนในการบริการของการไฟฟ้าทั้ง 3 แห่ง รวมทั้งค่าเชื้อเพลิงของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ค่าซื้อไฟฟ้าจากผู้ผลิตไฟฟ้าเอกชนในประเทศและต่างประเทศ และค่าใช้จ่ายตามนโยบายของรัฐ ภายใต้สมมุติฐานและข้อมูลที่เปิดเผยและเป็นสาธารณะ เช่น ข้อมูลสมมุติฐานเกี่ยวกับความต้องการใช้ไฟฟ้า ราคาเชื้อเพลิง อัตราแลกเปลี่ยน และอัตราเงินเฟ้อระดับหนึ่ง เพื่อจัดทำเป็นอัตราค่าไฟฟ้าต่อหน่วยที่สะท้อนต้นทุนการผลิต การส่ง และการจำหน่ายไฟฟ้า ซึ่งแตกต่างกันตามลักษณะของการใช้

ไฟฟ้าของผู้ใช้ไฟฟ้าเป็น 8 ประเภทหลัก เป็นหลักการและแนวทางที่เป็นมาตรฐานเดียวกันกับประเทศต่างๆ ทั่วโลก ซึ่งลักษณะการใช้ไฟฟ้าในโครงการวังจันทร์วัลเลย์ คือ ประเภทที่ 3 กิจการขนาดกลาง

ประเภทที่ 3 กิจการขนาดกลาง: สำหรับการใช้ไฟฟ้าเพื่อประกอบธุรกิจ อุตสาหกรรม ส่วนราชการ สำนักงาน หรือหน่วยงานอื่นใดของรัฐ องค์กรปกครองส่วนท้องถิ่น รัฐวิสาหกิจ สถานทูต สถานที่ทำการของหน่วยงานราชการต่างประเทศ สถานที่ทำการขององค์การระหว่างประเทศ หรืออื่นๆ ตลอดจนบริเวณที่เกี่ยวข้อง ซึ่งมีความต้องการพลังไฟฟ้าเฉลี่ยใน 15 นาทีสูงสุดในช่วงเวลาใดเวลาหนึ่ง ตั้งแต่ 30 กิโลวัตต์ แต่ไม่ถึง 1,000 กิโลวัตต์และมีปริมาณการใช้พลังงานไฟฟ้าเฉลี่ย 3 เดือนก่อนหน้าไม่เกิน 250,000 หน่วยต่อเดือน โดยต่อผ่านเครื่องวัดไฟฟ้าเครื่องเดียว

1. ค่าความต้องการพลังไฟฟ้า (demand charge) : คิดจากความต้องการพลังไฟฟ้า (kW) เฉลี่ยใน 15 นาทีที่สูงสุดของช่วงเวลาในแต่ละเดือน ตามประเภทของอัตราค่าไฟฟ้าที่ใช้

2. ค่าพลังงานไฟฟ้า (energy charge) : คิดตามปริมาณการใช้ไฟฟ้า (ตามหน่วย หรือ kWh) ที่ใช้ในแต่ละเดือน ตามประเภทของอัตราค่าไฟฟ้าที่ใช้

- อัตราปกติ (Demand) : เป็นอัตราเดิมสำหรับผู้ใช้อีกก่อนเดือนตุลาคม 2543
- อัตราตามช่วงเวลาของการใช้ (Time of Use Rater) : เป็นอัตราบังคับแบ่ง 3 ช่วง

ตารางที่ 2.1 ช่วงเวลาของการใช้ Time of Use Rater

ช่วงเวลา	เวลา	รายละเอียดวัน
Peak (P)	09.00 – 22.00 น.	วันจันทร์ – วันศุกร์และวันพืชมงคล
Off Peak (OP)	22.00 – 09.00 น.	วันจันทร์ – วันศุกร์และวันพืชมงคล
Holiday (H)	00.00 – 24.00 น.	วันเสาร์ – วันอาทิตย์ วันแรงงานแห่งชาติ วันพืชมงคลที่ตรงกับวันเสาร์-วันอาทิตย์ และวันหยุดราชการตามปกติ (ไม่รวมวันหยุดชดเชย)

2) ค่าไฟฟ้าผันแปร (Ft) : ถูกกำหนดขึ้นเพื่อให้สะท้อนการเปลี่ยนแปลงจากต้นทุนค่าเชื้อเพลิง ค่าซื้อไฟฟ้าจากผู้ผลิตไฟฟ้าเอกชนในประเทศและต่างประเทศ และค่าใช้จ่ายตามนโยบายของรัฐ ซึ่งเป็นต้นทุนผันแปรของการผลิตและจัดหาไฟฟ้าที่อยู่นอกเหนือการควบคุมของการไฟฟ้าทั้ง 3 แห่ง ที่เปลี่ยนแปลงไปจากต้นทุนคงที่ซึ่งคำนวณไว้ในค่าไฟฟ้าฐาน ทั้งนี้ ค่า Ft มีการปรับปรุงทุก ๆ 4 เดือน โดยค่า Ft จะมีค่าเป็นบวกหรือลบก็ได้ขึ้นกับต้นทุนค่าใช้จ่ายที่เกิดขึ้นในช่วงเวลาต่าง ๆ กล่าวคือ ค่า Ft จะมีค่าเป็นบวก หากมีค่าใช้จ่ายสูงกว่าที่คิดไว้ในค่าไฟฟ้าฐาน และมีค่าเป็นลบ หากมีค่าใช้จ่ายต่ำกว่าที่คิดไว้ในค่าไฟฟ้าฐาน

3) ค่าบริการรายเดือน : ค่าใช้จ่ายคงที่ในการให้บริการจำหน่ายไฟฟ้า เช่น การจดหน่วยเอกสารนี้เป็นเอกสารที่ส่งมอบไว้สำหรับการใช้งานเพื่อการชำระหนี้ ไม่โอนสภาพให้ไปประโยชน์ด้านการค้า การพิมพ์บิล จัดส่งบิลและการรับชำระเงิน โดยตั้งแต่เดือนมกราคม 2565 เป็นต้นไป ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4) ภาษีมูลค่าเพิ่ม (VAT) : ในอัตราร้อยละ 7 ของค่าไฟฟ้าฐาน และค่า Ft ซึ่งการไฟฟ้าจะเรียกเก็บจากผู้ใช้ไฟฟ้านำส่งให้กรมสรรพากร เนื่องจากไฟฟ้าเป็นสินค้าและบริการประเภทหนึ่ง แสดงดังรูปที่ 2.3 ขั้นตอนอัตราค่าไฟฟ้าการไฟฟ้าส่วนภูมิภาค



รูปที่ 2.3 ขั้นตอนอัตราค่าไฟฟ้าการไฟฟ้าส่วนภูมิภาค

#### 2.1.5 ทฤษฎีเกี่ยวกับอินเทอร์เน็ตของทุกสรรพสิ่ง (Internet of things)

ปัจจุบันมีเทคโนโลยีมากมายเข้ามาเพื่อช่วยอำนวยความสะดวกสบายแก่มนุษย์ในด้านต่างๆ ไม่ว่าจะเป็นการคมนาคม การแพทย์ การศึกษา รวมถึงการใช้ IOT (Internet of things) “อินเทอร์เน็ตของทุกสรรพสิ่ง” ถูกนำมาใช้ในการเชื่อมต่อผู้คนและอุปกรณ์ทุกสิ่งให้เชื่อมโยงกัน เพื่อช่วยควบคุม แลกเปลี่ยน และส่งข้อมูลแบบ Real Time ได้อย่างอัจฉริยะ อีกทั้งช่วยอำนวยความสะดวกสบายให้กับการใช้ชีวิต ซึ่งในอนาคตอุปกรณ์เหล่านี้จะสามารถพูดคุยและเรียนรู้พฤติกรรมของมนุษย์ได้ ซึ่งโครงการวังจันทร์วัลเลย์ Smart City มีอินเทอร์เน็ตความเร็วสูง เพื่อการเชื่อมต่อในลักษณะการเป็นโครงข่าย LoRa ซึ่งเป็นเทคโนโลยีที่รับส่งข้อมูลระยะไกลเหมาะสำหรับการใช้งานสำหรับอุปกรณ์ IoT และ Free WIFI ที่สามารถเชื่อมต่อเครือข่ายในที่อยู่อาศัยและอาคารต่าง ๆ ในโครงการทั้งหมด นอกจากนี้ IoT ยังสามารถช่วยลดต้นทุน และเพิ่มประสิทธิภาพในการทำงานให้แม่นยำและรวดเร็วขึ้นอย่างไร้ขีดจำกัดในเรื่องของเวลาและสถานที่ เพราะทุกอย่างขับเคลื่อนด้วยอินเทอร์เน็ตไร้สาย และช่วยยกระดับธุรกิจให้ดู Smart ในสายตาของนักลงทุน (วังจันทร์วัลเลย์, 2565)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2 การทำเหมืองข้อมูล (Data Mining)

### 2.2.1 เหมืองข้อมูล

เหมืองข้อมูล (Data Mining) คือการนำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) วิธีการทางสถิติ (Statistical Methods) วิธีทางปัญญาประดิษฐ์ (Artificial Intelligence) หรือวิธีอื่น ๆ มาทำการวิเคราะห์และสกัดความรู้จากข้อมูลที่จัดเก็บไว้ในฐานข้อมูลหรือจัดเก็บไว้ในรูปอื่น ๆ โดยจุดประสงค์ของการทำเหมืองข้อมูล คือ การวิเคราะห์แนวโน้ม ความสัมพันธ์กฎ หรือรูปแบบของข้อมูล ซึ่งเป็นความรู้ที่ถูกซ่อนอยู่ภายใต้ข้อมูลขนาดใหญ่ และนำเสนอสารสนเทศที่ได้มาช่วยใช้ในการวางแผนการตัดสินใจการบริหารหรือแก้ปัญหาในด้านต่าง ๆ ซึ่งถือได้ว่าเป็นเครื่องมือที่ช่วยเพิ่มคุณค่าให้กับข้อมูลที่มีอยู่ เหมืองข้อมูลจะสามารถแก้ปัญหาได้ บางปัญหาตามเทคนิควิธีการที่เลือกใช้ได้นั้น โดยประโยชน์หลักของเหมืองข้อมูล คือ การค้นหาความรู้ที่ซ่อนอยู่ในฐานข้อมูล เพื่อให้ได้ซึ่งความรู้มาช่วยประกอบในการตัดสินใจ (ธนะวัฒน์, 2564)

การทำเหมืองข้อมูล เป็นกระบวนการวิเคราะห์และกลั่นกรองข้อมูลจากฐานข้อมูลขนาดใหญ่ เพื่อค้นหาความสัมพันธ์ของข้อมูล และนำประโยชน์ที่ได้รับมาใช้ในการสนับสนุนการตัดสินใจในด้านต่าง ๆ ซึ่งสามารถแบ่งออกได้เป็น 2 ประเภท ดังนี้

- 1) การคาดการณ์หรือพยากรณ์ (Predictive Data Mining) เป็นการประมาณค่าที่เหมาะสมของข้อมูลล่วงหน้าที่จะเกิดขึ้นโดยใช้ข้อมูลที่ผ่านมาในอดีต
- 2) การบรรยายหรืออธิบายลักษณะ (Descriptive Data Mining) เป็นการแบ่งกลุ่มข้อมูลที่มีอยู่เพื่ออธิบายข้อมูลต่าง ๆ ที่เกิดขึ้น

### 2.2.2 ประเภทของการทำเหมืองข้อมูล

1) การจำแนกประเภทข้อมูล (Classification) เป็นการทำเหมืองข้อมูลที่มีจุดประสงค์ที่สร้างตัวแบบจำแนกประเภทข้อมูลจากข้อมูลเรียนรู้ที่มีการจำแนกประเภทแล้ว และใช้ตัวแบบที่สร้างได้จำแนก ข้อมูลใหม่ ที่ไม่ทราบประเภท

2) การจับกลุ่มข้อมูล (Clustering) เป็นการแบ่งข้อมูลออกเป็นกลุ่มโดยข้อมูลที่อยู่ในกลุ่มเดียวกันจะมีลักษณะที่คล้ายคลึงกันและข้อมูลที่อยู่ต่างกลุ่มจะมีลักษณะที่แตกต่างกันซึ่งการจับกลุ่มข้อมูลดังกล่าวต้องอาศัยมาตรวัดความเหมือนหรือแตกต่างระหว่างข้อมูลใด ๆ เพื่อจัดข้อมูลที่มีลักษณะคล้ายคลึงกันเข้าอยู่ในกลุ่มเดียวกัน

3) การสร้างกฎความสัมพันธ์ (Association Rule) เป็นการทำเหมืองข้อมูลที่ต้องการหา กฎที่บอกความสัมพันธ์ระหว่างเหตุการณ์ที่มักเกิดขึ้นพร้อม ๆ กันอยู่เสมอ ข้อมูลที่จะทำการวิเคราะห์ อาจเป็นรายการสินค้าที่ ลูกค้าสั่งซื้อในแต่ละครั้งกฎความสัมพันธ์ที่สร้างได้จะระบุถึงความสัมพันธ์ว่า เมื่อพบเหตุการณ์หนึ่งหรือหลาย เหตุการณ์เกิดขึ้นจะมีโอกาสสูงที่เหตุการณ์อีกอย่างหนึ่งหรืออีกหลายเหตุการณ์จะเกิดขึ้นด้วย

4) การคาดคะเน (Estimation) มีลักษณะคล้ายกับการจำแนกประเภทข้อมูล คือ มีการสร้างตัวแบบเพื่อคาดคะเนค่าของตัวแปรเป้าประสงค์จากค่าตัวแปรอื่น ๆ ข้อแตกต่างคือตัวแปรที่จะ

ถูกคาดคะเนจะมีชนิดเป็นตัวเลขแทนที่จะเป็นประเภทข้อมูล เช่น การประมาณค่าปริมาณการขายสินค้าช่วงวันหยุด เป็นต้น

5) การค้นหาข้อมูลที่มีความผิดปกติ (Anomaly Detection) เป็นการค้นหาข้อมูลที่มีลักษณะผิดปกติหรือ ความแตกต่างจากข้อมูลส่วนใหญ่ (Outlier Data) ข้อมูลผิดปกติเหล่านี้จะมีจำนวนน้อยปะปนอยู่ในข้อมูลส่วนใหญ่ ซึ่งอาจส่งผลให้การวิเคราะห์ข้อมูลมีความถูกต้องลดน้อยลง

### 2.2.3 ขั้นตอนการทำเหมืองข้อมูล

การทำเหมืองข้อมูลนั้นมีกระบวนการมาตรฐานที่เรียกว่าวิธีการ CRISP-DM (Cross Industry Standard Process for Data Mining) ประกอบด้วย 6 ขั้นตอน แสดงดังรูปที่ 2.4 ขั้นตอนการทำเหมืองข้อมูล (ธนิตเชษฐ์, 2562)

1) Business Understanding เป็นการทำความเข้าใจ ระบุปัญหาหรือโอกาสเชิงธุรกิจ จากนั้นทำการแปลงโจทย์ที่ได้ให้อยู่ในรูปแบบที่เหมาะสมต่อการนำมาวิเคราะห์ข้อมูลเหมืองข้อมูล

1.1 ตั้งเป้าหมายว่าการทำเหมืองข้อมูลครั้งนี้ ต้องการที่จะแก้ไขปัญหาใด เช่น ทำนายปริมาณน้ำฝนที่ตกใน 7 วันถัดไป เป็นต้น

1.2 ตั้งเกณฑ์การวัดความสำเร็จในการทำเหมืองข้อมูล ซึ่งอาจเป็นได้ทั้งความสำเร็จในด้านรูปธรรม และความสำเร็จในด้านนามธรรม

1.3 ประเมินสถานการณ์ในด้านต่าง ๆ เช่น ความรู้พื้นฐานในเรื่องที่จะทำเหมืองข้อมูลมีเพียงพอหรือไม่ และผลประโยชน์จากการทำเหมืองข้อมูลจะคุ้มค่ากับต้นทุนที่เสียไปหรือไม่ เป็นต้น

1.4 ตั้งเป้าหมายในเชิงการทำเหมืองข้อมูล ซึ่งต่างไปจากเป้าหมายหลักใน การแก้ไขปัญหา

1.5 วางแผนการทำเหมืองข้อมูลว่าจะเก็บข้อมูลอย่างไร และใช้อัลกอริทึมใด ในการทำเหมืองข้อมูล

2) Data Understanding เป็นการรวบรวมข้อมูลที่เกี่ยวข้อง เพื่อใช้ในการวิเคราะห์ด้วยเทคนิคเหมืองข้อมูล ในการรวบรวมข้อมูลนั้นควรพิจารณาด้วยว่าเป็นข้อมูลที่ได้มาจากแหล่งข้อมูลที่ต้องการนำเชื่อถือข้อมูลที่ได้มีปริมาณมากพอหรือยัง และเป็นข้อมูลที่เหมาะสม มีรายละเอียดเพียงพอต่อการนำไปใช้ในการวิเคราะห์ ประกอบด้วยกระบวนการย่อย ดังนี้

2.1 เก็บรวบรวมข้อมูลที่เกี่ยวข้อง

2.2 ตรวจสอบข้อมูลขั้นต้น โดยตรวจสอบทั้งความสมบูรณ์และความถูกต้องของข้อมูล

3) Data Preparation ขั้นตอนการเตรียมข้อมูลเป็นขั้นตอนที่ใช้เวลานานที่สุด เนื่องจากแบบจำลองที่ได้จากการทำเหมืองข้อมูลจะให้ผลลัพธ์ที่ถูกต้องหรือไม่ ขึ้นอยู่กับคุณภาพของข้อมูลที่ใช้กล่าวคือ ถ้าข้อมูลที่ใช้นั้นไม่ถูกต้องจะมีผิดพลาดย่อมสะท้อนถึงผลลัพธ์ที่ได้ ซึ่งอาจทำให้ตีความผลลัพธ์ได้คลาดเคลื่อนเช่นกัน โดยการเตรียมข้อมูลนั้น สามารถแบ่งออกได้เป็น 3 ขั้นตอนย่อย มีรายละเอียดดังนี้

3.1 การคัดเลือกข้อมูล (Data Selection) ควรกำหนดเป้าหมายก่อนว่าจะทำการวิเคราะห์อะไรแล้วทำการเลือกใช้เฉพาะข้อมูลที่เกี่ยวข้องกับสิ่งที่เราจะทำการวิเคราะห์

3.2 การกลั่นกรองข้อมูล (Data Cleaning) ในบางกรณีอาจพบข้อมูลที่ไม่ถูกต้อง อันเนื่องมาจากปัญหาในระหว่างการจัดเก็บข้อมูล เช่น การกรอกข้อมูลไม่ครบข้าง กรอกข้อมูลซ้ำซ้อน บางในขั้นตอนนี้เราจะทำการกรองข้อมูลที่ไม่ถูกต้องหรือซ้ำซ้อนออก หรืออาจทำการซ่อมข้อมูลที่ขาดหายไปด้วยวิธีการบางอย่าง เช่น การพิจารณาจากค่าเฉลี่ยของข้อมูลส่วนใหญ่ เป็นต้น


3.3 การแปลงรูปแบบของข้อมูล (Data Transformation) เป็นขั้นตอนการเตรียมข้อมูลให้อยู่ในรูปแบบที่พร้อมนำไปใช้ในการวิเคราะห์ตามอัลกอริทึมของการทำเหมืองข้อมูลที่เลือกใช้

3.4 Modeling เป็นขั้นตอนการวิเคราะห์ข้อมูลด้วยเทคนิคเหมืองข้อมูล ได้แก่ แบบจำลองเพื่อพยากรณ์ (Prediction Model) ในบางครั้งพบว่ามีกรนำเทคนิคเหมืองข้อมูลหลายเทคนิคมาใช้ในการวิเคราะห์ข้อมูล เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด ดังนั้นเมื่อทำขั้นตอนนี้แล้วอาจมีการย้อนกลับไปขั้นตอน Data Preparation เพื่อแปลงข้อมูลบางส่วนให้เหมาะสมกับแต่ละเทคนิคด้วย นอกจากนี้ยังมีการประเมินแบบจำลองวิเคราะห์ข้อมูลที่ได้ในรูปแบบความถูกต้องของแบบจำลอง เพื่อเป็นตัวบ่งชี้ความน่าเชื่อถือของแบบจำลองที่ได้ สำหรับรายละเอียดเทคนิคเหมืองข้อมูลแต่ละเทคนิค และวิธีการประเมินผลแบบจำลอง

3.5 Evaluation เป็นการประเมินประสิทธิภาพของผลลัพธ์ที่ได้จากแบบจำลองวิเคราะห์ข้อมูลว่าตรงกับวัตถุประสงค์หรือสามารถตอบโจทย์ทางธุรกิจที่ได้ตั้งไว้ในขั้นตอนแรกหรือไม่ มีความน่าเชื่อถือมากน้อยเพียงใด ซึ่งอาจจะย้อนกลับไปยังขั้นตอนก่อนหน้า เพื่อเปลี่ยนแปลงแก้ไขให้ได้ผลลัพธ์ตามที่ต้องการในกรณีที่มีการสร้างแบบจำลองวิเคราะห์ข้อมูลหลายแบบจำลอง ในขั้นตอนนี้ จะทำการประเมินแต่ละแบบจำลองด้วยว่ามีส่วนดีส่วนด้อยอย่างไร และควรเลือกใช้แบบจำลองใดในการทำงานส่วนนี้ต้องอาศัยทักษะการวิเคราะห์ข้อมูลและธุรกิจ เพื่อช่วยให้การวิเคราะห์ทำได้สะดวกและรวดเร็วขึ้น จึงมีการใช้เครื่องมือทางด้านกราฟิก เช่น การแสดงผลการวิเคราะห์ด้วยกราฟ รายงานรูปแบบต่าง ๆ หรือ Dashboard เป็นต้น

3.6 Deployment ผลลัพธ์หรือองค์ความรู้ที่ได้จากการวิเคราะห์ข้อมูลด้วย เทคนิคเหมืองข้อมูลจะไม่มีประโยชน์ ถ้าไม่นำไปใช้งานจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.4 ขั้นตอนการทำเหมืองข้อมูล

## 2.3 การเรียนรู้ของเครื่อง (Machine Learning)

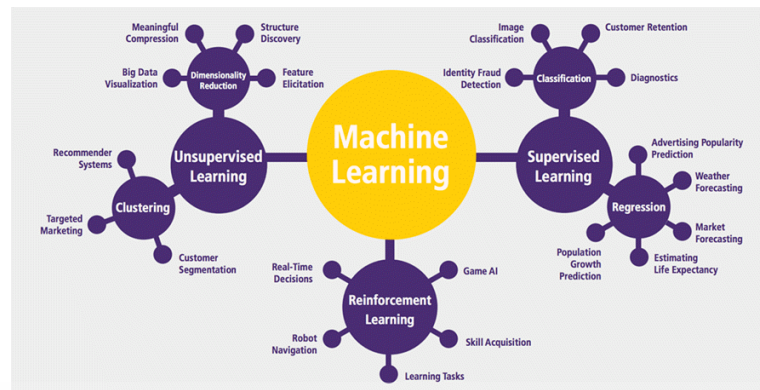
### 2.3.1 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง (Machine Learning) คือระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเองโดยปราศจากการป้อนคำสั่งของโปรแกรมเมอร์ ความก้าวหน้าในครั้งนี้นำมาพร้อมกับความคิดที่ว่าเครื่องคอมพิวเตอร์สามารถเรียนรู้เพียงแค่ว่าจากข้อมูลอย่างเดียวเพื่อที่จะผลิตผลลัพธ์ที่แม่นยำออกมาได้ เพียงแค่มีข้อมูลและเครื่องมือทางสถิติเพื่อทำนายผลลัพธ์ออกมา ผลลัพธ์ในที่นี้จะถูกใช้เพื่อทำประโยชน์กับภายในองค์กรเชิงลึกต่อไป การทำเหมืองข้อมูล (Data mining) และ โมเดลการทำนายของ Bayes ( Bayesian predictive models) เครื่องคอมพิวเตอร์จะรับข้อมูลเข้ามาและใช้อัลกอริทึมเพื่อหาคำตอบขึ้น และยังถูกใช้กับงานหลากหลายด้าน เช่น การตรวจจับการฉ้อโกง ( Fraud detection ) , การพยากรณ์เพื่อปรับปรุงแก้ไข ( Predictive Maintenance) , การเพิ่มประสิทธิภาพในการถือหุ้น ( Portfolio optimization) , การทำงานอัตโนมัติ และอื่น ๆ อีกมากมาย

### 2.3.2 อัลกอริทึมของ Machine Learning

Machine Learning สามารถถูกแบ่งออกเป็นการเรียนรู้ได้ 2 แบบ ได้แก่ การเรียนรู้แบบผู้สอน (Supervised Learning) และ การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งมีอัลกอริทึมแบบอื่นอยู่อีกมากมาย แสดงดังรูปที่ 2.5 อัลกอริทึมของ Machine Learning

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.5 อัลกอริทึมของ Machine Learning

1) การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นการเรียนรู้ข้อมูลต่าง ๆ โดยมีผู้สอน อาศัยข้อมูลในการฝึกฝน เพื่อช่วยให้ตัวเทคโนโลยีสามารถเรียนรู้ผล และคาดคะเนผลลัพธ์ต่าง ๆ ได้อย่างแม่นยำมากยิ่งขึ้น โดยการเรียนรู้ในรูปแบบนี้ มักถูกนำมาใช้งานในเชิงธุรกิจทั้งการคำนวณราคาบ้าน การคาดคะเนค่าเงิน หรือแม้แต่การวิเคราะห์ผลการแข่งขันต่าง ๆ แบ่งออกเป็น 2 ประเภท คือ การแบ่งแยกประเภท (Classification) และการถดถอย (Regression)

2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นการเรียนรู้ที่ไม่มีผู้สอน โดยที่เครื่องจักรนั้น ๆ จะทำการเรียนรู้สิ่งต่าง ๆ ด้วยตัวเอง โดยไม่ต้องตั้งค่าเป้าหมายของแต่ละข้อมูล ระบบสามารถนำไปวิเคราะห์และสร้างแบบแผนจากข้อมูลที่ได้รับเข้าไป มักนำไปใช้ในการแนะนำผลิตภัณฑ์ต่าง ๆ หรือคัดเลือกรหัสหรือผลิตภัณฑ์ (สมาคมโปรแกรมเมอร์ไทย, 2561)

## 2.4 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์

วิธีการพยากรณ์ในปัจจุบันมีหลากหลายวิธี โดยจะนำเอาหลักการ เช่น คณิตศาสตร์ สถิติ และปัญญาประดิษฐ์ เป็นต้น มาประยุกต์ใช้ในการพยากรณ์ โดยแต่ละวิธีมีความรู้เกี่ยวเนื่องในแบบจำลอง ข้อดีข้อเสีย และความถูกต้องแม่นยำต่างกัน โดยจะยกตัวอย่างต้นแบบที่เกี่ยวข้องดังนี้

