



การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วยแบบจำลอง
การขับเคลื่อนด้วยข้อมูล

ภาณุเดช คุณชม

การศึกษารายบุคคลนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตร
มหาบัณฑิต สาขาวิชาการจัดการทางวิศวกรรม วิทยาลัยนวัตกรรมด้านเทคโนโลยี
และวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิต

ปีการศึกษา 2565

FORECASTING ELECTRICITY CONSUMPTION OF AN OFFICE BUILDING
USING DATA-DRIVEN MODELING

PANUDET KHONCHOM

An Individual Study Submitted in Partial Fulfillment of the
Requirements for the Degree of Master of Engineering
College of Innovative Technology and Engineering
Dhurakij Pundit University
Academic Year 2022



ใบรับรองการศึกษารายบุคคล

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิต

ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อการศึกษารายบุคคล การพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วย
แบบจำลองการขับเคลื่อนด้วยข้อมูล

เสนอโดย ภาณุเดช คุณชม

สาขาวิชา การจัดการทางวิศวกรรม

อาจารย์ที่ปรึกษาการศึกษารายบุคคล ดร.สมหญิง งามพรประเสริฐ

ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบการศึกษารายบุคคลแล้ว

.....ประธานกรรมการ

(รองศาสตราจารย์ ดร.อำนาจ ผดุงศิลป์)

.....กรรมการและอาจารย์ที่ปรึกษาการศึกษารายบุคคล

(ดร.สมหญิง งามพรประเสริฐ)

.....กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ศุภรัชชัย วรรัตน์)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ รับรองแล้ว

.....
(ดร.ชัยพร เขมะภาคะพันธ์)

คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์

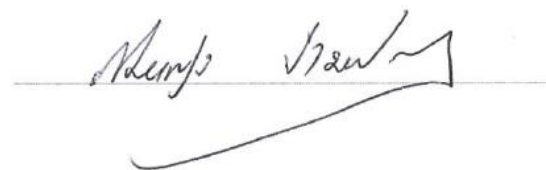
วันที่ ..20... เดือน ..พฤษภาคม.. พ.ศ. ๒๕๖๖...

หัวข้อการศึกษารายบุคคล การพยากรณ์การใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วยแบบจำลองการ
ขับเคลื่อนด้วยข้อมูล
ชื่อผู้เขียน ภาณุเดช คุณชม
อาจารย์ที่ปรึกษา ดร.สมหญิง งามพรประเสริฐ
หลักสูตร วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาการจัดการทางวิศวกรรม
ปีการศึกษา 2565

บทคัดย่อ

งานวิจัยนี้มีจุดประสงค์เพื่อศึกษาการสร้างรูปแบบการพยากรณ์การใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วยการทำเหมืองข้อมูล 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 โดยผลของการศึกษานี้พบว่า มิเตอร์ไฟฟ้าตัวที่1และมิเตอร์ไฟฟ้าตัวที่ 2 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Gradient Booster Trees ส่วนมิเตอร์ไฟฟ้าตัวที่3 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Random Forest ซึ่งตัวแบบของแต่ละมิเตอร์ไฟฟ้ามามีค่าAccuracy และ Precision ที่มากที่สุด, มีค่า Classification error น้อยที่สุด และ MAPE เทียบกับข้อมูลจริงน้อยที่สุด

คำสำคัญ: พลังงานไฟฟ้า, ตัวแบบการพยากรณ์, เหมืองข้อมูล



Individual Study Title	FORECASTING ELECTRICITY CONSUMPTION OF AN OFFICE BUILDING USING DATA-DRIVEN MODELING
Author	Panudet Khunchom
Individual Study Advisor	Dr. Somying Ngampornprasert
Program	Master of Engineering Engineering Management
Academic Year	2022

ABSTRACT

This research aims to study the construction of a forecasting model for office building electricity consumption through data mining. It collects data from electric power consumption (kW) and the unit value in one hour (h) for 2176 hours to apply text mining algorithm techniques to analyze problems in power management. The RapidMiner Studio program divides the data into three sets according to the electricity meter in the office building. To create a forecasting model that is appropriate for the data set. This study used Naïve Bayes forecasting models, Generalized Linear Model, Logistic Regression, Fast Large Margin, Deep Learning, Decision Trees, Random Forests, Gradient-Boosted Trees, and Support Vector machines to find models that fit the power meter data set. This study found suitable forecast models for electricity meters 1 and 2, including Gradient Booster Trees. As for the third electricity meter, the most suitable forecasting model is Random Forest, in which the model of each electricity meter has the highest accuracy and precision, the least classification error, and the least MAPE compared to actual data.

Keywords: electrical energy, forecasting models, data mining

Somying Ngampornprasert.

กิตติกรรมประกาศ

การศึกษารายบุคคลฉบับนี้สำเร็จลุล่วงได้อย่างสมบูรณ์ ผู้จัดทำใคร่ขอกราบขอบพระคุณท่านที่มีส่วนช่วยเหลือและแนะนำ ดังนี้ ดร.สมหญิง งามพรประเสริฐ อาจารย์ที่ปรึกษา ที่ให้คำแนะนำ การค้นคว้าหาข้อมูล และช่วยในการตรวจสอบเพื่อแก้ไขข้อบกพร่องและชี้แนะเกี่ยวกับการศึกษาวิจัยที่เป็นประโยชน์ กราบขอขอบพระคุณ ผศ.ดร.ศุภรัชชัย วรรัตน์ อาจารย์และผู้อำนวยการหลักสูตรสำหรับการสอนและขอแนะนำแนวทางการทำหัวข้อการศึกษารายบุคคลให้สำเร็จลุล่วงในเวลาที่กำหนด และขอขอบคุณ รองศาสตราจารย์ ดร.อำนาจ ผดุงศิลป์ อาจารย์รายวิชา ที่ให้ความช่วยเหลือและแนะนำในการเขียนสารนิพนธ์ รวมทั้งการค้นคว้าหาข้อมูลและแนวทางการนำเสนอจนสำเร็จลุล่วง

ขอขอบคุณคณะกรรมการตรวจสอบรายบุคคลที่ให้ข้อเสนอแนะในการปรับปรุงเนื้อหาอันเป็นประโยชน์ของการค้นคว้าของผู้จัดทำ

สุดท้ายขอขอบคุณคณาจารย์ทุกท่านและเลขาคณะฯ ที่ช่วยเหลือมาตลอดระยะเวลาของการศึกษา

ภาณุเดช คุณชม

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญภาพ.....	ญ
บทที่	
1. บทนำ.....	1
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตงานวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
2. แนวคิด ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้า.....	4
2.2 การทำเหมืองข้อมูล (Data Mining) และการเรียนรู้ของเครื่องมือ (Machine Learning)	8
2.3 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์และการวัดความผิดพลาดแบบจำลองในการพยากรณ์.....	11
2.4 ผลการศึกษาและงานวิจัยที่เกี่ยวข้อง.....	21
3. วิธีดำเนินการวิจัย.....	26
3.1 ระเบียบงานวิจัย.....	26
3.2 แผนภาพการดำเนินงานวิจัย.....	27
3.3 เครื่องมือในการทำงานวิจัย.....	27
3.4 ขั้นตอนในการดำเนินงาน.....	32
4. ผลการดำเนินงานวิจัย.....	45
4.1 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	45
4.2 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2.....	55
4.3 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	65
5. สรุปผลงานวิจัย และข้อเสนอแนะ.....	76

สารบัญ (ต่อ)

บทที่	หน้า
5.1 สรุปผลการศึกษา.....	78
5.2 ปัญหาและอุปสรรคและข้อเสนอแนะ.....	77
บรรณานุกรม.....	79
ภาคผนวก.....	81
ก ชุดข้อมูลพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า.....	82
ประวัติผู้เขียน.....	112

สารบัญตาราง

ตารางที่	หน้า
3.1 แสดงข้อมูลประเภทของข้อมูลที่นำมาจากการเก็บข้อมูล.....	35
3.2 แสดงตามข้อมูลที่น่ามาวิเคราะห์กลุ่มที่จะนำมาพยากรณ์.....	38
4.1 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	51
4.2 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE)ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	52
4.3 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน24ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้าชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	54
4.4 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2.....	61
4.5 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE)ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2.....	62
4.6 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน24ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้าชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2.....	64
4.7 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	71
4.8 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE).....	73
4.9 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน 24ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้าชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	74
5.1 แสดงการเปรียบเทียบค่า Accuracy, Precision, classification ErrorและMAPE.....	77

สารบัญภาพ

ภาพที่	หน้า
2.1 การแปลงข้อมูลเป็นความรู้เพื่อช่วยในการตัดสินใจ.....	2
2.2 แสดงขั้นตอนการทำเหมืองข้อมูล.....	9
2.3 ตัวอย่างชุดข้อมูลสอน และต้นไม้ตัดสินใจที่สร้างได้จากชุดข้อมูลสอน.....	16
2.4 แสดงกระบวนการทำงานของ Gradient Boosted Trees.....	17
2.5 แสดงกระบวนการทำงานของ Random Forest.....	17
2.6 ภาพแสดงการแบ่งกลุ่มข้อมูลของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน.....	18
3.1 ภาพแผนภาพการดำเนินงานวิจัย.....	27
3.2 แสดงหน้าเว็บไซต์ RapidMiner Amplify the Impact of Your People, Expertise & Data.....	28
3.3 แสดง โครงสร้างการทำงานระบบโปรแกรม xView.....	30
3.4 แผนผังขั้นตอนในการดำเนินงาน.....	32
3.5 ตัวอย่าง หน้า UI ของ ตัวโปรแกรมที่เก็บข้อมูล.....	33
3.6 แสดงตัวอย่างแผนภูมิชุดข้อมูลที่ได้จากการเก็บข้อมูล.....	34
3.7 แสดงตัวอย่างชุดข้อมูลที่จะนำมาคัดกรอง.....	36
3.8 แสดงแผนภูมิตัวอย่างชุดข้อมูล24ชั่วโมง ที่ติด0.....	36
3.9 แสดงตัวอย่างแผนภูมิปริมาตรชุดข้อมูลที่ผ่านคัดกรองและตัดข้อมูล.....	37
3.10 แสดงแผนภูมิพลังงานไฟฟ้าทั้งหมด.....	38
3.11 แสดงการสร้าง operators Read CSV.....	39
3.12 แสดงการแสดงผลของการใช้พลังงานไฟฟ้าของมิเตอร์ไฟฟ้าแต่ละตัว.....	40
3.13 ตัวอย่างแสดงฟังก์ชัน Auto Modle.....	41
3.14 ตัวอย่างแสดงขั้นตอนการรันหลายอัลกอริทึม.....	42
3.15 แสดงตัวอย่าง การพยากรณ์ ชุดข้อมูลปริมาณการใช้ไฟฟ้า.....	43
3.16 แสดง Performance ของตัวแบบพยากรณ์.....	43
3.17 แสดงแผนภูมิปริมาตรผลลัพธ์ชุดข้อมูลการพยากรณ์.....	44
4.1 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	45
4.2 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	46
4.3 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1.....	47

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.4 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ไฟฟ้า ตัวที่ 1.....	47
4.5 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้า ตัวที่ 1.....	48
4.6 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ ไฟฟ้าตัวที่ 1.....	49
4.7 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 1.....	49
4.8 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 1.....	50
4.9 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 1 กับ ชุดข้อมูลปริมาณ การใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่1.....	53
4.10 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2.....	55
4.11 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ ไฟฟ้าตัวที่ 2.....	56
4.12 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ ไฟฟ้าตัวที่ 2.....	56
4.13 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ ไฟฟ้าตัวที่ 2.....	57
4.14 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้า ตัวที่ 2.....	58
4.15 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ ไฟฟ้าตัวที่ 2.....	58
4.16 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 2.....	59
4.17 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 2.....	60
4.18 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 2 กับ ชุดข้อมูลปริมาณ การใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่ 2.....	63

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.19 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	65
4.20 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	66
4.21 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	66
4.22 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	67
4.23 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	68
4.24 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	68
4.25 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	69
4.26 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3.....	70
4.27 แสดงชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3 ที่นำมาพยากรณ์.....	72
4.28 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 3 กับ ชุดข้อมูลปริมาณการใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่ 3.....	73

บทที่ 1 บทนำ

1.1 ที่มาและความสำคัญของปัญหา

พลังงานไฟฟ้า เป็นพลังงานที่ได้จากพลังงานศักย์ พลังงานที่มีในวัตถุเนื่องด้วยตำแหน่งในสนามแรง หรือมีในระบบนั้น เนื่องด้วยการกำหนดค่าในส่วนนั้นๆ รวมถึงพลังงานจลน์ พลังงานที่เกิดซึ่งเกิดจากวัตถุที่กำลังเคลื่อนที่ เช่น รถยนต์กำลังแล่น เครื่องบินกำลังบิน พัดลมกำลังหมุน จึงกล่าวว่า พลังงานจลน์ล้วนเป็นพลังงานกลที่สามารถเปลี่ยนรูปกลับไปกลับมาได้ และเมื่อไฟฟ้าเมื่อถูกใช้อย่างหลวมๆ จะใช้เพื่ออธิบายพลังงานที่ถูกดูดซับ หรือถูกถ่ายถอดโดยวงจรไฟฟ้าหนึ่ง เช่นพลังงานที่จัดหามาให้จากโรงไฟฟ้า เป็นต้น

ปัจจุบันการใช้พลังงานไฟฟ้ากำลังเป็นประเด็นสำคัญอย่างมากของประเทศไทย เป็นหนึ่งในปัจจัยสำคัญสำหรับการดำรงชีวิต โดยความต้องการของพลังงานไฟฟ้านั้น ในการผลิตไฟฟ้า ถือเป็นต้นทุนสำคัญของอาคารพาณิชย์ต่างๆ และครัวเรือน ซึ่งมีการคาดการณ์ถึงแนวโน้ม การใช้พลังงานไฟฟ้าที่สูงขึ้นและลดลงผันผวนไม่แน่นอนในแต่ละเดือนเป็นหนึ่งในปัจจัยสำคัญในการดำรงชีวิต โดยความต้องการพลังงานไฟฟ้าเป็นต้นทุนสำคัญต่อธุรกิจเป็นอย่างมาก โดยเฉพาะการใช้ไฟฟ้าภายในอาคารสำนักงานขนาดกลาง จะมีระบบและการใช้งานอุปกรณ์ที่ใช้พลังงานไฟฟ้าเข้ามาเกี่ยวข้อง ในปัจจุบันอาคารสำนักงานขนาดกลาง มีแนวโน้มในการใช้พลังงานที่มีความไม่แน่นอน ก่อให้เกิดปัญหาทางด้านการจัดการพลังงานและค่าใช้จ่ายที่สูงจากการจัดการพลังงานที่ไม่แน่นอนขึ้นตามมา จึงทำให้อาคารสำนักงานขนาดกลางต่างๆ เริ่มที่จะมีการนำโครงการที่เกี่ยวข้องกับการควบคุมและการจัดการความต้องการพลังงานไฟฟ้าได้อย่างมีประสิทธิภาพ โดยในปัจจุบันก็มีเทคโนโลยี และแนวทางที่จะมาช่วยในการจัดการพลังงานไฟฟ้าอยู่มากมาย ซึ่งหนึ่งในวิธีการจัดการพลังงานไฟฟ้าภายในอาคารสำนักงานขนาดกลางนั้นคือ การเก็บข้อมูล จากข้อมูลที่กล่าวมานั้นหมายถึงข้อมูลแสดงความต้องการไฟฟ้าในแต่ละช่วงเวลา ซึ่งจะแสดงพฤติกรรมการใช้ไฟฟ้าภายในอาคาร เพื่อที่จะนำข้อมูลดังกล่าวมาวางแผนในการจัดการพลังงานไฟฟ้าภายในตัวอาคารสำนักงาน เพิ่มความมั่นคงให้กับระบบไฟฟ้าสามารถลดต้นทุนที่ต้องจ่ายไปกับการใช้พลังงานไฟฟ้าได้

ทั้งนี้ผู้ศึกษาศาสตร์นี้มีแนวคิดการจัดการพลังงานไฟฟ้าจากชุดข้อมูลที่เก็บข้อมูลความต้องการพลังงานไฟฟ้า โดยสังเกตเห็นความเปลี่ยนแปลงของการใช้พลังงานไฟฟ้าในแต่ละช่วงเวลา ซึ่งที่เรียกว่า ข้อมูลขนาดใหญ่ (Big Data) ข้อมูลที่ได้จากการเก็บข้อมูลพลังงานไฟฟ้านั้น จะทำการนำข้อมูลมาทำเหมืองข้อมูล (Data Mining) เพื่อวิเคราะห์ข้อมูล และหาความสัมพันธ์ของข้อมูล เช่น การจำแนกข้อมูล หรือการเชื่อมโยงข้อมูลที่มีความสัมพันธ์กัน เป็นต้น หลังจากนั้นจะทำการพยากรณ์ความต้องการไฟฟ้าภายในอาคารสำนักงานขนาดกลาง ค่าพยากรณ์ปริมาณความต้องการไฟฟ้าที่ได้มีความสำคัญในการวางแผนการจัดการพลังงานไฟฟ้า เพราะจะสามารถนำข้อมูลไปใช้ดูแนวโน้มความเสี่ยงการใช้ไฟฟ้าที่ไม่แน่นอน จะทำให้ทราบถึงปริมาณความต้องการพลังงานไฟฟ้าล่วงหน้าได้ และสามารถวางแผนสำหรับการตัดสินใจการใช้ไฟฟ้าในอนาคต

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อศึกษาและวิเคราะห์แนวทางการสร้างแบบจำลองที่เหมาะสมในการพยากรณ์ชุดข้อมูลการใช้พลังงานไฟฟ้าภายในอาคารสำนักงานขนาดกลาง

1.2.2 เพื่อศึกษาวิธีการสร้างเหมืองข้อมูลและการวัดประสิทธิภาพของชุดข้อมูลที่พยากรณ์

1.3 ขอบเขตงานวิจัย

1.3.1 การใช้พลังงานรายชั่วโมง ตั้งแต่วันที่ 1 กันยายน 2565 จนถึง 30 พฤศจิกายน 2565 ตลอดระยะเวลา 2,184 ชั่วโมง ของอาคารอาคารสำนักงานขนาดกลางแห่งหนึ่งโดยวิเคราะห์ข้อมูลที่ได้จากระบบบริหาร จัดการพลังงาน และความแตกต่างของการใช้พลังงานของแต่ละชั่วโมง

1.3.2 การศึกษาการวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในอาคารสำนักงานขนาดกลาง ถูกเก็บข้อมูล โดยการใช้โปรแกรม SCADA (Supervisory Control And Data Acquisition) โดยข้อมูลที่นำมาใช้ นั้นจะเป็นค่าความต้องการไฟฟ้ามีหน่วยเป็นกิโลวัตต์ (kW) ทุกชั่วโมง ซึ่งเป็นโปรแกรมสำหรับติดต่อสื่อสารกับอุปกรณ์ ควบคุมต่าง ๆ เพื่อรับข้อมูลประมวลผลซึ่งเก็บข้อมูลการใช้ไฟฟ้าทั้ง 24 ชั่วโมง แต่สำหรับกลุ่มผู้ใช้อื่น ๆ เช่น บ้านพักอาศัย หรือ อพาร์ทเมนท์ อาจจะมีผลกระทบของการใช้พลังงานไฟฟ้าที่แตกต่างกัน ขึ้นอยู่กับขนาด ของตัวอาคารหรือพฤติกรรมการใช้พลังงานไฟฟ้า

1.3.3 การศึกษาเครื่องมือที่ใช้ในการหาตัวแบบการพยากรณ์ที่เหมาะสม คือโปรแกรม RapidMiner ซึ่งจะเป็นการใช้ตัวแบบทั้งหมด 9 ตัวแบบ คือ

- (1) Naive Bayes
- (2) Generalized linear Model
- (3) Fast Large Margin
- (4) Deep Learning
- (5) Decision Tree
- (6) Random Forest
- (7) Gradient Booster Trees
- (8) Support Vector Machine

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 เพื่อที่จะนำมาประยุกต์ใช้กับชุดข้อมูลการใช้พลังงานไฟฟ้าภายในอาคารสำนักงานขนาดกลาง เพื่อสนับสนุนแผนการจัดการพลังงานไฟฟ้าของอาคารสำนักงานขนาดกลาง ที่มีการเก็บชุดข้อมูลการใช้พลังงานไฟฟ้าภายในอาคารสำนักงานรูปแบบเดียวกันได้

1.4.2 เพื่อเป็นแนวทางเกี่ยวกับการจัดการพลังงานไฟฟ้าภายในอาคารสำนักงานขนาดกลาง ด้วยวิธีการพยากรณ์ข้อมูลความต้องการไฟฟ้าในแต่ละช่วงเวลา เพื่อไปใช้ในการวางแผนการจัดการพลังงานไฟฟ้าในอนาคตต่อไปได้

1.4.3 ผลลัพธ์วิธีการจากการศึกษานี้สามารถนำไปใช้เป็นข้อมูลไปใช้วิเคราะห์แนวทางการจัดการพลังงานของอาคารสำนักงานที่เป็นกรณีศึกษาต่อไปได้

บทที่ 2

แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง

การศึกษาวิธีการทำเหมืองข้อมูลและการพยากรณ์การใช้พลังงานไฟฟ้าภายในอาคารสำนักงาน
ขนาดกลาง ผู้ศึกษาได้ทำการศึกษาแนวคิดทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง

- 2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้า
- 2.2 การทำเหมืองข้อมูล (Data Mining) และการเรียนรู้ของเครื่องมือ (Machine Learning)
- 2.3 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์และการวัดความผิดพลาด
แบบจำลองในการพยากรณ์
- 2.4 ผลการศึกษาและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของพลังงานไฟฟ้า