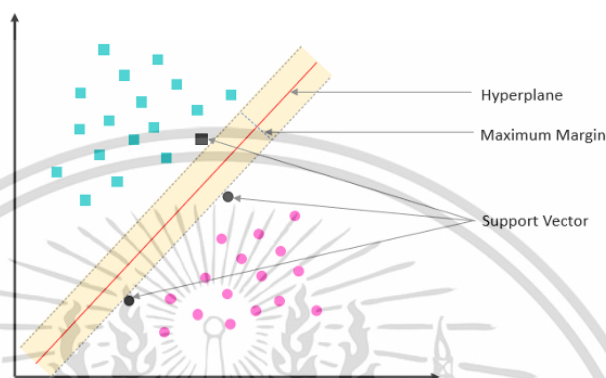
### 2.4.1 แบบจำลอง Support Vector Machine

แบบจำลอง Support Vector Machine หรือ SVM จัดเป็นการเรียนรู้ของเครื่องประเภทแบบการเรียนรู้โดยอาศัยตัวอย่างประเภทหนึ่ง ซึ่งมีความสามารถในการจัดหมวดหมู่ และการทำนาย (Regression) โดย SVM เป็นตัวจำแนกเชิงเส้น (Linear Classifier) แบบไบนารี (Binary) ข้อได้เปรียบของ SVM คือมีประสิทธิภาพในการจำแนกข้อมูลที่มีมิติจำนวนมากได้ นอกจากนี้การใช้ฟังก์ชันเคอร์เนล (Kernel Function) ยังช่วยให้สามารถจำแนกข้อมูลที่มีความคลุมเครือได้อย่างมีประสิทธิภาพ หลักการของ SVM คือการหา Hyperplane ที่สามารถแบ่งจุดข้อมูลออกเป็น 2 Class ด้วยระยะห่างที่มากที่สุด (Maximum Margin) ในขณะที่ยังสามารถแบ่งจุดข้อมูลได้อย่างถูกต้องมากที่สุดเท่าที่จะเป็นไปได้ จากหลักการเดียวกันนี้ยังถูกนำไปใช้สำหรับ Regression อีกด้วย

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการเขียนเพื่อการศึกษาเท่านั้น เมื่อผู้ยืมได้เห็นว่าไม่เหมาะสมหรือมีความผิดพลาดประการใด ขออภัยเป็นอย่างสูง และขอสงวนสิทธิ์ในการนำไปใช้

### ข้อดีของแบบจำลอง Support Vector Machine

แบบจำลอง Support Vector Machine สามารถจัดการกับ Non-Linear ได้ โดยใช้เทคนิคของ Kernel และการ Maximized Margin ทำให้เกิดความทนทานที่ดี (Robustness) สามารถควบคุม Overfitting โดยใช้เทคนิค Soft Margins แสดงดังรูปที่ 2.6 การจำแนกประเภทของข้อมูลของแบบจำลอง Support Vector Machine (นรุตม์ , 2566)



รูปที่ 2.6 การจำแนกประเภทของข้อมูลของแบบจำลอง Support Vector Machine

### 2.4.2 แบบจำลอง Random Forest

แบบจำลอง Random Forest เป็นเทคนิคที่พัฒนาขึ้นโดยใช้แนวความคิดของการใช้แบบจำลองหลายแบบพร้อมกัน ซึ่งจะทำให้มีประสิทธิภาพดีกว่า การใช้แค่แบบจำลองเดียว แนวทางนี้เรียกว่า แบบจำลอง Ensemble ซึ่งแนวคิดของวิธีการนี้จะเป็นการใช้แบบจำลองหลาย ๆ ตัวมาช่วยกันหาคำตอบให้แต่ไม่ใช่การแข่งขันกันเพื่อหาว่าแบบจำลองไหนดีกว่ากัน

#### แนวความคิดของการสร้างแบบจำลอง Random Forest

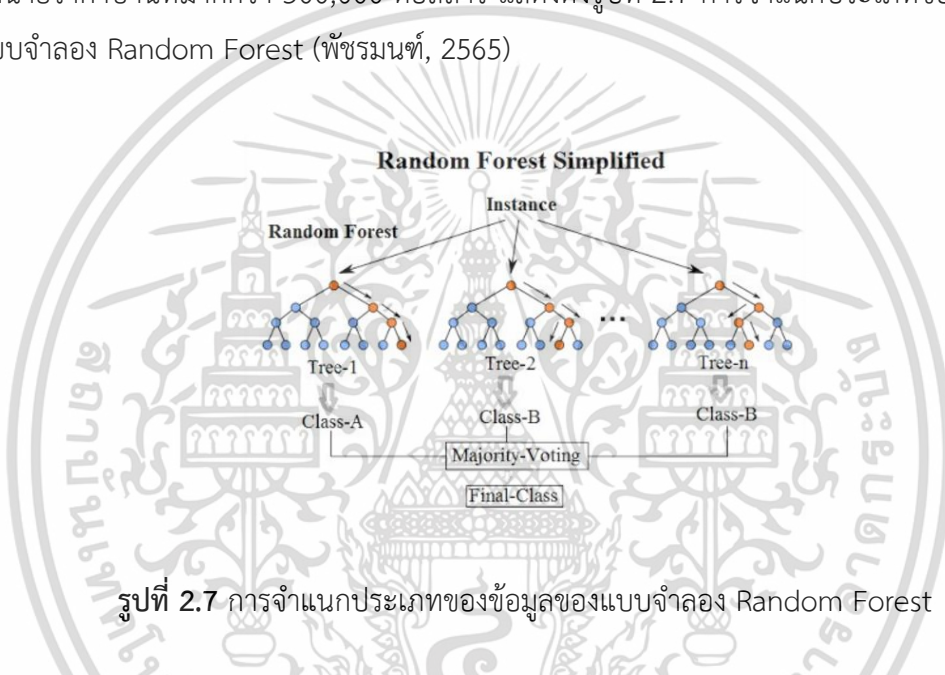
สำหรับแนวคิดของแบบจำลอง Random Forest จะสร้างแบบจำลอง Decision Tree หลายๆ แบบจำลองขึ้นมาจากข้อมูลย่อย ๆ หลังจากนั้นจึงนำผลการพยากรณ์ของแต่ละแบบจำลองมารวมกันด้วยวิธีการโหวต เพื่อเลือกคำตอบที่ดีที่สุดเป็นคำตอบสุดท้าย แต่การสร้างแบบจำลอง Decision Tree ด้วยชุดข้อมูลเดียวกันย่อมจะได้แบบจำลองที่มีลักษณะเดิม จึงต้องมีชุดข้อมูลสุ่ม (Sampling) ซึ่งจะทำให้การกำหนดว่าแบบจำลอง Decision Tree เป็นจำนวนเท่าไร

#### ข้อดีของแบบจำลอง Random Forest

แบบจำลอง Random Forest มีประสิทธิภาพค่อนข้างสูง เนื่องจากใช้แนวคิดของ Ensemble เข้าใจได้ง่าย (เมื่อเทียบกับ SVM หรือ Deep Learning) ปรับพารามิเตอร์ได้ไม่ยาก ส่วนใหญ่จะเป็นการปรับจำนวนของ Decision Tree และมีความสามารถในการปรับใช้แบบจำลองจำนวนมากที่มีความแตกต่างกัน ซึ่งทำให้แบบจำลองสามารถรับมือได้กับความซับซ้อนของข้อมูลได้ดีสามารถจัดการกับความหลากหลายของข้อมูลได้และยังป้องกันปัญหา Overfitting ที่อาจเกิดขึ้น

### ข้อจำกัดของแบบจำลอง Random Forest

การสร้างและฝึกฝน Random Forest มักจะใช้เวลาและทรัพยากรคอมพิวเตอร์มากกว่าเมื่อเปรียบเทียบกับแบบจำลองที่มีความซับซ้อนต่ำ เนื่องจากต้องสร้างและวิเคราะห์หลายต้นไม้การตัดสินใจ แบบจำลอง Random Forest ไม่สามารถใช้ในการทำนายข้อมูลที่มีความต่อเนื่อง หรือข้อมูลที่เปลี่ยนแปลงอย่างรวดเร็ว การทำนายข้อมูลของ Random Forest ขึ้นอยู่กับข้อมูลที่ได้รับมาในการฝึกฝน และไม่สามารถทำนายอนุกรมเวลาหรือข้อมูลอื่นๆ ที่มีการเปลี่ยนแปลงที่รวดเร็ว นอกจากนี้ยังไม่สามารถทำนายค่าที่อยู่นอกขอบเขตข้อมูลที่ใช้ในการฝึกฝน นั่นคือ ถ้ามีข้อมูลฝึกฝนเกี่ยวกับราคาบ้านที่อยู่ระหว่าง 100,000 และ 500,000 ดอลลาร์ Random Forest จะไม่สามารถทำนายราคาบ้านที่มากกว่า 500,000 ดอลลาร์ แสดงดังรูปที่ 2.7 การจำแนกประเภทของข้อมูลของแบบจำลอง Random Forest (พีชรมนต์, 2565)



รูปที่ 2.7 การจำแนกประเภทของข้อมูลของแบบจำลอง Random Forest

### 2.4.3 แบบจำลอง Extreme Gradient Boosting

แบบจำลอง Extreme Gradient Boosting หรือ XGBoost เนื่องมาจากอัลกอริทึมนี้ถูกพัฒนามาจาก Gradient Boosting ซึ่งออกแบบให้มีประสิทธิภาพสูง ยืดหยุ่น และสามารถนำไปใช้กับระบบต่างๆ โดยการทำงานของมันจะใช้เทคนิคการนำการเรียนรู้ต้นไม้ตัดสินใจจำนวนหลายๆ โมเดลมาทำนายต่อกัน ซึ่งแต่ละต้นไม้ตัดสินใจจะได้เรียนรู้จากค่าความผิดพลาดของต้นไม้ตัดสินใจก่อนหน้า โดยนำค่าความผิดพลาดนั้นมาปรับปรุงในการสร้างโมเดลถัดไป

#### แนวคิดของการสร้างแบบจำลอง Extreme Gradient Boosting

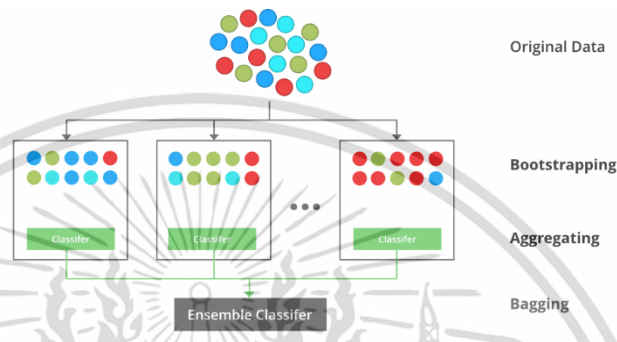
แบบจำลอง Extreme Gradient Boosting มีแนวคิดที่พัฒนาจากเทคนิค Gradient boosting เพื่อเพิ่มความแม่นยำและความยืดหยุ่นให้กับแบบจำลอง โดยใช้หลักการของ Ensemble Learning Method ในการ Boosting เพื่อสร้างตัวเรียนรู้หลายๆตัว (Multiple Learner) หรือเรียกได้

ว่าเป็นการรวม Weak Learners หลายๆตัวเข้าด้วยกัน ซึ่ง Learner ที่สร้างขึ้นใหม่แต่ละรุ่นนั้นจะทำเอกสารนี้เป็นเอกสารทบทวนวิชาสำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอญาตเหนาไปใช้ประโยชน์ด้านการค้า การแก้ไขข้อบกพร่องในการทำงานของ Learner รุ่นก่อนหน้าเพื่อลด Error

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งยังมีเหตุตบแต่งเนื้อหาและตียงอย่างองตงเงาของเอกสารทุกครั้งที่มีการนำไปใช้

## ข้อดีของแบบจำลอง Extreme Gradient Boosting

แบบจำลอง Extreme Gradient Boosting ซึ่งเป็นการเรียนรู้แบบ multiple-learners หรือก็คือการเรียนรู้แบบมีผู้เรียนหลายคน ช่วยๆกันเรียน สำหรับ Ensemble learning สามารถแบ่งวิธีการเป็น 3 ตัวหลักๆ ได้ดังนี้ Bagging, Boosting, Stacking แสดงดังรูปที่ 2.8 การจำแนกประเภทของข้อมูลของแบบจำลอง Extreme Gradient Boosting (สุเชษฐ, 2565)



รูปที่ 2.8 การจำแนกประเภทของข้อมูลของแบบจำลอง Extreme Gradient Boosting

### 2.4.4 แบบจำลอง Linear Regression

แบบจำลอง Linear Regression หรือการวิเคราะห์การถดถอยเชิงเส้นวิธีการวิเคราะห์ข้อมูลเพื่อหา ความสัมพันธ์ระหว่างตัวแปรต้น (หนึ่งตัวแปรหรือมากกว่า) และตัวแปรตาม โดย Simple Linear Regression คือการวิเคราะห์ข้อมูลถดถอยเชิงเส้นอย่างง่ายเป็นการวิเคราะห์ข้อมูลเมื่อมีตัวแปรต้นเพียง 1 ตัวแปร และ Multiple Linear Regression คือการวิเคราะห์ข้อมูลถดถอยเชิงเส้นพหุคูณเป็นการวิเคราะห์ข้อมูลเมื่อมีตัวแปรต้นหลายตัว

#### 1) การวิเคราะห์ข้อมูลถดถอยเชิงเส้นแบบง่าย (Simple Linear Regression)

การวิเคราะห์ข้อมูลถดถอยเชิงเส้นแบบง่ายคือ การวิเคราะห์ความสัมพันธ์เชิงเส้นระหว่างตัวแปรต้น (แทนด้วย  $x$ ) และตัวแปรตาม (แทนด้วย  $y$ ) โดยมีตัวแปรต้นเพียง 1 ตัว ซึ่งมีความสัมพันธ์เชิงเส้นต่อกัน โดยจุดมุ่งหมายของการวิเคราะห์ข้อมูลคือการสร้างสมการเส้นตรงแบบถดถอยเชิงเส้นที่สามารถอธิบายความสัมพันธ์ของทั้งสองตัวแปรได้ดีที่สุด

#### ข้อจำกัดของแบบจำลอง Simple Linear Regression

การมีข้อกำหนดในเบื้องต้นว่าตัวแปรต้นและตัวแปรตามจะต้องมีความสัมพันธ์เชิงเส้นต่อกัน ถ้าหากว่าสองปัจจัยไม่มีความสัมพันธ์แบบเส้นตรงจะไม่เหมาะกับการวิเคราะห์ข้อมูลด้วยวิธีนี้ และข้อมูลควรจะมีการกระจายตัวแบบปกติ

#### 2) การวิเคราะห์ข้อมูลถดถอยพหุคูณเชิงเส้น (Multiple Linear Regression)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่นิยามความเห็นไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การวิเคราะห์ข้อมูลถดถอยพหุคูณเชิงเส้น คือการวิเคราะห์ข้อมูลเพื่อหาความสัมพันธ์ระหว่าง ตัวแปรต้นที่มีมากกว่า 1 ตัวแปร(แทนด้วย  $X_1, X_2, X_3, \dots, X_n$ ) ที่มีต่อตัวแปรตาม (แทนด้วย  $y$ ) ซึ่งมีการหาความสัมพันธ์เชิงเส้นระหว่างตัวแปรต้นและตัวแปรตาม การวิเคราะห์ถดถอยพหุคูณมีจุดประสงค์เพื่อต้องการทราบสมการถดถอยพหุคูณที่จะนำไปพัฒนาหรือตอบโจทย์ของการวิจัย

ข้อจำกัดของแบบจำลอง Multiple Linear Regression

การมีข้อกำหนดเรื่องความสัมพันธ์เชิงเส้นต่อกันระหว่างตัวแปรต้นและตัวแปรตาม และการมีการกระจายของข้อมูลแบบปกติ นอกจากนี้ การวิเคราะห์ข้อมูลถดถอยพหุคูณเชิงเส้นยังมีอีกข้อจำกัดหนึ่งคือ Multicollinearity หรือ ภาวะร่วมเส้นตรงหลายตัวแปร หรือการที่ตัวแปรต้นมีความสัมพันธ์กันเองในระดับมากแต่ไม่สมบูรณ์ซึ่ง อาจส่งผลต่อการนำผลการวิเคราะห์ข้อมูลไปใช้ แสดงดังรูปที่ 2.9 การจำแนกประเภทของข้อมูลของแบบจำลอง Linear Regression (Data Investigator Team, 2566)

Simple Linear Regression

Multiple Linear Regression



รูปที่ 2.9 การจำแนกประเภทของข้อมูลของแบบจำลอง Linear Regression

#### 2.4.5 แบบจำลอง Moving Average

แบบจำลอง Moving Average หรือ MA คือเส้นค่าเฉลี่ยเคลื่อนที่เป็นค่าที่ใช้ข้อมูลย้อนหลังในการคำนวณ โดยจำนวนของข้อมูลที่ใช้คำนวณจะมีผลกับการแกว่งตัวของเส้นค่าเฉลี่ย โดยถ้าใช้ข้อมูลย้อนหลังจำนวนน้อยในการคำนวณ เส้นค่าเฉลี่ยที่ได้จะมีการเคลื่อนที่ใกล้เคียงกับค่าของข้อมูล แต่หากใช้ข้อมูลย้อนหลังจำนวนมากมาคำนวณ เส้นค่าเฉลี่ยที่ได้จะมีการเคลื่อนที่ช้ากว่าข้อมูล แสดงดังรูปที่ 2.10 เส้นแบบจำลอง Moving Average (Blog Trade hom, 2022)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.10 เส้นแบบจำลอง Moving Average

เส้น Moving Average (MA) ที่นิยมใช้กันอย่างแพร่หลายมีอยู่ด้วยกัน 3 แบบ ดังนี้

1) วิธีเฉลี่ยเคลื่อนที่แบบง่าย (Simple Moving Average Method) หรือ SMA ค่าพยากรณ์จะได้จากค่าสังเกตล่าสุดจำนวนหนึ่ง แล้วนำมาหาค่าเฉลี่ยซึ่งการเฉลี่ยนี้เป็นการเฉลี่ยที่ให้น้ำหนักกับค่าสังเกตแต่ละค่าเท่ากัน กรณีใช้  $k$  ค่าสังเกตจะให้ค่าพยากรณ์ ณ เวลา  $t+1$

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k} \quad (2.1)$$

จำนวนค่าสังเกตที่จะนำมาหาค่าเฉลี่ยนั้นจะมีจำนวนไม่แน่นอน จำนวนที่เหมาะสมคือจำนวนที่ทำให้ค่าพยากรณ์มีค่าใกล้เคียงกับค่าจริงมากที่สุด นั่นคือให้ค่า SSE หรือ MSE หรือ RMSE น้อยที่สุด

2) วิธีเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average Method) หรือ WMA ค่าพยากรณ์จะได้จากค่าสังเกตล่าสุดจำนวนหนึ่ง โดยน้ำหนักที่ให้กับค่าสังเกตแต่ละค่าไม่เท่ากัน กรณีใช้  $k$  ค่าสังเกตจะให้ค่าพยากรณ์ ณ เวลา  $t+1$

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k} \quad (2.2)$$

ซึ่ง  $W_i$  เป็นค่าถ่วงน้ำหนักซึ่ง  $\sum_{i=1}^k W_i = 1$

เมื่อ  $Y_t$  และ  $\hat{Y}_{t+1}$  เป็นค่าจริงและค่าพยากรณ์ ณ เวลา  $t$  ตามลำดับ และ  $n$  เป็นจำนวนค่าสังเกตที่พยากรณ์ได้ จากค่า MSE จะเห็นว่าการเฉลี่ยเคลื่อนที่แบบง่าย 5 ช่วงเวลา จะให้ค่า MSE ต่ำที่สุด ดังนั้น จึงควรใช้การเฉลี่ยเคลื่อนที่แบบง่าย 5 ช่วงเวลาในการพยากรณ์

3) วิธีปรับให้เรียบเอ็กซ์โปเนนเชียลแบบง่าย (Single Exponential Smoothing Method) หรือ SES ค่าพยากรณ์จะใช้ค่าสังเกตที่ผ่านมาทั้งหมด โดยน้ำหนักที่ให้กับค่าสังเกตแต่ละค่าไม่เท่ากัน น้ำหนักที่ให้กับค่าที่เกิดขึ้นล่าสุดสูงที่สุด และจะลดหลั่นกันไปสำหรับค่าสังเกตที่อยู่ห่างไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ออกไป น้ำหนักที่จะขึ้นอยู่กับค่าปรับน้ำหนัก ( $\alpha$ ) สมการพยากรณ์สำหรับพยากรณ์ ณ เวลา  $t$  เมื่อใช้ค่าสังเกต  $Y_t, Y_{t+1}, \dots$

$$\hat{Y}_{t+1} = \alpha Y_t + \alpha(1-\alpha) Y_{t-1} + \alpha(1-\alpha)^2 Y_{t-2} + \dots \quad (2.3)$$

ซึ่งค่าถ่วงน้ำหนักทั้งหมดจะรวมกันเป็น 1 อาจเขียนสมการพยากรณ์ใหม่อีกสองแบบได้แก่ แบบปรับให้เรียบ (smoothing form) และแบบปรับค่าเดิมด้วยความคลาดเคลื่อน (error correction form) ดังนี้

$$\hat{Y}_{t+1} = \alpha Y_t + \alpha(1-\alpha) \hat{Y}_t \quad (2.4)$$

และ

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha e_t \quad (2.5)$$

แบบปรับให้เรียบจะได้จากการเฉลี่ยแบบถ่วงน้ำหนักของค่าจริงและค่าพยากรณ์ ณ เวลา  $t$  ส่วนแบบปรับค่าเดิมด้วยความคลาดเคลื่อนจะได้จากการปรับค่าพยากรณ์ ณ เวลา  $t$  ด้วย  $\alpha$  เท่าของความคลาดเคลื่อน ณ เวลา  $t$  ที่เหมาะสมจะเป็นค่าที่ทำให้ค่า SSE หรือ MSE หรือ RMSE มีค่าต่ำสุด คือ เป็นค่าที่ทำให้ค่าพยากรณ์ใกล้เคียงกับค่าจริงมากที่สุดเมื่อใช้ค่าปรับน้ำหนักต่างกันสมการพยากรณ์ที่ได้จะต่างกัน


## 2.5 การปรับแต่งพารามิเตอร์ของแบบจำลองในการพยากรณ์

Hyperparameters คือ การปรับค่าต่างๆ ก่อนที่จะสร้างโมเดล ในการควบคุมการทำงานของ Machine Learning Algorithm สิ่งเหล่านี้มีผลกระทบอย่างยิ่งสำหรับการ Train Model เพราะเกี่ยวกับเวลาในการสอนโมเดล ข้อกำหนดเกี่ยวกับสเปคของเครื่องที่ต้องใช้ในการสร้างโมเดล นอกจากนี้ยังส่งผลโดยตรงกับ ค่า Convergence และ Accuracy ของโมเดล การสร้างโมเดลการเรียนรู้ของเครื่องประกอบไปด้วยพารามิเตอร์ที่แตกต่างกัน 2 ชนิด ได้แก่

1) Model Parameters คือ พารามิเตอร์ที่ได้มาระหว่างขั้นตอนการเรียนรู้ข้อมูลของโมเดล (Model Training) เช่น ค่า Weights ที่ใช้ใน Neural Network หรือค่า Coefficients ที่ได้จากการทำ Linear Regression เป็นต้น

2) Hyperparameters คือ พารามิเตอร์ต่าง ๆ ที่ผู้ใช้สามารถกำหนดเองได้ก่อนที่โมเดลจะทำการเรียนรู้ เช่น ค่า Learning Rate ที่ใช้ในการควบคุมว่าใน 1 Step ของการเรียนรู้จะปรับค่า Weights ของ Neural Network อย่างไร หรือค่า n estimators ซึ่งกำหนดจำนวนต้นไม้สำหรับการ

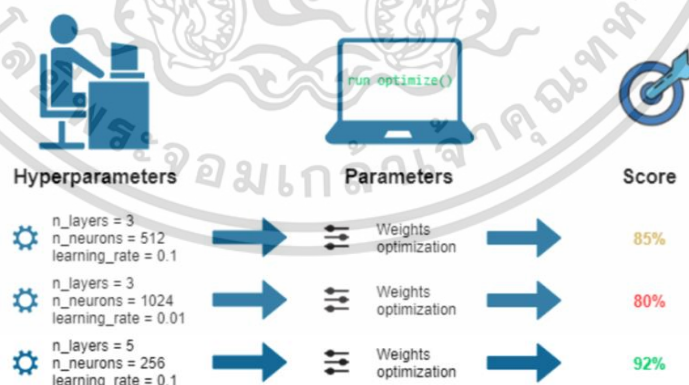
สร้างโมเดล Random Forest เป็นต้น แสดงดังรูปที่ 2.11 การสร้างโมเดลการเรียนรู้ของเครื่อง เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.11 การสร้างโมเดลการเรียนรู้ของเครื่อง

ดังนั้นการทำ Hyperparameter Tuning นับได้ว่าเป็น Optimization Problem รูปแบบหนึ่ง เนื่องจากต้องการหาว่า Set ของ Hyperparameters ที่เหมาะสมสำหรับโมเดลที่จะส่งผลให้โมเดลมีความแม่นยำที่สูง หรือต้องการลดค่า Loss ให้มีค่าต่ำที่สุด ในปัจจุบันมีเทคนิคที่ได้ถูกคิดค้นมาเพื่อใช้สำหรับ Hyperparameter Tuning ซึ่งแบ่งออกเป็น 2 ประเภท ได้แก่

- 1) Traditional Hyperparameter Tuning คือ วิธีการปรับค่าชุด Hyperparameters โดยจะเป็นการปรับค่าด้วยการเทียบผลของโมเดลทุก Combination ของ Hyperparameters หรือปรับค่าด้วยตนเองไปเรื่อย ๆ จนกว่าจะเจอชุดของ Hyperparameter ที่ส่งผลให้โมเดลบรรลุผลตามที่คาดหวังไว้
- 2) Automated Hyperparameter Tuning คือ วิธีการปรับค่าชุด Hyperparameters ที่เหมาะสมโดยอัตโนมัติด้วยอัลกอริทึมชนิดต่าง ๆ ที่ถูกออกแบบมาเพื่องานประเภทนี้ แสดงดังรูปที่ 2.12 การทำ Hyperparameter Tuning



รูปที่ 2.12 การทำ Hyperparameter Tuning

วิธีการค้นหา Hyperparameter ประเภทนี้มี 3 วิธี ได้แก่ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1) Grid Search คือ เทคนิคในการปรับแต่งพารามิเตอร์ของโมเดล Machine Learning เพื่อให้ได้ค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับแต่ละโมเดล การทำ Grid Search นั้นจะทำการสร้างโมเดลตั้งแต่เบื้องต้นจนถึงการปรับแต่งพารามิเตอร์ โดยการทำให้สามารถหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับโมเดลได้อย่างมีประสิทธิภาพมากยิ่งขึ้น เนื่องจากจะเป็นการทำลองทั้งหมดของค่าพารามิเตอร์ที่เป็นไปได้ ดังนั้น Grid Search เป็นเทคนิคที่เป็นที่นิยมใช้กันอย่างแพร่หลายในการปรับแต่งโมเดล Machine Learning