2.1.1 ความหมายของพลังงานและพลังงานไฟฟ้า

พลังงาน (Energy) หมายถึงความสามารถซึ่งมีอยู่ในตัวของสิ่งให้อาจให้แรงงานได้เป็นผล จากการ
ถ่ายเทหรือการเปลี่ยนแปลงสภาพของพลังงาน มีทรัพยากรหลายชนิดที่สามารถนำมาใช้ให้เป็นประโยชน์ในด้าน
พลังงานได้ สำหรับประเทศไทยแม้ว่าจะสามารถจัดหาได้จากแหล่งภายในประเทศแต่ยังไม่เพียงพอ จำเป็นต้อง
นำเข้าเชื้อเพลิงและแหล่งพลังงานจากต่างประเทศ จากผลของวิกฤตการณ์พลังงานเชื้อเพลิงเมื่อ พ.ศ. 2516
แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติจึงได้ลดสัดส่วนการพึ่งพาเชื้อเพลิงจากต่างประเทศลง โดยเร่งรัด
สำรวจและพัฒนาแหล่งพลังงานภายในประเทศ รวมทั้งการใช้พลังงานอย่างประหยัด และมีประสิทธิภาพ
ยิ่งขึ้น แหล่งพลังงานในประเทศได้แก่ พลังงานสมัยใหม่ เช่น ปิโตรเลียม (น้ำมันดิบ ก๊าซธรรมชาติ และคอน
เดนเสท) ถ่านลิกไนต์ พลังน้ำและวัสดุทางการเกษตร เช่น แสงอาทิตย์ความร้อนใต้พิภพ และลม เป็นต้น

สำหรับเชื้อเพลิงและพลังงานที่ต้องนำเข้าได้แก่น้ำมันดิบ น้ำมันสำเร็จรูป ถ่านหิน ไฟฟ้า ฟืน และ
ถ่าน ส่วนเชื้อเพลิงที่ประเทศไทยสามารถส่งออกได้คือ คอนเดนเสท น้ำมันเตา น้ำมัน เครื่องบิน เป็นต้น

แต่ละปีประเทศไทยได้สูญเสียเงินตราต่างประเทศเป็นจำนวนมากในการจัดหาเชื้อเพลิงและ
พลังงาน แม้ว่าความพยายามในการลดสัดส่วนการพึ่งพาพลังงานจากต่างประเทศจะประสบผลสำเร็จแต่ก็ยังมี
สัดส่วนที่สูงอยู่ ดังนั้นสถานการณ์พลังงานของโลกจะยังคงมีผลกระทบต่อเศรษฐกิจของประเทศอยู่มาก
ในขณะที่ความต้องการพลังงานรวมภายในประเทศเพิ่มขึ้นตลอดเวลา

พลังงานไฟฟ้าเกิดขึ้นได้หลายวิธี

- (1) เกิดขึ้นเองตามธรรมชาติได้แก่ ฟาแลบ ฟาผ่า
- (2) เกิดจากการเปลี่ยนพลังงานความร้อนเป็นพลังงานไฟฟ้า
- (3) เกิดจากการเปลี่ยนแสงสว่างให้เป็นพลังงานไฟฟ้า โดยเซลล์แสงอาทิตย์ (Solar Cell) หรือโฟ
โตเซลล์ (Photocell)

(4) เกิดจากปฏิกิริยาเคมี เช่น แบตเตอรี่ถ่านไฟฉาย เซลล์แห้ง และเซลล์เชื้อเพลิง

(5) เกิดจากการเหนี่ยวนำของอำนาจแม่เหล็กโดยเครื่องกำเนิดไฟฟ้า ได้แก่ ไฟฟ้าที่ใช้อยู่ในอาคารบ้านเรือนในปัจจุบัน

เครื่องกำเนิดไฟฟ้า เป็นอุปกรณ์ที่ทำหน้าที่เปลี่ยนแปลงพลังงานกลมาเป็นพลังงานไฟฟ้า โดยอาศัยการเหนี่ยวนำของแม่เหล็กตามหลักการของ ไมเคิล ฟาราเดย์ คือการเคลื่อนที่ของขดลวดตัวนำผ่านสนามแม่เหล็ก หรือการเคลื่อนที่แม่เหล็กผ่านขดลวดตัวนำ จะทำให้เกิดแรงดันไฟฟ้าเหนี่ยวนำขึ้นในขดลวดตัวนำนั้น

เครื่องกำเนิดไฟฟ้ามี 2 ชนิด คือชนิดกระแสตรงเรียกว่า ไดนาโม (Dynamo) และชนิดกระแสสลับเรียกว่า อัลเตอร์เนเตอร์ (Alternator) สำหรับเครื่องกำเนิดไฟฟ้าที่ใช้งานในเชิงอุตสาหกรรมนั้น โดยมากจะเป็นเครื่องกำเนิดไฟฟ้าชนิดกระแสสลับ ซึ่งมีทั้งแบบ 1 เฟส และแบบ 3 เฟส โดยเฉพาะเครื่องกำเนิดไฟฟ้าขนาดใหญ่ที่ใช้ตามโรงไฟฟ้าจะเป็นเครื่อง กำเนิดแบบ 3 เฟสทั้งหมด เนื่องจากสามารถผลิตและจ่ายกำลังไฟฟ้าได้เป็นสามเท่าของเครื่อง กำเนิดไฟฟ้าแบบ 1 เฟส โดยทั่วไปแล้วเครื่องกำเนิดไฟฟ้าจะประกอบด้วยส่วนสำคัญ 2 ส่วน คือ ส่วนที่เรียกว่า โรเตอร์ (Rotor) ซึ่งจะมีขดลวดตัวนำฝังอยู่ในร่องรอบแกนโรเตอร์ ที่ทำจากแผ่นเหล็กซิลิคอน (Silicon Steel Sheet) ขนาดหนาประมาณ 0.35 - 0.50 มิลลิเมตร นำมาอัดแน่นโดยระหว่างแผ่นเหล็กซิลิคอนจะมีฉนวนเคลือบ ทั้งนี้เพื่อลดการสูญเสียที่เกิดจากกระแสไฟฟ้าไหลวน (Eddy Current) ภายในแกนเหล็กของโรเตอร์จะได้รับไฟฟ้ากระแสตรงจากเอ็กไซเตเตอร์ (Excitor) เพื่อทำหน้าที่ในการสร้าง สนามแม่เหล็กไฟฟ้าขึ้นอีกส่วนหนึ่งของเครื่องกำเนิดไฟฟ้าคือส่วนที่อยู่กับที่เรียกว่า สเตเตอร์ (Stator) ภายในร่องแกนสเตเตอร์มีขดลวดซึ่งทำจากแผ่นเหล็กอัดแน่นเหมือนกับโรเตอร์ฝังอยู่ อาศัยหลักการของการเคลื่อนที่ของแม่เหล็กผ่านขดลวดตัวนำจะทำให้เกิดการเหนี่ยวนำแรงดันไฟฟ้าที่สเตเตอร์และนำแรงดันไฟฟ้านี้ไปใช้ต่อไป อุปกรณ์ประกอบที่สำคัญอีกอย่างหนึ่งของเครื่องกำเนิดไฟฟ้าขนาดใหญ่ คือเอ็กไซเตเตอร์ อยู่แกนเดียวกับโรเตอร์ทำหน้าที่ผลิตไฟฟ้ากระแสตรงป้อนให้แก่โรเตอร์ (D.C. Exciting Current) เพื่อสร้างสนามแม่เหล็กขึ้นบนโรเตอร์ชนิดของเอ็กไซเตเตอร์จะเป็นแบบไฟฟ้ากระแสตรง หรือ อาจจะใช้แบบกระแสสลับ แล้วผ่านวงจรแปลงไฟฟ้าให้เป็นกระแสตรงก่อนป้อนเข้าสู่โรเตอร์ เครื่องกำเนิดไฟฟ้าขนาดใหญ่ มักจะใช้เอ็กไซเตเตอร์ชนิดหลังเป็นส่วนมาก

การควบคุมแรงดันไฟฟ้าของเครื่องกำเนิดไฟฟ้าสามารถทำได้โดยการปรับความเข้มของสนามแม่เหล็กที่โรเตอร์สร้างขึ้นด้วยการปรับกระแสไฟฟ้าตรงที่ป้อนให้กับโรเตอร์ ส่วนความถี่ของไฟฟ้าที่ผลิตขึ้นอยู่กับปัจจัย 2 อย่างคือ ความเร็วรอบที่โรเตอร์หมุนยิ่งหมุนรอบมากความถี่ไฟฟ้าก็จะยิ่งสูง และจำนวนขั้วแม่เหล็กไฟฟ้าที่สร้างขึ้นบนโรเตอร์ยังมีขั้วมากเท่าใด ความถี่ไฟฟ้าก็จะมากขึ้นตาม

ด้านประสิทธิภาพ มีข้ออยู่ที่ตัวเครื่องกำเนิดไฟฟ้าเท่านั้น ต้องควบคุมการผลิตไฟฟ้าให้ได้ ระดับแรงดันและความถี่อยู่ในเกณฑ์ที่กำหนดด้วยดังนั้น ความเร็วรอบหมุนและสนามแม่เหล็กที่ สร้างขึ้นบนโรเตอร์ จึงต้องได้รับการควบคุมอยู่เสมอ โดยจะมีตัวโกเวอร์เนอร์ (Governor) ควบคุม ความเร็วรอบให้คงที่ถ้า

ความเร็วรอบลดลงก็จะส่งสัญญาณไปยังแหล่งต้นกำลังงาน ให้เพิ่มกำลังใน การหมุนมากขึ้นเพื่อเข้าสู่สภาวะปกติต่อไป

2.1.2 กำลังไฟฟ้า (Electric Power)

บนเครื่องใช้ไฟฟ้าทุกชนิดจะมีตัวเลขกำกับไว้เสมอ เกี่ยวกับกำลังไฟฟ้า และความต่าง ศักย์ไฟฟ้าที่ใช้กับเครื่องใช้ไฟฟ้าชนิดนั้นๆ เช่น หม้อหุงข้าวขนาด "220 V 800 W" 200 V หมายถึง หม้อหุงข้าวใบนี้ใช้กับไฟที่มีความต่างศักย์ 220 โวลต์ ส่วน 800 W หมายถึงค่าพลังงานที่ หม้อหุงข้าวนี้ใช้ในเวลา 1 วินาทีหรือเรียกว่ากำลัง ไฟฟ้า ดังนั้น พลังงานไฟฟ้าที่เครื่องใช้ไฟฟ้าใช้ ไปในเวลา 1 วินาที เช่น เตารีด 1,000 วัตต์ คือเมื่อใช้เตารีดนี้จะสิ้นเปลืองพลังงานไฟฟ้า 1,000 จูล ต่อวินาทีหรือวัตต์ กำลังไฟฟ้าจะมีค่าขึ้นอยู่กับปริมาณ กระแสที่ไหลผ่านเครื่องใช้ไฟฟ้าโดย กำลังไฟฟ้า มีค่าเท่ากับผลคูณระหว่างความต่างศักย์กับกระแสไฟฟ้า เขียนสมการ 2.1 ได้ดังนี้

$$P = VI \quad (2.1)$$

เมื่อกำหนดให้ P แทน กำลังไฟฟ้า มีหน่วยเป็น วัตต์

V แทน ความต่างศักย์ที่ต่อกับเครื่องใช้ไฟฟ้ามีหน่วยเป็น โวลต์

I แทน กระแสไฟฟ้าที่ไหลผ่านเครื่องใช้ไฟฟ้ามีหน่วยเป็น แอมแปร์

$$\text{หรือ } W = P \times t \quad (2.2)$$

พลังงานไฟฟ้า (จูล) = กำลังไฟฟ้า (วัตต์) × เวลา (วินาที)

เมื่อกำหนดให้ P แทน กำลังไฟฟ้า มีหน่วยเป็น วัตต์

W แทน พลังงานไฟฟ้า มีหน่วยเป็นจูล

t แทน เวลา มีหน่วยเป็น วินาที

ดังนั้นเครื่องใช้ไฟฟ้าที่ใช้กำลังไฟฟ้าสูงๆ ถ้าใช้เป็นเวลานานจะสิ้นเปลืองพลังงานไฟฟ้ามาก ซึ่งในการคิดค่าพลังงานไฟฟ้าจะคิดเป็นหน่วยที่ใหญ่กว่าจูลคือกิโลวัตต์และคิดเวลาเป็น ชั่วโมงดังนั้น หน่วยของพลังงานไฟฟ้าจึงเป็น กิโลวัตต์-ชั่วโมง หรือหน่วย หรือยูนิต ซึ่งเขียนเป็น สมการได้ดังนี้

$$\text{พลังงานไฟฟ้า(หน่วย)} = \text{กำลังไฟฟ้า (กิโลวัตต์)} \times \text{เวลา (ชั่วโมง)}$$

พลังงานไฟฟ้าที่ใช้ในบ้านอ่านได้จากเครื่องมือวัดพลังงานไฟฟ้าที่เรียกว่า มาตรไฟฟ้า ซึ่งวัดพลังงานไฟฟ้าเป็นกิโลวัตต์ต่อชั่วโมง หรือหน่วยมาตรไฟฟ้า มีหลายขนาดกำหนดตามปริมาณ กระแสไฟฟ้าสูงสุดที่ผ่านมาตรไฟฟ้า

2.1.3 ระบบบริหารจัดการพลังงาน

ระบบบริหารจัดการพลังงาน (Energy Management System: EMS)หมายถึงระบบอัตโนมัติที่นำเข้ามาใช้ในการควบคุมให้การผลิตรวมถึงให้การใช้พลังงานนั้นเป็นไปอย่างเหมาะสมที่สุด ความหมายของระบบบริหารจัดการพลังงานนั้นค่อนข้างกว้างโดยมีได้หมายถึงเฉพาะเพียงพลังงานไฟฟ้าเท่านั้น แต่ยังคงครอบคลุมถึงพลังงานในรูปแบบอื่นด้วย เช่น พลังงานความร้อน เป็นต้น ระบบบริหารจัดการพลังงานจะหมายความถึง การบริหารจัดการพลังงานไฟฟ้าเท่านั้น ซึ่งอ้างอิงระบบบริหาร

จัดการพลังงานตามแผนแม่บทการพัฒนาระบบโครงข่ายไฟฟ้าสมาร์ทกริด พ.ศ. 2558 – 2579 ซึ่งเน้นระบบบริหาร จัดการพลังงานด้านผู้ใช้ไฟฟ้าเป็นหลัก ซึ่งการบริหารจัดการพลังงานในด้านของผู้ใช้ไฟฟ้าจะกล่าวถึงระบบบริหาร จัดการพลังงานในบ้านเรือน ระบบบริหารจัดการพลังงานในอาคาร และระบบบริหารจัดการพลังงาน ในโรงงานอุตสาหกรรมพัฒนาต่อเนื่องโดยใช้ Software เทคโนโลยีที่ทันสมัย และเป็นที่ยอมรับสามารถขยาย การใช้งานได้หลายระดับ ตั้งแต่ PC 1 เครื่องจนถึงระบบ Network ขนาดใหญ่ เทคโนโลยีทันสมัยประยุกต์ใช้กับ อุปกรณ์สมัยใหม่ได้ เช่น Smart Devices, Web Based, SMS

ระบบจัดการพลังงาน (Energy Management System: EMS) คือเทคโนโลยีการสื่อสารด้วยด้านระบบสารสนเทศที่ใช้ในการเชื่อมต่อกับอุปกรณ์ไฟฟ้า ทำให้ระบบไฟฟ้าสามารถทำงานจัดการพลังงานไฟฟ้าได้อย่างมีประสิทธิภาพ ประหยัดพลังงาน และการจัดการด้านการผลิตไฟฟ้าจากพลังงานลม พลังงานแสงอาทิตย์ เป็นต้น

โดยระบบจัดการพลังงานสามารถแบ่งออกได้เป็น 3 ประเภท ดังนี้

(1) ระบบจัดการพลังงานภายในโรงงาน (Factory Energy Management System:FEMS) คือเทคโนโลยีการสื่อสารและสารสนเทศที่ใช้เชื่อมต่อกับเครื่องจักรและอุปกรณ์ไฟฟ้าภายในโรงงาน เพื่อเก็บรวบรวมข้อมูลการใช้พลังงานไฟฟ้าของเครื่องจักรเหล่านี้ และวิเคราะห์ข้อมูลโดยใช้ระบบประมวลผล เพื่อดำเนินการเปิดปิดเครื่องจักรในเวลาที่เหมาะสม หรือปรับปรุงคุณภาพของการใช้ไฟฟ้าให้ดีกว่าเดิม เพื่อให้ผู้ประกอบการ จ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม

(2) ระบบจัดการพลังงานภายในตึกอาคาร (Building Energy Management System : BEMS) คือเทคโนโลยีการสื่อสารและสารสนเทศที่ใช้ในการเชื่อมต่อกับโหนดภายในอาคาร ได้แก่ โหลดแสงสว่าง และโหลดปรับอากาศ รวมถึงเครื่องกำเนิดไฟฟ้าแบบกระจาย ของตัวอาคาร เช่น ระบบผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ ระบบผลิตไฟฟ้าจากพลังงานความร้อนที่เกิดจากโหลดปรับอากาศ ระบบผลิตไฟฟ้าจากพลังงานลม ระบบผลิตไฟฟ้าจากเครื่องยนต์ดีเซล เป็นต้น

เพื่อเก็บรวบรวมข้อมูลการใช้พลังงานไฟฟ้าของโหนดรวมถึงข้อมูลการผลิตพลังงานไฟฟ้าจากเครื่องกำเนิดไฟฟ้าเหล่านี้และวิเคราะห์ข้อมูลโดยใช้ระบบประมวลผลเพื่อดำเนินการจัดสรรการจ่ายพลังงานไฟฟ้าจากเครื่องกำเนิดไฟฟ้าให้แก่โหนดในเวลาที่เหมาะสมที่สุดเพื่อให้เจ้าของอาคารจ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม


(3) ระบบจัดการพลังงานภายในบ้าน (Home Energy Management System: HEMS) คือ การประยุกต์เทคโนโลยีการสื่อสาร และสารสนเทศเพื่อจัดการความต้องการพลังงานไฟฟ้าของอุปกรณ์ภายในบ้าน เช่น การตัดต่อโหลดตามลำดับความสำคัญ การควบคุมพลังงานไฟฟ้าที่ได้จากแหล่งจ่ายไฟฟ้าที่ไม่แน่นอน เป็นต้น และเก็บข้อมูลการใช้ไฟฟ้าจากเครื่องใช้ไฟฟ้า โดยใช้ SmartMeter รวมถึงแจ้งเตือนให้ผู้ใช้ไฟฟ้าทราบถึงสถานการณ์ใช้พลังงานไฟฟ้า เพื่อให้เจ้าของบ้านจ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม และผู้อาศัยภายในบ้านมีความสะดวกสบายมากกว่าเดิม

2.2 การทำเหมืองข้อมูล (Data Mining) และการเรียนรู้ของเครื่องมือ (Machine Learning)

2.2.1 เหมืองข้อมูล

เหมืองข้อมูล (Data Mining) คือการนำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) วิธีการทางสถิติ (Statistical Methods) วิธีการปัญญาประดิษฐ์ (Artificial Intelligence) หรือวิธีอื่น ๆ มาทำการวิเคราะห์และสกัดความรู้จากข้อมูลที่จัดเก็บไว้ในฐานข้อมูลหรือจัดเก็บไว้ในรูปอื่น ๆ โดยจุดประสงค์ของการทำเหมืองข้อมูล คือ การวิเคราะห์แนวโน้ม ความสัมพันธ์กฎ หรือรูปแบบของข้อมูล ซึ่งเป็นความรู้ที่ถูกละทิ้งอยู่ภายใต้ข้อมูลขนาดใหญ่ และนำสารสนเทศที่ได้มาช่วยใช้ในการวางแผนการตัดสินใจการบริหารหรือแก้ปัญหาต่าง ๆ ซึ่งถือได้ว่าเป็นเครื่องมือที่ช่วยเพิ่มคุณค่าให้กับข้อมูลที่มีอยู่ เหมืองข้อมูลจะสามารถแก้ปัญหาได้ บางปัญหาตามเทคนิควิธีการที่เลือกใช้ได้เท่านั้น โดยประโยชน์หลักของเหมืองข้อมูล คือ การค้นหาความรู้ที่ซ่อนอยู่ในฐานข้อมูล เพื่อให้ได้ซึ่งความรู้มาช่วยประกอบในการตัดสินใจ

รายละเอียดการแปลงข้อมูลมาเป็นความรู้เพื่อช่วยในการประกอบการตัดสินใจ ดังภาพที่ 2.1



ภาพที่ 2.1 การแปลงข้อมูลเป็นความรู้เพื่อช่วยในการตัดสินใจ

ที่มา: การใช้เทคนิคเหมืองข้อมูลเพื่อคัดกรองบุคคลที่มีแนวโน้มสัมฤทธิ์ผล ธาระวัฒน์ วรณประภา

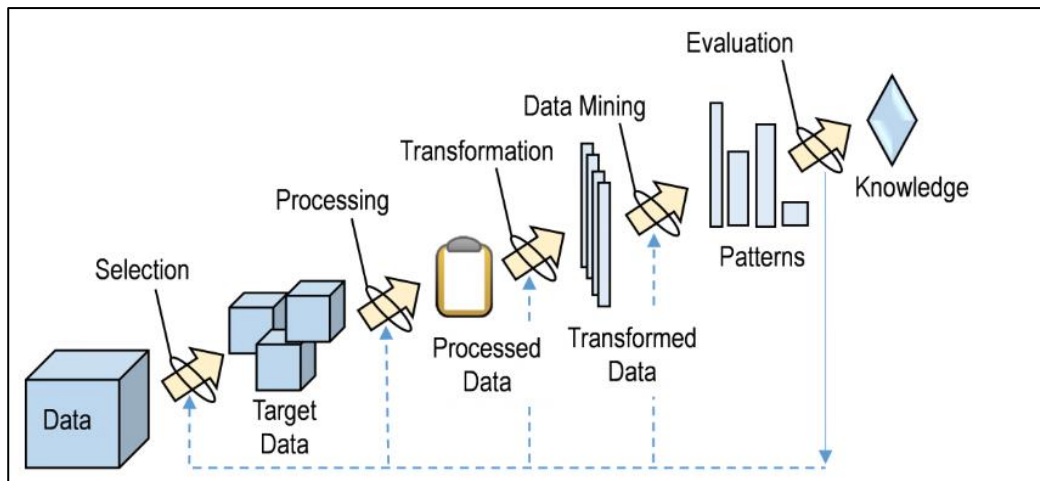
การทำเหมืองข้อมูล เป็นกระบวนการวิเคราะห์และกลั่นกรองข้อมูลจากฐานข้อมูลขนาดใหญ่ เพื่อค้นหาความสัมพันธ์ของข้อมูล และนำประโยชน์ที่ได้รับมาใช้ในการสนับสนุนการตัดสินใจในด้านต่าง ๆ ซึ่งสามารถแบ่งออกได้เป็น 2 ประเภทหลัก ๆ คือ

การคาดการณ์หรือพยากรณ์ (Predictive Data Mining) เป็นการประมาณค่าที่เหมาะสมของข้อมูลล่วงหน้าที่จะเกิดขึ้นโดยใช้ข้อมูลที่ผ่านมาในอดีต

การบรรยายหรืออธิบายลักษณะ (Descriptive Data Mining) เป็นการแบ่งกลุ่มข้อมูลที่มีอยู่เพื่ออธิบายข้อมูลต่าง ๆ ที่เกิดขึ้น

- (1) ประเภทของการทำเหมืองข้อมูล

1. การจำแนกประเภทข้อมูล (Classification) เป็นการทำให้เหมือนข้อมูลที่มีจุดประสงค์ที่สร้างตัวแบบจำแนกประเภทข้อมูลจากข้อมูลเรียนรู้ที่มีการจำแนกประเภทแล้ว และใช้ตัวแบบที่สร้างได้จำแนก ข้อมูลใหม่ ที่ไม่ทราบประเภท
2. การจับกลุ่มข้อมูล (Clustering) เป็นการแบ่งข้อมูลออกเป็นกลุ่มโดยข้อมูลที่อยู่ในกลุ่มเดียวกันจะมีลักษณะที่คล้ายคลึงกันและข้อมูลที่อยู่ต่างกลุ่มจะมีลักษณะที่แตกต่างกันซึ่งการจับกลุ่มข้อมูลดังกล่าวต้องอาศัยมาตรวัดความเหมือนหรือแตกต่างระหว่างข้อมูลใด ๆ เพื่อจัดข้อมูลที่มีลักษณะคล้ายคลึงกันเข้าอยู่ในกลุ่มเดียวกัน
3. การสร้างกฎความสัมพันธ์ (Association Rule) เป็นการทำให้เหมือนข้อมูลที่ต้องการหากฎที่บอกความสัมพันธ์ระหว่างเหตุการณ์ที่มักเกิดขึ้นพร้อม ๆ กันอยู่เสมอ ข้อมูลที่จะทำการวิเคราะห์อาจเป็นรายการสินค้าที่ ลูกค้าสั่งซื้อในแต่ละครั้งกฎความสัมพันธ์ที่สร้างได้จะระบุถึงความสัมพันธ์ว่าเมื่อพบเหตุการณ์หนึ่งหรือหลาย เหตุการณ์เกิดขึ้นจะมีโอกาสสูงที่เหตุการณ์อีกอย่างหนึ่งหรืออีกหลาย เหตุการณ์จะเกิดขึ้นด้วย
4. การคาดคะเน (Estimation) มีลักษณะคล้ายกับการจำแนกประเภทข้อมูล คือ มีการสร้างตัวแบบเพื่อ คาดคะเนค่าของตัวแปรเป้าประสงค์ จากค่าตัวแปรอื่น ๆ ข้อแตกต่างคือตัวแปรที่จะถูกคาดคะเนจะมี ชนิดเป็น ตัวเลขแทนที่จะเป็นประเภทข้อมูล เช่น การประมาณค่าปริมาณการขายสินค้าช่วงวันหยุด เป็นต้น
5. การค้นหาข้อมูลที่มีความผิดปกติ (Anomaly Detection) เป็นการค้นหาข้อมูลที่มีลักษณะผิดปกติหรือ ความแตกต่างจากข้อมูลส่วนใหญ่ (Outlier Data) ข้อมูลผิดปกติเหล่านี้จะมีจำนวนน้อยปะปนอยู่ในข้อมูลส่วนใหญ่ ซึ่งอาจส่งผลให้การวิเคราะห์ข้อมูลมีความถูกต้องลดน้อยลง



ภาพที่ 2.2 แสดงขั้นตอนการทำเหมืองข้อมูล

ที่มา: การวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในบ้านสำหรับบ้านอัจฉริยะด้วยวิธีการเหมืองข้อมูล ธนิต เซษฐ์ คำศรีสุข

(2) ขั้นตอนการทำเหมืองข้อมูล

การทำเหมืองข้อมูลนั้นมีกระบวนการมาตรฐานที่เรียกว่าวิธีการ CRISP-DM (Cross Industry Standard Process for Data Mining) ประกอบด้วย 6 ขั้นตอน

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 และผลประโยชน์จากการทำเหมืองข้อมูลจะคุ้มค่างกับต้นทุนที่เสียไปหรือไม่ เป็นต้น

1.4) ตั้งเป้าหมายในเชิงการทำเหมืองข้อมูล ซึ่งต่างไปจากเป้าหมายหลักใน การแก้ไขปัญหา

1.5) วางแผนการทำเหมืองข้อมูลว่าจะเก็บข้อมูลอย่างไร และใช้อัลกอริทึมใด ในการทำเหมืองข้อมูล

2. Data Understanding เป็นการรวบรวมข้อมูลที่เกี่ยวข้อง เพื่อใช้ในการวิเคราะห์ด้วยเทคนิคเหมืองข้อมูล ในการรวบรวมข้อมูลนั้นควรพิจารณาด้วยว่าเป็นข้อมูลที่ได้มาจากแหล่งข้อมูลที่ต้องนำเชื่อถือ ข้อมูลที่ได้มีปริมาณมากพอหรือยัง และเป็นข้อมูลที่เหมาะสม มีรายละเอียดเพียงพอต่อการนำไปใช้ในการวิเคราะห์ ประกอบด้วยกระบวนการย่อย ดังนี้

2.1) เก็บรวบรวมข้อมูลที่เกี่ยวข้อง

2.2) ตรวจสอบข้อมูลขั้นต้น โดยตรวจสอบทั้งความสมบูรณ์และความถูกต้องของข้อมูล

3. Data Preparation ขั้นตอนการเตรียมข้อมูลเป็นขั้นตอนที่ใช้เวลานานที่สุด เนื่องจากแบบจำลองที่ได้จากการทำเหมืองข้อมูลจะให้ผลลัพธ์ที่ถูกต้องหรือไม่ขึ้นขึ้นอยู่กับคุณภาพของข้อมูลที่ใช้กล่าวคือ ถ้าข้อมูลที่ใช้นั้นไม่ถูกต้องมีผิดพลาดย่อมสะท้อนถึงผลลัพธ์ที่ได้ ซึ่งอาจทำให้ตีความผลลัพธ์ได้คลาดเคลื่อนเช่นกัน โดยการเตรียมข้อมูลนั้น สามารถแบ่งออกได้เป็น 3 ขั้นตอนย่อย มีรายละเอียดดังนี้

3.1) การคัดเลือกข้อมูล (Data Selection) ควรกำหนดเป้าหมายก่อนว่าจะทำการวิเคราะห์อะไรแล้วทำการเลือกใช้เฉพาะข้อมูลที่เกี่ยวข้องกับสิ่งที่เราจะทำการวิเคราะห์

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

3.3) การแปลงรูปแบบของข้อมูล (Data Transformation) เป็นขั้นตอนการเตรียมข้อมูลให้อยู่ในรูปแบบที่พร้อมนำไปใช้ในการวิเคราะห์ตามอัลกอริทึมของการทำเหมืองข้อมูลที่ใช้

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

3.5) Evaluation เป็นการประเมินประสิทธิภาพของผลลัพธ์ที่ได้จากแบบจำลอง วิเคราะห์ข้อมูลว่าตรงกับวัตถุประสงค์หรือสามารถตอบโจทย์ทางธุรกิจที่ตั้งไว้ในขั้นตอนแรกหรือไม่ มีความน่าเชื่อถือมากน้อยเพียงใด ซึ่งอาจจะย้อนกลับไปยังขั้นตอนก่อนหน้า เพื่อเปลี่ยนแปลงแก้ไขให้ได้ผลลัพธ์ตามที่ต้องการ ในกรณีที่มีการสร้างแบบจำลองวิเคราะห์ข้อมูลหลายแบบจำลอง ในขั้นตอนนี้จะทำการประเมินแต่ละแบบจำลองด้วยว่ามีส่วนดีส่วนด้อยอย่างไร และควรเลือกใช้แบบจำลองใดในการทำงานส่วนนี้ต้องอาศัยทักษะการวิเคราะห์ข้อมูลและธุรกิจ เพื่อช่วยให้การวิเคราะห์ทำได้สะดวกและรวดเร็วขึ้น จึงมีการใช้เครื่องมือทางด้านกราฟิก เช่น การแสดงผลการวิเคราะห์ด้วยกราฟ รายงานรูปแบบต่าง ๆ หรือ Dashboard เป็นต้น

3.6) Deployment ผลลัพธ์หรือองค์ความรู้ที่ได้จากการวิเคราะห์ข้อมูลด้วย เทคนิคเหมืองข้อมูลจะไม่มีประโยชน์ ถ้าไม่นำไปใช้งานจริง

2.2.2 การเรียนรู้ของเครื่องมือ (Machine Learning)

เป็นสาขาหนึ่งของปัญญาประดิษฐ์เกี่ยวข้องกับการศึกษาและการสร้างอัลกอริทึมที่สามารถเรียนรู้ข้อมูล และทำนายผลข้อมูลได้ อัลกอริทึมจะทำงานโดยอาศัยแบบจำลองที่สร้างมาจากชุดข้อมูลตัวอย่าง ขาเข้าเพื่อการทำนายหรือตัดสินใจในภายหลัง แทนที่จะทำงานตามลำดับของคำสั่งโปรแกรมคอมพิวเตอร์ การเรียนรู้ของเครื่องมือ แบ่งออกเป็นการเรียนรู้ของเครื่องมือแบบมีผู้สอน (Supervised Learning) และการเรียนรู้ของเครื่องมือแบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งการเรียนรู้แบบมีผู้สอนจำเป็นต้องมีข้อมูลในส่วนสำหรับฝึกสอน (Training Data) จากที่มนุษย์ป้อนเข้ามา เพื่อให้อัลกอริทึมสร้างแบบจำลองในการเรียนรู้ความสัมพันธ์ระหว่างข้อมูลแล้วทำนายผลลัพธ์ออกมา แต่การเรียนรู้แบบนี้แตกต่างจากการเรียนรู้แบบไม่มีผู้สอน คือจะไม่มีกระบวนการที่ต้องการไว้ก่อน เนื่องด้วยการเรียนรู้แบบนี้จะพิจารณาวัตถุเป็นเซต ของตัวแปรสุ่ม เพียงทำการป้อนข้อมูลเข้าไปแล้วบอกความต้องการจากนั้นจึงให้เครื่องมือทำนายออกมา

2.3 ทฤษฎีที่เกี่ยวกับนิยามหรือความหมายของตัวแบบการพยากรณ์และการวัดความผิดพลาดแบบจำลองในการพยากรณ์

วิธีในการพยากรณ์ในปัจจุบันมีหลากหลายวิธี โดยจะนำเอาหลักการ เช่น คณิตศาสตร์ สถิติ เศรษฐศาสตร์ สังคมศาสตร์ ปัญญาประดิษฐ์ เป็นต้น มาประยุกต์ใช้ในการพยากรณ์ โดยแต่ละวิธีมีความยากง่าย ในแบบจำลองและสมการ ความรู้เกี่ยวเนื่องในแบบจำลอง ข้อดีข้อเสีย และความถูกต้องแม่นยำต่างกัน โดยจะยกตัวอย่างแบบที่เกี่ยวจะขอกล่าวถึงโดยพอสังเขปดังนี้

2.3.1 การวิเคราะห์อนุกรมเวลา (Time-series analysis)

การพยากรณ์โดยการวิเคราะห์อนุกรมเวลา (Time-series analysis) เป็นการพยากรณ์โดยการศึกษาถึงความเคลื่อนไหวของข้อมูลชุดหนึ่ง ๆ ตามงวดระยะเวลาในอดีตว่า มีการเปลี่ยนแปลง อย่างไร ตั้งแต่อดีตถึงปัจจุบัน ตัวอย่างข้อมูลอนุกรมเวลา ได้แก่ ข้อมูลการขายสินค้ารายวัน ข้อมูลการผลิตสินค้ารายเดือน และข้อมูลส่งออกหรือข้อมูลการนำเข้าสินค้าในแต่ละไตรมาสของปีต่าง ๆ ในการนำเสนอข้อมูลอนุกรมเวลามักจะเรียงลำดับเวลาตามปฏิทิน

ในทางปฏิบัติหน่วยงานต่าง ๆ ทั้งภาครัฐบาลและเอกชน จะรวบรวมข้อมูลอนุกรมเวลา เพื่อประเมินผลทางเศรษฐกิจหรือธุรกิจที่ผ่านมา เพื่อการวางแผนการดำเนินงานต่าง ๆ ในอนาคต โดยกำหนดให้รูปแบบของธุรกิจไม่เปลี่ยนแปลงไปมากนัก ซึ่งจะช่วยในการวางแผนทางด้านการใช้ปัจจัยการผลิตต่างๆให้ เป็นไปอย่างเหมาะสมยิ่งขึ้น การรวบรวมข้อมูลอนุกรมเวลาอาจจะ รวบรวมได้ทั้งในรูปของรายวัน รายสัปดาห์ รายเดือน รายไตรมาส และรายปีทั้งนี้ขึ้นอยู่กับว่าจะ ต้องการใช้ประโยชน์จากข้อมูลในการวางแผนระยะสั้น ระยะยาว เช่น ฝ่ายควบคุมการผลิตต้องการทราบข้อมูลการขายสินค้าในแต่ละเดือนเพื่อวางแผนการผลิตและ ควบคุมของคงคลังในแต่ละปีให้ ถูกต้องและเป็นไปอย่างประหยัด

ข้อมูลอนุกรมเวลาที่ได้รวบรวมไว้นั้นสามารถนำเสนอได้ทั้งในรูปกราฟหรือตารางการ นำเสนอ ข้อมูลอนุกรมเวลารูปกราฟ จะช่วยให้ทราบถึงทิศทางของการเปลี่ยนแปลงของข้อมูลอนุกรม เวลาชุดนั้นเพื่อที่จะ ได้ภาพพจน์โดยกว้าง ๆ เกี่ยวกับแนวโน้มของข้อมูลอนุกรมเวลาชุดนั้น และพิจารณาคว่ามีลักษณะเป็นเส้นตรง หรือเส้นโค้งอย่างไรหรือไม่รวมทั้งการวิเคราะห์องค์ประกอบ ของอนุกรมเวลาต่อไป

การสังเกตข้อมูลอนุกรมเวลาแต่ละชุดจะมองเห็นการเปลี่ยนแปลง สาเหตุของการ เปลี่ยนแปลงที่ เกิดขึ้นกับข้อมูลนั้น เนื่องจากอิทธิพลขององค์ประกอบต่างๆ 4 ประการ (เรียกว่า องค์ประกอบของอนุกรม เวลา) คือองค์ประกอบของแนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cyclical) ความผิดปกติ (Irregular)

องค์ประกอบของแนวโน้ม เป็นองค์ประกอบที่แสดงถึงทิศทางของข้อมูลแต่ละชุด ตั้งแต่ อดีตจนถึง ระยะเวลาสุดท้ายของข้อมูลที่รวบรวมได้ซึ่งทิศทางของข้อมูลนั้นอาจจะพุ่งไปในแนวที่ สูงขึ้นหรือลดต่ำลง ข้อมูลอนุกรมเวลาที่มีองค์ประกอบของค่าแนวโน้ม ส่วนใหญ่จะเกี่ยวข้องกับ ความเคลื่อนไหวของข้อมูลใน ระยะเวลาที่ค่อนข้างยาวนาน เช่น อุปสงค์ของสินค้าการใช้พลังงาน เป็นต้น ลักษณะของแนวโน้มอาจจะเป็น เส้นตรง เส้นโค้ง หรืออื่น ๆ ก็ได้

องค์ประกอบของการเปลี่ยนแปลงตามฤดูกาล หมายถึงการที่ข้อมูลอนุกรมเวลามีรูปแบบ การ เคลื่อนไหวขึ้นลงทำนองเดียวกันในช่วงเวลาเดียวกันของรอบเวลาหนึ่ง ซึ่งส่วนใหญ่จะไม่เกิน 1 ปี ในการ พิจารณาความเคลื่อนไหวตามฤดูกาลนี้หน่วยของระยะเวลาอาจจะเป็น 3 เดือน รายเดือน รายสัปดาห์รายวัน หรือแม้กระทั่งรายชั่วโมงก็ได้ ข้อมูลที่มักได้รับผลกระทบจากความ เคลื่อนไหว หรือเปลี่ยนแปลงตามฤดูกาล ได้แก่การขายการผลิต เป็นต้น จากการนำข้อมูลการขาย สินค้าในห้างสรรพสินค้าแห่งหนึ่งเป็นรายเดือนมาลง จุดเพื่อดูการเคลื่อนไหวของข้อมูลจะพบว่า ในเดือนท้าย ๆ ของปีจะมียอดขายสูงและตอนต้นปียอดขาย

ค่อนข้างต่ำ โดยรูปแบบการขายสินค้า จะเคลื่อนไหวขึ้นลงเหมือนกันทุกปีการเกิดซ้ำกันเป็นระยะๆของการเคลื่อนไหวของข้อมูลในแต่ละปีนี้เป็นผลเนื่องจากการเปลี่ยนแปลงตามฤดูกาลนั่นเอง

องค์ประกอบของอนุกรมเวลาส่วนที่สามได้แก่การผันแปรตามวัฏจักร เป็นลักษณะการเคลื่อนไหวของข้อมูลที่ขึ้นลงคล้ายลูกคลื่นที่มีผลกระทบกระเทือนต่อธุรกิจโดยทั่วไป รูปแบบของ การผันแปรตามวัฏจักรนี้แตกต่างจากการผันแปรตามฤดูกาลกล่าวคือเราจะไม่ทราบว่าช่วงของการ เกิดวัฏจักรหนึ่ง ๆ จะกินระยะเวลาเวลานานเท่าใดและขนาดของการเปลี่ยนแปลงขึ้น ๆ ลง ๆ ในแต่ละวัฏจักรนั้นจะมีระดับความสูงต่ำมากน้อยเพียงใดเนื่องจากการเปลี่ยนแปลงตามวัฏจักรส่วนใหญ่เป็น ปรากฏการณ์ที่เกิดขึ้นในด้านธุรกิจและ เศรษฐศาสตร์ดังนั้น การผันแปรตามวัฏจักรโดยทั่วไป จะแสดงถึงภาวะการเกิดซ้ำกันของภาวะธุรกิจเพื่อพู่ ถดถอยและตกต่ำ ภาวะต่าง ๆ นี้ อาจจะสั้นหรือ ยาวก็ได้

องค์ประกอบประการสุดท้ายของอนุกรมเวลาก็คือการผันแปรเนื่องจากความผิดปกติเป็น การเปลี่ยนแปลงของข้อมูลอนุกรมเวลาที่เกิดจากปัจจัยที่ไม่อาจคาดคะเนได้ล่วงหน้า ตัวอย่างของ สาเหตุที่ทำให้เกิดการแปรผันแบบผิดปกติได้แก่การเกิดภาวะผิดปกติทางดินฟ้าอากาศการเกิดน้ำท่วม การนัดหยุดงานของ คนงาน และการเกิดสงคราม เป็นต้น ซึ่งเป็นปรากฏการณ์ที่เราไม่อาจ ทำนายได้ล่วงหน้า

ในการพยากรณ์โดยอาศัยการวิเคราะห์อนุกรมเวลา ข้อมูลที่นำมาวิเคราะห์นั้นก็ประกอบไปด้วย องค์ประกอบทั้ง 4 ดังที่ได้กล่าวมาแล้วเมื่อเราจะทำการพยากรณ์ข้อมูลชุดใดเราจะ รวมองค์ประกอบทั้ง 4 นี้ เข้าด้วยกัน โดยการรวมนั้นจะอยู่ในลักษณะของผลคูณ ซึ่งเราอาจเขียน เป็นสมการ 2.4 ได้ดังนี้

$$Y = T \times S \times C \times I \quad (2.4)$$

เมื่อ Y คือ ค่าของการพยากรณ์

T คือ ค่าอิทธิพลของแนวโน้ม

S คือ ค่าอิทธิพลของฤดูกาล

C คือ ค่าอิทธิพลของวัฏจักร

I คือ ค่าอิทธิพลของการผันแปรแบบผิดปกติ

2.3.2 การวิเคราะห์การถดถอย (Regression Analysis)