หลักการของ Grid Search คือการสร้างชุดของพารามิเตอร์ที่เป็นไปได้ทั้งหมดของโมเดล และทำการค้นหาค่าพารามิเตอร์ที่ดีที่สุดโดยทดลองใช้แต่ละชุดพารามิเตอร์นั้น ๆ กับโมเดลแต่ละตัว จากนั้นเลือกใช้ชุดพารามิเตอร์ที่ได้คะแนนความสำคัญสูงสุด และนำไปใช้งานจริง แสดงดังรูปที่ 2.13 จำลองการทำงานของ Grid Search




รูปที่ 2.13 จำลองการทำงานของ Grid Search

2) Random Search คือ เทคนิคในการปรับแต่งพารามิเตอร์ของโมเดล Machine Learning โดยการสุ่มค่าพารามิเตอร์จากช่วงที่กำหนดไว้ แล้วทดลองโมเดลด้วยค่าพารามิเตอร์ที่สุ่มนั้นๆ ซึ่ง Random Search มีความยืดหยุ่นมากกว่า Grid Search เนื่องจากไม่จำเป็นต้องทดลองทุกรูปแบบที่คิดคำนวณได้ ทำให้มีโอกาสการค้นพบค่าพารามิเตอร์ที่ดีที่สุดมากขึ้น และลดเวลาที่ใช้ในกระบวนการปรับแต่งพารามิเตอร์

หลักการของ Random Search คือ กำหนดช่วงค่าที่จะสุ่มสำหรับแต่ละพารามิเตอร์ เพื่อสุ่มค่าพารามิเตอร์ ในช่วงที่กำหนดมาสำหรับแต่ละพารามิเตอร์ที่ต้องการปรับแต่ง จากนั้นทดลองโมเดลด้วยค่าพารามิเตอร์ที่สุ่มได้ และประเมินประสิทธิภาพของโมเดลที่ทดลองด้วยเกณฑ์ที่กำหนด พร้อมทั้งบันทึกผลและเปรียบเทียบค่าพารามิเตอร์ที่ให้ผลลัพธ์ที่ดีที่สุด จะทำซ้ำขั้นตอนทั้งหมดนี้ จนกว่าจะพบค่าพารามิเตอร์ที่ดีที่สุด แสดงดังรูปที่ 2.14 จำลองการทำงานของ Random Search

เอกสารนี้(สถาบันข้อมูลขนาดใหญ่, 2564) ใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.14 จำลองการทำงานของ Random Search

3) Bayesian Optimization คือ เทคนิคที่ใช้หลักการของ Bayesian inference เพื่อปรับแต่งพารามิเตอร์ของโมเดล Machine Learning โดยเรียนรู้จากการทดลองที่เคยทำมาและใช้ข้อมูลนั้นในการทำนายพารามิเตอร์ที่เหมาะสม ซึ่งมีประสิทธิภาพในการปรับแต่งพารามิเตอร์เมื่อพารามิเตอร์มีจำนวนมากหรือต้องการทดลองในช่วงที่ยากต่อการค้นหาทั้งที่จะใช้เวลาน้อยลง

หลักการของ Bayesian Optimization คือ กำหนดหรือสร้างโมเดล (surrogate model) ที่ใช้ในการประมาณความน่าจะเป็นของประสิทธิภาพของโมเดลที่เกิดขึ้นจากการใช้พารามิเตอร์ที่ต่างๆ สามารถทดลองใช้พารามิเตอร์ต่างๆ พร้อมทั้งบันทึกผลประสิทธิภาพ โดยใช้ข้อมูลผลลัพธ์ที่ได้มาปรับปรุงโมเดล (surrogate model) เพื่อประมาณค่าพารามิเตอร์ที่ทำให้ประสิทธิภาพมีค่าสูงสุด และสามารถทดลองใช้พารามิเตอร์ที่คำนวณได้จากขั้นตอนก่อนหน้านี้ พร้อมทั้งบันทึกผลประสิทธิภาพ จะทำซ้ำขั้นตอนทั้งหมดนี้ตามจำนวนรอบที่กำหนด

## 2.6 การวัดประสิทธิภาพของแบบจำลองในการพยากรณ์

รากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (root mean square error: RMSE) คือ การวัดค่าความแตกต่างระหว่างค่าจริงและค่าที่ประมาณจากแบบจำลองยกกำลังสองถ้า RMSE มีค่าน้อยแสดงว่า แบบจำลองสามารถประมาณค่าประมาณได้ใกล้เคียงกับค่าจริง แต่ถ้ามามีค่าเท่ากับศูนย์หมายความว่าไม่เกิดความคลาดเคลื่อนในแบบจำลองนี้ RMSE คำนวณได้ดังนี้ (สุนิสา, 2559)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2} \quad (2.6)$$

เมื่อ  $n$  คือ จำนวนตัวอย่าง

$\hat{x}_i$  คือ ค่าพยากรณ์

$x_i$  คือ ค่าจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.7 งานวิจัยที่เกี่ยวข้อง

**ชัยพฤกษ์ นิละนนท์ (2563)** ได้ทำการศึกษาเรื่อง การพยากรณ์ปริมาณความต้องการ เหล็กกรัดร่อนภายในประเทศด้วยวิธีการเรียนรู้ของเครื่อง โดยเหล็กเป็นวัสดุที่สำคัญชนิดหนึ่งและมี ปริมาณความต้องการใช้งานมากขึ้นทุกปีในอุตสาหกรรมเหล็ก การพยากรณ์เพื่อวางแผนการจัดซื้อ วัตถุดิบ การจัดเตรียมการผลิต และแผนการขายจึงเป็นสิ่งที่สำคัญ การพยากรณ์ที่แม่นยำสามารถทำให้การวางแผนต่าง ๆ เป็นอย่างเหมาะสมและสามารถลดต้นทุนในการผลิตและการดำเนินการได้โดยใช้ข้อมูลตั้งแต่เดือนมกราคม ปีค.ศ. 2014 จนถึงเดือนธันวาคม ปีค.ศ. 2019 ตัวแบบการพยากรณ์ที่ใช้ในงานวิจัยนี้ประกอบไปด้วย ตัวแบบ Holt's Exponential Smoothing, ARIMA, Multiple Regression, Artificial Neural Network, Extreme Gradient Boosting, Random Forest, Support Vector Regression และ Light Gradient Boosting Machine และตัวแบบผสมที่คัดเลือกจากตัวแบบการเรียนรู้ของเครื่องที่มีความแม่นยำที่สุดสามอันดับแรกมาทำการผสม จากนั้นทำการเปรียบเทียบความแม่นยำด้วยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) ผลการวิจัยพบว่าตัวแบบที่มีความแม่นยำมากที่สุดคือตัวแบบผสม Artificial Neural Network, Random Forest และ Extreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม มีค่า MAPE เท่ากับ 3.59% แม่นยำกว่าตัวแบบ Artificial Neural Network ที่เป็นตัวแบบการเรียนรู้ของเครื่องที่แม่นยำที่สุดด้วยค่า MAPE เท่ากับ 5.63% ถึง 36.23%

**พัชรมนต์ นาวายก (2565)** ได้ทำการศึกษาเรื่อง การพยากรณ์การหยุดใช้งานบัตรเครดิตด้วยเทคนิคการเรียนรู้ของเครื่อง: กรณีศึกษาธนาคารพาณิชย์แห่งหนึ่ง เพื่อสร้างแบบจำลองที่สามารถคาดการณ์ได้ว่าลูกค้าจะหยุดใช้งานบัตรเครดิตโดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) และเปรียบเทียบแบบจำลองการพยากรณ์ที่ให้ค่าความเที่ยงตรง (Accuracy) สูงสุด เพื่อช่วยในการตัดสินใจและวางแผนกลยุทธ์ของผู้ให้บริการบัตรเครดิต โดยข้อมูลที่นำมาใช้ในการวิจัยเป็นข้อมูลส่วนบุคคลของลูกค้า และข้อมูลพฤติกรรมการใช้งานบัตรเครดิตของลูกค้า โดยแบ่งข้อมูลออกเป็น 2 ส่วน คือร้อยละ 80 เป็นชุดฝึกสอน และร้อยละ 20 เป็นชุดทดสอบ โดยได้นำข้อมูลชุดฝึกสอนไปสร้างแบบจำลอง 3 แบบ คือแบบจำลองการถดถอยโลจิสติกส์ (Logistic Regression) แบบจำลองจำแนกประเภทต้นไม้ตัดสินใจ (Decision Tree) และแบบจำลองจำแนกประเภทการสุ่มป่าไม้ (Random Forest) ผลการวิจัยพบว่าแบบจำลองสุ่มป่าไม้ โดยใช้เทคนิคการสุ่มจำนวนตัวอย่างแบบ SMOTE-ENN เป็นแบบจำลองที่มีประสิทธิภาพที่ดีที่สุดในด้านค่าประสิทธิภาพโดยรวม (F1-score) และค่าความเที่ยงตรง (Accuracy) ร้อยละ 99.45 ปัจจัยสำคัญที่ส่งผลต่อแบบจำลองมากที่สุดคือ ความถี่ในการใช้บัตรเครดิตในเดือนกันยายน รองลงมาคือ จำนวนเงินที่ใช้จ่ายในเดือนกันยายน และอัตราส่วนการเปลี่ยนแปลงของการใช้จ่ายระหว่างเดือนสิงหาคมและเดือนกันยายนตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**ภาณุเดช คุณชม (2565)** ได้ทำการศึกษาเรื่อง การพยากรณ์การใช้พลังงานไฟฟ้าของ อาคารสำนักงานด้วยแบบจำลองการขับเคลื่อนด้วยข้อมูล โดยทำการรวบรวมข้อมูลจากการใช้พลังงานไฟฟ้า (kW) และข้อมูลค่าหน่วยในหนึ่งชั่วโมง (h) จำนวนทั้งหมด 2176 ชั่วโมง มาประยุกต์ใช้เทคนิคอัลกอริทึมในการทำเหมืองข้อความเพื่อวิเคราะห์ปัญหาทางด้านการจัดการพลังงานไฟฟ้า ผ่านทางโปรแกรม RapidMiner Studio โดยแบ่งข้อมูลออกเป็น 3 ชุดตามมิเตอร์ไฟฟ้าภายในอาคารสำนักงาน เพื่อนำมาสร้างรูปแบบการพยากรณ์ที่เหมาะสมกับตัวชุดข้อมูล โดยใช้ตัวแบบการพยากรณ์ Naïve Bayes, Generalized linear Model, Logistic Regression, Fast Large Margin, Deep Learning, Decision Tree, Random Forest, Gradient Booster Trees และ Support Vector Machine เพื่อหาตัวแบบที่เหมาะสมกับชุดข้อมูลมิเตอร์ไฟฟ้า โดยผลของการศึกษานี้พบว่ามิเตอร์ไฟฟ้าตัวที่ 1 และมิเตอร์ไฟฟ้าตัวที่ 2 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Gradient Booster Trees ส่วนมิเตอร์ไฟฟ้าตัวที่ 3 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Random Forest ซึ่งตัวแบบของแต่ละมิเตอร์ไฟฟ้ามียุทธศาสตร์ Accuracy และ Precision ที่มากที่สุด, มีค่า Classification error น้อยที่สุด และ MAPE เทียบกับข้อมูลจริงน้อยที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



### 1) รวบรวมข้อมูลปริมาณการใช้พลังงานไฟฟ้า

ผู้วิจัยจะทำการรวบรวมข้อมูลปริมาณการใช้พลังงานไฟฟ้าในระดับจุลภาครายเดือนของเขตจำหน่ายพลังงานไฟฟ้าส่วนภูมิภาค ซึ่งจะเก็บข้อมูลค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh) โดยทำการรวบรวมข้อมูลตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566

### 2) การจัดการข้อมูล

ในการจัดการข้อมูลมีการแบ่งข้อมูลออกเป็น 2 ชุด ดังนี้

ชุดที่ 1 ชุดข้อมูลฝึกสอน (training set) จะใช้ข้อมูลตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 เพื่อใช้ในการสร้างแบบจำลองการพยากรณ์

ชุดที่ 2 ชุดข้อมูลทดสอบ (testing set) จะใช้ข้อมูลตั้งแต่เดือนมกราคม ถึงเดือนธันวาคม ปีพ.ศ. 2566 เพื่อใช้ในการทดสอบประสิทธิภาพแบบจำลองการพยากรณ์

### 3) การสร้างแบบจำลอง

การสร้างแบบจำลองเพื่อนำมาใช้ในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์ จะใช้แบบจำลอง Support Vector Machines, Random Forest, Extreme Gradient Boosting, Linear Regression และแบบจำลอง Moving Average โดยใช้ชุดข้อมูลฝึกสอน

### 4) การปรับแต่งพารามิเตอร์

การปรับแต่งพารามิเตอร์เพื่อช่วยการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์มีความแม่นยำมากขึ้น จะใช้แบบจำลอง Support Vector Machines, Random Forest และแบบจำลอง Extreme Gradient Boosting โดยใช้ชุดข้อมูลฝึกสอน

### 5) การวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

การเปรียบเทียบประสิทธิภาพในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า โดยพิจารณาจากรากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย Root Mean Squared Error (RMSE)

### 6) แบบจำลองที่มีประสิทธิภาพ

เลือกแบบจำลองที่เหมาะสมที่สุดสำหรับการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์

### 7) การประยุกต์ใช้แบบจำลอง

การประยุกต์ใช้แบบจำลองที่ดีที่สุดสำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.2 เครื่องมือที่ใช้ในการศึกษาวิจัย

การวิเคราะห์ข้อมูลและดำเนินการทดสอบข้อมูลด้วยการเขียนโปรแกรม R และศึกษาไลบรารีเพิ่มเติมประกอบการเขียนโปรแกรม R

ไลบรารี (library) เปรียบเสมือนโปรแกรมสำเร็จรูปที่ได้ทำการเก็บฟังก์ชันการทำงานที่เฉพาะทางไว้เป็นที่เรียบร้อยแล้ว เมื่อผู้ใช้งานต้องการใช้จึงสามารถเรียกใช้ได้ทันทีโดยไม่ต้องสร้างไลบรารีขึ้นมาใหม่เอง ซึ่งมีหลากหลายไลบรารีที่ใช้กันและแยกไปตามประเภทของการใช้งาน โดยในงานวิจัยนี้จะใช้ไลบรารี ดังนี้

#### 1) การสร้างแบบจำลองการเรียนรู้ของเครื่องจักร (Machine Learning)

##### • ไลบรารี E1071

เป็นไลบรารีที่ให้เครื่องมือสำหรับการทำงานที่เกี่ยวข้องกับการทำนายและการจัดกลุ่ม (classification) ในทางเศรษฐศาสตร์ ไลบรารีนี้มีฟังก์ชันที่น่าสนใจมากมายโดยเฉพาะการสร้างและประเมินแบบจำลอง Support Vector Machines (SVM) เป็นเทคนิคการทำนายและการจัดกลุ่มที่มีประสิทธิภาพสูง และยังมีเครื่องมือสำหรับการประเมินแบบจำลองที่สร้างขึ้น เพื่อให้ผู้ใช้สามารถวิเคราะห์ประสิทธิภาพของ SVM ที่ได้รับ

##### • ไลบรารี RandomForest

เป็นไลบรารีที่ให้เครื่องมือสำหรับการสร้างแบบจำลอง Random Forest ซึ่งเป็นวิธีที่มีประสิทธิภาพสูงในการทำนายและจัดกลุ่มข้อมูล Random Forest ถูกพัฒนาขึ้นจากการรวมกันของหลาย Decision Trees ที่สร้างขึ้นโดยการให้แต่ละต้นไม้ใช้ข้อมูลส่วนหนึ่งของชุดข้อมูลและแต่ละต้นไม้มีการสร้างในลักษณะที่แบบสุ่ม

##### • ไลบรารี XGBoost

เป็นไลบรารีที่ให้เครื่องมือสำหรับการสร้างแบบจำลอง Extreme Gradient Boosting ที่มีประสิทธิภาพสูง XGBoost ถูกพัฒนาขึ้นโดย DMLC และมีการใช้งานแพร่หลายในการแข่งขันด้านการเรียนรู้ของเครื่องจักรและวิทยาศาสตร์ข้อมูล นอกจาก Extreme Gradient Boosting, XGBoost ยังสนับสนุนการทำนายที่มีประสิทธิภาพด้วย Linear Model และ Factorization Machine

##### • ไลบรารี Forecast

เป็นไลบรารีที่ให้เครื่องมือสำหรับการสร้างแบบจำลอง Moving Average เป็นเทคนิคที่ใช้ในการทำนายการเฉลี่ยข้อมูลที่อยู่ในช่วงเวลาที่กำหนด โดยการใช้ Moving Average ช่วยในการลด noise และเน้นที่แนวโน้มของข้อมูลซึ่งมีหลายรูปแบบ เช่น Simple Moving Average (SMA), Exponential Moving Average (EMA), หรือ Weighted Moving Average (WMA) เป็นเครื่องมือที่มีความเร็วและง่ายต่อการใช้งานทำให้เหมาะสำหรับการทำนายในสถานการณ์ที่ต้องการความยืดหยุ่นและการตอบสนองรวดเร็วต่อการเปลี่ยนแปลงของข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2) คณิตศาสตร์และสถิติ (Mathematics and Statistics)

- การถดถอยเชิงเส้น (Linear Regression)

เป็นวิธีการสร้างแบบจำลองทางสถิติที่ใช้ในการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิสระ (independent variables) กับตัวแปรตาม (dependent variable) หลักการหลักของ Linear Regression คือการสร้างเส้นตรงที่จะเชื่อมโยงตัวแปรอิสระกับตัวแปรตาม โดยทำให้ค่าทำนายของตัวแปรตามมีความใกล้เคียงกับค่าจริงในข้อมูลที่มีอยู่

- เส้นค่าเฉลี่ยเคลื่อนที่ (Moving Average)

เป็นเทคนิคในการวิเคราะห์ข้อมูลชุดต่อเนื่อง โดยวิธีนี้จะใช้ค่าเฉลี่ยของข้อมูลในช่วงเวลาหรือระยะเวลาที่กำหนดมา เพื่อสร้างค่าที่เรียบเนียนขึ้นและลดการเอียงที่อาจเกิดขึ้นจากข้อมูลที่มีความผิดปกติหรือข้อมูลที่มีความสัมพันธ์ที่ไม่คงที่ในช่วงเวลาที่แตกต่างกัน

### 3.3 การจัดเตรียมข้อมูล

ขั้นตอนการเตรียมข้อมูลให้พร้อมก่อนนำไปใช้งาน ซึ่งข้อมูลที่ผู้วิจัยได้มานั้นเป็นตารางบันทึกการใช้พลังงานไฟฟ้าตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566 (กฟภ. 115 kV - Utility Center) ในวังจันทร์วัลเลย์

ตารางที่ 3.1 ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	560.00		
2	560.00	560.00	
3	560.00	560.00	560.00
4	560.00	560.00	560.00
5	560.00	560.00	560.00
6	560.00	560.00	560.00
7	543.75	560.00	560.00
8	509.27	543.75	560.00
9	519.86	509.27	543.75
10	534.04	519.86	509.27
11	789.21	534.04	519.86
12	645.32	789.21	534.04
13	722.15	645.32	789.21

ตารางที่ 3.1 ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
14	494.35	722.15	645.32
15	499.63	494.35	722.15
16	428.54	499.63	494.35
17	411.22	428.54	499.63
18	452.10	411.22	428.54
19	448.12	452.10	411.22
20	439.85	448.12	452.10
21	441.96	439.85	448.12
22	590.04	441.96	439.85
23	572.15	590.04	441.96
24	423.54	572.15	590.04
25	370.77	423.54	572.15
26	377.26	370.77	423.54
27	283.79	377.26	370.77
28	307.49	283.79	377.26
29	116.76	307.49	283.79
30	498.80	116.76	307.49
31	355.33	498.80	116.76
32	331.38	355.33	498.80
33	396.15	331.38	355.33
34	356.59	396.15	331.38
35	354.30	356.59	396.15
36	341.34	354.30	356.59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.2 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	56800.00		
2	51200.00	56800.00	
3	49600.00	51200.00	56800.00
4	50400.00	49600.00	51200.00
5	73600.00	50400.00	49600.00
6	66400.00	73600.00	50400.00
7	62142.66	66400.00	73600.00
8	59657.14	62142.66	66400.00
9	57833.94	59657.14	62142.66
10	61117.55	57833.94	59657.14
11	101939.86	61117.55	57833.94
12	79589.36	101939.86	61117.55
13	88824.65	79589.36	101939.86
14	55614.93	88824.65	79589.36
15	70503.35	55614.93	88824.65
16	48210.19	70503.35	55614.93
17	65281.54	48210.19	70503.35
18	70326.79	65281.54	48210.19
19	58752.98	70326.79	65281.54
20	80693.43	58752.98	70326.79
21	77588.69	80693.43	58752.98
22	64904.00	77588.69	80693.43
23	80418.81	64904.00	77588.69
24	53295.50	80418.81	64904.00
25	51234.32	53295.50	80418.81
26	53759.95	51234.32	53295.50
27	43599.81	53759.95	51234.32
28	37537.22	43599.81	53759.95
29	18866.47	37537.22	43599.81

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับใช้ในงานเพื่อการศึกษาเท่านั้น ไม่สามารถที่จะนำเอกสารนี้ไปใช้  
 อย่างไม่ถูกต้อง หักฉ้อ หรือทำซ้ำโดยไม่ได้รับอนุญาตจากเจ้าของเอกสาร หากมีการนำไปใช้

ตารางที่ 3.2 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
30	106082.79	18866.47	37537.22
31	58924.85	106082.79	18866.47
32	62205.66	58924.85	106082.79
33	66615.75	62205.66	58924.85
34	63963.62	66615.75	62205.66
35	65650.53	63963.62	66615.75
36	50167.33	65650.53	63963.62

ตารางที่ 3.3 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	77600.00		
2	81600.00	77600.00	
3	74400.00	81600.00	77600.00
4	66400.00	74400.00	81600.00
5	83200.00	66400.00	74400.00
6	92000.00	83200.00	66400.00
7	87776.50	92000.00	83200.00
8	83665.51	87776.50	92000.00
9	70180.51	83665.51	87776.50
10	64677.79	70180.51	83665.51
11	109831.98	64677.79	70180.51
12	106119.15	109831.98	64677.79
13	88824.65	106119.15	109831.98
14	114822.10	88824.65	106119.15
15	67355.86	114822.10	88824.65
16	77165.09	67355.86	114822.10
17	53031.21	77165.09	67355.86
18	62711.40	53031.21	77165.09

ตารางที่ 3.3 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
19	63796.45	62711.40	53031.21
20	52280.20	63796.45	62711.40
21	72819.85	52280.20	63796.45
22	71204.81	72819.85	52280.20
23	58582.18	71204.81	72819.85
24	69293.68	58582.18	71204.81
25	54942.07	69293.68	58582.18
26	50930.48	54942.07	69293.68
27	45405.72	50930.48	54942.07
28	32200.29	45405.72	50930.48
29	13089.76	32200.29	45405.72
30	75824.77	13089.76	32200.29
31	43033.89	75824.77	13089.76
32	44500.25	43033.89	75824.77
33	46391.25	44500.25	43033.89
34	43682.47	46391.25	44500.25
35	46997.44	43682.47	46391.25
36	39409.80	46997.44	43682.47

ตารางที่ 3.4 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	56000.00		
2	74400.00	56000.00	
3	40000.00	74400.00	56000.00
4	88800.00	40000.00	74400.00
5	91200.00	88800.00	40000.00
6	60800.00	91200.00	88800.00
7	72240.84	60800.00	91200.00

ตารางที่ 3.4 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) เดือนมกราคม ปีพ.ศ. 2564 ถึง เดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
8	65477.35	72240.84	60800.00
9	51985.56	65477.35	72240.84
10	67644.66	51985.56	65477.35
11	76948.15	67644.66	51985.56
12	83891.49	76948.15	67644.66
13	91713.25	83891.49	76948.15
14	52525.21	91713.25	83891.49
16	66958.60	44411.56	52525.21
17	56543.06	66958.60	44411.56
18	49228.76	56543.06	66958.60
19	91614.82	49228.76	56543.06
20	51804.72	91614.82	49228.76
21	47142.50	51804.72	91614.82
22	71225.82	47142.50	51804.72
23	55943.52	71225.82	47142.50
24	54707.30	55943.52	71225.82
25	37751.61	54707.30	55943.52
26	35525.58	37751.61	54707.30
27	30442.47	35525.58	37751.61
28	41734.50	30442.47	35525.58
29	10723.77	41734.50	30442.47
30	54508.45	10723.77	41734.50
31	41257.26	54508.45	10723.77
32	39198.09	41257.26	54508.45
33	37113.00	39198.09	41257.26
34	43793.91	37113.00	39198.09
35	32200.02	43793.91	37113.00
36	38478.86	32200.02	43793.91

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้ผู้ใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.4 การสร้างแบบจำลอง

การสร้างแบบจำลองเพื่อนำมาใช้ในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์ จะใช้แบบจำลอง Linear Regression และแบบจำลอง Moving Average สำหรับการเรียนรู้ของเครื่องคือ แบบจำลอง Support Vector Machines, Random Forest และแบบจำลอง Extreme Gradient Boosting โดยการเลือกใช้แบบจำลองทั้ง 5 วิธี ในการทำงานด้านการเรียนรู้ของเครื่องและวิทยาการข้อมูลเนื่องจากคุณสมบัติและประสิทธิภาพที่แตกต่างกันตามลักษณะของข้อมูล

ก่อนการสร้างแบบจำลองได้มีการแบ่งข้อมูลออกเป็น 2 ชุด คือชุดข้อมูลฝึกสอน (training set) จะใช้ข้อมูลตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 เพื่อใช้ในการสร้างแบบจำลองปริมาณการใช้พลังงานไฟฟ้า และชุดข้อมูลทดสอบ (testing set) จะใช้ข้อมูลตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 เพื่อใช้ในการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

ตารางที่ 3.5 ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	560.00		
2	560.00	560.00	
3	560.00	560.00	560.00
4	560.00	560.00	560.00
5	560.00	560.00	560.00
6	560.00	560.00	560.00
7	543.75	560.00	560.00
8	509.27	543.75	560.00
9	519.86	509.27	543.75
10	534.04	519.86	509.27
11	789.21	534.04	519.86
12	645.32	789.21	534.04
13	722.15	645.32	789.21
14	494.35	722.15	645.32
15	499.63	494.35	722.15
16	428.54	499.63	494.35
17	411.22	428.54	499.63