งานวิจัยที่มีวัตถุประสงค์ในการพยากรณ์หรือทำนายตัวแปรที่ต้องการศึกษาโดยมีตัวแปรตามที่เป็น ตัวแปรต่อเนื่องเพียงหนึ่งตัว เรียกว่าการวิเคราะห์การถดถอย (Regression Analysis) โดยเรียกตัวแปรตามที่ต้องการศึกษาว่า ตัวแปรเกณฑ์ (Criterion Variable) และเรียกตัวแปรที่ใช้พยากรณ์ว่า ตัวแปรพยากรณ์หรือ ตัวแปรทำนาย (Predictor Variable) กรณีใช้ตัวแปรพยากรณ์เพียงตัวเดียวจะเรียกว่าการ วิเคราะห์การถด ถอยอย่างง่าย (Simple Regression) ส่วนกรณีที่มีตัวแปรพยากรณ์มากกว่า 1 ตัว จะเรียกว่า การวิเคราะห์ การถดถอยพหุคูณ (Multiple Regression) วิธีการวิเคราะห์การถดถอย มีดังนี้

(1) วิธี Enter จะใช้ตัวแปรทำนายที่ศึกษาเข้าไปในสมการทำนายทุกตัว ถึงแม้ว่าตัวแปรทำนายบางตัวจะพยากรณ์ตัวแปรเกณฑ์ได้หรือไม่ก็ตามวิธีนี้มักใช้ในกรณีที่ต้องการทราบว่าตัวแปรแต่ละตัวที่ทำการศึกษจะสามารถทำนายตัวแปรเกณฑ์ได้หรือไม่ มากน้อยเพียงใด

(2) วิธี Forward เป็นวิธีการที่ต้องการได้แบบจำลองประหยัดคือจะคัดเลือกเฉพาะตัวแปรทำนายที่สามารถพยากรณ์ตัวแปรตามได้เท่านั้นโดยจะคัดเลือกตัวแปรพยากรณ์เข้ามาในสมการที่ละตัวขั้นแรกจะคัดเลือกตัวแปรทำนายที่มีค่าสัมประสิทธิ์สหสัมพันธ์กับตัวแปรเกณฑ์สูงสุดเข้ามาก่อนจากนั้นจึงคัดเลือกตัวแปรที่สำคัญรอง ลงมาโดยพิจารณาจากค่าสัมประสิทธิ์สหสัมพันธ์บางส่วน (Partial Correlation) นั่นคือพิจารณาความสัมพันธ์ระหว่างตัวแปรทำนายที่เหลือแต่ละตัวกับตัวแปรเกณฑ์โดยควบคุมอิทธิพลอันเนื่องมาจากตัวแปรทำนายที่เข้าสมการก่อนหน้า

(3) วิธี Backward เป็นวิธีที่พยายามจะคัดเลือกตัวแปรที่ดีที่สุดในการทำนายแต่เป็นวิธีที่ตรงข้ามกับวิธี Forward นั่นคือ ในตอนแรกจะนำตัวแปรทำนายทุกตัวเข้ามาในสมการ (เหมือนวิธี Enter)จากนั้นจะดำเนินการพิจารณาตัวแปรทำนายที่มีค่าสัมประสิทธิ์สหสัมพันธ์บางส่วน (Partial Correlation)กับตัวแปรเกณฑ์โดยควบคุมอิทธิพลของตัวแปรทำนายอื่น ๆ ซึ่งมีค่าต่ำสุดออกจากสมการ แล้วจึงดำเนินการทดสอบว่าค่าสัมประสิทธิ์การพยากรณ์ R² ลดลงอย่างมีนัยสำคัญหรือไม่ ถ้าพบว่า ลดลงอย่างไม่มีนัยสำคัญ แสดงว่า ตัวแปรดังกล่าวไม่ได้มีส่วนทำให้การพยากรณ์ตัวแปรเกณฑ์เพิ่มขึ้นเลยจากนั้นจึงดำเนินการขจัดตัวแปรทำนายที่มีความสำคัญน้อยรองลงม่ออกไปอีก ซึ่งการขจัดตัวแปรทำนายจะ สิ้นสุดลง เมื่อพบว่า มีผลทำให้ค่า R² ลดลงอย่างมีนัยสำคัญทางสถิติ นั่นแสดงว่าตัวแปรดังกล่าวมีความสำคัญต่อการทำนายตัวแปรตาม

(4) วิธี Stepwise เป็นวิธีที่มีความเหมาะสมในการพิจารณาคัดเลือกตัวแปรทำนายที่ดีที่สุด ซึ่งลำดับขั้น ตอนจะคล้ายกับวิธี Forward เพียงแต่ว่าการวิเคราะห์ด้วย Stepwise นั้น จะทำการทดสอบตัวแปรทำนายที่เข้า สมการไปแล้วทุกครั้งที่มีการนำตัวแปรใหม่เข้าในสมการนั้น หมายความว่า ตัวแปรบางตัวเข้าไปใน สมการแล้วก็ สามารถถูกขจัดออกจากสมการได้หากพบว่าไม่มีความสำคัญในการทำนาย ซึ่งวิธี Forward จะไม่ได้ ทดสอบในส่วนนี้

2.3.3 อัลกอริทึมนาอิวเบย์ (Naïve Bayes)

เป็นวิธีการเรียนรู้เพื่อสร้างตัวจำแนกข้อมูลโดยอาศัยหลักทฤษฎีความน่าจะเป็น มีความคิดพื้นฐานมาจากทฤษฎีของเบย์ (Bay theorem) ในการวิเคราะห์หาความน่าจะเป็นของเหตุการณ์ที่ยังไม่เคยเกิดขึ้น โดยคาดเดาจากเหตุการณ์ที่เคยเกิดขึ้นมาแล้ว บนสมมติฐานว่า ตัวแปรแต่ละตัวที่เกี่ยวข้องนั้นมีความเป็นอิสระต่อกัน

โดยมีสูตรการคำนวณความน่าจะเป็นแบบมีเงื่อนไข ดังสมการที่ 2.5

$$P(B|A) = \frac{P(A|B) \times P(B)}{P(A)}$$

เมื่อ P(A) คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ A
P(B) คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ B

$P(A|B)$ คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ A เมื่อเกิดเหตุการณ์ B

$P(B|A)$ คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ B เมื่อเกิดเหตุการณ์ A

โดยสามารถประยุกต์ใช้ทฤษฎีแบบเบย์ให้สอดคล้องกับการจำแนกประเภทข้อมูล ดังสมการที่

$$P(\text{Class}|\text{Attribute}) = \frac{P(\text{Attribute}|\text{Class}) \times P(\text{Class})}{P(\text{Attribute})}$$

เมื่อ $P(\text{Class})$ คือ ความน่าจะเป็นในการเกิดคลาส

$P(\text{Attribute})$ คือ ความน่าจะเป็นในการเกิดคุณลักษณะ

$P(\text{Class}|\text{Attribute})$ คือ ความน่าจะเป็นในการเกิดคลาส (Class) เมื่อมีคุณลักษณะ (Attribute) เกิดขึ้น

จากสมการที่ เมื่อข้อมูลแต่ละตัวอย่างมีจำนวนคุณลักษณะมากกว่า 1 ตัวจะได้สมการที่ ดังนี้

$$P(\text{Class}|a_1, a_2 \dots a_n) = \frac{P(\text{Class})P(a_1, a_2 \dots a_n|\text{Class})}{P(a_1, a_2 \dots a_n|\text{Class})}$$

กรณีที่เกิดคุณลักษณะ a_i ใด ๆ ไม่ขึ้นตรงต่อกันสามารถคำนวณ $P(a_1, a_2 \dots a_n|\text{Class})$ ได้ดังสมการที่

$$P(a_1, a_2 \dots a_n|\text{Class}) = \prod_{i=1}^n P(a_i|\text{Class})$$

$$\text{เมื่อ } \prod_{i=1}^n P(a_i|\text{Class}) = P(a_1|\text{Class}) P(a_2|\text{Class}) \dots P(a_n|\text{Class})$$

ดังนั้นการจำแนกแบบเบย์อย่างง่ายจึงสามารถหา ได้โดยการหาค่าความน่าจะเป็น $P(a_1, a_2 \dots a_n|\text{Class})$ ซึ่งขึ้นอยู่กับประเภทข้อมูลที่มีการเรียนรู้ในชุดข้อมูลนั้น เมื่อ c_j เป็นสมาชิกของคลาสต่าง ๆ โดยผลลัพธ์ของการจำแนกประเภทจะกำหนดคลาสที่มีค่าความน่าจะเป็นมากที่สุดให้กับตัวอย่างที่ต้องการพยากรณ์ ดังสมการที่ 2-6

$$\text{Classify(Data)} = \underset{c_j \in C}{\text{argmax}} P(c_j) \prod_{i=1}^n P(a_i|c_j)$$

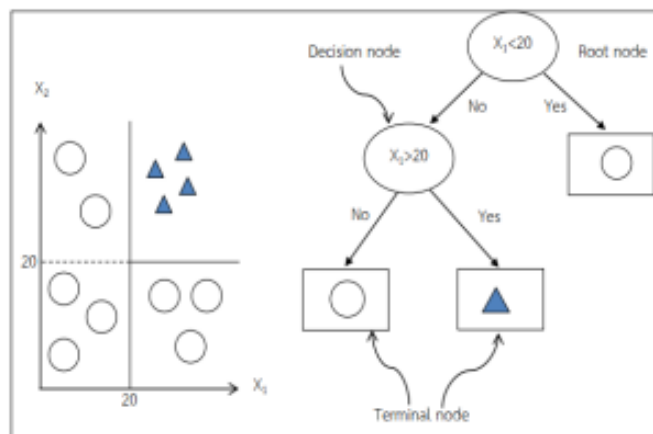
2.3.4 เทคนิค Decision Tree

เทคนิคต้นไม้ตัดสินใจ (Decision Tree) เป็นการนำข้อมูลมาสร้างตัวแบบการพยากรณ์ในรูปของต้นไม้ช่วยตัดสินใจ ซึ่งต้นไม้ช่วยตัดสินใจนั้นทำงานแบบ Supervised Learning คือ สามารถสร้างตัวแบบการจำแนกหมวดหมู่ได้จากกลุ่มตัวอย่างของข้อมูลที่ได้กำหนดก่อนล่วงหน้าซึ่งเรียกว่า Training Set ได้อัตโนมัติและสามารถพยากรณ์กลุ่มรายการที่ยังไม่เคยนำมาจัดหมวดหมู่ได้ด้วย

ต้นไม้ตัดสินใจมีลักษณะคล้ายต้นไม้ประกอบด้วยโหนดภายใน (Internal node) จะแสดงคุณลักษณะ (Attribute) ของข้อมูลโดยที่จุดเริ่มต้นของต้นไม้เรียกว่า โหนดราก แต่ละกิ่งแสดงค่าของคุณลักษณะของแต่ละโหนด และสีโหนดแสดงกลุ่ม (Class) ซึ่งเป็นผลลัพธ์ที่สามารถแยกแยะได้

ต้นไม้ตัดสินใจเป็นวิธีการเรียนรู้ที่นิยมใช้มากแบบหนึ่งในการเรียนรู้ของเครื่องการเรียนรู้แบบนี้เป็นการเรียนรู้โดยการแยกแยะ (Classification) ข้อมูลออกเป็นกลุ่ม (Class) ต่างๆ โดยใช้คุณสมบัติ

(Attribute) ของข้อมูลในการแยกแยะต้นไม้ตัดสินใจที่ได้จากการเรียนรู้ทำให้ทราบว่าคุณสมบัติใดของข้อมูลที่เป็นตัวกำหนดแยกแยะ และคุณสมบัติแต่ละตัวของข้อมูลมีความสำคัญมากน้อยต่างกันอย่างไรซึ่งเป็นประโยชน์ช่วยให้ผู้ใช้สามารถวิเคราะห์ข้อมูลและตัดสินใจได้ถูกต้องยิ่งขึ้นต้นไม้ตัดสินใจเป็นเทคนิคของการเรียนรู้ (Learning Algorithm) ทำการสร้างรูปแบบที่ใช้สำหรับคาดคะเนหรือทำนายเหตุการณ์ล่วงหน้า เป็นผลลัพธ์ที่ได้จากการตัดสินใจจากต้นไม้จะไม่ซับซ้อน โดยจะมีการแตกแขนงจากโหนดราก (Root) สู่ใบ (Leaf) และมีกิ่งก้าน (Branch) แตกออกไปตามเงื่อนไขหรือข้อมูลที่คาดคะเนว่าจะเกิดขึ้นจากการศึกษาสรุปได้ว่าเทคนิคต้นไม้ตัดสินใจเป็นแบบจำลองที่มีรูปแบบที่ได้รับความนิยม โครงสร้างต้นไม้ตัดสินใจเป็นแบบลำดับชั้น โดยมีการตัดสินใจ ซึ่งประกอบด้วย โหนดที่ใช้ในการตัดสินใจ (Decision Node) และโหนดใบ (Leaf node or Terminal node) ซึ่งแต่ละโหนดตัดสินใจนั้นจะมีการสร้างฟังก์ชันที่เอาไว้สำหรับทดสอบทางเลือก $f_m(x)$ จากการป้อนข้อมูลเข้า (Input) จะทดสอบตามทางเลือกไปเรื่อยๆ ไปจนถึง Terminal node จะได้คำตอบในที่สุด ดังภาพ



ภาพที่ 2.3 ตัวอย่างชุดข้อมูลสอน และต้นไม้ตัดสินใจที่สร้างได้จากชุดข้อมูลสอน

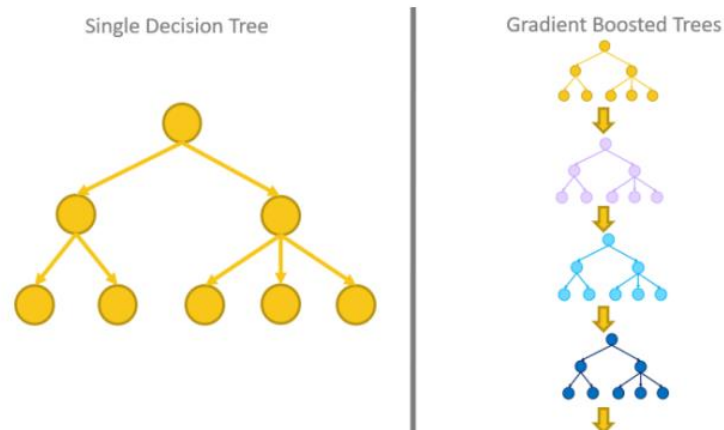
ที่มา: การใช้เทคนิคเหมืองข้อมูลเพื่อคัดกรองบุคคลที่มีแนวโน้มสัมฤทธิ์ผล ณะวัฒน์ วรรณประภา

2.3.5 GBM (Gradient Boosting) Gradient Boosting

เป็นเทคนิคการเรียนรู้ของเครื่องสำหรับแก้ปัญหาการถดถอย (Regression) และการจำแนกประเภท (Classification) GBM จะสร้างโครงสร้างการถดถอยตามลำดับ ซึ่ง GBM ใช้เทคนิคการเพิ่มการรวมจำนวน classifier ที่มีความแม่นยำต่ำ เพื่อสร้างเป็น classifier ใหม่โดย ต้นไม้ในลำดับต่อไปจะถูกสร้างจากข้อผิดพลาดจากการคำนวณต้นไม้ก่อนหน้าโดยใช้อัลกอริทึม Level-wise ในการสร้างต้นไม้

- (1) Gradient Boosted Trees

เป็นแบบจำลองที่มีพื้นฐานมาจาก Decision tree ซึ่งเป็นการปรับปรุงประสิทธิภาพของแบบจำลองใหม่ค่าสูงขึ้น โดยการสุ่มสร้าง Decision tree หลายร้อยแบบจำลอง ทำซ้ำ และประเมินผลแต่ละแบบจำลองจนกว่า จะได้ Decision tree ที่สมบูรณ์

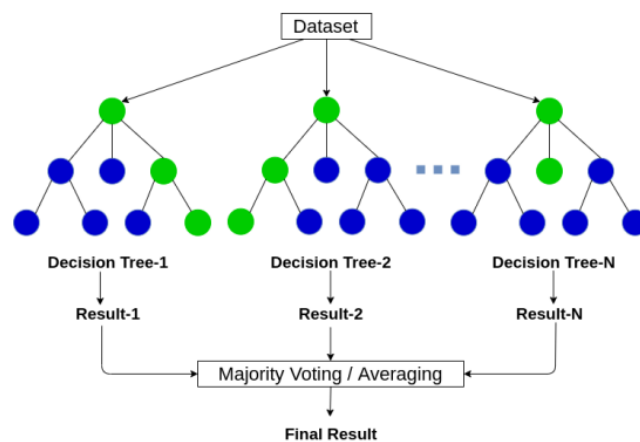


ภาพที่ 2.4 แสดงกระบวนการทำงานของ Gradient Boosted Trees

ที่มา: การพยากรณ์การเกิดภัยแล้งในประเทศไทย วรวิภา ตรีเจริญกิจพัฒน์ และ เอกสิทธิ์ พัทธวงค์ศักดิ์ดา

2.3.6 Random Forest

การสร้างแบบจำลองจาก Decision Tree หลายแบบจำลองย่อย โดยให้แต่ละแบบจำลองได้รับชุดข้อมูลย่อยที่ไม่เหมือนกันซึ่งข้อมูลนี้เป็นส่วนหนึ่งของชุดข้อมูลทั้งหมด แล้วทำการพยากรณ์ ข้อมูลในแต่ละ Decision Tree และคำนวณผลด้วยการ vote ที่ถูกเลือกโดย Decision Tree มากที่สุด




ภาพที่ 2.5 แสดงกระบวนการทำงานของ Random Forest

ที่มา: การพยากรณ์การเกิดภัยแล้งในประเทศไทย วรภัทรา เจริญกิจสุพัฒน์ และ เอกสิทธิ์ พัทธวงค์ศักดิ์ดา

2.3.7 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

เป็นตัวจำแนกเชิงเส้น (Linear Classifier) แบบ 2 คลาส ซึ่งเป็นที่ยอมรับถึงประสิทธิภาพของการจำแนกที่เหนือกว่าวิธีการจำแนกอื่น ๆ ข้อได้เปรียบของ ซัพพอร์ตเวกเตอร์แมชชีน คือมีประสิทธิภาพในการจำแนกข้อมูลที่มีมิติจำนวนมากได้ นอกจากนี้การใช้ฟังก์ชันเคอร์เนล (Kernel Function) เพื่อแปลงข้อมูลไปยังมิติที่สูงขึ้นในปริภูมิคุณลักษณะ (Feature Space) สามารถจำแนกข้อมูลที่มีความคลุมเครือได้อย่างมีประสิทธิภาพ หลักการของ ซัพพอร์ตเวกเตอร์แมชชีน คือการหาเส้นตรงที่มีมาร์จิ้นที่โตที่สุด (Maximum Margin) ที่สามารถแบ่งข้อมูลออกเป็น 2 คลาส ดังตัวอย่างในภาพที่ 2 เป็นข้อมูลขนาด 2 มิติ โดนถูกจำแนกออกเป็น 2 คลาส ได้แก่ + (○) และคลาส - (△) โดยเส้นตรงที่ใช้แบ่งข้อมูลมีมาร์จิ้นเท่ากับ $M=2w$ ซึ่ง เป็นความกว้างระหว่างเส้นตรงกับซัพพอร์ตเวกเตอร์ (Support vector) ของข้อมูลทั้ง 2 คลาส ดังภาพที่ 2.6



ภาพที่ 2.6 ภาพแสดงการแบ่งกลุ่มข้อมูลของอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน

ที่มา: การประยุกต์ใช้เทคนิคอัลกอริทึมในการทำเหมืองข้อความเพื่อ วิเคราะห์ทัศนคติ ของผู้ใช้ที่มีต่อการเลือกซื้อโพลีแลมినาร์บนทวิตเตอร์ นางสาวนภัสสร สังวรวิตรี

จากภาพที่ เป็นภาพแสดงการแบ่งกลุ่มข้อมูลด้วยอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีนโดย ซัพพอร์ตเวกเตอร์แมชชีน จะใช้ฟังก์ชันแมปสำหรับย้ายข้อมูลจาก Input Space ไปยังฟีเจอร์สเปซ (Feature Space) และสร้างฟังก์ชันวัดความคล้ายที่เรียกว่า เคอร์เนลฟังก์ชัน (Kernel Function) บนฟีเจอร์สเปซ (Feature Space) ซึ่งเหมาะสำหรับใช้กับข้อมูลที่มีมิติของข้อมูลสูง ดังสมการ

$$(X_i, Y_i), \dots, (X_n, Y_n) \text{ เมื่อ } X \in R^m, Y \in \{+1, -1\}$$

เมื่อ $(X_i, Y_i), \dots, (X_n, Y_n)$ คือ ตัวอย่างที่ใช้สำหรับการสอน

- n คือ จำนวนข้อมูลตัวอย่าง
- m คือ จำนวนมิติข้อมูลเข้า
- Y คือ ผลลัพธ์ที่มีค่า +1 หรือ -1

สำหรับปัญหาเชิงเส้นที่มีมิติของข้อมูลมีขนาดสูงจะถูกแบ่งเป็นสองกลุ่ม โดยระนาบตัดสินใจ ซึ่งคำนวณได้ดังสมการ

$$(W \times X) + b = 0$$

$$(W \times X) + b > 0 \text{ ถ้า } y_i = +1$$

$$(W \times X) + b < 0 \text{ ถ้า } y_i = -1$$

เมื่อ W คือ ค่าน้ำหนัก

b คือ ค่า bias ใช้สำหรับจำแนกประเภทของข้อมูล

ข้อดีของเทคนิคซัพพอร์ตเวกเตอร์แมชชีน คือ สามารถแบ่งกลุ่มข้อมูลได้ทั้งรูปแบบข้อมูลที่แบ่งกลุ่มได้ด้วยเส้นตรงและไม่เป็นเส้นตรง นอกจากนี้ยังสามารถรองรับคุณลักษณะจำนวนมากกว่า 10,000 คุณลักษณะได้ เนื่องจากใช้การแทนข้อมูลแบบเวกเตอร์และพิจารณาเส้นแบ่งกลุ่มข้อมูลจากเวกเตอร์ซัพพอร์ตถึงแม้จะมีประสิทธิภาพในการจำแนกมาก แต่ข้อเสีย คือ ต้องใช้เวลาในการเรียนรู้และใช้หน่วยความจำมากขึ้น และฟังก์ชันเคอร์เนลภายในซัพพอร์ตเวกเตอร์แมชชีน ไม่สามารถระบุได้อย่างตายตัวขึ้นอยู่กับความเหมาะสมกับงานที่จะนำอัลกอริทึมไปใช้ซึ่งต้องอาศัยการทดลองเพื่อปรับค่าพารามิเตอร์ให้เหมาะสม

2.3.8 การวัดประสิทธิภาพของแบบจำลองแบบจำลอง

การพัฒนาระบบนั้น การประเมินผลการทำงานเป็นส่วนสำคัญ เพื่อให้ผู้พัฒนาได้ทราบประสิทธิภาพการทำงานของระบบว่ามีจุดเด่นจุดด้อยในด้านใดบ้าง เพื่อนำไปปรับปรุงระบบงานให้มีประสิทธิภาพมากยิ่งขึ้น ในงานด้านค้นคืนของสารสนเทศมีการวัดในด้านประสิทธิภาพของผลลัพธ์ที่ได้จากการสืบค้น ได้ด้วยค่าดังนี้

(1) ค่าระลึก (Recall) คือ การคำนวณการส่งคำตอบทั้งหมดไป แล้วแบบจำลองมีผลการทำนายถูกต้องกลับมาทั้งหมดถูกเท่าใด ดังสมการที่ 2.6

$$\frac{TP}{TP+FN} \quad (2.6)$$

เมื่อ TP คือ True Positive จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสที่กำลังสนใจ

FN คือ False Negative จำนวนข้อมูลที่ทำนายผิดว่าเป็นคลาสที่ไม่ได้สนใจ

(2) การวัดค่าความถูกต้อง (Accuracy) คือ การคำนวณจำนวนคำตอบที่ถูกต้องทั้งหมดเทียบกับจำนวนคำตอบทั้งหมดที่นำไปให้แบบจำลองทำนายว่าผลการทำนายถูกต้องเท่าใด

ดังสมการที่ 2.7

$$\frac{TP}{TP+FP} \quad (2.7)$$

เมื่อ TP คือ True Positive จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสที่กำลังสนใจ
FP คือ False Positive จำนวนข้อมูลที่ทำนายผิดว่าเป็นคลาสที่กำลังสนใจ

(3) ค่าความแม่นยำ (Precision) คือ การคำนวณเทียบกับคำตอบทั้งหมดที่ผิด ว่าผลการทำนายถูกต้องเท่าใด ดังสมการที่ 2.8

$$\frac{TP+TN}{TP+TN+FP+FN} \quad (2.8)$$

เมื่อ TP คือ True Positive จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสที่กำลังสนใจ
TN คือ True Negative จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาสไม่ได้สนใจ
FP คือ False Positive จำนวนข้อมูลที่ทำนายผิดว่าเป็นคลาสที่กำลังสนใจ
FN คือ False Negative จำนวนข้อมูลที่ทำนายผิดว่าเป็นคลาสที่ไม่ได้สนใจ

2.3.9 การวัดความผิดพลาดแบบจำลองในการพยากรณ์

การวัดความผิดพลาดของค่าพยากรณ์มีหลายวิธีจะขอยกตัวอย่างพอสังเขปดังนี้

การวัดค่าความผิดพลาดของความเบี่ยงเบนสมบูรณ์ (Mean Absolute Deviation :MAD) คือ การวัดความแม่นยำ โดยเปรียบเทียบค่าที่เกิดขึ้นจริงกับค่าพยากรณ์

$$MAD = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n}$$

โดยที่

Y_t คือ ค่าสังเกตของอนุกรมเวลา ณ เวลา t

\hat{Y}_t คือ ค่าพยากรณ์ของอนุกรมเวลา ณ เวลา t

n คือ ค่าจำนวนข้อมูลที่สนใจ

การวัดค่าความผิดพลาดเฉลี่ยกำลังสอง (Mean Square Error: MSE) คือการวัดค่าความผิดพลาดเฉลี่ยโดยลงโทษ (Penalty) ค่าความผิดพลาดที่มีค่ามาก อีกทั้งรวมผลทั้งการพยากรณ์เกินจริง (Over forecast) และค่าพยากรณ์ที่ต่ำกว่าความเป็นจริง (Under forecast) ซึ่งเป็นวิธีวัดความแม่นยำโดยแก้ปัญหาวิธีค่าเฉลี่ยความผิดพลาดจะพิจารณาความแตกต่างระหว่างค่าจริงกับค่าพยากรณ์โดยวิธียกกำลังสอง มีรายละเอียดดังสมการที่

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n} = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}$$

โดยที่

Y_t คือ ค่าสังเกตของอนุกรมเวลา ณ เวลา t

\hat{Y}_t คือ ค่าพยากรณ์ของอนุกรมเวลา ณ เวลา t

e_t คือ ค่าความผิดพลาดของพยากรณ์ ณ เวลา t

n คือ ค่าจำนวนข้อมูลที่สนใจ

การวัดความผิดพลาดเป็นเปอร์เซ็นต์ (Mean Absolute Percentage Error :MAPE) คือ การวัดความผิดพลาดเป็นเปอร์เซ็นต์ซึ่งจะสามารถวิเคราะห์ความหมายได้ง่าย อีกทั้งรวมผลพยากรณ์ทั้งเกินจริงและต่ำกว่าค่าจริง

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{e_t}{Y_t} \right|}{n} \times 100 = \frac{\sum_{t=1}^n \left| \frac{(Y_t - \hat{Y}_t)}{Y_t} \right|}{n} \times 100$$

โดยที่

Y_t	คือ ค่าสังเกตของอนุกรมเวลา ณ เวลา t
\hat{Y}_t	คือ ค่าพยากรณ์ของอนุกรมเวลา ณ เวลา t
e_t	คือ ค่าความผิดพลาดของพยากรณ์ ณ เวลา t
n	คือ ค่าจำนวนข้อมูลที่สนใจ

สำหรับวิธีการวัด 2 วิธีแรกคือ MAD และ MSE เป็นการประเมินผลวิธีการพยากรณ์ หรือ ใช้ วัดสภาพความแตกต่างระหว่างค่าพยากรณ์ที่คำนวณได้กับข้อมูลจริง วิธีการพยากรณ์ที่ให้ค่า MAD หรือ MSE ต่ำ แสดงว่าเป็นค่าพยากรณ์ที่ดีกว่าวิธีการพยากรณ์ที่ให้ค่า MAD หรือ MSE ต่ำจะให้ผลการพยากรณ์ที่ดี วิธีวัดตัวสุดท้ายคือ MAPE จะนำไปใช้ประเมินผลวิธีการพยากรณ์นั้นให้ผลดีหรือไม่อย่างไร

2.4 ผลการศึกษาและงานวิจัยที่เกี่ยวข้อง

มีผลการศึกษาวิจัยที่เกี่ยวข้องกับการศึกษาค้นคว้านี้ได้แก่

2.4.1 ธนิตเชษฐ คำศรีสุข ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้ามหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี 2562 ได้ศึกษาเรื่องการวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในบ้านสำหรับบ้านอัจฉริยะ ด้วยวิธีการเหมืองข้อมูล โดยงานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในบ้าน สำหรับบ้านอัจฉริยะ เพื่อสร้างแบบจำลองสำหรับการพยากรณ์การใช้พลังงาน สำหรับการวางแผนการลดใช้ พลังงานภายในบ้าน สำหรับการวิเคราะห์ข้อมูล ได้ใช้โปรแกรม Python เป็นเครื่องมือสำหรับวิเคราะห์ให้ ข้อมูล และงานวิจัยนี้ได้ออกแบบอัลกอริทึมสำหรับการจัดการพลังงานในบ้าน เมื่อเกิดสัญญาณการตอบสนองด้านโหลดที่เกิดขึ้นภายในบ้าน การวิจัยได้ทำการวิเคราะห์ข้อมูลของการใช้พลังงานภายในบ้านโดยใช้ข้อมูลบ้าน จำนวน 1 หลังในงานวิจัยนี้ได้สร้างรูปแบบการพยากรณ์โหลดโดยใช้วิธีเหมืองข้อมูล และได้เลือกแบบจำลอง Autoregressive Integrated Moving Average (ARIMA) และแบบจำลอง Recurrent Neural Network (RNN) ในการทำนายผลข้อมูล เพื่อเปรียบเทียบหาค่าเฉลี่ยความคลาดเคลื่อนที่เหมาะสมที่สุด และได้ กำหนดโหลดภายในบ้านโดยใช้อัลกอริทึมสำหรับการตอบสนองด้านโหลด สำหรับการลดใช้พลังงานภายในบ้าน ผลการวิเคราะห์ข้อมูลพบว่าการพยากรณ์พลังงานไฟฟ้า ได้นำ 2 แบบจำลองมาวิเคราะห์ผลการ ทำนายข้อมูลแบบจำลอง ARIMA รายชั่วโมง วัน สัปดาห์ค่าเฉลี่ยความคลาดเคลื่อน 0.160 0.076 และ 0.179 ตามลำดับ ส่วนแบบจำลอง RNN ค่าเฉลี่ยความคลาดเคลื่อน 0.349 ซึ่งแบบจำลอง ARIMA

ค่าเฉลี่ย ความคลาดเคลื่อนรายวันที่สุด และจากการจำลองอัลกอริทึมการจัดการพลังงานในบ้านค่าไฟฟ้าสูงสุด เฉลี่ยคือ 12.83 kW ลดลงเหลือ 8.31 โดยจะปิดโหนดตามลำดับความสำคัญที่ตั้งไว้

จากการศึกษางานวิจัยพบว่า งานวิจัยนี้ได้นำการพยากรณ์มาวิเคราะห์ข้อมูลของการใช้พลังงานภายในบ้านโดยใช้ข้อมูลบ้าน จำนวน 1 หลัง เพื่อสร้างรูปแบบการพยากรณ์โหนด โดยใช้วิธีเหมืองข้อมูล และงานวิจัยนี้ได้เลือกตัวแบบ แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) และแบบจำลอง Recurrent Neural Network (RNN) ทั้งนี้ การทำนายข้อมูลของแบบจำลอง ARIMA จะแบ่งเป็นรายชั่วโมง, วันและสัปดาห์ ซึ่งมีส่วนเกี่ยวข้องกับงานวิจัยการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าภายในอาคาร ด้วยวิธีการทำเหมืองข้อมูล ได้ศึกษาการทำเหมืองข้อมูล แต่ก็มีแตกต่างกันคือ งานวิจัยที่ศึกษานั้นใช้โปรแกรม Python แตกต่างกับงานวิจัยนี้ใช้ โปรแกรม Rapid miner เป็นเครื่องมือในการทำงานวิจัย

2.4.2 อัครช บรรจงศิลป์ ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาการจัดการงานวิศวกรรมบัณฑิตวิทยาลัย มหาวิทยาลัยศิลปากร ปีการศึกษา 2550 การพยากรณ์การใช้พลังงานไฟฟ้าในอุตสาหกรรมขนาดใหญ่ การวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการหารูปแบบการพยากรณ์ (Forecasting model) ที่เหมาะสมกับโรงงานอุตสาหกรรมแต่ละประเภท เพื่อนำไปใช้ในการวางแผนการใช้พลังงานไฟฟ้าใน อนาคตของแต่ละโรงงานอุตสาหกรรม โดยใช้ข้อมูลการใช้พลังงานไฟฟ้าของผู้ใช้ไฟรายใหญ่ใน ระบบ 115 KV. ในเขตพื้นที่รับผิดชอบของการไฟฟ้าส่วนภูมิภาคเขต 3 ภาคกลาง ตั้งแต่เดือน พฤศจิกายน ปี 2547 ถึงเดือนตุลาคม ปี 2550 รวมทั้งสิ้น 36 เดือน และมีจำนวนโรงงานที่นำมาใช้ พิจารณารวมทั้งสิ้น 23 โรงงาน ซึ่งข้อมูลการใช้พลังงานไฟฟ้าสามารถแบ่งออกได้เป็น 2 ประเภท คือ ข้อมูลค่าโหนดการใช้พลังงานไฟฟ้าสูงสุด (KW.) และข้อมูลค่าหน่วยการใช้พลังงานไฟฟ้า (KWH.) ซึ่งในที่นี้จะเลือกใช้รูปแบบการพยากรณ์ 7 รูปแบบมาใช้ในการพิจารณา ได้แก่ Trend Analysis, TimeSeries Decomposition, Moving Average 3 เดือน, Moving Average 4 เดือน, Single Exponential Smoothing, Double Exponential Smoothing, Winter's Method และนำรูปแบบการพยากรณ์ทั้ง 7 รูปแบบที่ได้ไปเปรียบเทียบกับรูปแบบการพยากรณ์โดยวิธีการประมาณค่าในช่วง (Interpolation) โดยใช้ค่าเฉลี่ยเปอร์เซ็นต์ของความคลาดเคลื่อนสมบูรณ์ (Mean Absolute Percent Error, MAPE) และการ ให้ระดับความสำคัญของข้อมูลมาใช้พิจารณาเลือกรูปแบบการพยากรณ์ทั้ง 7 รูปแบบและนำมาใช้ พิจารณาเปรียบเทียบกับรูปแบบการพยากรณ์ทั้ง 7 รูปแบบกับรูปแบบการพยากรณ์โดยวิธีการประมาณค่า ในช่วง ซึ่งจะใช้โปรแกรมสำเร็จรูปทางสถิติกับโปรแกรมที่พัฒนาขึ้นมาเพื่อใช้ในการประมาณค่า ในช่วง มาช่วยในการวิเคราะห์ผล ผลการศึกษาพบว่าการใช้ค่าเฉลี่ยเปอร์เซ็นต์ของความคลาดเคลื่อนสมบูรณ์ (Mean Absolute Percent Error, MAPE) และการ ให้ระดับความสำคัญของข้อมูลมาใช้พิจารณาเลือกรูปแบบ การพยากรณ์ทั้ง 7 รูปแบบ สามารถหารูปแบบการพยากรณ์ (Forecasting model) ที่เหมาะสมกับ โรงงานอุตสาหกรรมแต่ละประเภทได้และรูปแบบการพยากรณ์โดยวิธีการประมาณค่าในช่วง จะ ให้ผลในการพยากรณ์ที่ดีกว่าการเลือกใช้รูปแบบการพยากรณ์ทั้ง 7 รูปแบบ

จากการศึกษางานวิจัยพบว่า งานวิจัยที่ศึกษานั้น มีวัตถุประสงค์ในการหาตัวแบบที่เหมาะสมในการพยากรณ์ และ ข้อมูลที่ใช้ในการพยากรณ์เป็นประเภทปริมาณความต้องการไฟฟ้าคล้ายๆกัน จึงศึกษาการ

เตรียมและการจัดการข้อมูลจากงานวิจัยที่ศึกษานี้ จุดที่แตกต่างนั้นคือ งานวิจัยนี้ใช้ตัวแบบ Trend Analysis, Time Series Decomposition, Moving Average 3 เดือน, Moving Average 4 เดือน, Single Exponential Smoothing, Double Exponential Smoothing, Winter's Method และ งานวิจัยได้มีการวัดค่าผิดพลาดจากการพยากรณ์ที่เหมือนกัน

2.4.3 คงฤทธิ โกมาสถิต ปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ปีการศึกษา 2555 โดยงานวิจัยนี้ได้ศึกษาวิธีการพยากรณ์อุปสงค์พลังงานไฟฟ้า (Electrical Energy Consumption) ของประเทศไทยในระยะยาวด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Network) โดยได้นำ โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back-Propagation Neural Network: BPNN) มาใช้ในการพยากรณ์พลังงานไฟฟ้าของประเทศไทย ช่วง พ.ศ. 2555-2573 โดยมีช่วงฝึกสอนตั้งแต่ พ.ศ. 2537-2549 และช่วงทดสอบตั้งแต่ พ.ศ. 2550-2554 โดยตัวแปรป้อนเข้าในแบบจำลองจะพิจารณา จากตัวแปรด้านเศรษฐศาสตร์ ดินฟ้าอากาศ สังคมศาสตร์ และอุตสาหกรรม โดยพิจารณาตัวแปรที่มีความสัมพันธ์กับค่าพลังงานไฟฟ้าที่ดี (Strong parameter) ไป ออกแบบโครงข่ายประสาทเทียม ส่วนตัวแปรที่มีความสัมพันธ์ไม่ดี (Weak parameter) จะถูกตัดออก การศึกษา และออกแบบทำให้ ได้โครงข่าย ประสาทเทียม 1 ชั้นซ่อน ที่มี 4 นิวรอนเป็น ฟังก์ชันเส้นตรง และมีตัวแปรป้อนเข้าแบบจำลอง 4 ตัวแปร คือ ผลผลิตมวลรวมในประเทศ (GDP) จำนวนลูกค้าการไฟฟ้า (Customer) ดัชนีอุตสาหกรรม (Industrial Index) และจำนวน นักท่องเที่ยวต่างชาติ (Foreign Tourist) ส่วนตัวแปรผลลัพธ์มี 1 ตัวแปรคือ อุปสงค์พลังงานไฟฟ้า ผลการศึกษา สามารถสรุปได้ว่าวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับสามารถ พยากรณ์ได้แม่นยำกว่าวิธีของคณะกรรมการพยากรณ์แห่งประเทศไทย (Thailand Load Forecast Sub-Committee : TLFS) ที่ถูกใช้ในแผนพัฒนาแหล่งผลิตไฟฟ้า ฉบับ พ.ศ. 2553-2573 (ทบทวนครั้งที่ 2) โดยวิธีโครงข่ายประสาทเทียม มีค่าร้อยละความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (Mean Percentage Absolute Error: MAPE) เท่ากับ 2.5% ส่วนวิธีของคณะกรรมการฯ ฉบับ เม.ย. 2553 มีค่าเท่ากับ 4.54%

จากการศึกษางานวิจัยพบว่า งานวิจัยที่ศึกษานั้น เป็นงานวิจัยที่มีส่วนสำคัญในเลือกใช้ตัวแปรวิธีการเลือกตัวแปรที่มีผลต่อการพยากรณ์ มีตัวแปรที่มีผล 4 ตัวแปร คือ ผลผลิตมวลรวมในประเทศ (GDP) จำนวนลูกค้าการไฟฟ้า (Customer) ดัชนีอุตสาหกรรม (Industrial Index) และจำนวน นักท่องเที่ยวต่างชาติ (Foreign Tourist) ซึ่งแสดงการวิเคราะห์ที่มีผลต่อค่าพยากรณ์อุปสงค์พลังงานไฟฟ้า ความแตกต่างของงานวิจัยคือ รูปแบบการพยากรณ์ของงานวิจัยใช้วิธี วิธีโครงข่ายประสาทเทียม (Artificial Neural Network) โดยได้นำ โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back-Propagation Neural Network: BPNN)

2.4.4 ธนะวัฒน์ วรรณประภา หลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชา วิศวกรรมคอมพิวเตอร์ และโทรคมนาคม วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิต พ.ศ. 2564 โดย งานวิจัยนี้นำเทคนิคการทำเหมืองข้อมูลมาใช้ในการคัดกรองบุคคลที่มีแนวโน้ม สัมฤทธิ์ผล สำหรับการเรียนระดับปริญญาตรี สาขาวิชาเทคโนโลยีการศึกษา โดยมี วัตถุประสงค์ การวิจัย 1) เพื่อสร้างตัว

แบบสำหรับการคัดกรองบุคคลที่มีแนวโน้มสัมฤทธิ์ผลในการศึกษาระดับปริญญาตรี สาขาวิชาเทคโนโลยีการศึกษา 2) เพื่อเปรียบเทียบประสิทธิภาพตัวแบบจำแนกตามร้อยละจำนวนการฝึกสอนและจำนวนข้อมูลฝึกสอนที่แตกต่างกัน ด้วยเทคนิค Decision Tree, Support Vector Machine และ Deep Learning เก็บข้อมูลจากบัณฑิตที่สำเร็จการศึกษาระหว่างปี การศึกษา 2554-2558 จากระบบกองทะเบียนและประมวลผลการศึกษา จำนวน 738 คน ซึ่งถูกใช้เป็นชุดข้อมูล ที่ใช้ในการศึกษา โดยได้แบ่งชุดข้อมูลสำหรับการสอนและทดสอบด้วยอัตราส่วน 70:30 75:25 และ 80:20 นอกจากนี้ได้ใช้วิธีการวิเคราะห์ความถดถอยเพื่อคัดกรองจำนวนแอททริบิวต์ตั้งต้นที่มี ทั้งหมด 30 แอททริบิวต์ให้ลดลงเหลือเท่าที่จำเป็นด้วยวิธีการ Backward Selection และ Stepwise Selection ผลการศึกษาพบว่าการวิเคราะห์การถดถอยแบบ Stepwise selection ที่มีการแบ่งกลุ่ม การสอนและการทดสอบที่ 80:20 ให้ผลค่าความถูกต้องดีที่สุดในตัวแบบที่ใช้วิธีการ Deep Learning ให้ค่าความถูกต้องดีกว่าตัวแบบที่ใช้วิธีการ Decision Tree และ Support Vector Machine ซึ่งมีค่าความถูกต้องเท่ากับ 85.94, 84.46 และ 80.81 ตามลำดับ ทั้งนี้แอททริบิวต์ที่ถูกคัดกรองและส่งผลต่อการวิเคราะห์ของตัวแบบมากที่สุดได้แก่ เกรดเฉลี่ยสะสมมัธยมศึกษาตอนปลายของผู้เรียน ในสาขาวิชาเทคโนโลยีการศึกษา และการรับเข้าของนิสิตที่เป็นการรับตรงรอบที่ 5