เอกสารนี้เป็นเอกสารสงวนไว้สำหรับการศึกษาเท่านั้น ไม่ควรนำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น ยกเว้นหากมีเหตุตบแต่งและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.5 ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
18	452.10	411.22	428.54
19	448.12	452.10	411.22
20	439.85	448.12	452.10
21	441.96	439.85	448.12
22	590.04	441.96	439.85
23	572.15	590.04	441.96
24	423.54	572.15	590.04

ตารางที่ 3.6 ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
25	370.77	423.54	572.15
26	377.26	370.77	423.54
27	283.79	377.26	370.77
28	307.49	283.79	377.26
29	116.76	307.49	283.79
30	498.80	116.76	307.49
31	355.33	498.80	116.76
32	331.38	355.33	498.80
33	396.15	331.38	355.33
34	356.59	396.15	331.38
35	354.30	356.59	396.15
36	341.34	354.30	356.59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.7 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	56800.00		
2	51200.00	56800.00	
3	49600.00	51200.00	56800.00
4	50400.00	49600.00	51200.00
5	73600.00	50400.00	49600.00
6	66400.00	73600.00	50400.00
7	62142.66	66400.00	73600.00
8	59657.14	62142.66	66400.00
9	57833.94	59657.14	62142.66
10	61117.55	57833.94	59657.14
11	101939.86	61117.55	57833.94
12	79589.36	101939.86	61117.55
13	88824.65	79589.36	101939.86
14	55614.93	88824.65	79589.36
15	70503.35	55614.93	88824.65
16	48210.19	70503.35	55614.93
17	65281.54	48210.19	70503.35
18	70326.79	65281.54	48210.19
19	58752.98	70326.79	65281.54
20	80693.43	58752.98	70326.79
21	77588.69	80693.43	58752.98
22	64904.00	77588.69	80693.43
23	80418.81	64904.00	77588.69
24	53295.50	80418.81	64904.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.8 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
25	51234.32	53295.50	80418.81
26	53759.95	51234.32	53295.50
27	43599.81	53759.95	51234.32
28	37537.22	43599.81	53759.95
29	18866.47	37537.22	43599.81
30	106082.79	18866.47	37537.22
31	58924.85	106082.79	18866.47
32	62205.66	58924.85	106082.79
33	66615.75	62205.66	58924.85
34	63963.62	66615.75	62205.66
35	65650.53	63963.62	66615.75
36	50167.33	65650.53	63963.62

ตารางที่ 3.9 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) สำหรับทำการฝึกสอน เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	77600.00		
2	81600.00	77600.00	
3	74400.00	81600.00	77600.00
4	66400.00	74400.00	81600.00
5	83200.00	66400.00	74400.00
6	92000.00	83200.00	66400.00
7	87776.50	92000.00	83200.00
8	83665.51	87776.50	92000.00
9	70180.51	83665.51	87776.50
10	64677.79	70180.51	83665.51
11	109831.98	64677.79	70180.51
12	106119.15	109831.98	64677.79
13	88824.65	106119.15	109831.98

ตารางที่ 3.9 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) สำหรับทำการฝึกสอน เดือน มกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 (ต่อ)

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
14	114822.10	88824.65	106119.15
15	67355.86	114822.10	88824.65
16	77165.09	67355.86	114822.10
17	53031.21	77165.09	67355.86
18	62711.40	53031.21	77165.09
19	63796.45	62711.40	53031.21
20	52280.20	63796.45	62711.40
21	72819.85	52280.20	63796.45
22	71204.81	72819.85	52280.20
23	58582.18	71204.81	72819.85
24	69293.68	58582.18	71204.81

ตารางที่ 3.10 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) สำหรับทำการทดสอบ เดือน มกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
25	54942.07	69293.68	58582.18
26	50930.48	54942.07	69293.68
27	45405.72	50930.48	54942.07
28	32200.29	45405.72	50930.48
29	13089.76	32200.29	45405.72
30	75824.77	13089.76	32200.29
31	43033.89	75824.77	13089.76
32	44500.25	43033.89	75824.77
33	46391.25	44500.25	43033.89
34	43682.47	46391.25	44500.25
35	46997.44	43682.47	46391.25
36	39409.80	46997.44	43682.47

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.11 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) สำหรับทำการฝึกสอน เดือน มกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
1	56000.00		
2	74400.00	56000.00	
3	40000.00	74400.00	56000.00
4	88800.00	40000.00	74400.00
5	91200.00	88800.00	40000.00
6	60800.00	91200.00	88800.00
7	72240.84	60800.00	91200.00
8	65477.35	72240.84	60800.00
9	51985.56	65477.35	72240.84
10	67644.66	51985.56	65477.35
11	76948.15	67644.66	51985.56
12	83891.49	76948.15	67644.66
13	91713.25	83891.49	76948.15
14	52525.21	91713.25	83891.49
15	44411.56	52525.21	91713.25
16	66958.60	44411.56	52525.21
17	56543.06	66958.60	44411.56
18	49228.76	56543.06	66958.60
19	91614.82	49228.76	56543.06
20	51804.72	91614.82	49228.76
21	47142.50	51804.72	91614.82
22	71225.82	47142.50	51804.72
23	55943.52	71225.82	47142.50
24	54707.30	55943.52	71225.82

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.12 ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) สำหรับทำการทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	$Y_t$	$Y_{t-1}$	$Y_{t-2}$
25	37751.61	54707.30	55943.52
26	35525.58	37751.61	54707.30
27	30442.47	35525.58	37751.61
28	41734.50	30442.47	35525.58
29	10723.77	41734.50	30442.47
30	54508.45	10723.77	41734.50
31	41257.26	54508.45	10723.77
32	39198.09	41257.26	54508.45
33	37113.00	39198.09	41257.26
34	43793.91	37113.00	39198.09
35	32200.02	43793.91	37113.00
36	38478.86	32200.02	43793.91

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh)

3.4.1 แบบจำลอง Support Vector Machine

1	library(e1071)
2	
3	svm_model <- svm(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
4	
5	svm_predictions <- predict(svm_model, newdata = testing_set)

รูปที่ 3.2 Code สำหรับ Support Vector Machine

- เรียกใช้งานแพ็คเกจ e1071 ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ SVM
- สร้างโมเดล SVM โดยให้ Yt เป็นตัวแปรตาม (dependent variable) และ Yt\_1, Yt\_2, time เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน training\_set
- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล SVM ที่สร้างขึ้นมาก่อนหน้านี้

3.4.2 แบบจำลอง Random Forest

1	library(randomForest)
2	
3	rf_model <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
4	
5	rf_predictions <- predict(rf_model, newdata = testing_set)

รูปที่ 3.3 Code สำหรับ Random Forest

- เรียกใช้งานแพ็คเกจ randomForest ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ Random Forest
- สร้างโมเดล Random Forest โดยให้ Yt เป็นตัวแปรตาม (dependent variable) และ Yt\_1, Yt\_2, time เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน training\_set โดยใช้ข้อมูลที่อยู่ใน training\_set ศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล Random Forest ที่สร้างขึ้นมาก่อนหน้านี้

### 3.4.3 แบบจำลอง Extreme Gradient Boosting

1	library(xgboost)
2	
3	xgb_model <- xgboost(data = as.matrix(training_set[, -1]),
4	label = training_set\$Yt, nrounds = 100)
5	
6	xgb_predictions <- predict(xgb_model, newdata = as.matrix(testing_set[, -1]))

#### รูปที่ 3.4 Code สำหรับ Extreme Gradient Boosting

- เรียกใช้งานแพ็คเกจ xgboost ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ XGBoost  
 - สร้างโมเดล XGBoost โดยให้ข้อมูล as.matrix(training\_set[, -1]) เป็นข้อมูลอินพุต (input data) และ training\_set\$Yt เป็นตัวแปรตาม (dependent variable) โดยใช้จำนวนรอบการฝึก (nrounds) เท่ากับ 100  
 - ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล XGBoost ที่สร้างขึ้นมาก่อนหน้านี้

### 3.4.4 แบบจำลอง Linear Regression

Code สำหรับ Linear Regression

1	linear_model <- lm(Yt ~ Yt_1 + Yt_2 + time, data = training_set)
2	
3	linear_predictions <- predict(linear_model, newdata = testing_set)

#### รูปที่ 3.5 Code สำหรับ Linear Regression

- สร้างโมเดล Linear Regression โดยให้ Yt เป็นตัวแปรตาม (dependent variable) และ Yt\_1, Yt\_2, time เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน training\_set  
 - ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล Linear Regression ที่สร้างขึ้นมาก่อนหน้านี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 3.4.5 แบบจำลอง Moving Average

Code สำหรับ Moving Average

1	ma_model <- function(data, window_size) {
2	y <- data\$Yt
3	n <- length(y)
4	moving_avg <- rep(0, n)
5	for (i in window_size:n) { moving_avg[i] <- mean(y[(i - window_size + 1):i]) }
6	return(moving_avg)
7	}
8	window_size <- 3
9	ma_predictions <- ma_model(testing_set, window_size)

รูปที่ 3.6 Code สำหรับ Moving Average

- การสร้างฟังก์ชันรับพารามิเตอร์ data และ window size
- เก็บค่าของตัวแปรตาม (dependent variable) ของข้อมูลที่กำหนดไว้ใน data ไว้ในตัวแปร y
- หาความยาวของข้อมูลใน y และเก็บไว้ในตัวแปร n
- สร้างเวกเตอร์ที่มีความยาวเท่ากับ n โดยให้มีค่าเริ่มต้นทั้งหมดเป็น 0
- วนลูปเพื่อคำนวณค่าเฉลี่ยเคลื่อนที่ (moving average) โดยเริ่มต้นที่ตำแหน่ง window\_size ไปจนถึงตำแหน่ง n โดยใช้ฟังก์ชัน mean() เพื่อหาค่าเฉลี่ยของข้อมูลในช่วงที่กำหนด
- ส่งค่าเวกเตอร์ moving\_avg ออกจากฟังก์ชัน.
- กำหนดขนาดของหน้าต่าง (window size) เท่ากับ 3
- เรียกใช้ฟังก์ชัน ma\_model() เพื่อสร้างแบบจำลอง Moving Average โดยใช้ข้อมูลทดสอบ (testing\_set) และขนาดของหน้าต่าง (window\_size)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5 การปรับแต่งพารามิเตอร์

การปรับแต่งพารามิเตอร์คือการหาว่า Set ของ Hyperparameters ที่เหมาะสมสำหรับโมเดลประเภทนั้น ๆ ที่จะส่งผลให้โมเดลมีความแม่นยำที่สูง หรือต้องการลดค่า Loss ให้มีค่าต่ำที่สุด เพื่อนำมาใช้ในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวงจันท์วัลเลย์ จะสามารถใช้ได้กับแบบจำลอง Support Vector Machines, Random Forest และแบบจำลอง Extreme Gradient โดยการเลือกใช้แบบจำลองทั้ง 3 วิธีในการทำงานด้านการเรียนรู้ของเครื่องและวิทยาการข้อมูล เนื่องจากคุณสมบัติและประสิทธิภาพที่แตกต่างกันตามลักษณะของข้อมูล

#### ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)

##### 3.5.1 แบบจำลอง Support Vector Machine

1	library(e1071)
2	
3	svm_HTmodel <- svm(Yt ~ Yt_1 + Yt_2, data = training_set, kernel = "radial",
4	cost = 100)
5	
6	svm_HTpredictions <- predict(svm_HTmodel, newdata = testing_set)

#### รูปที่ 3.7 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine

- เรียกใช้งานแพ็คเกจ e1071 ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ SVM
- สร้างโมเดล SVM โดยให้ Yt เป็นตัวแปรตาม (dependent variable) และ Yt\_1, Yt\_2 เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน training\_set เพื่อสร้างโมเดล SVM โดยกำหนด radial kernel และ cost parameter เท่ากับ 100
- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล SVM ที่สร้างขึ้นมาก่อนหน้านี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5.2 แบบจำลอง Random Forest

1	library(randomForest)
2	
3	rf_HTmodel <- randomForest(Yt ~ Yt_1 + Yt_2 , data = training_set, ntree = 500)
4	
5	rf_HTpredictions <- predict(rf_HTmodel, newdata = testing_set)

รูปที่ 3.8 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Random Forest

- เรียกใช้งานแพ็คเกจ randomForest ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ Random Forest

- สร้างโมเดล Random Forest โดยให้ Yt เป็นตัวแปรตาม (dependent variable) และ Yt\_1, Yt\_2 เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน training\_set โดยใช้ข้อมูลที่อยู่ใน training\_set เพื่อสร้างโมเดล Random Forest และกำหนดจำนวนต้นไม้ (ntree) เท่ากับ 500

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล Random Forest ที่สร้างขึ้นมาก่อนหน้านี้

### 3.5.3 แบบจำลอง Extreme Gradient Boosting

1	library(xgboost)
2	
3	xgb_HTmodel <- xgboost(data = as.matrix(training_set[, -1]),
4	label = training_set\$Yt, nrounds = 200, eta = 0.01,
5	max_depth = 10, gamma = 1, colsample_bytree = 0.01,
6	min_child_weight = 5)
7	
8	xgb_HTpredictions <- predict(xgb_HTmodel,
9	newdata = as.matrix(testing_set[, -1]))

รูปที่ 3.9 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Extreme Gradient

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษา Boosting นั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- เรียกใช้งานแพ็คเกจ `xgboost` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ XGBoost
- สร้างโมเดล XGBoost โดยให้ข้อมูล `as.matrix(training_set[, -1])` เป็นข้อมูลอินพุต (input data) และ `training_set$Yt` เป็นตัวแปรตาม (dependent variable) โดยใช้จำนวนรอบการฝึก (nrounds) เท่ากับ 200 ค่าการเรียนรู้ (learning rate) เท่ากับ 0.01 ความลึกของต้นไม้สูงสุด (maximum tree depth) เท่ากับ 10 ค่าที่ใช้ในการลดความซับซ้อนของโมเดล (regularization) เท่ากับ 1 สัดส่วนของตัวแปรอิสระที่สุ่มในแต่ละรอบ (column subsample ratio) เท่ากับ 0.01 และค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้ เท่ากับ 5

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล XGBoost ที่สร้างขึ้นมาก่อนหน้านี้

### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh)

#### 3.5.4 แบบจำลอง Support Vector Machine

1	<code>library(e1071)</code>
2	
3	<code>svm_HTmodel &lt;- svm(Yt ~ Yt_1 + Yt_2 , data = training_set, kernel = "radial",</code>
4	<code>cost = 1, gamma = 3)</code>
5	
6	<code>svm_HTpredictions &lt;- predict(svm_HTmodel, newdata = testing_set)</code>

รูปที่ 3.10 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine

- เรียกใช้งานแพ็คเกจ `e1071` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ SVM
- สร้างโมเดล SVM โดยให้ `Yt` เป็นตัวแปรตาม (dependent variable) และ `Yt_1`, `Yt_2` เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน `training_set` เพื่อสร้างโมเดล SVM โดยกำหนด kernel เป็น radial kernel ซึ่งเป็นเคอร์เนลที่ใช้ในการหาค่าความแตกต่างระหว่างข้อมูล และกำหนด `cost` และ `gamma` ด้วยค่า 1 และ 3 ตามลำดับ

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล SVM ที่สร้างขึ้นมาก่อนหน้านี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



- เรียกใช้งานแพ็คเกจ `xgboost` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ XGBoost
- สร้างโมเดล XGBoost โดยให้ข้อมูล `as.matrix(training_set[, -1])` เป็นข้อมูลอินพุต (input data) และ `training_set$Yt` เป็นตัวแปรตาม (dependent variable) โดยใช้จำนวนรอบการฝึก (nrounds) เท่ากับ 200 ค่าการเรียนรู้ (learning rate) เท่ากับ 0.01 ความลึกของต้นไม้สูงสุด (maximum tree depth) เท่ากับ 10 ค่าที่ใช้ในการลดความซับซ้อนของโมเดล (regularization) เท่ากับ 1 สัดส่วนของตัวแปรอิสระที่สุ่มในแต่ละรอบ (column subsample ratio) เท่ากับ 0.01 และค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้ เท่ากับ 5

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล XGBoost ที่สร้างขึ้นมาก่อนหน้านี้

### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)

#### 3.5.7 แบบจำลอง Support Vector Machine

1	<code>library(e1071)</code>
2	
3	<code>svm_HTmodel &lt;- svm(Yt ~ Yt_1 + Yt_2 , data = training_set, kernel = "radial",</code>
4	<code>cost = 1, gamma = 3)</code>
5	
6	<code>svm_HTpredictions &lt;- predict(svm_HTmodel, newdata = testing_set)</code>

รูปที่ 3.13 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine

- เรียกใช้งานแพ็คเกจ `e1071` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ SVM
- สร้างโมเดล SVM โดยให้ `Yt` เป็นตัวแปรตาม (dependent variable) และ `Yt_1`, `Yt_2` เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน `training_set` เพื่อสร้างโมเดล SVM โดยกำหนด kernel เป็น radial kernel ซึ่งเป็นเคอร์เนลที่ใช้ในการหาค่าความแตกต่างระหว่างข้อมูล และกำหนด `cost` และ `gamma` ด้วยค่า 1 และ 3 ตามลำดับ
- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล SVM ที่สร้างขึ้นมาก่อนหน้านี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



- เรียกใช้งานแพ็คเกจ `xgboost` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ XGBoost
- สร้างโมเดล XGBoost โดยให้ข้อมูล `as.matrix(training_set[, -1])` เป็นข้อมูลอินพุต (input data) และ `training_set$Yt` เป็นตัวแปรตาม (dependent variable) โดยใช้จำนวนรอบการฝึก (nrounds) เท่ากับ 200 ค่าการเรียนรู้ (learning rate) เท่ากับ 0.01 ความลึกของต้นไม้สูงสุด (maximum tree depth) เท่ากับ 10 ค่าที่ใช้ในการลดความซับซ้อนของโมเดล (regularization) เท่ากับ 1 สัดส่วนของตัวแปรอิสระที่สุ่มในแต่ละรอบ (column subsample ratio) เท่ากับ 0.01 และค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้ เท่ากับ 5

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล XGBoost ที่สร้างขึ้นมาก่อนหน้านี้

### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh)

#### 3.5.10 แบบจำลอง Support Vector Machine

1	<code>library(e1071)</code>
2	
3	<code>svm_HTmodel &lt;- svm(Yt ~ Yt_1 + Yt_2 + time, data = training_set,</code>
4	<code>kernel = "radial", cost = 1, gamma = 3)</code>
5	
6	<code>svm_HTpredictions &lt;- predict(svm_HTmodel, newdata = testing_set)</code>

รูปที่ 3.16 Code สำหรับ Hyperparameter Tuning ของแบบจำลอง Support Vector Machine

- เรียกใช้งานแพ็คเกจ `e1071` ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ SVM
- สร้างโมเดล SVM โดยให้ `Yt` เป็นตัวแปรตาม (dependent variable) และ `Yt_1`, `Yt_2` และ `time` เป็นตัวแปรอิสระ (independent variables) โดยใช้ข้อมูลที่อยู่ใน `training_set` เพื่อสร้างโมเดล SVM โดยกำหนด kernel เป็น radial kernel ซึ่งเป็นเคอร์เนลที่ใช้ในการหาค่าความแตกต่างระหว่างข้อมูล และกำหนด `cost` และ `gamma` ด้วยค่า 1 และ 3 ตามลำดับ

- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน `testing_set` โดยใช้โมเดล SVM ที่สร้างขึ้นมาก่อนหน้านี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



- เรียกใช้งานแพ็คเกจ xgboost ซึ่งเป็นแพ็คเกจที่มีการสร้างอัลกอริทึมสำหรับ XGBoost
- สร้างโมเดล XGBoost โดยให้ข้อมูล as.matrix(training\_set[, -1]) เป็นข้อมูลอินพุต (input data) และ training\_set\$Yt เป็นตัวแปรตาม (dependent variable) โดยใช้งานวนรอบการฝึก (nrounds) เท่ากับ 200 ค่าการเรียนรู้ (learning rate) เท่ากับ 0.01 ความลึกของต้นไม้สูงสุด (maximum tree depth) เท่ากับ 10 ค่าที่ใช้ในการลดความซับซ้อนของโมเดล (regularization) เท่ากับ 1 สัดส่วนของตัวแปรอิสระที่สุ่มในแต่ละรอบ (column subsample ratio) เท่ากับ 0.01 และค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้ เท่ากับ 5
- ทำนายผลลัพธ์ของข้อมูลที่อยู่ใน testing\_set โดยใช้โมเดล XGBoost ที่สร้างขึ้นมาก่อนหน้านี้

### 3.6 การวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง Support Vector Machines, Random Forest, Extreme Gradient Boosting Linear Regression และแบบจำลอง Moving Average ซึ่งเป็นวิธีการพยากรณ์ปริมาณการใช้ไฟฟ้าในปัจจุบันมาเปรียบเทียบกับค่าวัดประสิทธิภาพในการพยากรณ์ คือ Root Mean Squared Error (RMSE) : คือรากที่สองของค่าคลาดเคลื่อนกำลังสองเฉลี่ย โดยพิจารณาแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบน้อยที่สุด และจะเป็นตัวแบบที่ดีที่สุดจากนั้นจะนำตัวแบบที่ดีที่สุดไปพยากรณ์ 1 ปีข้างหน้า

1	RMSE <- sqrt(mean((predictions - testing_set\$Yt)^2))
2	RMSE

รูปที่ 3.19 Code สำหรับการวัดประสิทธิภาพของแบบจำลอง

การคำนวณ Root Mean Squared Error (RMSE) ใช้ตรวจสอบความแตกต่างระหว่างค่าที่ทำนายได้จากโมเดล (predictions) กับค่าจริงของข้อมูลที่ใช้ทดสอบ (testing\_set\$Yt) เพื่อให้ได้ค่า RMSE ซึ่งเป็นค่าที่แสดงถึงความคลาดเคลื่อนทั้งหมดของการทำนายของโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.7 การพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี

การนำแบบจำลอง Support Vector Machines, Random Forest, Extreme Gradient Boosting, Linear Regression และแบบจำลอง Moving Average ซึ่งเป็นวิธีการพยากรณ์ปริมาณการใช้ไฟฟ้ามาเปรียบเทียบกับค่าวัดประสิทธิภาพในการพยากรณ์ คือ RMSE แสดงถึงความแม่นยำของแบบจำลอง และจะนำมาประยุกต์ใช้ในการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี หรือ 12 เดือน คือพยากรณ์ตั้งแต่เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh)

1	future_data <- data.frame(
2	Yt_1 = 341.34,
3	Yt_2 = 354.30,
4	time = 37
5	)
6	future_data

รูปที่ 3.20 Code สำหรับการสร้างข้อมูลเพื่อพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี

สร้างข้อมูลใหม่ชื่อ future\_data เพื่อกำหนดค่าของตัวแปร Yt\_1, Yt\_2 และ time ให้กับข้อมูลใหม่ จากนั้นแสดงข้อมูลใหม่ที่ถูกสร้างขึ้นมา ซึ่งประกอบด้วยค่าตัวแปร Yt\_1, Yt\_2 และ time ตามที่กำหนด

#### 3.7.1 แบบจำลอง Support Vector Machine

1	svm_future_HTpredictions <- predict(svm_HTmodel, newdata = future_data)
2	print(svm_future_HTpredictions)

รูปที่ 3.21 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Support Vector Machine

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ทำนายผลลัพธ์สำหรับข้อมูลใหม่ future\_data โดยใช้โมเดล SVM ที่ได้สร้างไว้ก่อนหน้า

- แสดงผลลัพธ์การทำนายที่ได้จากโมเดล SVM สำหรับข้อมูลใหม่ future\_data โดยใช้ฟังก์ชัน print() เพื่อแสดงผลลัพธ์ออกทางหน้าจอหรือคอนโซล

### 3.7.2 แบบจำลอง Random Forest

1	<code>rf_future_HTpredictions &lt;- predict(rf_HTmodel, newdata = future_data)</code>
2	<code>print(rf_future_HTpredictions)</code>

#### รูปที่ 3.22 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Random Forest

- ทำนายผลลัพธ์สำหรับข้อมูลใหม่ future\_data โดยใช้โมเดล Random Forest ที่ได้สร้างไว้ก่อนหน้า

- แสดงผลลัพธ์การทำนายที่ได้จากโมเดล Random Forest สำหรับข้อมูลใหม่ future\_data โดยใช้ฟังก์ชัน print() เพื่อแสดงผลลัพธ์ออกทางหน้าจอหรือคอนโซล

### 3.7.3 แบบจำลอง Extreme Gradient Boosting

1	<code>xgb_future_HTpredictions &lt;- predict(xgb_HTmodel,</code>
2	<code>newdata = as.matrix(future_data))</code>
3	<code>print(xgb_future_HTpredictions)</code>

#### รูปที่ 3.23 Code สำหรับการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี ของแบบจำลอง Extreme Gradient Boosting

- ทำนายผลลัพธ์สำหรับข้อมูลใหม่ future\_data โดยใช้โมเดล XGBoost ที่ได้สร้างไว้ก่อนหน้า

- แสดงผลลัพธ์การทำนายที่ได้จากโมเดล XGBoost สำหรับข้อมูลใหม่ future\_data โดยใช้ฟังก์ชัน print() เพื่อแสดงผลลัพธ์ออกทางหน้าจอหรือคอนโซล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



- สร้างฟังก์ชัน `ma_future_predictions()` โดยรับพารามิเตอร์ `data`, `window_size`, และ `future_data`
  - รวมข้อมูล `Yt` จาก `data` และ `Yt_1` จาก `future_data` เข้าด้วยกันในเวกเตอร์ `y`
  - หาความยาวของเวกเตอร์ `y` และเก็บไว้ใน `n`
  - สร้างเวกเตอร์ `moving_avg` ที่มีค่าเริ่มต้นทั้งหมดเป็น 0 และมีความยาวเท่ากับ `n`
  - วนลูปเพื่อคำนวณค่าเฉลี่ยเคลื่อนที่ (moving average) โดยเริ่มต้นที่ตำแหน่งสุดท้ายของ `y` และสิ้นสุดที่ตำแหน่ง `n` โดยใช้ฟังก์ชัน `mean()` เพื่อหาค่าเฉลี่ยของข้อมูลในช่วงที่กำหนด
  - ส่งค่า moving average ที่ตำแหน่งสุดท้ายใน `moving_avg` ออกจากฟังก์ชัน
  - ใช้ฟังก์ชัน `ma_future_predictions()` เพื่อทำนายค่า moving average สำหรับข้อมูลใหม่ `future_data` โดยใช้ข้อมูลเริ่มต้นจาก `data` และขนาดของหน้าต่าง (window\_size)
  - แสดงค่า moving average สำหรับข้อมูลใหม่ `future_data`



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4

### ผลการวิจัยและการอภิปรายผล

ในบทนี้ จะกล่าวถึงผลการเปรียบเทียบการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์ โดยแบ่งออกเป็น 4 ส่วน ดังต่อไปนี้