จากการศึกษางานวิจัยพบว่า งานวิจัยที่ศึกษานั้น มีเครื่องมือที่ใช้ในการทำเหมืองข้อมูล โดยใช้โปรแกรม Rapid miner เหมือนกัน ผู้วิจัยได้รับองค์ความรู้ เกี่ยวกับวิธีการทำเหมืองข้อมูล และขั้นตอนการใช้โปรแกรม Rapid miner และได้ศึกษาเกี่ยวกับการแบ่งชุดข้อมูลสำหรับการสอนและทดสอบด้วยการแบ่งอัตราส่วน ด้วยวิธีการ Backward Selection และ Stepwise Selection ความแตกต่างกันคือ ชุดข้อมูลที่นำมาพยากรณ์นั้นเป็นข้อมูลโอกาสในการสำเร็จการศึกษา

2.4.5 วริศทรา เจริญกิจสุวัฒน์ และ เอกสิทธิ์ พัชรวงศ์ศักดิ์ ได้ทำงานวิจัยเรื่องการพยากรณ์การเกิดภัยแล้งในประเทศไทยด้วยวิธีการเรียนรู้ของเครื่อง A Large-Scale Drought Forecasting with Machine Learning งานวิจัยนี้มีวัตถุประสงค์เพื่อพยากรณ์การเกิดภัยแล้งของแต่ละตำบลในประเทศไทย และหาแบบจำลองที่ดีที่สุดที่ใช้ในการพยากรณ์การเกิดภัยแล้ง โดยทำการหาแบบจำลองที่สามารถพยากรณ์ การเกิดภัยแล้งที่มีค่าความถูกต้องของการเกิดและไม่เกิดภัยแล้งใกล้เคียงกันจากข้อมูลปริมาณน้ำฝน และดัชนีเสี่ยงภัยแล้ง(DRI) ด้วยการใช้แบบจำลอง Neural Network, Gradient Boosted Trees และ Random Forest ด้วย Rapid Miner และ Automated machine learning (AutoML) ของ H2o.ai ผลงานวิจัย พบว่าแบบจำลอง Neural Network ที่ Learning Rate 0.01, Training cycle 50, momentum 0.1 และใช้แอททริบิวต์ 28 ตัวมีประสิทธิภาพดีกว่าทุกแบบจำลองที่ทำการทดลอง พบว่าค่าความถูกต้องของการเกิด ภัยแล้ง 64.43% และไม่เกิดภัยแล้ง 65.29%

จากการศึกษางานวิจัยพบว่า งานวิจัยที่ศึกษานั้น มีเครื่องมือที่ใช้ในการทำเหมืองข้อมูล โดยใช้โปรแกรม Rapid miner เหมือนกัน ผู้วิจัยได้รับองค์ความรู้ เกี่ยวกับตัวแบบในการพยากรณ์ ซึ่งตัวแบบที่ศึกษามามีดังนี้ Neural Network, Gradient Boosted Trees และ Random Forest ความแตกต่างกันของ

งานวิจัยคือ ชุดข้อมูลที่นำมาพยากรณ์นั้นเป็นข้อมูลที่เรียนรู้จากข้อมูลปริมาณน้ำฝน เพื่อพยากรณ์อัตราการเกิดภัยแล้ง

2.4.6 นภัตสร สังวรวิตร์ หลักสูตรวิทยาศาสตร์มหาบัณฑิต สาขาวิชาระบบสารสนเทศเพื่อการจัดการ ภาควิชาการจัดการเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ปีการศึกษา 2562 ได้ทำงานวิจัยการประยุกต์ใช้เทคนิคอัลกอริทึมในการทำเหมืองข้อความเพื่อ วิเคราะห์ทัศนคติ ของผู้ใช้ที่มีต่อการเลือกซื้อโคมกลางแจ้ง บน ทวิตเตอร์ งานวิจัยนี้มีจุดประสงค์เพื่อวิเคราะห์ทัศนคติและปัจจัยในการเลือกซื้อโคมกลางแจ้งของผู้ใช้ บน ทวิตเตอร์ และ เพื่อเปรียบเทียบประสิทธิภาพของเทคนิคอัลกอริทึมในการทำเหมืองข้อความในการวิเคราะห์ทัศนคติของผู้ใช้ที่มีต่อการเลือกซื้อ โคมกลางแจ้ง บน ทวิตเตอร์ โดยทำการรวบรวมข้อมูลจากทวิตเตอร์ช่วงเวลาตั้งแต่เดือน สิงหาคม 2562 ถึง ธันวาคม 2562 มาประยุกต์ใช้เทคนิคอัลกอริทึมในการทำเหมืองข้อความเพื่อวิเคราะห์ทัศนคติของผู้ใช้ที่มีต่อการเลือกซื้อโคมกลางแจ้ง บน ทวิตเตอร์ ผ่านทางโปรแกรม RapidMiner Studio โดยทำการแบ่งคุณลักษณะ 4 ด้าน คือ ด้านคุณสมบัติ ด้านประเภทโคมกลางแจ้ง ด้านผลิตภัณฑ์ และด้านส่งเสริมทางการตลาด และทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้เทคนิคอัลกอริทึมนาอิวเบย์ (Naïve Bayes) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) เพื่อหาวิธีการจำแนกคุณลักษณะที่ดีที่สุด

ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง สามารถสรุปผลได้ว่าแบบจำลองของอัลกอริทึมนาอิวเบย์ สามารถจำแนกข้อความโดยประสิทธิภาพของแบบจำลองให้ค่าความถูกต้องเท่ากับ 89.81% รองลงมา คือ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ให้ค่าความถูกต้องเท่ากับ 89.58% ดังนั้นอัลกอริทึมนาอิวเบย์มีประสิทธิภาพของแบบจำลองให้ค่าความถูกต้อง มากกว่า อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน และจากการวิเคราะห์ทัศนคติของผู้ใช้ที่มีต่อโคมกลางแจ้ง ผู้ใช้ส่วนใหญ่เลือกซื้อโคมในด้านคุณสมบัติมากที่สุด คือการรักษาสีว ถึง 90% ด้านประเภทโคมกลางแจ้ง คือ เนื้อโคมมีฟอง 5% ด้านผลิตภัณฑ์ คือ เรืองกลิ้ง 3% ด้านการส่งเสริมทางการตลาด คือ เรื่อง 1 แกรม 1 เป็น 2% ตามลำดับ

จากการศึกษางานวิจัยพบว่า งานวิจัยที่ศึกษานั้น มีเครื่องมือที่ใช้ในการทำเหมืองข้อมูล โดยใช้โปรแกรม Rapid miner เหมือนกัน ผู้วิจัยได้รับองค์ความรู้ เกี่ยวกับ เกี่ยวกับตัวแบบในการพยากรณ์ ซึ่งตัวแบบที่ศึกษามามีดังนี้ เทคนิคอัลกอริทึมนาอิวเบย์ (Naïve Bayes) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) ความแตกต่างกันของงานวิจัยคือ การนำข้อมูลเป็นประเภทค่า เพื่อนำมาวิเคราะห์ทัศนคติในการเลือกโคมกลางแจ้ง

บทที่ 3

วิธีดำเนินการวิจัย

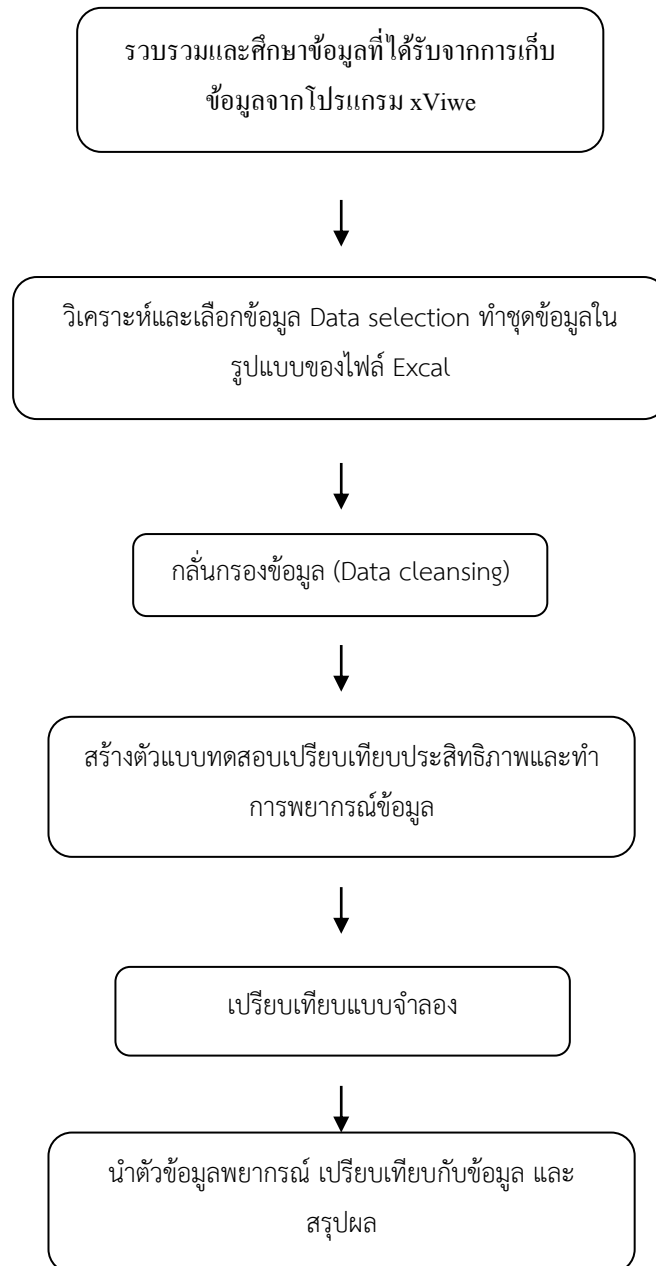
งานวิจัยนี้ได้นำเทคนิคเหมืองข้อมูลมาใช้ในการแบ่งแยกข้อมูล โดยการนำข้อมูลที่ได้จากการเก็บข้อมูลจะโปรแกรม xViwe ซึ่งเป็นโปรแกรม SCADA Software เป็นโปรแกรมสำหรับติดต่อสื่อสารกับอุปกรณ์ควบคุมต่างๆ เพื่อรับข้อมูลมาประมวลกับอุปกรณ์ส่งคำสั่งออกไปควบคุมการทำงานของเครื่องจักรหรืออุปกรณ์นั้นๆ พร้อมทั้งแสดงผล แล้วบันทึกการทำงาน โดยที่เราได้นำข้อมูล มาทำเหมืองข้อมูลเพื่อวิเคราะห์ การใช้พลังงานไฟฟ้าในแต่ละช่วงเวลา ของมิเตอร์ภายในอาคารกรณีศึกษาโดยที่เราจะนำข้อมูลที่ได้จากมิเตอร์ไฟฟ้าทั้งหมดจำนวน 8 ตัว โดยที่แต่ละตัวจะมีการเก็บข้อมูลทุกๆ ชั่วโมงเป็นเวลา 24 ชั่วโมง หลังจากนั้นเราจะนำข้อมูลปริมาณการใช้พลังงานไฟฟ้าซึ่งมีหน่วยเป็น(kW) นำมาจัดการข้อมูลเพื่อเข้าโปรแกรม Rapid miner และให้โปรแกรม Rapid miner หาตัวแบบที่เหมาะสมในการพยากรณ์ปริมาณการใช้ไฟฟ้าของแต่ละมิเตอร์ไฟฟ้า

3.1 ระเบียบงานวิจัย

โดยมีขั้นตอนดำเนินการวิจัยดังนี้

- 3.1.1 รวบรวมข้อมูลและศึกษาข้อมูล ที่ได้รับจากการเก็บข้อมูลจากโปรแกรม Xviwe
- 3.1.2 วิเคราะห์และเลือกข้อมูล Data selection ทำชุดข้อมูลในรูปแบบของไฟล์ Excel
- 3.1.3 กลั่นกรองข้อมูล (Data cleansing)
- 3.1.4 แปลงข้อมูล (Data transformation)
- 3.1.5 สร้างตัวแบบทดสอบเปรียบเทียบประสิทธิภาพและทำการพยากรณ์ข้อมูล
- 3.1.6 เปรียบเทียบแบบจำลอง
- 3.1.7 นำตัวข้อมูลพยากรณ์ เปรียบเทียบกับข้อมูล และสรุปผล

3.2 แผนภาพการดำเนินงานวิจัย



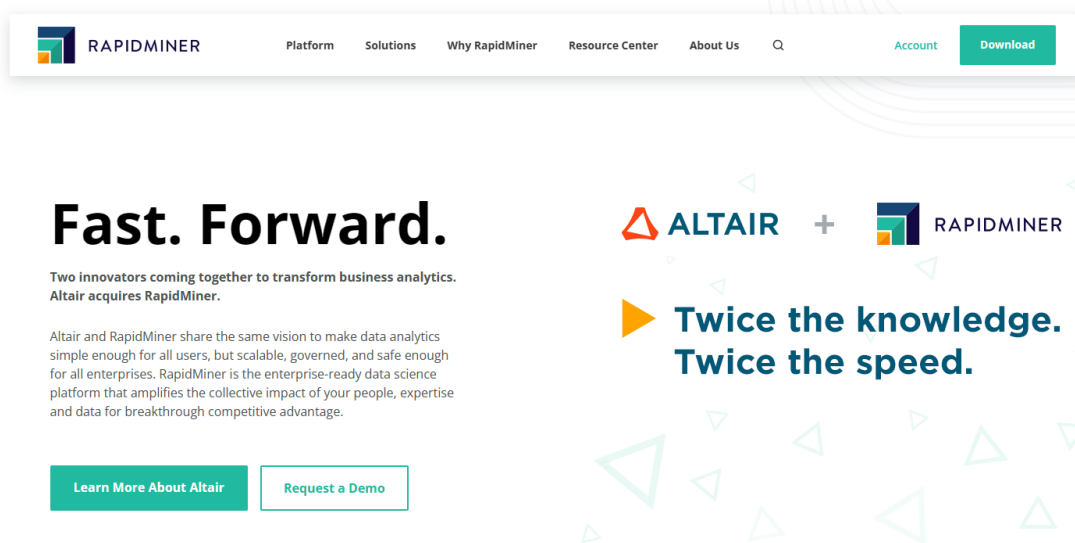
ภาพที่ 3.1 ภาพแผนภาพการดำเนินงานวิจัย

3.3 เครื่องมือในการทำงานวิจัย

3.3.1 โปรแกรม RapidMiner Studio

RapidMiner Studio เป็นโปรแกรมสำเร็จรูปที่ช่วยให้การทำเหมืองข้อมูลได้สะดวกมากขึ้น ทั้งนี้ ข้อมูลที่นำมาวิเคราะห์จำเป็นต้องกรองข้อมูล (Data Cleansing) และตรวจสอบความสมบูรณ์ของข้อมูลให้

เป็นที่เรียบร้อยแล้ว นับได้ว่าขั้นตอนการเตรียมข้อมูลก่อนการวิเคราะห์มีความสำคัญเป็นอย่างยิ่ง ถ้าไม่มีการกรองข้อมูล เมื่อนำเข้าโปรแกรม RapidMiner จะทำให้ได้แบบจำลองที่ได้ (Model) มีความถูกต้องน้อย สามารถโหลดโปรแกรมได้ที่ [RapidMiner | Amplify the Impact of Your People, Expertise & Data](#) RapidMiner เป็นการนำปัญญาประดิษฐ์มาใช้ในองค์กรผ่านแพลตฟอร์มวิทยาศาสตร์ข้อมูลแบบเปิดและขยายได้ สร้างขึ้นเพื่อการวิเคราะห์ข้อมูลโดยเฉพาะ RapidMiner รวมกระบวนการเกี่ยวกับการวิเคราะห์ข้อมูล ตั้งแต่การเตรียมข้อมูลไปจนถึงการเรียนรู้ของเครื่อง (Machine Learning) ไปจนถึง การปรับใช้โมเดลทำนาย มีผู้เชี่ยวชาญด้านการวิเคราะห์ จำนวนมากกว่า 700,000 คนใช้ RapidMiner เพื่อเพิ่มรายได้ ลดต้นทุน และ หลีกเลี่ยงความเสี่ยงต่าง ๆ



ภาพที่ 3.2 แสดงหน้าเว็บไซต์ [RapidMiner | Amplify the Impact of Your People, Expertise & Data](#)

RapidMiner Studio มีคุณสมบัติดังนี้

1. ทำงานแบบ Visual Workflow Designer รวมทั้งมีระบบ Wisdom of Crowds เป็นการให้คำแนะนำเชิงรุกในทุกขั้นตอนเพื่อช่วยเหลือผู้เริ่มต้นใช้งานโปรแกรมใหม่ๆ
2. สามารถเชื่อมต่อกับทุกแหล่งข้อมูล (Connect to Any Data Source) โปรแกรมสามารถทำงานกับข้อมูลไม่ว่าจะอยู่ที่ใด สร้างการเชื่อมต่อแบบชี้และคลิกไปยังฐานข้อมูลคลังข้อมูลขององค์กร (Data Warehouses) ข้อมูลที่มีการจัดเก็บบนคลาวด์และโซเชี่ยลมีเดียได้
3. สามารถประมวลผลแบบอัตโนมัติ (Automated In-Database Processing) สามารถเตรียมข้อมูลและประมวลผลได้ในฐานข้อมูล สร้างการสืบค้นและการดึงข้อมูลโดยไม่ต้องเขียน SQL ที่ซับซ้อน และรองรับ MySQL, PostgreSQL, and Google Big Query
4. มีความสามารถแสดงผลข้อมูลแบบ Data Visualization & Exploration

5. สามารถเตรียมข้อมูลได้อย่างง่าย (Data Prep & Blending)
6. ทำงานแบบ Visual & Automated Machine Learning คือสามารถสร้างโมเดล Machine Learning ที่มีประสิทธิภาพได้อย่างรวดเร็ว และมีกระบวนการตรวจสอบโมเดล (Model Validation) คือทำความเข้าใจประสิทธิภาพของโมเดลก่อนที่จะนำไปใช้งานจริงทำงานร่วมกับโปรแกรม R และ Python ได้

3.3.2 ระบบ SCADA Software

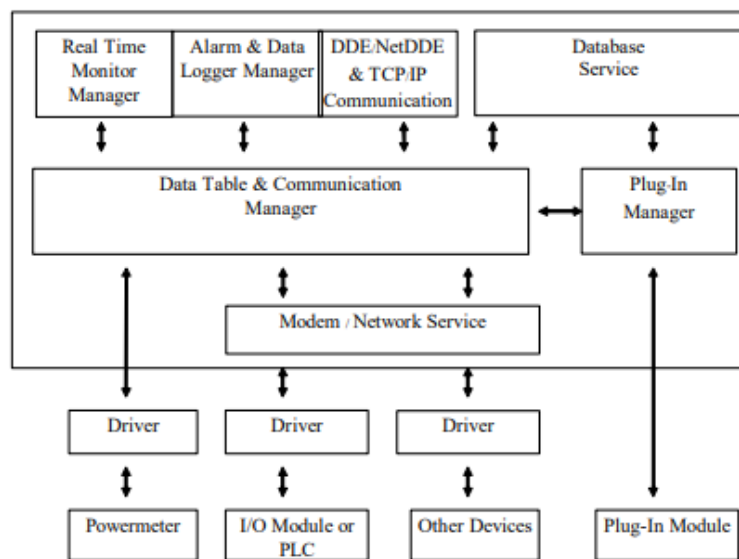
SCADA นั้นย่อมาจากคำว่า Supervisory Control And Data Acquisition เป็นระบบตรวจสอบและวิเคราะห์ข้อมูลแบบ Real-time ใช้ในการตรวจสอบสถานะตลอดจนถึงควบคุมการทำงานของระบบควบคุมในอุตสาหกรรมและงานวิศวกรรมต่าง ๆ เช่น งานด้านโทรคมนาคมสื่อสาร การประปา การบำบัดน้ำเสีย โทรมาตร การจัดการด้านพลังงาน อุตสาหกรรมการกลั่นน้ำมันและก๊าซ อุตสาหกรรมเคมี อุตสาหกรรมประกอบรถยนต์ การขนส่ง กระบวนการนิวเคลียร์ในโรงไฟฟ้า เป็นต้น ตัวอย่างการใช้งานเช่นใช้ SCADA ตรวจสอบข้อมูลเช่นการรั่วไหลของของเหลวที่เกิดขึ้นในท่อขนส่งจากตัวตรวจจับแล้วส่งสัญญาณแจ้งเตือนให้พนักงานทราบ โดยส่งข้อมูลสู่ส่วนกลางของระบบ SCADA เป็นต้น นอกจากนี้ SCADA อาจทำหน้าที่คำนวณและประมวลผลข้อมูลที่ได้จากฮาร์ดแวร์ต่าง ๆ เช่น PLC, Controller, DCS, RTU แล้วแสดงข้อมูลทางหน้าจอหรือส่งสัญญาณควบคุมฮาร์ดแวร์ดังกล่าว เช่นหากอุณหภูมิของอุปกรณ์สูงเกินพิกัด ให้ทำการปิดอุปกรณ์นั้น เป็นต้น โดยส่งงานผ่าน PLC หรือ Controller ที่ติดต่อกัน ทั้งนี้ SCADA สามารถเก็บรวบรวมข้อมูลที่ได้จากระบบควบคุมทั้งหมดไว้ในฐานข้อมูลเพื่อให้พนักงานหรือโปรแกรมอื่น ๆ สามารถนำไปใช้งานได้ SCADA นั้นเข้าไปมีส่วนในงานควบคุมทั้งเล็กและใหญ่ที่ต้องการแสดงผล แลกเปลี่ยนข้อมูล หรือควบคุมระบบต่าง ๆ จากส่วนกลาง เพื่อการทำงานของระบบรวมทั้งสัมพันธ์กัน มองเห็นภาพรวมได้อย่างชัดเจนและมีความรวดเร็วต่อเหตุการณ์ต่าง ๆ ที่เกิดขึ้น ระบบ SCADA ในปัจจุบันมีความสามารถในการสื่อสาร ควบคุม และประมวลผลข้อมูลจาก I/O ของอุปกรณ์เช่น PLC, DCS, RTU ได้ถึงระดับที่เกินหนึ่งแสน I/O แล้ว และได้รับการพัฒนาให้มีความสามารถรองรับความต้องการใหม่ ๆ ของผู้ใช้งานอย่างต่อเนื่องตลอดมา SCADA สามารถลดความคั่งค้างในกระบวนการอุตสาหกรรม/วิศวกรรมได้เนื่องจากผู้ใช้รับทราบเหตุการณ์และแก้ไขได้ทันที่ซึ่งช่วยลด Downtime ช่วยให้การงานหรือการผลิตมีความต่อเนื่องซึ่งส่งผลต่อศักยภาพการผลิต นอกจากนี้ยังสรุปปัญหาที่เกิดขึ้นพร้อมสภาพแวดล้อม/พารามิเตอร์ต่างๆที่สนใจที่ช่วยวิเคราะห์สาเหตุของปัญหาได้และยังเพิ่มศักยภาพการบริหารธุรกิจและอุตสาหกรรมเนื่องจากผู้บริหารสามารถตัดสินใจบนพื้นฐานข้อมูลที่แม่นยำและรวดเร็ว โดยข้อมูลมาจากรายงานที่รวบรวมและสรุปผลด้วยพีเจอาร์ของ SCADA ซึ่งมีความเที่ยงตรงและรวดเร็วกว่ามนุษย์ ดังนั้นธุรกิจและอุตสาหกรรมที่ใช้ระบบ SCADA จึงมีความได้เปรียบทางธุรกิจมากกว่า