- 4.1 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าก่อนการปรับแต่งพารามิเตอร์
- 4.2 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าหลังการปรับแต่งพารามิเตอร์
- 4.3 ผลการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง
- 4.4 ผลการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี

โดยจะทำการเปรียบเทียบผลการวิเคราะห์ เพื่อเลือกรูปแบบการพยากรณ์ที่เหมาะสมที่สุด สำหรับข้อมูลค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh) โดยพิจารณาจากค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (RMSE) ที่ให้ค่าน้อยที่สุด

#### 4.1 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าก่อนการปรับแต่งพารามิเตอร์

ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)

- 4.1.1 ผลการพยากรณ์ของแบบจำลอง Support Vector Machines


ตารางที่ 4.1 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	457.58
26	377.26	506.51
27	283.79	521.78
28	307.49	528.52
29	116.76	531.49
30	498.80	532.20
31	355.33	532.52
32	331.38	526.21
33	396.15	534.97
34	356.59	537.62

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้สำหรับใช้ในวงจำกัดเท่านั้น ไม่อนุญาตให้เผยแพร่โดยไม่ได้รับอนุญาต  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งยังมีเห็นด้วยกับแบบสงวนสิทธิ์ และต้องยังรับรองถึงเจ้าของเอกสารในทุกครั้งที่มีการใช้

ตารางที่ 4.1 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	354.30	536.38
36	341.34	535.86
RMSE	203.15	



รูปที่ 4.1 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.1 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 203.15 กิโลวัตต์ (kW)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.2) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.2 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	488.05
26	377.26	494.56
27	283.79	494.56
28	307.49	494.56
29	116.76	494.56
30	498.80	494.56
31	355.33	502.78
32	331.38	476.02
33	396.15	494.56
34	356.59	494.56
35	354.30	494.56
36	341.34	494.56
RMSE		174.21



รูปที่ 4.2 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.2 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 174.21 กิโลวัตต์ (kW)

#### 4.1.3) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

**ตารางที่ 4.3** ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	487.19
26	377.26	532.83
27	283.79	513.28
28	307.49	513.28
29	116.76	513.28
30	498.80	513.28
31	355.33	511.53
32	331.38	514.92
33	396.15	513.28
34	356.59	513.28
35	354.30	513.28
36	341.34	513.28
RMSE		191.79

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.3 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.3 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 191.79 กิโลวัตต์ (kW)


#### 4.1.4) ผลการพยากรณ์ของแบบจำลอง Linear Regression

ตารางที่ 4.4 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	450.16
26	377.26	416.61
27	283.79	412.08
28	307.49	373.26
29	116.76	372.61
30	498.80	297.73
31	355.33	427.69
32	331.38	394.67
33	396.15	372.48
34	356.59	392.16

ตารางที่ 4.4 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	354.30	377.82
36	341.34	370.82
RMSE	110.68	



รูปที่ 4.4 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Linear Regression จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือน มกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.4 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 110.68 กิโลวัตต์ (kW)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.5) ผลการพยากรณ์ของแบบจำลอง Moving Average

ตารางที่ 4.5 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	0.00
26	377.26	0.00
27	283.79	343.94
28	307.49	322.85
29	116.76	236.01
30	498.80	307.68
31	355.33	323.63
32	331.38	395.17
33	396.15	360.95
34	356.59	361.37
35	354.30	369.01
36	341.34	350.74
RMSE		78.26



รูปที่ 4.5 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Moving Average จะพบว่าเมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.5 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 78.26 กิโลวัตต์ (kW)

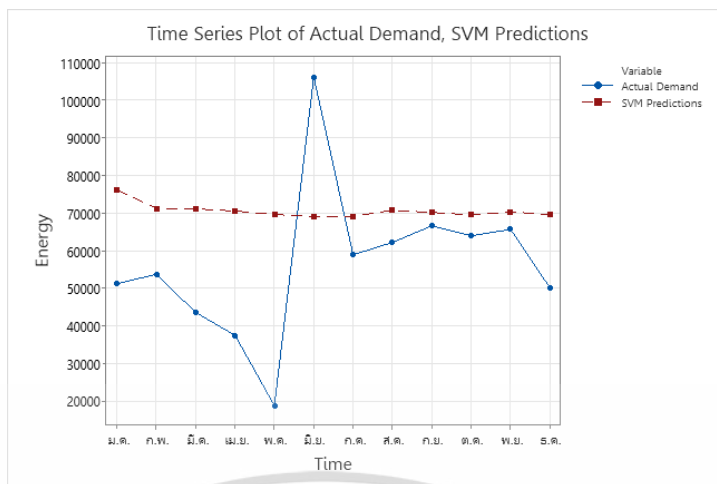
### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh)

#### 4.1.6) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.6 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	76173.83
26	53759.95	71249.98
27	43599.81	71107.99
28	37537.22	70530.66
29	18866.47	69595.80
30	106082.79	69078.04
31	58924.85	69149.50
32	62205.66	70713.96
33	66615.75	70156.91
34	63963.62	69527.47
35	65650.53	70326.06
36	50167.33	69613.70
RMSE	24725.86	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.6 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.6 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 24725.86 กิโลวัตต์ชั่วโมง (kWh)


#### 4.1.7) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.7 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	69394.14
26	53759.95	65618.70
27	43599.81	67868.96
28	37537.22	64793.53
29	18866.47	67148.96
30	106082.79	67148.96
31	58924.85	68015.05
32	62205.66	75147.95
33	66615.75	72364.11
34	63963.62	65980.72

ตารางที่ 4.7 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	65650.53	67601.79
36	50167.33	66656.13
RMSE	22752.81	



รูปที่ 4.7 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่า รูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.7 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 22752.81 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.8) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.8 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	59881.55
26	53759.95	55786.45
27	43599.81	60537.11
28	37537.22	55824.35
29	18866.47	56947.98
30	106082.79	56947.98
31	58924.85	54014.67
32	62205.66	61733.13
33	66615.75	67253.09
34	63963.62	55181.69
35	65650.53	60047.79
36	50167.33	57044.18
RMSE	19885.39	



รูปที่ 4.8 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.8 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 19885.39 กิโลวัตต์ชั่วโมง (kWh)

#### 4.1.9) ผลการพยากรณ์ของแบบจำลอง Linear Regression

**ตารางที่ 4.9** ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	69161.58
26	53759.95	62848.19
27	43599.81	62608.58
28	37537.22	62269.57
29	18866.47	59430.94
30	106082.79	56389.30
31	58924.85	59979.52
32	62205.66	75464.70
33	66615.75	65102.55
34	63963.62	66238.76
35	65650.53	66997.81
36	50167.33	66549.57
RMSE	22260.76	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.9 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Linear Regression จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือน มกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.9 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 22260.76 กิโลวัตต์ชั่วโมง (kWh)


#### 4.1.10) ผลการพยากรณ์ของแบบจำลอง Moving Average

ตารางที่ 4.10 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	0.00
26	53759.95	0.00
27	43599.81	49531.36
28	37537.22	44965.66
29	18866.47	33334.50
30	106082.79	54162.16
31	58924.85	61291.37
32	62205.66	75737.77
33	66615.75	62582.09
34	63963.62	64261.68

ตารางที่ 4.10 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	65650.53	65409.97
36	50167.33	59927.16
RMSE	18154.42	



รูปที่ 4.10 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Moving Average จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.10 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 18154.42 กิโลวัตต์(kWh)

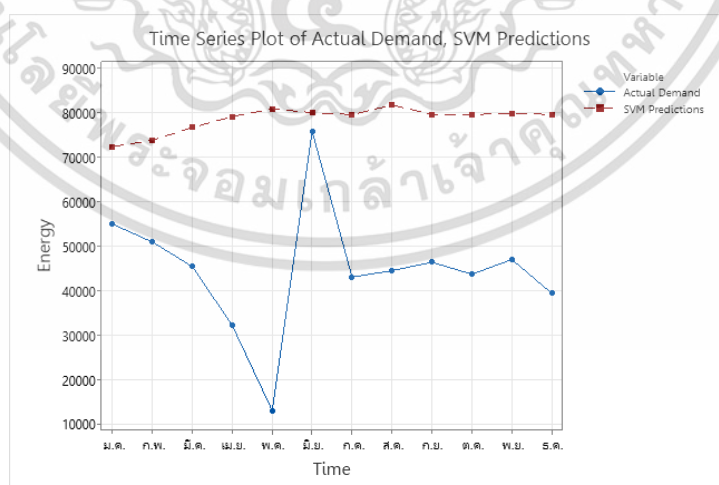
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)

## 4.1.11) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.11 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	72323.38
26	50930.48	73772.26
27	45405.72	76639.58
28	32200.29	79088.31
29	13089.76	80815.46
30	75824.77	79981.48
31	43033.89	79536.35
32	44500.25	81663.53
33	46391.25	79615.40
34	43682.47	79522.48
35	46997.44	79852.11
36	39409.80	79543.46
RMSE		36961.66



รูปที่ 4.11 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ประโยชน์ในการศึกษาวิจัยเท่านั้น ไม่สามารถนำข้อมูลไปใช้ประโยชน์อื่นใดได้โดยไม่ได้รับอนุญาตจากเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่า รูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.11 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 36961.66 กิโลวัตต์ชั่วโมง (kWh)

#### 4.1.12) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.12 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	68867.55
26	50930.48	63893.59
27	45405.72	64290.18
28	32200.29	64795.27
29	13089.76	64795.27
30	75824.77	64795.27
31	43033.89	62929.51
32	44500.25	66843.85
33	46391.25	64795.27
34	43682.47	64795.27
35	46997.44	64795.27
36	39409.80	64795.27
RMSE	24523.53	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.12 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่า รูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.12 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 24523.53 กิโลวัตต์ชั่วโมง (kWh)

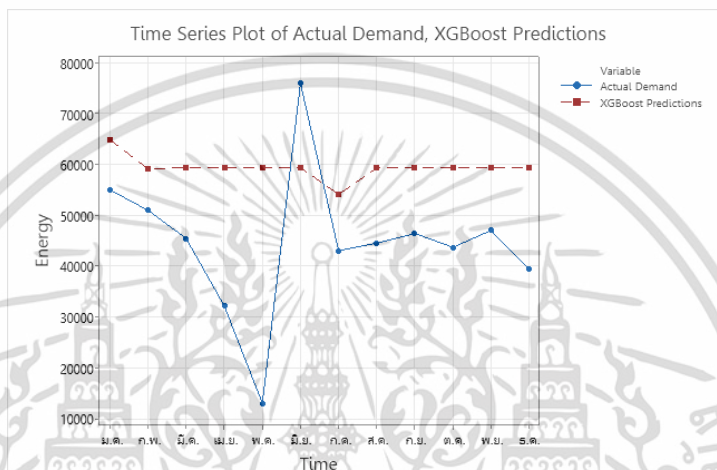
#### 4.1.13) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.13 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	64788.37
26	50930.48	59061.82
27	45405.72	59326.05
28	32200.29	59326.05
29	13089.76	59326.05
30	75824.77	59326.05
31	43033.89	54052.73
32	44500.25	59229.97
33	46391.25	59326.05
34	43682.47	59326.05

ตารางที่ 4.13 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	46997.44	59326.05
36	39409.80	59326.05
RMSE	20003.57	



รูปที่ 4.13 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

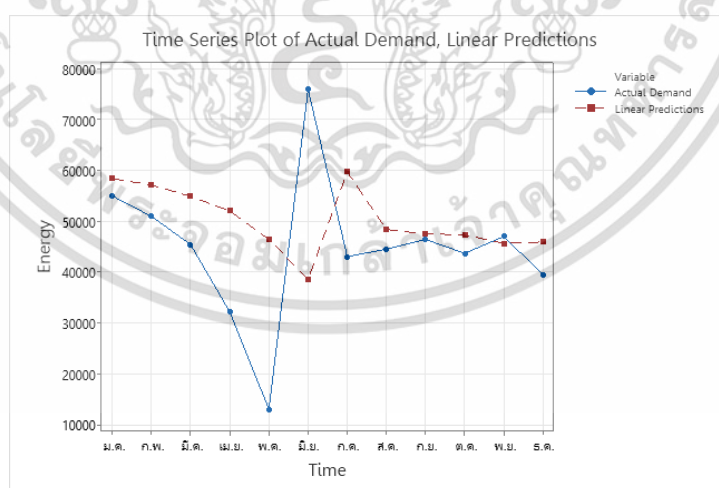
จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.13 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 20003.57 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.14) ผลการพยากรณ์ของแบบจำลอง Linear Regression

ตารางที่ 4.14 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	58325.59
26	50930.48	57091.55
27	45405.72	54847.13
28	32200.29	52002.71
29	13089.76	46411.27
30	75824.77	38589.64
31	43033.89	59640.78
32	44500.25	48352.62
33	46391.25	47461.62
34	43682.47	47342.33
35	46997.44	45602.05
36	39409.80	45911.23
RMSE		16775.1



รูปที่ 4.14 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Linear Regression จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.14 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 16775.1 กิโลวัตต์ชั่วโมง (kWh)

#### 4.1.15) ผลการพยากรณ์ของแบบจำลอง Moving Average

ตารางที่ 4.15 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	0.00
26	50930.48	0.00
27	45405.72	50426.09
Time	Testing	Predictions
28	32200.29	42845.50
29	13089.76	30231.92
30	75824.77	40371.61
31	43033.89	43982.81
32	44500.25	54452.97
33	46391.25	44641.80
34	43682.47	44857.99
35	46997.44	45690.39
36	39409.80	43363.24
RMSE		13457.50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.15 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Moving Average จะพบว่าเมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.15 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 13457.50 กิโลวัตต์ชั่วโมง (kWh)

#### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh)


##### 4.1.16) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.16 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	65034.11
26	35525.58	70886.07
27	30442.47	70152.41
28	41734.50	68644.41
29	10723.77	67669.09
30	54508.45	65233.23
31	41257.26	63934.10
32	39198.09	67705.33
33	37113.00	67345.88

ตารางที่ 4.16 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
34	43793.91	66575.09
35	32200.02	65937.18
36	38478.86	65630.17
RMSE	32001.06	



รูปที่ 4.16 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

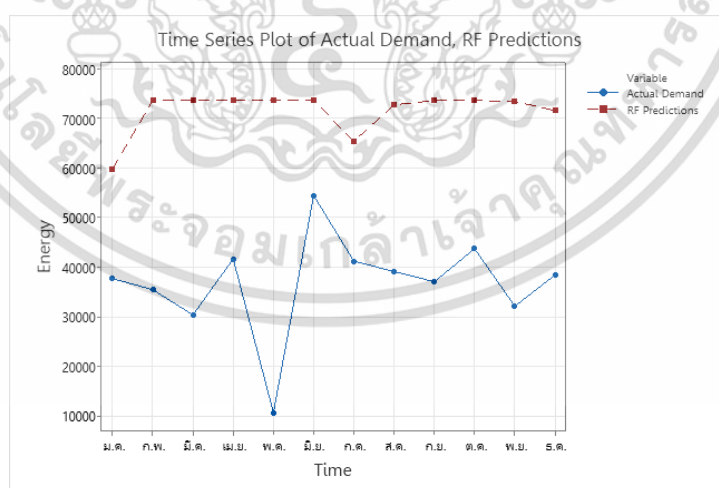
จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.16 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 32001.06 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.17) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.17 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	59889.67
26	35525.58	73671.10
27	30442.47	73671.10
28	41734.50	73671.10
29	10723.77	73671.10
30	54508.45	73671.10
31	41257.26	65482.92
32	39198.09	72786.11
33	37113.00	73671.10
34	43793.91	73671.10
35	32200.02	73483.23
36	38478.86	71609.29
RMSE	37098.07	



รูปที่ 4.17 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.17 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 37098.07 กิโลวัตต์ชั่วโมง (kWh)

#### 4.1.18) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.18 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	53476.83
26	35525.58	79502.18
27	30442.47	60717.49
28	41734.50	60717.49
29	10723.77	60717.49
30	54508.45	60717.49
31	41257.26	49922.09
32	39198.09	60717.49
33	37113.00	60717.49
34	43793.91	60717.49
35	32200.02	60327.67
36	38478.86	60717.49
RMSE	26869.35	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.18 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.18 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 26869.35 กิโลวัตต์ชั่วโมง (kWh)

#### 4.1.19) ผลการพยากรณ์ของแบบจำลอง Linear Regression


ตารางที่ 4.19 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	59795.50
26	35525.58	61724.20
27	30442.47	65675.99
28	41734.50	66157.57
29	10723.77	65036.33
30	54508.45	65685.76
31	41257.26	66722.13
32	39198.09	56255.03
33	37113.00	59206.70
34	43793.91	59213.03

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านอื่นโดยไม่ได้รับอนุญาต  
ไม่ว่าการใด ๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกไปเผยแพร่และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งในการนำไปใช้

ตารางที่ 4.19 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	32200.02	57965.15
36	38478.86	57036.38
RMSE	27016.16	



รูปที่ 4.19 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Linear Regression สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Linear Regression จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือน มกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.19 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 27016.16 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1.20) ผลการพยากรณ์ของแบบจำลอง Moving Average

ตารางที่ 4.20 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	0.00
26	35525.58	0.00
27	30442.47	34573.22
28	41734.50	35900.85
29	10723.77	27633.58
30	54508.45	35655.57
31	41257.26	35496.49
32	39198.09	44987.93
33	37113.00	39189.45
34	43793.91	40035.00
35	32200.02	37702.31
36	38478.86	38157.60
RMSE		8988.86



รูปที่ 4.20 ผลการพยากรณ์ก่อนปรับของแบบจำลอง Moving Average สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Moving Average ก่อนการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้าไม่มีความใกล้เคียงกันดังรูปที่ 4.20 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 8988.86 กิโลวัตต์ชั่วโมง (kWh)

## 4.2 ผลการวิเคราะห์ปริมาณการใช้พลังงานไฟฟ้าหลังการปรับแต่งพารามิเตอร์


### ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)

#### 4.2.1) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.21 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	452.77
26	377.26	401.22
27	283.79	385.72
28	307.49	316.27
29	116.76	381.81
30	498.80	500.27
31	355.33	500.17
32	331.38	370.36
33	396.15	314.78
34	356.59	384.67
35	354.30	361.76
36	341.34	338.46
RMSE	99.16	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.21 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.21 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 99.16 กิโลวัตต์ (kW)

#### 4.2.2) ผลการพยากรณ์ของแบบจำลอง Random Forest


ตารางที่ 4.22 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	494.01
26	377.26	466.42
27	283.79	466.40
28	307.49	466.40
29	116.76	466.40
30	498.80	466.40
31	355.33	491.35
32	331.38	447.85
33	396.15	466.40
34	356.59	466.40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่าการใด ๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.22 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	354.30	466.40
36	341.34	466.40
RMSE	153.34	



รูปที่ 4.22 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.22 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 153.34 กิโลวัตต์ (kW)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2.3) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.23 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	370.77	418.42
26	377.26	407.66
27	283.79	407.66
28	307.49	407.66
29	116.76	407.66
30	498.80	407.66
31	355.33	407.66
32	331.38	407.66
33	396.15	407.66
34	356.59	407.66
35	354.30	407.66
36	341.34	407.66
RMSE		108.03



รูปที่ 4.23 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.23 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 108.03 กิโลวัตต์ (kW)


#### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh)

#### 4.2.4) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.24 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	69978.97
26	53759.95	55700.33
27	43599.81	62354.24
28	37537.22	60563.01
29	18866.47	67237.04
30	106082.79	67258.71
31	58924.85	67258.71
32	62205.66	67280.49
33	66615.75	63734.37
34	63963.62	58909.09
35	65650.53	59769.38
36	50167.33	58542.14
RMSE		21051.22

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.24 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่า ค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.24 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 21051.22 กิโลวัตต์ชั่วโมง (kWh)


#### 4.2.5) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.25 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	66779.39
26	53759.95	58298.21
27	43599.81	62884.36
28	37537.22	58086.15
Time	Testing	Predictions
29	18866.47	62670.69
30	106082.79	62670.69
31	58924.85	68497.75
32	62205.66	78145.44
33	66615.75	70880.72

ตารางที่ 4.25 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
34	63963.62	63544.96
35	65650.53	65262.54
36	50167.33	64401.60
RMSE	21265.51	



รูปที่ 4.25 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.25 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 21265.51 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2.6) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.26 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	51234.32	57754.27
26	53759.95	54936.30
27	43599.81	54936.30
28	37537.22	54936.30
29	18866.47	54936.30
30	106082.79	54936.30
31	58924.85	55500.36
32	62205.66	58915.50
33	66615.75	59105.56
34	63963.62	57692.73
35	65650.53	58637.42
36	50167.33	58637.42
RMSE	19645.48	



รูปที่ 4.26 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.26 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 19645.48 กิโลวัตต์ชั่วโมง (kWh)


#### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)

##### 4.2.7) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.27 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	67746.68
26	50930.48	70929.71
27	45405.72	74403.10
28	32200.29	75650.30
29	13089.76	75549.14
30	75824.77	75547.73
31	43033.89	75547.73
32	44500.25	71532.37
33	46391.25	75543.95
34	43682.47	75525.11
35	46997.44	75568.12
36	39409.80	75516.20
RMSE	32870.46	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.27 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.27 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 32870.46 กิโลวัตต์ชั่วโมง (kWh)


#### 4.2.8) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.28 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	70435.10
26	50930.48	63355.17
27	45405.72	63707.60
28	32200.29	64144.53
29	13089.76	64144.53
30	75824.77	64144.53
31	43033.89	61413.45
32	44500.25	67276.65
33	46391.25	64144.53
34	43682.47	64144.53

ตารางที่ 4.28 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	46997.44	64144.53
36	39409.80	64144.53
RMSE	24133.48	



รูปที่ 4.28 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566


จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.28 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 24133.48 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2.9) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.29 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	54942.07	59953.32
26	50930.48	56078.74
27	45405.72	56078.74
28	32200.29	56078.74
29	13089.76	56078.74
30	75824.77	56078.74
31	43033.89	53632.62
32	44500.25	58542.00
33	46391.25	56078.74
34	43682.47	56078.74
35	46997.44	56078.74
36	39409.80	56078.74
RMSE	18006.97	



รูปที่ 4.29 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.29 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 18006.97 กิโลวัตต์ชั่วโมง (kWh)


#### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh)

##### 4.2.10) ผลการพยากรณ์ของแบบจำลอง Support Vector Machines

ตารางที่ 4.30 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	63182.52
26	35525.58	62858.53
27	30442.47	62685.54
28	41734.50	62682.60
29	10723.77	62682.57
30	54508.45	62682.48
31	41257.26	62682.48
32	39198.09	62682.63
33	37113.00	62682.50
34	43793.91	62682.48
35	32200.02	62682.48
36	38478.86	62682.48
RMSE	27650.99	

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.30 ผลการพยากรณ์หลังปรับของแบบจำลอง Support Vector Machines สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Support Vector Machines หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่า ค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.30 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 27650.99 กิโลวัตต์ชั่วโมง (kWh)


#### 4.2.11) ผลการพยากรณ์ของแบบจำลอง Random Forest

ตารางที่ 4.31 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	59624.98
26	35525.58	71853.93
27	30442.47	74332.09
28	41734.50	74332.09
29	10723.77	74332.09
30	54508.45	74332.09
31	41257.26	65466.08
32	39198.09	71853.93
33	37113.00	74332.09
34	43793.91	74332.09

ตารางที่ 4.31 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566 (ต่อ)

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
35	32200.02	73581.73
36	38478.86	70539.87
RMSE	36442.6	



รูปที่ 4.31 ผลการพยากรณ์หลังปรับของแบบจำลอง Random Forest สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

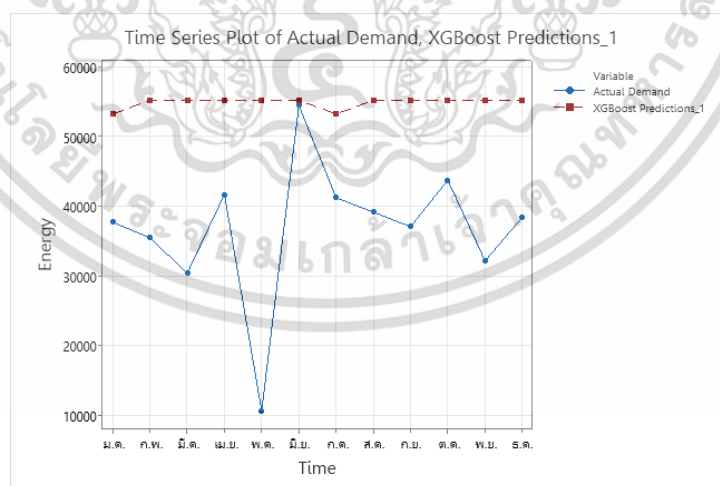
จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Random Forest หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.31 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 36442.6 กิโลวัตต์ชั่วโมง (kWh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2.12) ผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting

ตารางที่ 4.32 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

Time	ข้อมูลชุดทดสอบ	ค่าทำนาย
25	37751.61	53272.57
26	35525.58	55235.19
27	30442.47	55235.19
28	41734.50	55235.19
29	10723.77	55235.19
30	54508.45	55235.19
31	41257.26	53272.57
32	39198.09	55235.19
33	37113.00	55235.19
34	43793.91	55235.19
35	32200.02	55235.19
36	38478.86	55235.19
RMSE	19841.15	



รูปที่ 4.32 ผลการพยากรณ์หลังปรับของแบบจำลอง Extreme Gradient Boosting สำหรับข้อมูลชุดทดสอบ เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางและกราฟแสดงผลการพยากรณ์ของแบบจำลอง Extreme Gradient Boosting หลังการปรับแต่งพารามิเตอร์ จะพบว่า เมื่อนำค่าจริงมาทำการเปรียบเทียบกับค่าพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้า ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2565 แสดงให้เห็นว่าค่ารูปแบบการใช้พลังงานไฟฟ้ามีความใกล้เคียงเพิ่มมากขึ้นดังรูปที่ 4.32 โดยมีค่าความแม่นยำที่ได้มาจากการพยากรณ์เมื่อวัดด้วยค่า RMSE เท่ากับ 19841.15 กิโลวัตต์ชั่วโมง (kWh)

#### 4.3 ผลการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)

ตารางที่ 4.33 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

แบบจำลอง	Root Mean Squared Error (RMSE)	
	ก่อนปรับแต่งพารามิเตอร์	หลังปรับแต่งพารามิเตอร์
Support Vector Machines	203.15	99.16
Random Forest	174.21	153.38
Extreme Gradient Boosting	191.79	108.04
Linear Regression	110.68	-
Moving Average	78.26	-

จากตารางจะพบว่า การเปรียบเทียบระหว่างปริมาณการใช้พลังงานไฟฟ้าจริงกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของชุดข้อมูลทดสอบ โดยการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองหลังปรับแต่งพารามิเตอร์ ซึ่งแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average (RMSE = 78.26 กิโลวัตต์ (kW) จากนั้นจะนำตัวแบบที่ดีที่สุดไปพยากรณ์ 1 ปีข้างหน้า

### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh)