3.3.3 xView Overview

เป็น Software ระบบ SCADA สัญชาติไทย ที่ประยุกต์ใช้ได้ ในหลากหลายลักษณะ Monitoring โดยพื้นฐานแล้วคำว่า Monitoring เราจะให้ความหมายไปในเรื่องของ การเฝ้าสังเกต บันทึกพฤติกรรมที่เกิดขึ้นประจำ ไม่ว่าจะเป็นใน Project , Program , Service , Document หรืออื่นๆ อีกมากมาย เป็นกระบวนการที่จะรวบรวมข้อมูลในทุกๆด้าน เพื่อนำมาใช้ในการวิเคราะห์ ตรวจสอบ แก้ไข รวมไปถึงวิธีป้องกันต่างๆ แต่หาก

มองเฉพาะในมุมมองของ IT แล้วคงไม่พ้นในเรื่อง การเฝ้าสังเกตการทำงานของ Service ต่าง ๆ ที่อยู่ใน Infrastructure ของตัวเองว่ามีการทำงานเป็นอย่างไร ปกติดีไหม มี Performance เป็นอย่างไร เพื่อให้มั่นใจว่า Infrastructure ของเราทำงานได้อย่างมีประสิทธิภาพเต็มที่

Automate Control คือระบบการควบคุมแบบต่าง ๆ เช่น การทำงานของเครื่องจักรในโรงงาน หม้อต้มและเตาอบ โครงข่ายโทรศัพท์ การบังคับทิศทางและการรักษาสมดุลในเรือ ในเครื่องบิน หรือ ยานพาหนะต่าง ๆ เพื่อลดการทำงานของคนที่มากที่สุด และงานบางงานไม่ต้องอาศัยคนช่วยอีกต่อไป ระบบ automation system ในด้านอุตสาหกรรมนั้นเป็นสิ่งที่จำเป็นอย่างมาก เนื่องจากงานบางอย่างคนไม่สามารถทำได้ เช่น ในเตาหลอมที่มีอุณหภูมิสูงมาก ในโรงงานนิวเคลียร์ซึ่งมีสารพิษระบบอัตโนมัติ automation system ประสบความสำเร็จอย่างสูง ถูกนำไปใช้ในเครื่องจักรกลไฮดรอลิก นิวแมติกอุปกรณ์ไฟฟ้า อุปกรณ์อิเล็กทรอนิกส์และคอมพิวเตอร์ซึ่งโดยปกติจะใช้ร่วมกัน ระบบที่ซับซ้อน เช่นโรงงานที่ทันสมัย เครื่องบินและเรือ มักใช้เทคนิคเหล่านี้ร่วมกันประโยชน์ของของระบบอัตโนมัติคือการช่วยประหยัดแรงงาน แต่ก็ยังใช้เพื่อประหยัดพลังงานและวัสดุรวมทั้งปรับปรุงคุณภาพความถูกต้องและความแม่นยำของสายการผลิตได้อีกด้วย



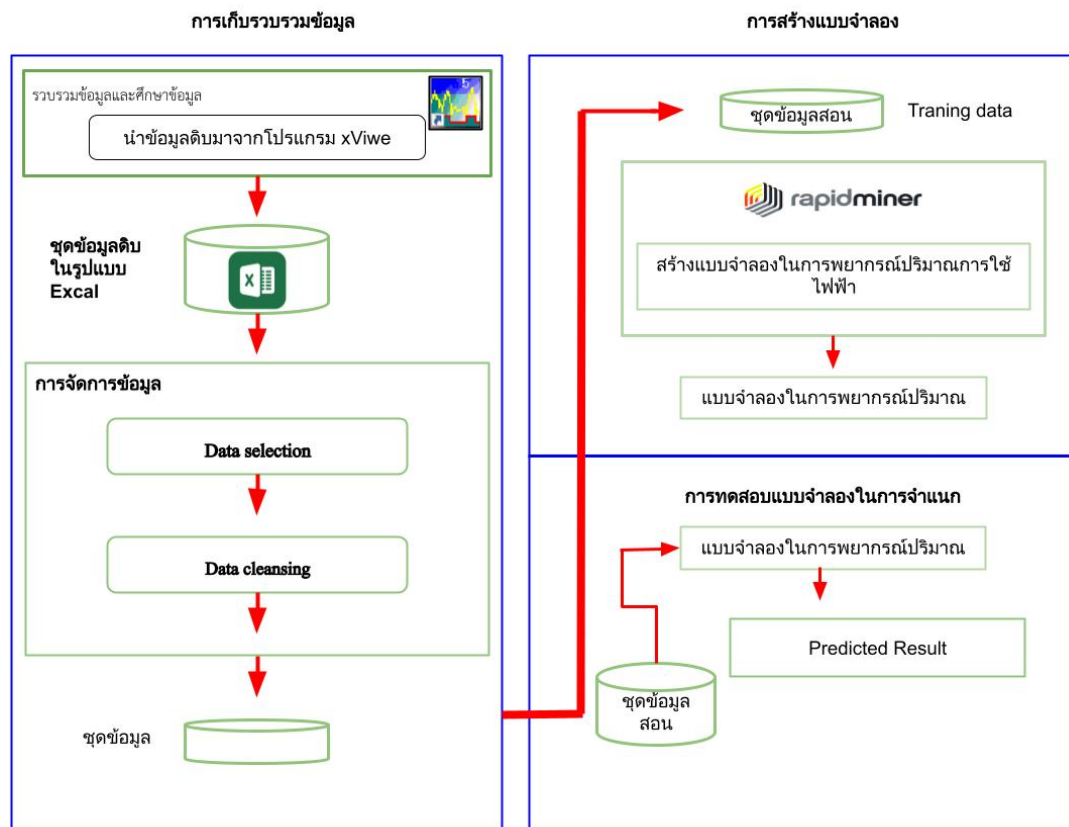
ภาพที่ 3.3 แสดง โครงสร้างการทำงานระบบโปรแกรม xView

ระบบโปรแกรม xView เป็น โปรแกรมสำหรับสื่อสารกับอุปกรณ์ต่าง ๆ แลแสดงผลและบันทึกข้อมูลโดยทำงานแบบ GUI (Graphical User Interface) บน MS-Windows ดังนั้นจึงมีความง่ายและสะดวกในการทำงาน และมีความสามารถตามคุณลักษณะของ Application บน MS-Windows ทั่วไป (Multi Tasking, Multi Threading) โดยโปรแกรมสามารถจัดการอุปกรณ์ที่มีอยู่ในระบบได้ด้วยตัวเอง ผ่านทาง Driver สื่อสารข้อมูล สรุปรายละเอียดเป็นข้อๆ ได้ดังนี้

1. สามารถรับข้อมูลจากอุปกรณ์ในระบบที่ต่อตรงผ่าน Network หรือ Serial Port (รุ่นมาตรฐาน) หรือผ่าน RTU เข้าสู่ระบบได้ (รุ่น Central Server)
2. สามารถแสดงข้อมูลทางไฟฟ้าจากเครื่องวัดไฟฟ้า Digital Powermeter ได้ทุกค่าและเก็บบันทึกได้
3. สามารถแสดง Harmonic Spectrum และ Harmonic Waveform ของแต่ละ Phase ทั้ง Voltage และ Current ได้ทั้งแบบ Line to Line หรือ Line to Neutral
4. สามารถแสดงข้อมูลที่รับมาหรือข้อมูลทางไฟฟ้าเป็นกราฟตามเวลาจริงได้ทุกค่าและเก็บบันทึกได้โดยละเอียด
5. สามารถวิเคราะห์เปรียบเทียบกราฟข้อมูลที่รับมาหรือข้อมูลทางไฟฟ้าระหว่างค่าต่าง ๆ ได้
6. สามารถจัดพิมพ์กราฟและข้อมูลที่รับมาหรือข้อมูลทางไฟฟ้าอื่น ๆ ออกทางเครื่องพิมพ์ได้
7. สามารถสื่อสารเพื่อรับข้อมูลจากอุปกรณ์ต่าง ๆ ผ่านหลายช่องทาง
 - 7.1. Serial Port (RS232/RS422/RS485)
 - 7.2. Ethernet, IP Network
 - 7.3. Modem ต่างๆ (Dial Modem, GSM Modem, Radio Modem)
 - 7.4. อุปกรณ์ RTU (Remote Terminal Unit)
8. สามารถส่งข้อมูลทางไฟฟ้าออกไปสู่อุปกรณ์เพิ่มเติมชนิดอื่น เช่น ชุด Remote Display หรือ PLC ได้ซึ่งสามารถกำหนดการควบคุมได้หลายรูปแบบ
 - 8.1. แบบควบคุมเองผ่าน MMI Screen
 - 8.2. แบบกึ่งอัตโนมัติผ่าน MMI Screen และ User Setpoint
 - 8.3. แบบอัตโนมัติผ่าน User Setpoint
9. สามารถใช้ทำให้ คอมพิวเตอร์ระบบ Multimedia ทำการเตือนเมื่อเกิดเหตุการณ์ตามที่กำหนดไว้ได้
10. กำหนดสูตรในการคำนวณค่ารวม หรือคำนวณในรูปแบบต่าง ๆ ได้
11. จัดเก็บข้อมูลลงฐานข้อมูลแบบ ODBC (MySQL, Ms SQL, Oracle) ได้
12. สามารถทำงานในลักษณะ Client/Server เพื่อทำการ Monitor ค่าต่าง ๆ แบบ Real Time ผ่านคอมพิวเตอร์ในระบบ Network ได้ หลายเครื่องพร้อมกัน (Optional)
13. รองรับการแลกเปลี่ยนข้อมูลแบบ DDE และ NetDDE, OPC, TCP, Modbus สำหรับระบบอื่น เช่น BAS (Building Automation System), SAP หรือ PI (www.osisoft.com) (Optional)
14. สามารถรายงานข้อมูลออกทาง World Wide Web ได้ทั้งข้อความและรูปภาพ และ MMI (Optional)
15. แสดงผล MMI ด้วยความละเอียดสูง Full HD (1920 x 1080) และรองรับระบบจอภาพแบบสัมผัส

16. สามารถแสดงข้อมูล Realtime ผ่านทาง TCP/IP Network ได้ (Optional)
17. สามารถแจ้งเตือนเหตุการณ์ต่าง ๆ ทาง Pager/SMS ได้ (Optional)

3.4 ขั้นตอนในการดำเนินงาน



ภาพที่ 3.4 แผนผังขั้นตอนในการดำเนินงาน

จากภาพที่ 3.3 จะแสดงขั้นตอนการทำเหมืองข้อมูล วิธีการทำเหมืองข้อมูลจะเป็นไปตามขั้นตอนตามทฤษฎีจากหัวข้อที่ (2) ซึ่งจะทำตามกระบวนการมาตรฐานที่เรียกว่า CRISP-DM (Cross Industry Standard Process for Data Mining)

3.4.1 รวบรวมข้อมูลและศึกษาข้อมูล ที่ได้รับการเก็บข้อมูลจากโปรแกรม xViwe

โดยที่โปรแกรม xViwe นั้นมีการเก็บข้อมูลจะมิเตอร์ไฟฟ้าทุกช่วงเวลา โดยข้อมูล จะนำออกมาในรูปแบบ Excel โดยที่จะคัดเลือกอาคารตัวอย่างกรณีศึกษา โดยที่ข้อมูลจะมีให้เลือกจะทำเป็น Report รายเดือน รายสัปดาห์รายวัน รายชั่วโมง รายนาที


Date Time	Voltage			Current			Total kW	kW			Total kVA	kVA			Total kvar	kvar			kWh	PF			Hz
	L1	L2	L3	L1	L2	L3		L1	L2	L3		L1	L2	L3		L1	L2	L3		L1	L2	L3	
13/01/2023 06:31:00	397	401	395	70	73	73	47	15	16	16	48	15	16	17	5	3	1	2	21879	0.99	1	0.99	50
13/01/2023 06:32:00	397	400	395	68	73	74	47	15	16	16	47	15	16	17	5	3	1	2	21880	0.99	1	0.99	50
13/01/2023 06:33:00	397	400	395	66	74	74	47	14	16	17	48	15	16	17	7	3	1	3	21881	0.98	1	0.99	50
13/01/2023 06:34:00	396	400	395	83	91	91	57	17	20	20	60	18	21	21	16	6	5	6	21882	0.95	0.98	0.96	50
13/01/2023 06:35:00	396	400	394	83	91	100	60	18	20	22	62	19	21	23	17	6	4	6	21883	0.95	0.98	0.96	50
13/01/2023 06:36:01	397	400	395	89	91	100	61	19	20	22	63	20	21	23	17	6	5	6	21884	0.96	0.98	0.96	50
13/01/2023 06:37:00	396	400	395	87	91	88	57	18	20	19	60	19	20	20	16	6	5	6	21885	0.95	0.98	0.96	50
13/01/2023 06:38:00	396	400	394	87	91	90	58	18	20	20	60	19	20	20	16	6	5	5	21886	0.95	0.97	0.97	50
13/01/2023 06:39:00	396	400	394	88	92	94	59	19	20	20	61	20	21	21	15	6	4	5	21887	0.95	0.98	0.97	50
13/01/2023 06:40:00	397	400	395	96	91	95	61	20	20	21	63	21	21	21	16	6	4	5	21888	0.96	0.98	0.97	50
13/01/2023 06:41:00	397	400	395	83	78	84	54	18	17	19	54	18	17	19	7	3	2	2	21889	0.99	1	0.99	50
13/01/2023 06:42:00	397	400	395	87	83	88	57	19	18	20	57	19	18	20	7	3	2	3	21890	0.99	1	0.99	50
13/01/2023 06:43:00	397	400	395	91	87	89	59	20	20	20	60	20	20	20	8	3	2	3	21891	0.99	0.99	0.99	50
13/01/2023 06:44:00	396	400	395	99	100	90	64	21	23	20	65	22	23	20	8	3	2	3	21892	0.99	1	0.99	50
13/01/2023 06:45:00	397	400	395	96	97	91	63	21	22	20	64	21	22	20	8	3	2	3	21893	0.99	1	0.99	50
13/01/2023 06:46:00	397	400	395	98	96	104	66	22	22	23	67	22	22	23	9	3	3	4	21894	0.99	0.99	0.99	50
13/01/2023 06:47:00	397	400	395	95	95	103	64	20	21	23	65	21	21	23	10	3	3	4	21895	0.99	0.99	0.98	50
13/01/2023 06:48:00	397	400	395	94	96	103	64	20	21	23	65	21	21	23	10	3	3	4	21896	0.99	0.99	0.98	50
13/01/2023 06:49:00	397	400	395	94	104	88	63	20	24	20	64	20	24	20	8	2	3	3	21897	0.99	0.99	0.99	50
13/01/2023 06:50:00	396	399	395	107	108	103	69	23	24	22	71	23	24	23	16	5	5	6	21898	0.98	0.98	0.96	50
13/01/2023 06:51:00	396	400	395	108	107	102	69	23	24	22	71	23	24	23	16	5	5	6	21899	0.98	0.98	0.96	50
13/01/2023 06:52:00	397	400	396	108	107	100	69	23	24	22	70	24	24	23	16	5	5	6	21900	0.98	0.98	0.97	50.1
13/01/2023 06:53:00	396	400	395	105	108	100	69	23	24	22	70	23	24	23	16	5	5	6	21901	0.98	0.98	0.97	50
13/01/2023 06:54:00	397	401	396	92	95	87	60	20	21	19	61	20	21	19	8	2	2	3	21903	0.99	1	0.99	50
13/01/2023 06:55:00	397	400	395	96	94	91	62	21	21	20	62	21	21	20	7	3	2	2	21904	0.99	1	0.99	50
13/01/2023 06:56:00	396	400	395	91	95	90	60	20	21	20	61	20	21	20	7	3	2	2	21905	0.99	1	0.99	50

ภาพที่ 3.5 ตัวอย่าง หน้า UI ของ ตัวโปรแกรมที่เก็บข้อมูล

ข้อมูลที่งานวิจัยนี้เลือกใช้นั้นเป็นข้อมูลที่ถูกรวบรวมจากมิเตอร์ไฟฟ้าโดยตรงซึ่งข้อมูลนั้นคือข้อมูลการใช้พลังงานไฟฟ้าภายในอาคารประเภทสำนักงานขนาดกลาง ภายในสำนักงานจะประกอบไปด้วยมิเตอร์ไฟฟ้าภายในอาคาร จำนวน 3 ตัว ซึ่งข้อมูลจากมิเตอร์ไฟฟ้าที่นำมาใช้นั้นจะเป็นข้อมูลรายชั่วโมงเพื่อให้ง่ายต่อการสังเกตการเปลี่ยนแปลงในแต่ละช่วงเวลาซึ่งมีจำนวน 2176 ชั่วโมง ตั้งแต่วันที่ 1 กันยายน 2565 ถึง วันที่ 30 พฤศจิกายน 2565 จากนั้นรวบรวม Report ย้อนหลัง ในแต่ละมิเตอร์ไฟฟ้า ซึ่งยังสามารถหาข้อมูลย้อนหลังได้เยอะเท่าไรก็ยังมีความแม่นยำในการทำมาขึ้นเท่านั้น โดยที่ผู้วิจัยสามารถรวบรวมมาได้นั้นโปรแกรม xViwe สามารถ นำข้อมูลReport ออกมาในรูปแบบไฟล์ Excel

3.4.2 วิเคราะห์และเลือกข้อมูลData selection ทำชุดข้อมูลในรูปแบบของไฟล์ Excel

เมื่อเราได้ ข้อมูลเป็นไฟล์ Excel ออกมาแล้วดังภาพตัวอย่าง เราก็จะนำข้อมูลมาวิเคราะห์ปริมาณที่จะนำมาพยากรณ์ ดังภาพตัวอย่าง 3.5



ภาพที่ 3.6 แสดงตัวอย่างแผนภูมิชุดข้อมูลที่ได้จากการเก็บข้อมูล

จากภาพแผนภูมิชุดข้อมูลจะมีประเภทที่เก็บข้อมูลมาได้คือจะมีจำนวนข้อมูล ทั้งหมด มีประเภทข้อมูลที่เก็บมาได้ นั้นมีทั้งหมด 23 ประเภทได้แก่

ตารางที่ 3.1 แสดงข้อมูลประเภทของข้อมูลที่นำมาจากการเก็บข้อมูล


ประเภทชุดข้อมูล	ความหมาย
Date Time	ช่วงเวลารายชั่วโมงตลอดระยะเวลา 24 ชั่วโมง
kW	ค่าการใช้ไฟฟ้าในหนึ่งชั่วโมง มีหน่วยเป็น กิโลวัตต์
kWh	ค่าการใช้พลังงานทั้งหมด มีหน่วยเป็นกิโลวัตต์ต่อชั่วโมง
Voltage L1 L2 L3	ค่าแรงดันไฟฟ้า ของแต่ละเฟส
Current L1 L2 L3	ค่ากระแสไฟฟ้า ของแต่ละเฟส
kW L1 L2 L3	ค่ากำลังไฟฟ้า มีหน่วยเป็น กิโลวัตต์ ในแต่ละเฟส
kVA L1 L2 L3	หน่วยของกำลังไฟฟ้าที่ปรากฏ ในแต่ละเฟส
kvar L1 L2 L3	กำลังไฟฟ้าแฝง ในแต่ละเฟส
PF L1 L2 L3	ค่าพาวเวอร์แฟคเตอร์ ในแต่ละเฟส
Hz	ค่าความถี่ไฟฟ้าต่อวินาที
Max Demand	ค่าความต้องการไฟฟ้าสูงสุด

3.4.3 กลั่นกรองข้อมูล (Data cleansing)