ตารางที่ 4.34 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

แบบจำลอง	Root Mean Squared Error (RMSE)	
	ก่อนปรับแต่งพารามิเตอร์	หลังปรับแต่งพารามิเตอร์
Support Vector Machines	24723.86	21051.22
Random Forest	22752.81	21265.51
Extreme Gradient Boosting	19885.39	19645.48
Linear Regression	22260.76	-
Moving Average	18154.42	-

จากตารางจะพบว่า การเปรียบเทียบระหว่างปริมาณการใช้พลังงานไฟฟ้าจริงกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของชุดข้อมูลทดสอบ โดยการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองหลังปรับแต่งพารามิเตอร์ ซึ่งแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average (RMSE = 18154.42 กิโลวัตต์ชั่วโมง (kWh) จากนั้นจะนำแบบจำลองที่ดีที่สุดไปพยากรณ์ 1 ปีข้างหน้า

### ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)

ตารางที่ 4.35 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

แบบจำลอง	Root Mean Squared Error (RMSE)	
	ก่อนปรับแต่งพารามิเตอร์	หลังปรับแต่งพารามิเตอร์
Support Vector Machines	36961.66	32870.46
Random Forest	24523.53	24133.48
Extreme Gradient Boosting	20003.57	18006.97
Linear Regression	16775.10	-
Moving Average	13457.50	-

จากตารางจะพบว่า การเปรียบเทียบระหว่างปริมาณการใช้พลังงานไฟฟ้าจริงกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของชุดข้อมูลทดสอบ โดยการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองหลังปรับแต่งพารามิเตอร์ ซึ่งแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average (RMSE = 13457.50 กิโลวัตต์ชั่วโมง (kWh) จากนั้นจะนำแบบจำลองที่ดีที่สุดไปพยากรณ์ 1 ปีข้างหน้า

เอกสารนี้เป็นเอกสารสงวนลิขสิทธิ์ ห้ามเผยแพร่โดยไม่ได้รับอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh)

ตารางที่ 4.36 การเปรียบเทียบการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลอง

แบบจำลอง	Root Mean Squared Error (RMSE)	
	ก่อนปรับแต่งพารามิเตอร์	หลังปรับแต่งพารามิเตอร์
Support Vector Machines	32001.06	27650.99
Random Forest	37098.07	36442.60
Extreme Gradient Boosting	26869.35	19841.15
Linear Regression	27016.16	-
Moving Average	8988.86	-

จากตารางจะพบว่า การเปรียบเทียบระหว่างปริมาณการใช้พลังงานไฟฟ้าจริงกับค่าพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของชุดข้อมูลทดสอบ โดยการวัดประสิทธิภาพในการพยากรณ์ของแบบจำลองหลังปรับแต่งพารามิเตอร์ ซึ่งแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average (RMSE = 8988.86 กิโลวัตต์ชั่วโมง (kWh) จากนั้นจะนำแบบจำลองที่ดีที่สุดไปพยากรณ์ 1 ปีข้างหน้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 4.4 ผลการพยากรณ์ล่วงหน้าเป็นระยะเวลา 1 ปี

##### 4.4.1) ผลการพยากรณ์ของข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK

ตารางที่ 4.37 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

Time	SVM	Linear	Moving
37	322.77	362.20	345.66
38	316.48	365.82	347.10
39	331.07	365.08	347.58
40	334.12	361.53	347.74
41	324.23	356.62	347.79
42	320.79	351.00	347.81
43	328.56	345.02	347.82
44	330.55	338.86	347.82
45	324.95	332.60	347.82
46	323.19	326.29	347.82
47	327.55	319.96	347.82
48	328.64	313.61	347.82

จากตารางจะพบว่า ผลการพยากรณ์ของแบบจำลอง Support Vector Machines, Linear Regression และแบบจำลอง Moving Average มาประยุกต์ใช้ในการพยากรณ์ปริมาณพลังงานไฟฟ้าเป็นระยะเวลา 1 ปีหรือ 12 เดือน โดยแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average ซึ่งค่าพยากรณ์ในแต่ละเดือนไม่มีประสิทธิภาพ จึงเลือกใช้แบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยลงมาเป็นอันดับสอง คือ Support Vector Machines จึงนำแบบจำลองการพยากรณ์ที่ได้ไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.4.2) ผลการพยากรณ์ของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK

**ตารางที่ 4.38** ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

Time	SVM	Random	Linear	Moving
37	62654.62	62886.24	65544.42	55328.40
38	70123.33	68835.87	63422.63	57048.75
39	58641.50	61328.89	66707.29	57622.20
40	71252.44	73712.84	66521.95	57813.35
41	58593.89	64386.35	67247.56	57877.07
42	73064.53	69559.32	67270.65	57898.31
43	60273.63	59331.62	67436.68	57905.39
44	73764.23	70126.53	67456.76	57907.75
45	60893.70	64557.47	67496.07	57908.54
46	73799.86	69940.01	67504.13	57908.80
47	60750.04	59331.62	67513.73	57908.89
48	73991.72	70126.53	67516.41	57908.92

จากตารางจะพบว่า ผลการพยากรณ์ของแบบจำลอง Support Vector Machines, Random Forest, Linear Regression และแบบจำลอง Moving Average มาประยุกต์ใช้ในการพยากรณ์ปริมาณพลังงานไฟฟ้าเป็นระยะเวลา 1 ปีหรือ 12 เดือน โดยแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average จึงนำแบบจำลองการพยากรณ์ที่ได้ไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.4.3) ผลการพยากรณ์ของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK

ตารางที่ 4.39 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

Time	SVM	Linear	Moving
37	75570.01	42469.28	41939.01
38	75631.02	42599.50	42782.08
39	65141.62	41885.65	43063.11
40	78352.27	40819.81	43156.78
41	67321.76	39614.01	43188.01
42	74378.39	38352.28	43198.42
43	59821.59	37068.21	43201.89
44	74101.04	35775.21	43203.04
45	61518.03	34478.64	43203.43
46	76776.21	33180.65	43203.56
47	65322.72	31882.09	43203.60
48	77676.99	30583.30	43203.61

จากตารางจะพบว่า ผลการพยากรณ์ของแบบจำลอง Support Vector Machines, Linear Regression และแบบจำลอง Moving Average มาประยุกต์ใช้ในการพยากรณ์ปริมาณพลังงานไฟฟ้าเป็นระยะเวลา 1 ปีหรือ 12 เดือน โดยแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด คือ Moving Average ซึ่งค่าพยากรณ์ในแต่ละเดือนไม่มีประสิทธิภาพ จึงเลือกใช้แบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยลงมาเป็นอันดับสอง คือ Linear Regression ที่สามารถนำแบบจำลองการพยากรณ์ที่ได้ไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

## 4.4.4) ผลการพยากรณ์ของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY

ตารางที่ 4.40 ผลการพยากรณ์ล่วงหน้าของข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh) เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

Time	Linear	Moving
37	58351.88	36385.91
38	53002.38	35688.26
39	47699.24	35455.71
40	49035.49	35378.20
41	49404.42	35352.36
42	48163.04	35343.75
43	47408.20	35340.88
44	47007.68	35340.92
45	46427.98	35340.93
46	45780.70	35340.94
47	45190.36	35340.94
48	44609.63	35340.94

จากตารางจะพบว่า ผลการพยากรณ์ของแบบจำลอง Linear Regression และแบบจำลอง Moving Average มาประยุกต์ใช้ในการพยากรณ์ปริมาณพลังงานไฟฟ้าเป็นระยะเวลา 1 ปีหรือ 12 เดือน โดยแบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุดคือ Moving Average จึงนำแบบจำลองการพยากรณ์ที่ได้ไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

### สรุปผลการวิจัยและข้อเสนอแนะ

งานวิจัยนี้เป็นการศึกษาการประยุกต์ใช้การเรียนรู้ของเครื่อง มาใช้ในการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์ ตั้งแต่เดือนมกราคม ปีพ.ศ. 2564 ถึงเดือนธันวาคม ปีพ.ศ. 2566 ในการสร้างตัวแบบการเรียนรู้ของเครื่องและนำมาเปรียบเทียบหาตัวแบบการเรียนรู้ของเครื่องที่เหมาะสมสำหรับการนำไปใช้พยากรณ์ปริมาณการใช้พลังงานไฟฟ้าล่วงหน้าปีพ.ศ. 2567 เป็นระยะเวลา 1 ปี โดยใช้เกณฑ์ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุด และสามารถนำไปใช้ในการวางแผนการจัดการทรัพยากรในภาคต่ออย่างมีประสิทธิภาพ โดยทางบริษัทสามารถนำไปปรับใช้และหากกลยุทธ์ในการแก้ไขปัญหา จึงสามารถสรุปผลการดำเนินงานและข้อเสนอแนะ ดังต่อไปนี้

#### 5.1 สรุปผลการวิจัย

จากการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์โดยใช้เทคโนโลยีการเรียนรู้ของเครื่อง ได้ทำการศึกษาค้นคว้าปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์ ที่มีปัญหาทางด้านการจัดการพลังงานที่มีแนวโน้มในการใช้พลังงานที่มีความไม่แน่นอน ก่อให้เกิดปัญหาทางด้านการจัดการพลังงานและค่าใช้จ่ายที่สูงจากการจัดการพลังงานที่ไม่แน่นอนขึ้นตามมา จึงได้มีการนำเทคโนโลยีในการเก็บข้อมูลปริมาณการใช้พลังงานไฟฟ้าในวังจันทร์วัลเลย์ และนำข้อมูลมาพยากรณ์ปริมาณการใช้ไฟฟ้าล่วงหน้าปีพ.ศ. 2567 เป็นระยะเวลา 1 ปี เพื่อแสดงให้เห็นถึงปริมาณการใช้พลังงานไฟฟ้าและเห็นพฤติกรรมการใช้ไฟฟ้าในแต่ละเดือน โดยใช้ข้อมูลความต้องการไฟฟ้าในแต่ละเดือน ที่เก็บข้อมูลมาจากระบบ SCADA Software ซึ่งข้อมูลความต้องการทางไฟฟ้าในวังจันทร์วัลเลย์ประกอบด้วย ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) และข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK / OFF PEAK / HOLIDAY (kWh) จากนั้นนำข้อมูลที่นำมาพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าโดยวิธีการเรียนรู้ของเครื่องในการวิเคราะห์ข้อมูลและดำเนินการทดสอบข้อมูลด้วยการเขียนโปรแกรม R โดยตัวแปรที่จะนำมาใช้ในการเรียนรู้ข้อมูลมี 3 ตัวแปร ได้แก่ เวลา (Time), ความต้องการพลังงานไฟฟ้า (kW) และค่าพลังงานไฟฟ้าทั้งหมด (kWh) เพื่อที่จะสร้างแบบจำลองการพยากรณ์ที่มีความเหมาะสมกับชุดข้อมูลมากที่สุด โดยคัดเลือกจากแบบจำลองทั้ง 5 ตัวแบบที่ทางโปรแกรมได้ประมวลผลออกมา ได้แก่ Support Vector Machines, Random Forest, Extreme Gradient Boosting, Linear Regression และแบบจำลอง Moving Average และวัดประสิทธิภาพในการพยากรณ์แบบจำลองที่ให้ค่า RMSE ของข้อมูลชุดทดสอบ (Testing Data) ที่มีค่าน้อยที่สุดจะเป็นตัวแบบที่ดีที่สุด จากนั้นจะนำแบบจำลองที่ดีที่สุดไปพยากรณ์ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ล่วงหน้าเดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567 พบว่าข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW) เหมาะสมกับแบบจำลองซัพพอร์ทเวกเตอร์แมชชีน ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK / HOLIDAY (kWh) เหมาะสมกับแบบจำลองค่าเฉลี่ยเคลื่อนที่ และข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh) เหมาะสมกับแบบจำลองการถดถอยเชิงเส้น ดังตารางต่อไปนี้

ตารางที่ 5.1 พยากรณ์ปริมาณการใช้พลังงานไฟฟ้า เดือนมกราคมถึงเดือนธันวาคม ปีพ.ศ. 2567

Time	DEMAND	ENERGY CONSUMED		
	ON PEAK (kW)	ON PEAK (kWh)	OFF PEAK (kWh)	HOLIDAY (kWh)
ม.ค.	322.77	55328.40	42469.28	36385.91
ก.พ.	316.48	57048.75	42599.50	35688.26
มี.ค.	331.07	57622.20	41885.65	35455.71
เม.ย.	334.12	57813.35	40819.81	35378.20
พ.ค.	324.23	57877.07	39614.01	35352.36
มิ.ย.	320.79	57898.31	38352.28	35343.75
ก.ค.	328.56	57905.39	37068.21	35340.88
ส.ค.	330.55	57907.75	35775.21	35340.92
ก.ย.	324.95	57908.54	34478.64	35340.93
ต.ค.	323.19	57908.80	33180.65	35340.94
พ.ย.	327.55	57908.89	31882.09	35340.94
ธ.ค.	328.64	57908.92	30583.30	35340.94

จากตารางผลการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์โดยใช้เทคโนโลยีการเรียนรู้ของเครื่องจะนำแบบจำลองที่ดีที่สุดไปพยากรณ์ล่วงหน้าปีพ.ศ. 2567 เป็นระยะเวลา 1 ปี ค่าความต้องการพลังงานไฟฟ้าและค่าพลังงานไฟฟ้า สามารถนำไปเป็นแนวทางในการวางแผนความต้องการใช้พลังงานไฟฟ้าอย่างมีประสิทธิภาพ แต่ในส่วนของข้อมูลเกี่ยวกับค่าพลังงานไฟฟ้า พบว่าช่วง 6 เดือนแรก ปริมาณการใช้ไฟฟ้าแต่ละเดือนค่อนข้างต่างกัน เนื่องจากมีจัดค่ายวิทย์ จัดกิจกรรมสันหนนาการ และการรับเสด็จ ซึ่งทำให้ในช่วงนั้นมีการใช้ไฟฟ้าที่สูงขึ้นกว่าปกติ ส่งผลให้เกิดความผิดปกติของข้อมูล แต่ช่วง 6 เดือนหลัง ปริมาณการใช้ไฟฟ้าแต่ละเดือนค่อนข้างคงที่ เนื่องจากไม่มีการจัดกิจกรรม เพราะมีความแปรปรวนของสภาพอากาศ ดังนั้นควรปรับการใช้แบบจำลองที่เหมาะสมเพื่อให้ค่าการพยากรณ์ออกมามีประสิทธิภาพมากขึ้น และสามารถนำไปเป็นแนวทางในการวางแผนเพื่อจัดหาพลังงานไฟฟ้าเพียงพอต่อความต้องการใช้พลังงานไฟฟ้าในอนาคต

เอกสารนี้เป็นเอกสารสงวนไว้สำหรับการใช้งานเพื่อการศึกษาค้นคว้าเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น ยกเว้นที่ มิมีเหตุแต่สงสัยและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีกรนำไปใช้

## 5.2 ข้อเสนอแนะ

1) เนื่องจากปริมาณการใช้พลังงานไฟฟ้าจะสูงขึ้นกว่าปกติ เมื่อมีการจัดกิจกรรม เช่น การจัดค่ายวิทย์ การจัดกิจกรรม สันทนาการ และการรับเสด็จ และไม่ได้มีตารางกิจกรรมแต่ละเดือนที่แน่นอน ส่งผลต่อทำให้ความคลาดเคลื่อนในการพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้าจะสูงกว่าค่าพยากรณ์มากในเดือนที่มีการจัดกิจกรรม

2) แบบจำลองสำหรับพยากรณ์ข้อมูลอนุกรมเวลา บาววิธีต้องการข้อมูลรายเดือน ที่มากกว่า 3 ปี เช่น แบบจำลอง ARIMA ดังนั้น หากรวบรวมข้อมูล รายเดือนได้เกิน 5 ปี ผู้ที่สนใจสามารถพิจารณาให้แบบจำลอง ARIMA



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## เอกสารอ้างอิง

กฤษฎีกุศล กิตตินาถไกรวัฒน์. 2565. การประยุกต์ใช้การเรียนรู้ของเครื่องในการส่งแคมเปญบัญชีเงินฝากดิจิทัล:กรณีศึกษาธนาคารพาณิชย์แห่งหนึ่ง. วิทยาศาสตร์บัณฑิต สาขาสถิติประยุกต์. สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.

ชัยพฤกษ์ นิละนนท์. 2562. การพยากรณ์ปริมาณความต้องการการเหล็กรีดร้อนภายในประเทศด้วยวิธีการเรียนรู้ของเครื่อง. วิศวกรรมศาสตร์ สาขาวิศวกรรมอุตสาหการ. จุฬาลงกรณ์มหาวิทยาลัย.

ธนะวัฒน์ วรณประภา. 2564. การใช้เทคนิคเหมืองข้อมูลเพื่อคัดกรองบุคคลที่มีแนวโน้มสัมฤทธิ์ผลในการศึกษาระดับปริญญาตรี. วิศวกรรมศาสตร์ สาขาวิศวกรรมคอมพิวเตอร์และโทรคมนาคม. มหาวิทยาลัยธุรกิจบัณฑิต.

ธนิตเชษฐ์ คำศรีสุข. 2562. การวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในบ้านสำหรับบ้านอัจฉริยะด้วยวิธีการเหมืองข้อมูล. วิศวกรรมศาสตร์. สาขาวิศวกรรมไฟฟ้า. มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี.

ธนิสา ทวีศรี. 2565. “Carbon neutrality” กับ “net zero emissions” ต่างกันอย่างไร? และมีความสำคัญอย่างไร. [Online]. เข้าถึงได้จาก <https://www.pier.or.th/blog/2022/0301/>.

นรุตม์ สุนทรานนท์. 2566. SVM คือ อะไร. [Online]. เข้าถึงได้จาก <https://www.nerd-data.com/svm/>.

พัชรมนต์ นำวายกอ. 2565. การพยากรณ์การหยุดใช้งานบัตรเครดิตด้วยเทคนิคการเรียนรู้ของเครื่องกรณีศึกษาธนาคารพาณิชย์แห่งหนึ่ง. วิทยาศาสตร์บัณฑิต สาขาสถิติประยุกต์. สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง.

ภาณุเดช คุณชม. 2565. การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วยแบบจำลองการขับเคลื่อนด้วยข้อมูล. วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาการจัดการทางวิศวกรรม. มหาวิทยาลัยธุรกิจบัณฑิต.

วรพงษ์ นาคฉัตรีย์. 2566. ปตท.ลุยภารกิจ Net Zero Emissions ปี 2050 การปล่อยก๊าซเรือนกระจกสุทธิต้องเป็นศูนย์. [Online]. เข้าถึงได้จาก <https://moneyandbanking.co.th/2023/41014/>.

วังจันทร์วัลเลย์. 2565. โครงการพัฒนาพื้นที่วังจันทร์วัลเลย์ คืออะไร. [Online]. เข้าถึงได้จาก เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า <https://www.wangchanvalley.com/th/Home/About>.

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- วีรภัทรา เจริญกิจสุพัฒน์. 2564. การพยากรณ์การเกิดภัยแล้งในประเทศไทยด้วยวิธีการเรียนรู้ของเครื่อง. วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่. มหาวิทยาลัยธุรกิจบัณฑิต.
- สถาบันข้อมูลขนาดใหญ่. 2564. เพิ่มประสิทธิภาพของ Machine Learning Model ด้วย Hyperparameter Optimization. [Online]. เข้าถึงได้จาก <https://bdi.or.th/big-data-101/machine-learning-model-hyperparameter-optimization/>.
- สมาคมโปรแกรมเมอร์ไทย. 2561. อะไรคือ การเรียนรู้ของเครื่อง (Machine Learning). [Online]. เข้าถึงได้จาก <https://www.thaiprogrammer.org/>.
- สุเชษฐ หะเรบุตร. 2565. การพัฒนาการตรวจจับการฉ้อโกงในระบบการเงิน โดยการใช้เทคนิคการเรียนรู้ของเครื่องและการวิเคราะห์ข้อมูลเครือข่าย. วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่. มหาวิทยาลัยธุรกิจบัณฑิต.
- Blog Trade hom. 2022. Moving Average (MA) คืออะไร. [Online]. เข้าถึงได้จาก <https://www.blogtradehoon.com/2021/10/Moving-Average.html>.
- Cyber Elite. 2565. Machine Learning เทคโนโลยีประโยชน์ครบจากรวด. [Online]. เข้าถึงได้จาก <https://www.cyberelite.co.th/blog/machine-learning/>.
- Data Investigator Team. 2566. การวิเคราะห์ข้อมูลถดถอยเชิงเส้น (Linear Regression) คืออะไร. [Online]. เข้าถึงได้จาก <https://www.datainvestigatorth.com/post/what-is-linear-regression-analysis>.
- Depa. 2564. การส่งเสริมเมืองอัจฉริยะ. [Online]. เข้าถึงได้จาก <https://www.depa.or.th/th/smart-city-plan/smart-city-office>
- NPS. 2566. พลังงานไฟฟ้า (ELECTRICAL ENERGY) ความสำคัญของพลังงานไฟฟ้าNPS. [Online]. เข้าถึงได้จาก <https://www.npsplc.com/th/updates/blog/>.
- Sas. 2566. Internet of Things (IoT) นิยามและความสำคัญ. [Online]. เข้าถึงได้จาก [https://www.sas.com/th\\_th/insights/big-data/internet-of-things.html](https://www.sas.com/th_th/insights/big-data/internet-of-things.html).

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก ก

1	#ข้อมูลปริมาณค่าความต้องการพลังงานไฟฟ้าช่วง ON PEAK (kW)
2	# สร้างข้อมูล
3	Yt <- c(560.00,560.00,560.00, 560.00, 560.00, 560.00, 543.75, 509.27,
4	519.86, 534.04,789.21, 645.32, 722.15, 494.35, 499.63, 428.54,
5	411.22, 452.10,448.12, 439.85, 441.96, 590.04, 572.15, 423.54,
6	370.77, 377.26,283.79, 307.49, 116.76, 498.80, 355.33, 331.38,
7	396.15, 356.59,354.30, 341.34)
8	Yt_1 <- c(0,560.00,560.00, 560.00, 560.00, 560.00, 560.00, 543.75, 509.27,
9	519.86, 534.04, 789.21, 645.32, 722.15, 494.35, 499.63, 428.54,
10	411.22, 452.10, 448.12, 439.85, 441.96, 590.04, 572.15, 423.54,
11	370.77, 377.26, 283.79, 307.49, 116.76, 498.80, 355.33, 331.38,
12	396.15, 356.59, 354.30)
13	Yt_2 <- c(0,0,560.00, 560.00, 560.00, 560.00, 560.00, 560.00, 543.75, 509.27,
14	519.86, 534.04, 789.21, 645.32, 722.15, 494.35, 499.63, 428.54,
15	411.22, 452.10, 448.12, 439.85, 441.96, 590.04, 572.15, 423.54,
16	370.77, 377.26, 283.79, 307.49, 116.76, 498.80, 355.33, 331.38,
17	396.15, 356.59)
18	time =c(1:36)
19	# สร้างข้อมูลเป็น data frame
20	data <- data.frame(Yt, Yt_1, Yt_2, time)
21	
22	# 1. แบ่งข้อมูลเป็นชุดการฝึกและชุดทดสอบ
23	training_set <- data[3:24,]
24	testing_set = data[25:36,]
25	
26	library(e1071)
27	# 2.1 สร้างโมเดล Support Vector Machine
28	svm_model <- svm(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
29	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

30 svm_predictions <- predict(svm_model, newdata = testing_set)
31 svm_predictions
32
33 # 4. ประเมินประสิทธิภาพของโมเดล
34 RMSE_svm <- sqrt(mean((svm_predictions - testing_set$Yt)^2))
35 RMSE_svm
36
37 library(ggplot2)
38 # สร้างข้อมูลสำหรับกราฟ
39 comparison_data <- data.frame(
40   time = testing_set$time,
41   Actual_Demand = testing_set$Yt,
42   SVM_Predictions = svm_predictions
43 )
44
45 # สร้างกราฟเปรียบเทียบ
46 ggplot(comparison_data, aes(x = time)) +
47   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
48   geom_line(aes(y = SVM_Predictions, color = "SVM Predictions"),
49     linetype = "dashed", size = 1) +
50   labs(title = "Comparison of Actual Demand vs SVM Predictions",
51     x = "Time",
52     y = "Demand") +
53   scale_color_manual(values = c("Actual Demand" = "blue",
54     "SVM Predictions" = "red")) +
55   theme_minimal()
56
57
58 library(randomForest)
59 # 2.3 สร้างโมเดล Random Forests
60 rf_model <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
61 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

```

62 rf_predictions <- predict(rf_model, newdata = testing_set)
63 rf_predictions
64
65 # 4. ประเมินประสิทธิภาพของโมเดล
66 RMSE_rf <- sqrt(mean((rf_predictions - testing_set$Yt)^2))
67 RMSE_rf
68
69 # เพิ่มข้อมูล Random Forest Predictions เข้าไปใน comparison_data
70 comparison_data$RF_Predictions <- rf_predictions
71
72 # สร้างกราฟเปรียบเทียบ
73 ggplot(comparison_data, aes(x = time)) +
74   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
75   geom_line(aes(y = RF_Predictions, color = "RF Predictions"),
76     linetype = "dashed", size = 1) +
77   labs(title = "Comparison of Actual Demand vs RF Predictions",
78     x = "Time",
79     y = "Demand") +
80   scale_color_manual(values = c("Actual Demand" = "blue",
81     "RF Predictions" = "purple")) +
82   theme_minimal()
83
84
85 library(xgboost)
86 library(caret)
87 # 2.4 สร้างและฝึกโมเดล XGBoost
88 xgb_model <- xgboost(data = as.matrix(training_set[, -1]),
89   label = training_set$Yt, nrounds = 100)
90 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
91 xgb_predictions <- predict(xgb_model, newdata = as.matrix(testing_set[, -1]))
92 xgb_predictions
93

```

94	# 4. ประเมินประสิทธิภาพของโมเดล
95	RMSE_xgb <- sqrt(mean((xgb_predictions - testing_set\$Yt)^2))
96	RMSE_xgb
97	
98	# เพิ่มข้อมูล XGBoost Predictions เข้าไปใน comparison_data
99	comparison_data\$XGB_Predictions <- xgb_predictions
100	
101	# สร้างกราฟเปรียบเทียบ
102	ggplot(comparison_data, aes(x = time)) +
103	geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
104	geom_line(aes(y = XGB_Predictions, color = "XGBoost Predictions"),
105	linetype = "dashed", size = 1) +
106	labs(title = "Comparison of Actual Demand vs XGBoost Predictions",
107	x = "Time",
108	y = "Demand") +
109	scale_color_manual(values = c("Actual Demand" = "blue",
110	"XGBoost Predictions" = "orange")) +
111	theme_minimal()
112	
113	
114	# 2.2 สร้างโมเดล Linear Regression
115	linear_model <- lm(Yt ~ Yt_1 + Yt_2 + time, data = training_set)
116	
117	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล
118	linear_predictions <- predict(linear_model, newdata = testing_set)
119	linear_predictions
120	# 4. ประเมินประสิทธิภาพของโมเดล
121	RMSE_linear <- sqrt(mean((linear_predictions - testing_set\$Yt)^2))
122	RMSE_linear
123	
124	# เพิ่มข้อมูล Linear Regression Predictions เข้าไปใน comparison_data
125	comparison_data\$Linear_Predictions <- linear_predictions

```

126
127 # สร้างกราฟเปรียบเทียบ
128 ggplot(comparison_data, aes(x = time)) +
129   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
130   geom_line(aes(y = Linear_Predictions, color = "Linear Predictions"),
131             linetype = "dashed", size = 1) +
132   labs(title = "Comparison of Actual Demand vs Linear Predictions",
133        x = "Time",
134        y = "Demand") +
135   scale_color_manual(values = c("Actual Demand" = "blue",
136                                "Linear Predictions" = "green")) +
137   theme_minimal()
138
139 #####
140
141 # สร้างโมเดล Support Vector Machine กำหนด kernel = radial และ cost = 100
142 svm_HTmodel <- svm(Yt ~ Yt_1 + Yt_2, data = training_set, kernel = "radial",
143                  cost = 100)
144
145 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
146 svm_HTpredictions <- predict(svm_HTmodel, newdata = testing_set)
147 svm_HTpredictions
148
149 # 4. ประเมินประสิทธิภาพของโมเดล
150 HTRMSE_svm <- sqrt(mean((svm_HTpredictions - testing_set$Yt)^2))
151 HTRMSE_svm
152 # เพิ่มข้อมูล SVM Hyperparameter Tuning Predictions เข้าไปใน comparison_data
153 comparison_data$SVM_HT_Predictions <- svm_HTpredictions
154
155 # สร้างกราฟเปรียบเทียบ
156 ggplot(comparison_data, aes(x = time)) +
157   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +

```

158	geom_line(aes(y = SVM_HT_Predictions, color = "SVM HT Predictions"),
159	linetype = "dashed", size = 1) +
160	labs(title = "Comparison of Actual Demand vs SVM HT Predictions",
161	x = "Time",
162	y = "Demand") +
163	scale_color_manual(values = c("Actual Demand" = "blue",
164	"SVM HT Predictions" = "red")) +
165	theme_minimal()
166	
167	
168	library(randomForest)
169	# สร้างโมเดล Random Forests โดยกำหนดจำนวนต้นไม้เป็น 500
170	rf_HTmodel <- randomForest(Yt ~ Yt_1 + Yt_2 , data = training_set,
171	ntree = 500)
172	
173	# 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า max_depth ต่ำ
174	rf_HTpredictions <- predict(rf_HTmodel, newdata = testing_set)
175	rf_HTpredictions
176	
177	# 4. ประเมินประสิทธิภาพของโมเดล
178	HTRMSE_rf <- sqrt(mean((rf_HTpredictions - testing_set\$Yt)^2))
179	HTRMSE_rf
180	
181	# เพิ่มข้อมูล Random Forest Hyperparameter Tuning Predictions
182	comparison_data\$RF_HT_Predictions <- rf_HTpredictions
183	
184	# สร้างกราฟเปรียบเทียบ
185	ggplot(comparison_data, aes(x = time)) +
186	geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
187	geom_line(aes(y = RF_HT_Predictions, color = "RF HT Predictions"),
188	linetype = "dashed", size = 1) +
189	labs(title = "Comparison of Actual Demand vs RF HT Predictions",
190	

```

190     x = "Time",
191     y = "Demand") +
192     scale_color_manual(values = c("Actual Demand" = "blue",
193                                 "RF HT Predictions" = "purple")) +
194     theme_minimal()
195
196
197 library(xgboost)
198 # สร้างและฝึกโมเดล XGBoost โดยกำหนดพารามิเตอร์
199 xgb_HTmodel <- xgboost(data = as.matrix(training_set[, -1]),
200                       label = training_set$Yt,
201                       nrounds = 200,
202                       eta = 0.01, # อัตราการเรียนรู้
203                       max_depth = 10, # ความลึกของต้นไม้
204                       gamma = 1, # ค่าที่ใช้ในการลดความซับซ้อนของโมเดล
205                       colsample_bytree = 0.01, # สัดส่วนของ feature ที่ใช้ในการสร้างต้นไม้ในแต่ละรอบ
206                       min_child_weight = 5 # ค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้
207                       )
208
209 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า learning rate ต่ำ
210 xgb_HTPredictions <- predict(xgb_HTmodel,
211                             newdata = as.matrix(testing_set[, -1]))
212
213 # 4. ประเมินประสิทธิภาพของโมเดล
214 HTRMSE_xgb <- sqrt(mean((xgb_HTPredictions - testing_set$Yt)^2))
215
216
217 # เพิ่มข้อมูล XGBoost Hyperparameter Tuning Predictions
218 comparison_data$XGB_HT_Predictions <- xgb_HTPredictions
219
220 # สร้างกราฟเปรียบเทียบ
221 ggplot(comparison_data, aes(x = time)) +

```

```

222 geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
223 geom_line(aes(y = XGB_HT_Predictions, color = "XGB HT Predictions"),
224           linetype = "dashed", size = 1) +
225 labs(title = "Comparison of Actual Demand vs XGB HT Predictions",
226       x = "Time",
227       y = "Demand") +
228 scale_color_manual(values = c("Actual Demand" = "blue",
229                               "XGB HT Predictions" = "orange")) +
230 theme_minimal()
231
232 #Linear Regression : ไม่มีการปรับแต่งพารามิเตอร์
233
234 #####
235
236 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า
237 future_data <- data.frame(
238   Yt_1 = 341.34,
239   Yt_2 = 354.30,
240   time = 37
241 )
242 future_data
243 # 1. ทำการพยากรณ์ล่วงหน้า
244 svm_future_HTpredictions <- predict(svm_HTmodel, newdata = future_data)
245 # 2. แสดงผลลัพธ์
246 print(svm_future_HTpredictions)
247
248
249 # 1. ทำการพยากรณ์ล่วงหน้า
250 linear_future_HTpredictions <- predict(linear_model, newdata = future_data)
251 # 2. แสดงผลลัพธ์
252 print(linear_future_HTpredictions)
253

```

```

254 #####
255
256 #Moving Average:ไม่มีการปรับแต่งพารามิเตอร์เหมือนกับโมเดลที่ใช้ในการเรียนรู้เชิงลึก
257 # 2.4 สร้างและฝึกโมเดล Moving Average
258 ma_model <- function(data, window_size) {
259   y <- data$Yt
260   n <- length(y)
261   moving_avg <- rep(0, n)
262   for (i in window_size:n) {
263     moving_avg[i] <- mean(y[(i - window_size + 1):i])
264   }
265   return(moving_avg)
266 }
267
268 # ใช้ฟังก์ชันเพื่อสร้างโมเดล Moving Average ด้วยขนาดหน้าต่างต่าง 3
269 window_size <- 3
270 ma_predictions <- ma_model(testing_set, window_size)
271 ma_predictions
272 # ประเมินประสิทธิภาพของโมเดล Moving Average ด้วยค่า RMSE
273 RMSE_ma <- sqrt(mean((ma_predictions[window_size:length(ma_predictions)]
274   - testing_set$Yt[window_size:length(testing_set$Yt)])^2))
275 RMSE_ma
276
277 # เพิ่มข้อมูล Moving Average Predictions เข้าไปใน testing_set
278 testing_set$MA_Predictions <- ma_predictions
279 # สร้างกราฟเปรียบเทียบ
280 ggplot(testing_set, aes(x = time)) +
282   geom_line(aes(y = Yt, color = "Actual Demand"), size = 1) +
283   geom_line(aes(y = MA_Predictions, color = "Moving Average Predictions"),
284     linetype = "dashed", size = 1) +
285   labs(title = "Comparison of Actual Demand vs Moving Average Predictions",
286     x = "Time", y = "Demand") +

```



## ภาคผนวก ข

1	#ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง ON PEAK (kWh)
2	# สร้างข้อมูล
3	Yt <- c(56800.00, 51200.00, 49600.00, 50400.00, 73600.00, 66400.00,
4	62142.66, 59657.14, 57833.94, 61117.55, 101939.86, 79589.36,
5	88824.65, 55614.93, 70503.35, 48210.19, 65281.54, 70326.79,
6	58752.98, 80693.43, 77588.69, 64904.00, 80418.81, 53295.50,
7	51234.32, 53759.95, 43599.81, 37537.22, 18866.47, 106082.79,
8	58924.85, 62205.66, 66615.75, 63963.62, 65650.53, 50167.33)
9	Yt_1 <- c(0, 56800.00, 51200.00, 49600.00, 50400.00, 73600.00, 66400.00,
10	62142.66, 59657.14, 57833.94, 61117.55, 101939.86, 79589.36,
11	88824.65, 55614.93, 70503.35, 48210.19, 65281.54, 70326.79,
12	58752.98, 80693.43, 77588.69, 64904.00, 80418.81, 53295.50,
13	51234.32, 53759.95, 43599.81, 37537.22, 18866.47, 106082.79,
14	58924.85, 62205.66, 66615.75, 63963.62, 65650.53)
15	Yt_2 <- c(0, 0, 56800.00, 51200.00, 49600.00, 50400.00, 73600.00,
16	66400.00, 62142.66, 59657.14, 57833.94, 61117.55, 101939.86,
17	79589.36, 88824.65, 55614.93, 70503.35, 48210.19, 65281.54,
18	time =c(1:36)
19	# สร้างข้อมูลเป็น data frame
20	data <- data.frame(Yt, Yt_1, Yt_2, time)
21	
22	# 1. แบ่งข้อมูลเป็นชุดการฝึกและชุดทดสอบ
23	training_set <- data[3:24,]
24	testing_set = data[25:36,]
25	
26	library(e1071)
27	# 2.1 สร้างโมเดล Support Vector Machine
28	svm_model <- svm(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
29	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

30 svm_predictions <- predict(svm_model, newdata = testing_set)
31 svm_predictions
32
33 # 4. ประเมินประสิทธิภาพของโมเดล
34 RMSE_svm <- sqrt(mean((svm_predictions - testing_set$Yt)^2))
35 RMSE_svm
36
37 library(ggplot2)
38 # สร้างข้อมูลสำหรับกราฟ
39 comparison_data <- data.frame(
40   time = testing_set$time,
41   Actual_Energy = testing_set$Yt,
42   SVM_Predictions = svm_predictions
43 )
44
45 # สร้างกราฟเปรียบเทียบ
46 ggplot(comparison_data, aes(x = time)) +
47   geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
48   geom_line(aes(y = SVM_Predictions, color = "SVM Predictions"),
49     linetype = "dashed", size = 1) +
50   labs(title = "Comparison of Actual Energy vs SVM Predictions",
51     x = "Time",
52     y = "Energy") +
53   scale_color_manual(values = c("Actual Energy " = "blue",
54     "SVM Predictions" = "red")) +
55   theme_minimal()
56
57
58 library(randomForest)
59 # 2.3 สร้างโมเดล Random Forests
60 rf_model <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
61 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

```

62 rf_predictions <- predict(rf_model, newdata = testing_set)
63 rf_predictions
64
65 # 4. ประเมินประสิทธิภาพของโมเดล
66 RMSE_rf <- sqrt(mean((rf_predictions - testing_set$Yt)^2))
67 RMSE_rf
68
69 # เพิ่มข้อมูล Random Forest Predictions เข้าไปใน comparison_data
70 comparison_data$RF_Predictions <- rf_predictions
71
72 # สร้างกราฟเปรียบเทียบ
73 ggplot(comparison_data, aes(x = time)) +
74   geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
75   geom_line(aes(y = RF_Predictions, color = "RF Predictions"),
76     linetype = "dashed", size = 1) +
77   labs(title = "Comparison of Actual Energy vs RF Predictions",
78     x = "Time",
79     y = "Energy ") +
80   scale_color_manual(values = c("Actual Energy " = "blue",
81     "RF Predictions" = "purple")) +
82   theme_minimal()
83
84
85 library(xgboost)
86 library(caret)
87 # 2.4 สร้างและฝึกโมเดล XGBoost
88 xgb_model <- xgboost(data = as.matrix(training_set[, -1]),
89   label = training_set$Yt, nrounds = 100)
90 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
91 xgb_predictions <- predict(xgb_model, newdata = as.matrix(testing_set[, -1]))
92 xgb_predictions
93

```

94	# 4. ประเมินประสิทธิภาพของโมเดล
95	RMSE_xgb <- sqrt(mean((xgb_predictions - testing_set\$Yt)^2))
96	RMSE_xgb
97	
98	# เพิ่มข้อมูล XGBoost Predictions เข้าไปใน comparison_data
99	comparison_data\$XGB_Predictions <- xgb_predictions
100	
101	# สร้างกราฟเปรียบเทียบ
102	ggplot(comparison_data, aes(x = time)) +
103	geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
104	geom_line(aes(y = XGB_Predictions, color = "XGBoost Predictions"),
105	linetype = "dashed", size = 1) +
106	labs(title = "Comparison of Actual Energy vs XGBoost Predictions",
107	x = "Time",
108	y = " Energy ") +
109	scale_color_manual(values = c("Actual Energy " = "blue",
110	"XGBoost Predictions" = "orange")) +
111	theme_minimal()
112	
113	
114	# 2.2 สร้างโมเดล Linear Regression
115	linear_model <- lm(Yt ~ Yt_1 + Yt_2 + time, data = training_set)
116	
117	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล
118	linear_predictions <- predict(linear_model, newdata = testing_set)
119	linear_predictions
120	# 4. ประเมินประสิทธิภาพของโมเดล
121	RMSE_linear <- sqrt(mean((linear_predictions - testing_set\$Yt)^2))
122	RMSE_linear
123	
124	# เพิ่มข้อมูล Linear Regression Predictions เข้าไปใน comparison_data
125	comparison_data\$Linear_Predictions <- linear_predictions

```

126
127 # สร้างกราฟเปรียบเทียบ
128 ggplot(comparison_data, aes(x = time)) +
129   geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
130   geom_line(aes(y = Linear_Predictions, color = "Linear Predictions"),
131             linetype = "dashed", size = 1) +
132   labs(title = "Comparison of Actual Energy vs Linear Predictions",
133        x = "Time",
134        y = " Energy ") +
135   scale_color_manual(values = c("Actual Energy " = "blue",
136                                "Linear Predictions" = "green")) +
137   theme_minimal()
138
139 #####
140
141 # สร้างโมเดล Support Vector Machine และปรับพารามิเตอร์
142 svm_HTmodel <- svm(Yt ~ Yt_1 + Yt_2 , data = training_set, kernel = "radial",
143                   cost = 1, gamma = 3)
144
145 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
146 svm_HTpredictions <- predict(svm_HTmodel, newdata = testing_set)
147 svm_HTpredictions
148
149 # 4. ประเมินประสิทธิภาพของโมเดล
150 HTRMSE_svm <- sqrt(mean((svm_HTpredictions - testing_set$Yt)^2))
151 HTRMSE_svm
152 # เพิ่มข้อมูล SVM Hyperparameter Tuning Predictions เข้าไปใน comparison_data
153 comparison_data$SVM_HT_Predictions <- svm_HTpredictions
154
155 # สร้างกราฟเปรียบเทียบ
156 ggplot(comparison_data, aes(x = time)) +
157   geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +

```

```

158 geom_line(aes(y = SVM_HT_Predictions, color = "SVM HT Predictions"),
159           linetype = "dashed", size = 1) +
160 labs(title = "Comparison of Actual Energy vs SVM HT Predictions",
161       x = "Time",
162       y = " Energy ") +
163 scale_color_manual(values = c("Actual Energy " = "blue",
164                               "SVM HT Predictions" = "red")) +
165 theme_minimal()
166
167
168 library(randomForest)
169 # สร้างโมเดล Random Forests โดยกำหนดจำนวนต้นไม้เป็น 500
170 rf_HTmodel <- randomForest(Yt ~ Yt_1 + Yt_2 , data = training_set,
171                             ntree = 500)
172
173 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า max_depth ต่ำ
174 rf_HTpredictions <- predict(rf_HTmodel, newdata = testing_set)
175 rf_HTpredictions
176
177 # 4. ประเมินประสิทธิภาพของโมเดล
178 HTRMSE_rf <- sqrt(mean((rf_HTpredictions - testing_set$Yt)^2))
179 HTRMSE_rf
180
181 # เพิ่มข้อมูล Random Forest Hyperparameter Tuning Predictions
182 comparison_data$RF_HT_Predictions <- rf_HTpredictions
183
184 # สร้างกราฟเปรียบเทียบ
185 ggplot(comparison_data, aes(x = time)) +
186   geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
187   geom_line(aes(y = RF_HT_Predictions, color = "RF HT Predictions"),
188           linetype = "dashed", size = 1) +
189   labs(title = "Comparison of Actual Energy vs RF HT Predictions",

```

```

190     x = "Time",
191     y = " Energy ") +
192     scale_color_manual(values = c("Actual Energy " = "blue",
193                               "RF HT Predictions" = "purple")) +
194     theme_minimal()
195
196
197 library(xgboost)
198 # สร้างและฝึกโมเดล XGBoost โดยกำหนดพารามิเตอร์
199 xgb_HTmodel <- xgboost(data = as.matrix(training_set[, -1]),
200                       label = training_set$Yt,
201                       nrounds = 200,
202                       eta = 0.01, # อัตราการเรียนรู้
203                       max_depth = 10, # ความลึกของต้นไม้
204                       gamma = 1, # ค่าที่ใช้ในการลดความซับซ้อนของโมเดล
205                       colsample_bytree = 0.01, # สัดส่วนของ feature ที่ใช้ในการสร้างต้นไม้ในแต่ละรอบ
206                       min_child_weight = 5 # ค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้
207                       )
208
209 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า learning rate ต่ำ
210 xgb_HTPredictions <- predict(xgb_HTmodel,
211                             newdata = as.matrix(testing_set[, -1]))
212 xgb_HTPredictions
213 # 4. ประเมินประสิทธิภาพของโมเดล
214 HTRMSE_xgb <- sqrt(mean((xgb_HTPredictions - testing_set$Yt)^2))
215 HTRMSE_xgb
216
217 # เพิ่มข้อมูล XGBoost Hyperparameter Tuning Predictions
218 comparison_data$XGB_HT_Predictions <- xgb_HTPredictions
219
220 # สร้างกราฟเปรียบเทียบ
221 ggplot(comparison_data, aes(x = time)) +

```

```

222 geom_line(aes(y = Actual_Energy, color = "Actual Energy "), size = 1) +
223 geom_line(aes(y = XGB_HT_Predictions, color = "XGB HT Predictions"),
224           linetype = "dashed", size = 1) +
225 labs(title = "Comparison of Actual Energy vs XGB HT Predictions",
226       x = "Time",
227       y = " Energy ") +
228 scale_color_manual(values = c("Actual Energy " = "blue",
229                               "XGB HT Predictions" = "orange")) +
230 theme_minimal()
231
232 #Linear Regression : ไม่มีการปรับแต่งพารามิเตอร์
233
234 #####
235
236 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า
237 future_data <- data.frame(
238   Yt_1 = 50167.33,
239   Yt_2 = 65650.53,
240   time = 37
241 )
242 future_data
243 # 1. ทำการพยากรณ์ล่วงหน้า
244 svm_future_HTpredictions <- predict(svm_HTmodel, newdata = future_data)
245 # 2. แสดงผลลัพธ์
246 print(svm_future_HTpredictions)
247
248 # 1. ทำการพยากรณ์ล่วงหน้า
249 rf_future_HTpredictions <- predict(rf_HTmodel, newdata = future_data)
250 # 2. แสดงผลลัพธ์
251 print(rf_future_HTpredictions)
252
253

```

```

254 # 1. ทำการพยากรณ์ล่วงหน้า
255 linear_future_HTpredictions <- predict(linear_model, newdata = future_data)
256 # 2. แสดงผลลัพธ์
257 print(linear_future_HTpredictions)
258
259 #####
260
261 #Moving Average:ไม่มีการปรับแต่งพารามิเตอร์เหมือนกับโมเดลที่ใช้ในการเรียนรู้เชิงลึก
262 # 2.4 สร้างและฝึกโมเดล Moving Average
263 ma_model <- function(data, window_size) {
264   y <- data$Yt
265   n <- length(y)
266   moving_avg <- rep(0, n)
267   for (i in window_size:n) {
268     moving_avg[i] <- mean(y[(i - window_size + 1):i])
269   }
270   return(moving_avg)
271 }
272 # ใช้ฟังก์ชันเพื่อสร้างโมเดล Moving Average ด้วยขนาดหน้าต่าง 3
273 window_size <- 3
274 ma_predictions <- ma_model(testing_set, window_size)
275 ma_predictions
276
277 # ประเมินประสิทธิภาพของโมเดล Moving Average ด้วยค่า RMSE
278 RMSE_ma <- sqrt(mean((ma_predictions[window_size:length(ma_predictions)]
279   - testing_set$Yt[window_size:length(testing_set$Yt)])^2))
280 RMSE_ma
282
283 # เพิ่มข้อมูล Moving Average Predictions เข้าไปใน testing_set
284 testing_set$MA_Predictions <- ma_predictions
285 # สร้างกราฟเปรียบเทียบ
286 ggplot(testing_set, aes(x = time)) +

```

```

287 geom_line(aes(y = Yt, color = "Actual Energy "), size = 1) +
288 geom_line(aes(y = MA_Predictions, color = "Moving Average Predictions"),
289           linetype = "dashed", size = 1) +
290 labs(title = "Comparison of Actual Energy vs Moving Average Predictions",
291       x = "Time", y = " Energy ") +
292 scale_color_manual(values = c("Actual Energy " = "blue",
293                               "Moving Average Predictions" = "gray")) +
294 theme_minimal()
295
296 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า
297 future_data <- data.frame(
298   Yt_1 = 50167.33,
299   Yt_2 = 65650.53,
300   time = 37
301 )
302 future_data
303 # ฟังก์ชันทำนายค่า Moving Average สำหรับข้อมูลในอนาคต
304 ma_future_predictions <- function(data, window_size, future_data) {
305   # คำนวณค่าเฉลี่ยเคลื่อนที่จากข้อมูลในอนาคต
306   y <- c(data$Yt, future_data$Yt_1)
307   n <- length(y)
308   moving_avg <- rep(0, n)
309   for (i in (n - window_size + 1):n) {
309     moving_avg[i] <- mean(y[(i - window_size + 1):i])
310   }
311   return(moving_avg[n])
312 }
313
314 # ใช้ฟังก์ชันเพื่อทำนายค่า Moving Average สำหรับข้อมูลในอนาคต
315 future_ma_prediction <- ma_future_predictions(data, window_size,
316                                               future_data)
317 future_ma_prediction

```

## ภาคผนวก ค

1	#ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง OFF PEAK (kWh)
2	# สร้างข้อมูล
3	Yt <- c(77600.00, 81600.00, 74400.00, 66400.00, 83200.00, 92000.00,
4	87776.50, 83665.51, 70180.51, 64677.79, 109831.98, 106119.15,
5	114822.10, 67355.86, 77165.09, 53031.21, 62711.40, 63796.45,
6	52280.20, 72819.85, 71204.81, 58582.18, 69293.68, 55413.20,
7	54942.07, 50930.48, 45405.72, 32200.29, 13089.76, 75824.77,
8	43033.89, 44500.25, 46391.25, 43682.47, 46997.44, 39409.80)
9	Yt_1 <- c(0, 77600.00, 81600.00, 74400.00, 66400.00, 83200.00,
10	92000.00, 87776.50, 83665.51, 70180.51, 64677.79, 109831.98,
11	106119.15, 114822.10, 67355.86, 77165.09, 53031.21, 62711.40,
12	63796.45, 52280.20, 72819.85, 71204.81, 58582.18, 69293.68,
13	55413.20, 54942.07, 50930.48, 45405.72, 32200.29, 13089.76,
14	75824.77, 43033.89, 44500.25, 46391.25, 43682.47, 46997.44)
15	Yt_2 <- c(0, 0, 77600.00, 81600.00, 74400.00, 66400.00, 83200.00,
16	92000.00, 87776.50, 83665.51, 70180.51, 64677.79, 109831.98,
17	106119.15, 114822.10, 67355.86, 77165.09, 53031.21, 62711.40,
18	time =c(1:36)
19	# สร้างข้อมูลเป็น data frame
20	data <- data.frame(Yt, Yt_1, Yt_2, time)
21	
22	# 1. แบ่งข้อมูลเป็นชุดการฝึกและชุดทดสอบ
23	training_set <- data[3:24,]
24	testing_set = data[25:36,]
25	
26	library(e1071)
27	# 2.1 สร้างโมเดล Support Vector Machine
28	svm_model <- svm(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
29	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

30 svm_predictions <- predict(svm_model, newdata = testing_set)
31 svm_predictions
32
33 # 4. ประเมินประสิทธิภาพของโมเดล
34 RMSE_svm <- sqrt(mean((svm_predictions - testing_set$Yt)^2))
35 RMSE_svm
36
37 library(ggplot2)
38 # สร้างข้อมูลสำหรับกราฟ
39 comparison_data <- data.frame(
40   time = testing_set$time,
41   Actual_Demand = testing_set$Yt,
42   SVM_Predictions = svm_predictions
43 )
44
45 # สร้างกราฟเปรียบเทียบ
46 ggplot(comparison_data, aes(x = time)) +
47   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
48   geom_line(aes(y = SVM_Predictions, color = "SVM Predictions"),
49     linetype = "dashed", size = 1) +
50   labs(title = "Comparison of Actual Demand vs SVM Predictions",
51     x = "Time",
52     y = "Demand") +
53   scale_color_manual(values = c("Actual Demand" = "blue",
54     "SVM Predictions" = "red")) +
55   theme_minimal()
56
57
58 library(randomForest)
59 # 2.3 สร้างโมเดล Random Forests
60 rf_model <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
61 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

```

62 rf_predictions <- predict(rf_model, newdata = testing_set)
63 rf_predictions
64
65 # 4. ประเมินประสิทธิภาพของโมเดล
66 RMSE_rf <- sqrt(mean((rf_predictions - testing_set$Yt)^2))
67 RMSE_rf
68
69 # เพิ่มข้อมูล Random Forest Predictions เข้าไปใน comparison_data
70 comparison_data$RF_Predictions <- rf_predictions
71
72 # สร้างกราฟเปรียบเทียบ
73 ggplot(comparison_data, aes(x = time)) +
74   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
75   geom_line(aes(y = RF_Predictions, color = "RF Predictions"),
76     linetype = "dashed", size = 1) +
77   labs(title = "Comparison of Actual Demand vs RF Predictions",
78     x = "Time",
79     y = "Demand") +
80   scale_color_manual(values = c("Actual Demand" = "blue",
81     "RF Predictions" = "purple")) +
82   theme_minimal()
83
84
85 library(xgboost)
86 library(caret)
87 # 2.4 สร้างและฝึกโมเดล XGBoost
88 xgb_model <- xgboost(data = as.matrix(training_set[, -1]),
89   label = training_set$Yt, nrounds = 100)
90 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
91 xgb_predictions <- predict(xgb_model, newdata = as.matrix(testing_set[, -1]))
92 xgb_predictions
93

```

94	# 4. ประเมินประสิทธิภาพของโมเดล
95	RMSE_xgb <- sqrt(mean((xgb_predictions - testing_set\$Yt)^2))
96	RMSE_xgb
97	
98	# เพิ่มข้อมูล XGBoost Predictions เข้าไปใน comparison_data
99	comparison_data\$XGB_Predictions <- xgb_predictions
100	
101	# สร้างกราฟเปรียบเทียบ
102	ggplot(comparison_data, aes(x = time)) +
103	geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
104	geom_line(aes(y = XGB_Predictions, color = "XGBoost Predictions"),
105	linetype = "dashed", size = 1) +
106	labs(title = "Comparison of Actual Demand vs XGBoost Predictions",
107	x = "Time",
108	y = "Demand") +
109	scale_color_manual(values = c("Actual Demand" = "blue",
110	"XGBoost Predictions" = "orange")) +
111	theme_minimal()
112	
113	
114	# 2.2 สร้างโมเดล Linear Regression
115	linear_model <- lm(Yt ~ Yt_1 + Yt_2 + time, data = training_set)
116	
117	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล
118	linear_predictions <- predict(linear_model, newdata = testing_set)
119	linear_predictions
120	# 4. ประเมินประสิทธิภาพของโมเดล
121	RMSE_linear <- sqrt(mean((linear_predictions - testing_set\$Yt)^2))
122	RMSE_linear
123	
124	# เพิ่มข้อมูล Linear Regression Predictions เข้าไปใน comparison_data
125	comparison_data\$Linear_Predictions <- linear_predictions

```

126
127 # สร้างกราฟเปรียบเทียบ
128 ggplot(comparison_data, aes(x = time)) +
129   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
130   geom_line(aes(y = Linear_Predictions, color = "Linear Predictions"),
131             linetype = "dashed", size = 1) +
132   labs(title = "Comparison of Actual Demand vs Linear Predictions",
133         x = "Time",
134         y = "Demand") +
135   scale_color_manual(values = c("Actual Demand" = "blue",
136                                "Linear Predictions" = "green")) +
137   theme_minimal()
138
139 #####
140
141 # สร้างโมเดล Support Vector Machine กำหนด kernel = radial และ cost = 100
142 svm_HTmodel <- svm(Yt ~ Yt_1 + Yt_2, data = training_set, kernel = "radial",
143                   cost = 100)
144
145 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
146 svm_HTpredictions <- predict(svm_HTmodel, newdata = testing_set)
147 svm_HTpredictions
148
149 # 4. ประเมินประสิทธิภาพของโมเดล
150 HTRMSE_svm <- sqrt(mean((svm_HTpredictions - testing_set$Yt)^2))
151 HTRMSE_svm
152 # เพิ่มข้อมูล SVM Hyperparameter Tuning Predictions เข้าไปใน comparison_data
153 comparison_data$SVM_HT_Predictions <- svm_HTpredictions
154
155 # สร้างกราฟเปรียบเทียบ
156 ggplot(comparison_data, aes(x = time)) +
157   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +

```

```

158 geom_line(aes(y = SVM_HT_Predictions, color = "SVM HT Predictions"),
159           linetype = "dashed", size = 1) +
160 labs(title = "Comparison of Actual Demand vs SVM HT Predictions",
161       x = "Time",
162       y = "Demand") +
163 scale_color_manual(values = c("Actual Demand" = "blue",
164                               "SVM HT Predictions" = "red")) +
165 theme_minimal()
166
167
168 library(randomForest)
169 # สร้างโมเดล Random Forests โดยกำหนดจำนวนต้นไม้เป็น 500
170 rf_HTmodel <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set,
171                             ntree = 500)
172
173 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า max_depth ต่ำ
174 rf_HTpredictions <- predict(rf_HTmodel, newdata = testing_set)
175 rf_HTpredictions
176
177 # 4. ประเมินประสิทธิภาพของโมเดล
178 HTRMSE_rf <- sqrt(mean((rf_HTpredictions - testing_set$Yt)^2))
179 HTRMSE_rf
180
181 # เพิ่มข้อมูล Random Forest Hyperparameter Tuning Predictions
182 comparison_data$RF_HT_Predictions <- rf_HTpredictions
183
184 # สร้างกราฟเปรียบเทียบ
185 ggplot(comparison_data, aes(x = time)) +
186   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
187   geom_line(aes(y = RF_HT_Predictions, color = "RF HT Predictions"),
188           linetype = "dashed", size = 1) +
189   labs(title = "Comparison of Actual Demand vs RF HT Predictions",

```

```

190     x = "Time",
191     y = "Demand") +
192     scale_color_manual(values = c("Actual Demand" = "blue",
193                                "RF HT Predictions" = "purple")) +
194     theme_minimal()
195
196
197 library(xgboost)
198 # สร้างและฝึกโมเดล XGBoost โดยกำหนดพารามิเตอร์
199 xgb_HTmodel <- xgboost(data = as.matrix(training_set[, -1]),
200                       label = training_set$Yt,
201                       nrounds = 200,
202                       eta = 0.01, # อัตราการเรียนรู้
203                       max_depth = 10, # ความลึกของต้นไม้
204                       gamma = 1, # ค่าที่ใช้ในการลดความซับซ้อนของโมเดล
205                       colsample_bytree = 0.01, # สัดส่วนของ feature ที่ใช้ในการสร้างต้นไม้ในแต่ละรอบ
206                       min_child_weight = 5 # ค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้
207                       )
208
209 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า learning rate ต่ำ
210 xgb_HTPredictions <- predict(xgb_HTmodel,
211                             newdata = as.matrix(testing_set[, -1]))
212
213 # 4. ประเมินประสิทธิภาพของโมเดล
214 HTRMSE_xgb <- sqrt(mean((xgb_HTPredictions - testing_set$Yt)^2))
215
216
217 # เพิ่มข้อมูล XGBoost Hyperparameter Tuning Predictions
218 comparison_data$XGB_HT_Predictions <- xgb_HTPredictions
219
220 # สร้างกราฟเปรียบเทียบ
221 ggplot(comparison_data, aes(x = time)) +

```

```

222 geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
223 geom_line(aes(y = XGB_HT_Predictions, color = "XGB HT Predictions"),
224           linetype = "dashed", size = 1) +
225 labs(title = "Comparison of Actual Demand vs XGB HT Predictions",
226        x = "Time",
227        y = "Demand") +
228 scale_color_manual(values = c("Actual Demand" = "blue",
229                               "XGB HT Predictions" = "orange")) +
230 theme_minimal()
231
232 #Linear Regression : ไม่มีการปรับแต่งพารามิเตอร์
233
234 #####
235
236 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า
237 future_data <- data.frame(
238   Yt_1 = 39409.80,
239   Yt_2 = 46997.44,
240   time = 37
241 )
242 future_data
243 # 1. ทำการพยากรณ์ล่วงหน้า
244 svm_future_HTpredictions <- predict(svm_HTmodel, newdata = future_data)
245 # 2. แสดงผลลัพธ์
246 print(svm_future_HTpredictions)
247
248 # 1. ทำการพยากรณ์ล่วงหน้า
249 linear_future_HTpredictions <- predict(linear_model, newdata = future_data)
250 # 2. แสดงผลลัพธ์
251 print(linear_future_HTpredictions)
252
253 #####

```

```

254
255 #Moving Average:ไม่มีการปรับแต่งพารามิเตอร์เหมือนกับโมเดลที่ใช้ในการเรียนรู้เชิงลึก
256 # 2.4 สร้างและฝึกโมเดล Moving Average
257 ma_model <- function(data, window_size) {
258   y <- data$Yt
259   n <- length(y)
260   moving_avg <- rep(0, n)
261   for (i in window_size:n) {
262     moving_avg[i] <- mean(y[(i - window_size + 1):i])
263   }
264   return(moving_avg)
265 }
266
267 # ใช้ฟังก์ชันเพื่อสร้างโมเดล Moving Average ด้วยขนาดหน้าต่าง 3
268 window_size <- 3
269 ma_predictions <- ma_model(testing_set, window_size)
270 ma_predictions
271 # ประเมินประสิทธิภาพของโมเดล Moving Average ด้วยค่า RMSE
272 RMSE_ma <- sqrt(mean((ma_predictions[window_size:length(ma_predictions)]
273   - testing_set$Yt[window_size:length(testing_set$Yt)])^2))
274 RMSE_ma
275
276 # เพิ่มข้อมูล Moving Average Predictions เข้าไปใน testing_set
277 testing_set$MA_Predictions <- ma_predictions
278 # สร้างกราฟเปรียบเทียบ
279 ggplot(testing_set, aes(x = time)) +
280   geom_line(aes(y = Yt, color = "Actual Demand"), size = 1) +
282   geom_line(aes(y = MA_Predictions, color = "Moving Average Predictions"),
283     linetype = "dashed", size = 1) +
284   labs(title = "Comparison of Actual Demand vs Moving Average Predictions",
285     x = "Time", y = "Demand") +
286   scale_color_manual(values = c("Actual Demand" = "blue",

```



## ภาคผนวก ง

1	#ข้อมูลปริมาณค่าพลังงานไฟฟ้าช่วง HOLIDAY (kWh)
2	# สร้างข้อมูล
3	Yt <- c(56000.00, 74400.00, 40000.00, 88800.00, 91200.00, 60800.00,
4	72240.84, 65477.35, 51985.56, 67644.66, 76948.15, 83891.49,
5	91713.25, 52525.21, 44411.56, 66958.60, 56543.06, 49228.76,
6	91614.82, 51804.72, 47142.50, 71225.82, 55943.52, 54707.30,
7	37751.61, 35525.58, 30442.47, 41734.50, 10723.77, 54508.45,
8	41257.26, 39198.09, 37113.00, 43793.91, 32200.02, 38478.86)
9	Yt_1 <- c(0, 56000.00, 74400.00, 40000.00, 88800.00, 91200.00, 60800.00,
10	72240.84, 65477.35, 51985.56, 67644.66, 76948.15, 83891.49,
11	91713.25, 52525.21, 44411.56, 66958.60, 56543.06, 49228.76,
12	91614.82, 51804.72, 47142.50, 71225.82, 55943.52, 54707.30,
13	37751.61, 35525.58, 30442.47, 41734.50, 10723.77, 54508.45,
14	41257.26, 39198.09, 37113.00, 43793.91, 32200.02)
15	Yt_2 <- c(0, 0, 56000.00, 74400.00, 40000.00, 88800.00, 91200.00,
16	60800.00, 72240.84, 65477.35, 51985.56, 67644.66, 76948.15,
17	83891.49, 91713.25, 52525.21, 44411.56, 66958.60, 56543.06,
18	time =c(1:36)
19	# สร้างข้อมูลเป็น data frame
20	data <- data.frame(Yt, Yt_1, Yt_2, time)
21	
22	# 1. แบ่งข้อมูลเป็นชุดการฝึกและชุดทดสอบ
23	training_set <- data[3:24,]
24	testing_set = data[25:36,]
25	
26	library(e1071)
27	# 2.1 สร้างโมเดล Support Vector Machine
28	svm_model <- svm(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
29	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

30 svm_predictions <- predict(svm_model, newdata = testing_set)
31 svm_predictions
32
33 # 4. ประเมินประสิทธิภาพของโมเดล
34 RMSE_svm <- sqrt(mean((svm_predictions - testing_set$Yt)^2))
35 RMSE_svm
36
37 library(ggplot2)
38 # สร้างข้อมูลสำหรับกราฟ
39 comparison_data <- data.frame(
40   time = testing_set$time,
41   Actual_Demand = testing_set$Yt,
42   SVM_Predictions = svm_predictions
43 )
44
45 # สร้างกราฟเปรียบเทียบ
46 ggplot(comparison_data, aes(x = time)) +
47   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
48   geom_line(aes(y = SVM_Predictions, color = "SVM Predictions"),
49     linetype = "dashed", size = 1) +
50   labs(title = "Comparison of Actual Demand vs SVM Predictions",
51     x = "Time",
52     y = "Demand") +
53   scale_color_manual(values = c("Actual Demand" = "blue",
54     "SVM Predictions" = "red")) +
55   theme_minimal()
56
57
58 library(randomForest)
59 # 2.3 สร้างโมเดล Random Forests
60 rf_model <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set)
61 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล

```

```

62 rf_predictions <- predict(rf_model, newdata = testing_set)
63 rf_predictions
64
65 # 4. ประเมินประสิทธิภาพของโมเดล
66 RMSE_rf <- sqrt(mean((rf_predictions - testing_set$Yt)^2))
67 RMSE_rf
68
69 # เพิ่มข้อมูล Random Forest Predictions เข้าไปใน comparison_data
70 comparison_data$RF_Predictions <- rf_predictions
71
72 # สร้างกราฟเปรียบเทียบ
73 ggplot(comparison_data, aes(x = time)) +
74   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
75   geom_line(aes(y = RF_Predictions, color = "RF Predictions"),
76     linetype = "dashed", size = 1) +
77   labs(title = "Comparison of Actual Demand vs RF Predictions",
78     x = "Time",
79     y = "Demand") +
80   scale_color_manual(values = c("Actual Demand" = "blue",
81     "RF Predictions" = "purple")) +
82   theme_minimal()
83
84
85 library(xgboost)
86 library(caret)
87 # 2.4 สร้างและฝึกโมเดล XGBoost
88 xgb_model <- xgboost(data = as.matrix(training_set[, -1]),
89   label = training_set$Yt, nrounds = 100)
90 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
91 xgb_predictions <- predict(xgb_model, newdata = as.matrix(testing_set[, -1]))
92 xgb_predictions
93

```

94	# 4. ประเมินประสิทธิภาพของโมเดล
95	RMSE_xgb <- sqrt(mean((xgb_predictions - testing_set\$Yt)^2))
96	RMSE_xgb
97	
98	# เพิ่มข้อมูล XGBoost Predictions เข้าไปใน comparison_data
99	comparison_data\$XGB_Predictions <- xgb_predictions
100	
101	# สร้างกราฟเปรียบเทียบ
102	ggplot(comparison_data, aes(x = time)) +
103	geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
104	geom_line(aes(y = XGB_Predictions, color = "XGBoost Predictions"),
105	linetype = "dashed", size = 1) +
106	labs(title = "Comparison of Actual Demand vs XGBoost Predictions",
107	x = "Time",
108	y = "Demand") +
109	scale_color_manual(values = c("Actual Demand" = "blue",
110	"XGBoost Predictions" = "orange")) +
111	theme_minimal()
112	
113	
114	# 2.2 สร้างโมเดล Linear Regression
115	linear_model <- lm(Yt ~ Yt_1 + Yt_2 + time, data = training_set)
116	
117	# 3. ทำนายข้อมูลในชุดทดสอบโมเดล
118	linear_predictions <- predict(linear_model, newdata = testing_set)
119	linear_predictions
120	# 4. ประเมินประสิทธิภาพของโมเดล
121	RMSE_linear <- sqrt(mean((linear_predictions - testing_set\$Yt)^2))
122	RMSE_linear
123	
124	# เพิ่มข้อมูล Linear Regression Predictions เข้าไปใน comparison_data
125	comparison_data\$Linear_Predictions <- linear_predictions

```

126
127 # สร้างกราฟเปรียบเทียบ
128 ggplot(comparison_data, aes(x = time)) +
129   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
130   geom_line(aes(y = Linear_Predictions, color = "Linear Predictions"),
131             linetype = "dashed", size = 1) +
132   labs(title = "Comparison of Actual Demand vs Linear Predictions",
133         x = "Time",
134         y = "Demand") +
135   scale_color_manual(values = c("Actual Demand" = "blue",
136                                "Linear Predictions" = "green")) +
137   theme_minimal()
138
139 #####
140
141 # สร้างโมเดล Support Vector Machine กำหนด kernel = radial และ cost = 100
142 svm_HTmodel <- svm(Yt ~ Yt_1 + Yt_2 + time, data = training_set,
143                   kernel = "radial", cost = 100)
144
145 # 3. ทำนายข้อมูลในชุดทดสอบโมเดล
146 svm_HTpredictions <- predict(svm_HTmodel, newdata = testing_set)
147 svm_HTpredictions
148
149 # 4. ประเมินประสิทธิภาพของโมเดล
150 HTRMSE_svm <- sqrt(mean((svm_HTpredictions - testing_set$Yt)^2))
151 HTRMSE_svm
152 # เพิ่มข้อมูล SVM Hyperparameter Tuning Predictions เข้าไปใน comparison_data
153 comparison_data$SVM_HT_Predictions <- svm_HTpredictions
154
155 # สร้างกราฟเปรียบเทียบ
156 ggplot(comparison_data, aes(x = time)) +
157   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +

```

```

158 geom_line(aes(y = SVM_HT_Predictions, color = "SVM HT Predictions"),
159           linetype = "dashed", size = 1) +
160 labs(title = "Comparison of Actual Demand vs SVM HT Predictions",
161       x = "Time",
162       y = "Demand") +
163 scale_color_manual(values = c("Actual Demand" = "blue",
164                               "SVM HT Predictions" = "red")) +
165 theme_minimal()
166
167
168 library(randomForest)
169 # สร้างโมเดล Random Forests โดยกำหนดจำนวนต้นไม้เป็น 500
170 rf_HTmodel <- randomForest(Yt ~ Yt_1 + Yt_2 + time , data = training_set,
171                            ntree = 500)
172
173 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า max_depth ต่ำ
174 rf_HTpredictions <- predict(rf_HTmodel, newdata = testing_set)
175 rf_HTpredictions
176
177 # 4. ประเมินประสิทธิภาพของโมเดล
178 HTRMSE_rf <- sqrt(mean((rf_HTpredictions - testing_set$Yt)^2))
179 HTRMSE_rf
180
181 # เพิ่มข้อมูล Random Forest Hyperparameter Tuning Predictions
182 comparison_data$RF_HT_Predictions <- rf_HTpredictions
183
184 # สร้างกราฟเปรียบเทียบ
185 ggplot(comparison_data, aes(x = time)) +
186   geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
187   geom_line(aes(y = RF_HT_Predictions, color = "RF HT Predictions"),
188           linetype = "dashed", size = 1) +
189   labs(title = "Comparison of Actual Demand vs RF HT Predictions",

```

```

190     x = "Time",
191     y = "Demand") +
192     scale_color_manual(values = c("Actual Demand" = "blue",
193                                 "RF HT Predictions" = "purple")) +
194     theme_minimal()
195
196
197 library(xgboost)
198 # สร้างและฝึกโมเดล XGBoost โดยกำหนดพารามิเตอร์
199 xgb_HTmodel <- xgboost(data = as.matrix(training_set[, -1]),
200                       label = training_set$Yt,
201                       nrounds = 200,
202                       eta = 0.01, # อัตราการเรียนรู้
203                       max_depth = 10, # ความลึกของต้นไม้
204                       gamma = 1, # ค่าที่ใช้ในการลดความซับซ้อนของโมเดล
205                       colsample_bytree = 0.01, # สัดส่วนของ feature ที่ใช้ในการสร้างต้นไม้ในแต่ละรอบ
206                       min_child_weight = 5 # ค่าน้อยที่สุดของน้ำหนักที่จะแบ่งในโหนดในต้นไม้
207                       )
208
209 # 3. ทำนายข้อมูลในชุดทดสอบโดยใช้โมเดลที่มีค่า learning rate ต่ำ
210 xgb_HTPredictions <- predict(xgb_HTmodel,
211                             newdata = as.matrix(testing_set[, -1]))
212
213 # 4. ประเมินประสิทธิภาพของโมเดล
214 HTRMSE_xgb <- sqrt(mean((xgb_HTPredictions - testing_set$Yt)^2))
215
216
217 # เพิ่มข้อมูล XGBoost Hyperparameter Tuning Predictions
218 comparison_data$XGB_HT_Predictions <- xgb_HTPredictions
219
220 # สร้างกราฟเปรียบเทียบ
221 ggplot(comparison_data, aes(x = time)) +

```

```

222 geom_line(aes(y = Actual_Demand, color = "Actual Demand"), size = 1) +
223 geom_line(aes(y = XGB_HT_Predictions, color = "XGB HT Predictions"),
224           linetype = "dashed", size = 1) +
225 labs(title = "Comparison of Actual Demand vs XGB HT Predictions",
226       x = "Time",
227       y = "Demand") +
228 scale_color_manual(values = c("Actual Demand" = "blue",
229                               "XGB HT Predictions" = "orange")) +
230 theme_minimal()
231
232 #Linear Regression : ไม่มีการปรับแต่งพารามิเตอร์
233
234 #####
235
236 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า
237 future_data <- data.frame(
238   Yt_1 = 38478.86,
239   Yt_2 = 32200.02,
240   time = 37
241 )
242 future_data
243 # 1. ทำการพยากรณ์ล่วงหน้า
244 linear_future_HTpredictions <- predict(linear_model, newdata = future_data)
245 # 2. แสดงผลลัพธ์
246 print(linear_future_HTpredictions)
247
248 #####
249
250 #Moving Average:ไม่มีการปรับแต่งพารามิเตอร์เหมือนกับโมเดลที่ใช้ในการเรียนรู้เชิงลึก
251 # 2.4 สร้างและฝึกโมเดล Moving Average
252 ma_model <- function(data, window_size) {
253   y <- data$Yt

```

```

254 n <- length(y)
255 moving_avg <- rep(0, n)
256 for (i in window_size:n) {
257   moving_avg[i] <- mean(y[(i - window_size + 1):i])
258 }
259 return(moving_avg)
260 }
261
262 # ใช้ฟังก์ชันเพื่อสร้างโมเดล Moving Average ด้วยขนาดหน้าต่าง 3
263 window_size <- 3
264 ma_predictions <- ma_model(testing_set, window_size)
265 ma_predictions
266
267 # ประเมินประสิทธิภาพของโมเดล Moving Average ด้วยค่า RMSE
268 RMSE_ma <- sqrt(mean((ma_predictions>window_size:length(ma_predictions)]
269   - testing_set$Yt>window_size:length(testing_set$Yt))^2))
270 RMSE_ma
271
272 # เพิ่มข้อมูล Moving Average Predictions เข้าไปใน testing_set
273 testing_set$MA_Predictions <- ma_predictions
274 # สร้างกราฟเปรียบเทียบ
275 ggplot(testing_set, aes(x = time)) +
276   geom_line(aes(y = Yt, color = "Actual Demand"), size = 1) +
277   geom_line(aes(y = MA_Predictions, color = "Moving Average Predictions"),
278     linetype = "dashed", size = 1) +
279   labs(title = "Comparison of Actual Demand vs Moving Average Predictions",
280     x = "Time", y = "Demand") +
282   scale_color_manual(values = c("Actual Demand" = "blue",
283     "Moving Average Predictions" = "gray")) +
284   theme_minimal()
285
286 # 1. สร้างข้อมูลเพื่อทำนายล่วงหน้า

```

```

287 future_data <- data.frame(
288   Yt_1 = 38478.86,
289   Yt_2 = 32200.02,
290   time = 37
291 )
292 future_data
293
294 # ฟังก์ชันทำนายค่า Moving Average สำหรับข้อมูลในอนาคต
295 ma_future_predictions <- function(data, window_size, future_data) {
296   # คำนวณค่าเฉลี่ยเคลื่อนที่จากข้อมูลในอนาคต
297   y <- c(data$Yt, future_data$Yt_1)
298   n <- length(y)
299   moving_avg <- rep(0, n)
300   for (i in (n - window_size + 1):n) {
301     moving_avg[i] <- mean(y[(i - window_size + 1):i])
302   }
303   return(moving_avg[n])
304 }
305
306 # ใช้ฟังก์ชันเพื่อทำนายค่า Moving Average สำหรับข้อมูลในอนาคต
307 future_ma_prediction <- ma_future_predictions(data, window_size,
308   future_data)
309 future_ma_prediction

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก จ

## Plagiarism Checking Report

Created on 2024-04-02 09:04:04 at 09:04 AM

## Submission Information

ID	SUBMISSION DATE	SUBMITTED BY	ORGANIZATION	FILENAME	STATUS	SIMILARITY INDEX
3671460	Apr 2, 2024 at 08:59 AM	63050693@kmitl.ac.th	สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง	การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์ โดยใช้เทคโนโลยีการเรียนรู้ของเครื่อง.pdf	Completed	0.11%

## Match Overview

NO.	TITLE	AUTHOR(S)	SOURCE	SIMILARITY INDEX
1	การศึกษาผลกระทบทางเศรษฐศาสตร์สำหรับระบบจำหน่ายไฟฟ้าที่มีเครื่องกำเนิดไฟฟ้าแบบกระจายตัว	ทง ลานธารทอง	มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร	0.11 %

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



งานทะเบียนคณะวิทยาศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
คำรับรองเล่มโครงการพิเศษ/ปัญหาพิเศษ/สหกิจศึกษา

วันที่ 29 .เดือน มีนาคม พ.ศ. 2567

ข้าพเจ้า นางสาวอารยา มิติไช้มัน รหัสประจำตัว 63050693  
นักศึกษาหลักสูตรวิทยาศาสตรบัณฑิต สาขาวิชา สถิติประยุกต์ ภาควิชา สถิติ  
ขอรับรองว่าสหกิจศึกษา เรื่อง

การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าเมืองอัจฉริยะวังจันทร์วัลเลย์โดยใช้วิธีการเรียนรู้ของเครื่อง  
ELECTRICITY CONSUMPTION FORECASTING IN WANGCHAN VALLEY SMART CITY USING  
MACHINE LEARNING METHOD


ปีการศึกษา 2566

เป็นผลงานวิจัยที่มีได้คัดลอกหรือละเมิดลิขสิทธิ์ของผู้อื่นและได้ผ่านการตรวจสอบความซ้ำซ้อน  
เรียบร้อยแล้ว และได้แนบเอกสารการตรวจสอบการลอกเลียนงานวรรณกรรมที่ตรวจสอบจากเล่ม  
สหกิจศึกษาฉบับสมบูรณ์แล้ว  
โปรแกรมอักขราวิสุทธิ์ 0.11 %

ลงชื่อนักศึกษา.....อารยา มิติไช้มัน.....

( นางสาวอารยา มิติไช้มัน )

ข้าพเจ้า ผศ.ดร.ยวดี กลุ่มวิเศษ อาจารย์ที่ปรึกษาสหกิจศึกษา ได้ตรวจสอบสหกิจศึกษาของนักศึกษา  
ข้างต้นแล้ว ขอรับรองว่าเป็นผลงานวิจัยของนักศึกษาจริงและมีเนื้อหาสมบูรณ์ จึงลงชื่อไว้เป็น  
หลักฐาน

ลงชื่ออาจารย์ที่ปรึกษา..........

( ผศ.ดร.ยวดี กลุ่มวิเศษ )

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหาและต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้