หลังจากได้ทำการกลั่นกรองข้อมูลเพื่อให้ได้ข้อมูลที่มีความสมบูรณ์สำหรับการประมวลผลต่อไป ทั้งนี้ข้อมูลที่น่ามาวิเคราะห์ไม่ว่าจะเป็นตัวเลข ข้อมูลเป็นช่วง หรือข้อมูลที่เป็นข้อความ จะต้องทำการแปลงหรือแทนค่าให้อยู่ในรูปแบบมาตรฐานเดียวกัน เพื่อให้ง่ายต่อการวิเคราะห์ การแทนค่าข้อมูลที่ถูกต้องจะส่งให้การประมวลผลของคอมพิวเตอร์ทำได้อย่างรวดเร็ว มีความถูกต้องแม่นยำในการวิเคราะห์ข้อมูล และลดความผิดพลาดในการพยากรณ์ ซึ่งการทดลองจะต้องแปลงข้อมูลในภาษามนุษย์ให้ เป็นรูปแบบที่คอมพิวเตอร์เข้าใจ โดยเราจะทำการคัดกรองข้อมูลจากความสมบูรณ์แบบของแต่ละข้อมูลโดยที่เราจะวิเคราะห์จากข้อมูลที่ไม่สมบูรณ์ก่อนดังภาพตัวอย่างที่ 3.6

10/09/2022 19:00	397.6	8.63	24778	403.1	396	17.17	16.37	15.65	2.82	2.68	3.13	2.88	2.68	3.15	-0.4	-0.7	-0.4	-1	-1	-0	50	385
10/09/2022 20:00	400.2	0.48	24779	406.1	398.7	0.78	0.12	2.83	0.08	0.02	0.38	0.1	0.02	0.38	0	0	0	-0	-0	0.8	50	385
10/09/2022 21:00	398.6	0.41	24780	404.8	397.9	0.03	0.35	3.08	0	0.03	0.38	0	0.03	0.38	0	0	0	-0	-0.1	0.8	50	385
10/09/2022 22:00	399	0.28	24780	404.7	398.5	0.03	0	2.27	0	0	0.28	0	0	0.28	0	0	0	0	0	0.6	50	385
10/09/2022 23:00	401.7	0.33	24780	407	401	0.07	0	2.38	0	0	0.33	0	0	0.33	0	0	0	0	0	0.6	50	385
11/09/2022 00:00	398	0.2	24780.1	402.7	397.1	0.03	0	1.72	0	0	0.2	0	0	0.2	0	0	0	0	0	0.5	50	385
11/09/2022 01:00	398.2	0.23	24781	402.4	397.1	0	0	1.72	0	0	0.23	0	0	0.23	0	0	0	0	0	0.5	50	385
11/09/2022 02:00	399.6	0.27	24781	403.7	398.5	0.03	0	2.38	0	0	0.27	0	0	0.28	0	0	0	0	0	0.7	50	385
11/09/2022 03:00	400.7	0.7	24781.5	404.4	399.2	0.03	0	4.37	0	0	0.7	0	0	0.72	0	0	0	-0	0	0.8	50	385
11/09/2022 04:00	400.8	0.2	24782	404.5	399.2	0	0.03	1.75	0	0	0.2	0	0	0.2	0	0	0	0	0.02	0.5	50	385
11/09/2022 05:00	400.7	0.23	24782	404.1	398.8	0.03	0	1.93	0	0	0.23	0	0	0.23	0	0	0	0	0	0.6	50	385
11/09/2022 06:00	398.1	0.13	24782.5	401.8	396.6	0.03	0	1.32	0	0	0.13	0	0	0.13	0	0	0	-0	0	0.4	50	385
11/09/2022 07:00	397.9	1.26	24783.1	401.5	396.5	4.33	3.47	4.03	0.43	0.28	0.55	0.48	0.4	0.55	-0.1	-0.2	0	0	-0.2	0.8	50	385
11/09/2022 08:00	401.3	3.23	24785.8	405	399.9	6.47	8.37	17.35	0.62	0.68	1.93	0.62	0.78	1.95	-0	-0.3	-0.3	-0	-0.4	-0	50	385
11/09/2022 09:00	402.2	23.24	24797	405.9	400.8	44.57	44.2	46.83	7.38	7.53	8.33	8.6	8.77	9.73	4.42	4.35	4.38	0.8	0.78	0.8	50	385
11/09/2022 10:00	401	27.83	24823.7	404.9	399.5	52.1	53.25	52.7	8.88	9.35	9.6	10.35	10.98	11.25	5.47	5.35	5.58	0.9	0.87	0.9	50	385
11/09/2022 11:00	399.8	28	24851.4	404.2	398.8	51.44	52.85	53.67	8.66	9.21	10.13	10.21	10.9	11.31	5.51	5.28	5.92	0.9	0.88	0.9	50	385
11/09/2022 12:00	400.1	12.85	24872.8	404.6	399.1	25.47	29.75	32.13	3.22	4.28	5.35	3.77	4.78	5.57	1.57	1.92	2.28	0.7	0.73	0.9	50	385
11/09/2022 13:00	398.9	11.05	24884.9	403.6	398	22.85	24	30.43	2.72	3.45	4.88	3.32	4.07	5.05	1.37	2	1.57	0.6	0.6	0.8	50	385
11/09/2022 14:00	398.9	2.78	24890	403.4	398	5.44	3.89	19	0.11	0.11	2.56	0.89	0.78	2.78	-0.6	-0.6	-0.8	-0	-0	-0	50	385
11/09/2022 15:00	399.2	2.25	24891	404.1	398.2	0.93	1.03	21.74	-0.03	0	2.28	0.11	0.21	2.36	-0.1	-0.2	-0.1	-0	0	0.5	50	385
11/09/2022 16:00	399	2.07	24893.1	403.9	398.2	1.88	0	18.82	0.12	0	1.95	0.13	0	1.95	0	0	0	-0	0	1	50	385
11/09/2022 17:00	398.4	1.68	24895	403.1	397.1	0.17	0	11.12	0	0	1.68	0	0	1.68	0	0	0	-0	0	-0	50	385
11/09/2022 18:00	399.9	1.82	24896.8	405.1	398.2	0.17	0	11.57	0	0	1.82	0	0	1.85	0	0	-0	0.1	0	-1	50	385
11/09/2022 19:00	400.2	1.9	24898.6	406.5	398.6	0.37	0	11.83	0	0	1.9	0	0	1.9	0	0	0	0	0	0.1	50	385
11/09/2022 20:00	399.1	1.69	24900.3	406.4	398.3	0.16	0	11.13	0	0	1.69	0	0	1.72	0	0	0	0.1	0	-0	50	385
11/09/2022 21:00	400.1	1.81	24902.1	408.3	400.1	0.19	0.57	11.67	0	0.05	1.76	0	0.05	1.86	0	0	0	0.1	-0.1	0.2	50	385
11/09/2022 22:00		1.78	24903.8																			385
11/09/2022 23:00		1.75	24905.6																			385
12/09/2022 00:00	400.8	1.75	24908	406.4	400.1	0.07	0	11.08	0	0	1.75	0	0	1.78	0	0	-0	0	0	-0	50	385
12/09/2022 01:00	402.8	2.05	24910	407.8	401.7	0.03	0	12.07	0	0	2.05	0	0	2.05	0	0	0	0	0	0.6	50	385
12/09/2022 02:00	400.4	1.73	24912	405.2	399.2	0.17	0	11.02	0	0	1.73	0	0	1.8	0	0	0	0	0	-0	50	385
12/09/2022 03:00	399.4	1.85	24914	404	398.1	0.07	0	11.17	0	0	1.85	0	0	1.85	0	0	0	0	0	-0	50	385


ภาพที่ 3.7 แสดงตัวอย่างชุดข้อมูลที่จะนำมาคัดกรอง



ภาพที่ 3.8 แสดงแผนภูมิตัวอย่างชุดข้อมูล 24 ชั่วโมง ที่ติด 0

จากภาพที่ 3.6 จะเห็นสีในช่องภายในชุดข้อมูลโดยจะทำการแบ่งแยกประเภทข้อมูลไว้โดยที่จำแนกข้อมูลเป็นประเภทสีไว้ เพื่อต่อการสังเกตและการดูภาพรวม ในการคัดกรองข้อมูลโดยที่ สีแดงจะเป็นข้อมูลที่ติดศูนย์ ส่วนสีเหลืองคือข้อมูลที่มีปัญหาทางการเก็บข้อมูล อาจเกิดจากการคัดช่องของตัว software หรือการขัดข้องของตัวอุปกรณ์ และการสื่อสาร และภาพที่ 3.7 จะแสดงถึงแผนภูมิปริมาณการใช้

พลังงานไฟฟ้าใน 24 ชั่วโมง ส่วนที่มีค่าเท่ากับ 0 โดยที่การจัดการข้อมูลจะทำการตัดข้อมูลที่ติดศูนย์เยอะมากๆ และ ข้อมูลที่สามารถจะพอประมาณการจากข้อมูลที่มีอยู่ได้ เช่น ข้อมูล kW ซึ่งมีหน่วยต่อรายชั่วโมง สามารถประมาณการได้จาก ค่า kWh ที่เป็นผลการใช้รวมรายชั่วโมงได้ เป็นต้น ซึ่งการตัดค่า 0 และการเพิ่มค่าที่ต้องความผิดพลาดจะทำให้เปอร์เซ็นต์ Error ของการพยากรณ์ลดลง เมื่อทำการตัดข้อมูลเสร็จสิ้นเราจะได้ชุดข้อมูล ดังภาพที่ 3.8



ภาพที่ 3.9 แสดงตัวอย่างแผนภูมิปริมาณชุดข้อมูลที่ผ่านมาคัดกรองและตัดข้อมูล

ข้อมูลที่น่ามาศึกษา เก็บข้อมูลการใช้พลังงานไฟฟ้า ภายในตัวอาคารสำนักงานขนาดกลางโดยที่จะแบ่งเป็น แต่ละมิเตอร์มิเตอร์ไฟฟ้าตามหัวข้อที่ (3.4.1) โดยที่จะเก็บข้อมูลตลอด 24 ชั่วโมง เป็นระยะเวลา ย้อนหลังสามเดือน ในรูปแบบของไฟล์ Excel จากการวิเคราะห์ข้อมูล เราจะพยากรณ์ในเชิงปริมาณ เราจะต้องจัดข้อมูลเพื่อที่จะลดการผิดพลาดในการพยากรณ์โดยการ ตัดข้อมูลบางส่วนที่ไม่มีความจำเป็นออกไป และ คงเหลือข้อมูลที่เราจะใช้ โดยที่ข้อมูลที่เราจะใช้นั้นมีดังนี้

ตารางที่ 3.2 แสดงตามข้อมูลที่นำมาวิเคราะห์กลุ่มที่จะนำมาพยากรณ์

ตัวแปรที่นำมา	ความหมาย
Date Time	เป็นแถวที่บอกข้อมูลของวันที่และเวลาตลอดทั้งเดือน
kW	เป็นแถวที่บอกค่าความต้องการพลังงานไฟฟ้า ของแต่ละมิเตอร์ ในแต่ละชั่วโมง หน่วยเป็น กิโลวัตต์ (kW)
kWh	ค่าการใช้พลังงานทั้งหมด มีหน่วยเป็นกิโลวัตต์ต่อชั่วโมง
Max Demand	ค่าความต้องการไฟฟ้าสูงสุด

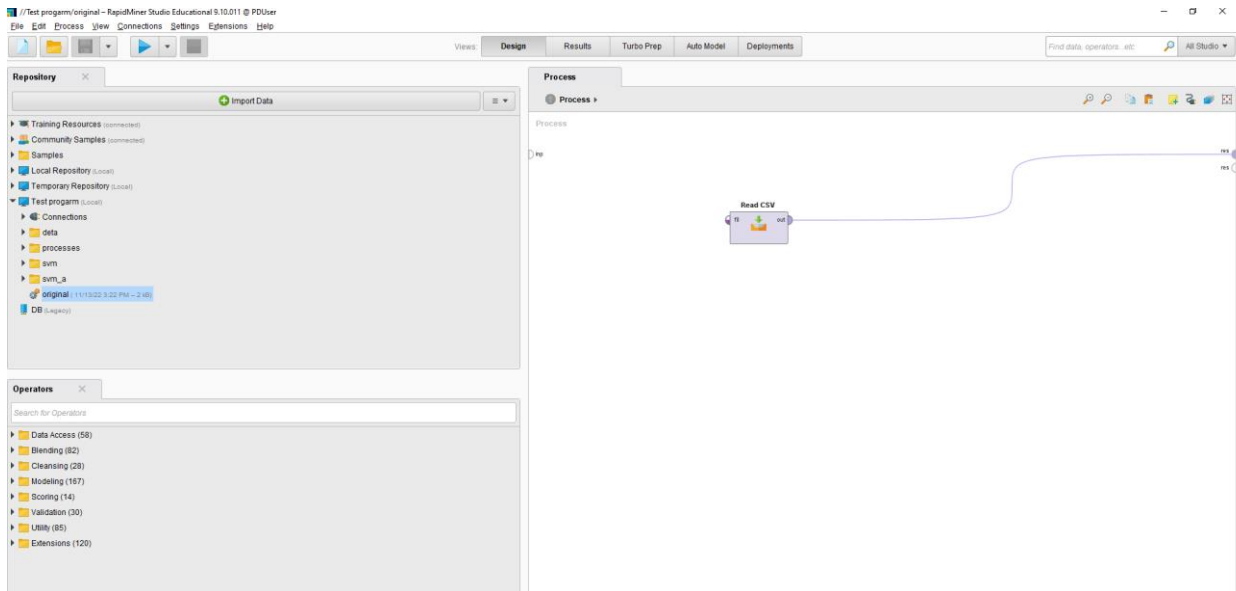
จากตารางที่ 3.2 จะแสดงถึงตัวแปรที่จะนำมาเป็นข้อมูลการเรียนรู้ให้กับการทำตัวแบบพยากรณ์ โดยที่จะเลือกตัวแปรจากค่าความต้องการการใช้พลังงานไฟฟ้า ซึ่งมีความสัมพันธ์กับตัวแปร Date Time ที่เป็นตัวแปรของข้อมูลเป็นเวลารายชั่วโมง อาคารสำนักงานขนาดกลางที่เป็นกรณีศึกษานั้น ระบบไฟฟ้าทั้งอาคารจะประกอบไปด้วยมิเตอร์ไฟฟ้าจำนวนทั้งหมด 3 มิเตอร์ไฟฟ้า การจัดสรรข้อมูลที่เตรียมทำแบบพยากรณ์ จะทำการแบ่งแยกชุดข้อมูลค่าความต้องการการใช้พลังงานไฟฟ้า เป็นตัวแปร MDB1 MBD2 และ MDB3 ตามลำดับ ดังภาพที่ 3.



ภาพที่ 3.10 แสดงแผนภูมิพลังงานไฟฟ้าทั้งหมด

3.3.4 สร้างตัวแบบทดสอบเปรียบเทียบประสิทธิภาพและทำการพยากรณ์ข้อมูล

การสร้างตัวแบบ (Model) ผู้วิจัยเลือกใช้เทคนิควิธีหรืออัลกอริทึมสำหรับการทดลอง โดยที่การที่เราจะเลือกอัลกอริทึมนั้นจะใช้ฟังก์ชันหนึ่งของโปรแกรม RapidMiner เพื่อทำการเรียนรู้ Model และสร้างผลการคำนวณเพื่อหาอัลกอริทึมที่เหมาะสม โดยมีวิธีการ ขั้นตอนแรกแปลงไฟล์ Data เป็นในรูปแบบ CSV โดยที่นำไฟล์มาใส่ใน operators ที่ชื่อว่า Read csv



ภาพที่ 3.11 แสดงการสร้าง operators Read CSV

หลังการที่ได้สร้าง Read csv แล้ว ให้กักรันข้อมูลและ เข้าไปดูข้อมูลที่ได้ทำการรันใน Results เพื่อที่จะได้มาดูผลกราฟแสดงข้อมูล โดยจะเห็นการแสดงผลข้อมูล ปริมาณการใช้พลังงานไฟฟ้าหน่วยเป็น kW เทียบกับช่วงเวลารายชั่วโมง



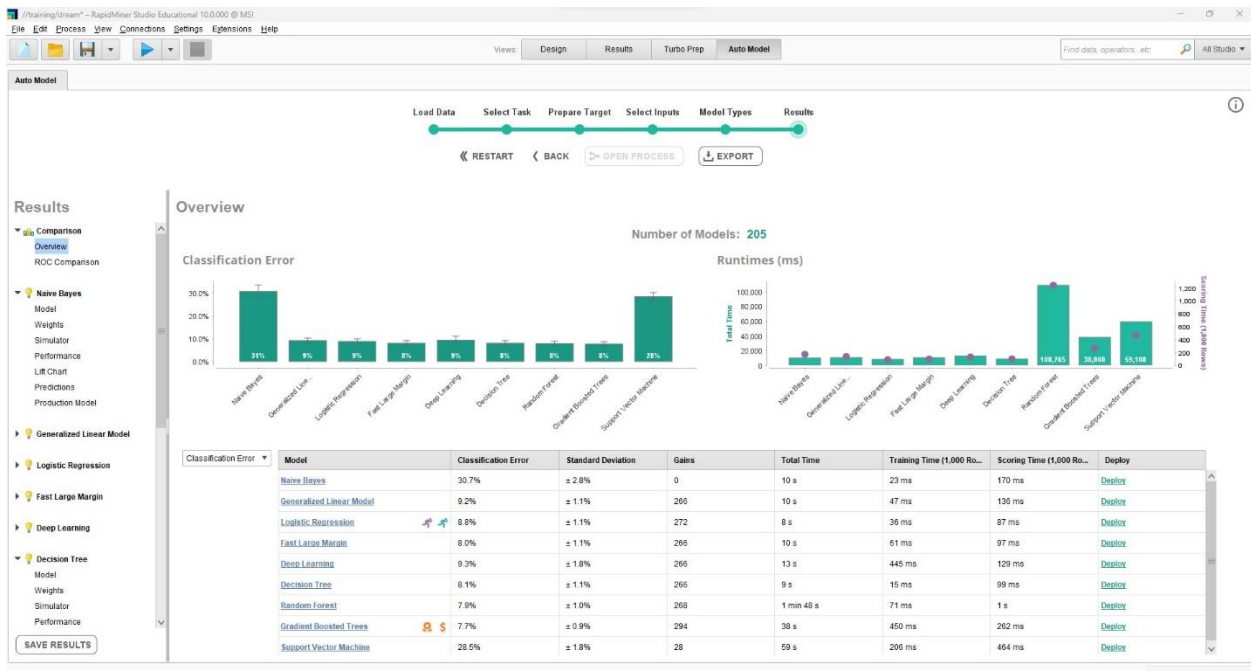
ภาพที่ 3.12 แสดงการแสดงผลของการใช้พลังงานไฟฟ้าของมิเตอร์ไฟฟ้าแต่ละตัว

ผู้วิจัยได้ใช้ฟังก์ชันของโปรแกรม RapidMiner ในคัดการเลือกอัลกอริทึม สำหรับการพยากรณ์ ข้อมูลโดยโปรแกรมจะทำการเรียนรู้ชุดข้อมูลที่ไว้ใช้สำหรับการพยากรณ์และหาความสัมพันธ์กับตัวกลุ่มหัวข้อ ภายในชุดข้อมูลนั้นๆ โดยจะใช้การวิเคราะห์ข้อมูลแบบถดถอย (Regression Analysis) ตามทฤษฎีข้อที่ (2.3.2) แบ่งชุดข้อมูลที่ไว้ในการเรียนรู้กับส่วนที่ไว้ใช้พยากรณ์ในอัตราส่วน 60 : 40 โดยจะใช้ชุดข้อมูล 60% นั้นไว้สำหรับการเรียนรู้ชุดข้อมูลย้อนหลัง ส่วน ข้อมูลอีก 40% นั้นไว้สำหรับการพยากรณ์ เนื่องจากเรา ต้องการชุดข้อมูลในเดือนถัดไป ซึ่งจำนวนข้อมูลทั้งหมดคือ 2184 การแบ่งชุดการเรียนรู้ข้อมูล 60% เพื่อความ แม่นยำจำนวนหนึ่ง นั้น 40% จะเป็นข้อมูลที่ไว้ใช้พยากรณ์จำนวนแถวจะเท่ากับจำนวนชั่วโมงในจำนวนเดือน ถัดไปพอดี ข้อมูลรันอัลกอริทึมหลายๆอัลกอริทึมและผู้จัดทำจะเปรียบเทียบอัลกอริทึมที่มีเปอร์เซ็นต์ความ ผิดพลาดของข้อมูลน้อยที่สุดดังภาพด้านล่าง

Row No.	Date Time	kw1	kw2	kw3
1	Sep 1, 2022 ...	0.370	43.120	135.330
2	Sep 1, 2022 ...	0.230	43.980	137.980
3	Sep 1, 2022 ...	0.200	42.610	135.910
4	Sep 1, 2022 ...	0.300	41.310	132.780
5	Sep 1, 2022 ...	1.270	42.090	133.100
6	Sep 1, 2022 ...	10.090	42.680	129.460
7	Sep 1, 2022 ...	56.760	74.120	160.400
8	Sep 1, 2022 ...	106.470	163.140	264.610
9	Sep 1, 2022 ...	266.670	281.160	319.650
10	Sep 1, 2022 ...	315.330	297.740	350.420
11	Sep 1, 2022 ...	343.290	310.070	358.590
12	Sep 1, 2022 ...	331.740	304.670	376.050
13	Sep 1, 2022 ...	320.500	300.350	366.320
14	Sep 1, 2022 ...	341.480	308.990	385.490
15	Sep 1, 2022 ...	215.950	299.620	340.380
16	Sep 1, 2022 ...	220.900	260.670	335.440
17	Sep 1, 2022 ...	206.830	242.580	326.180
18	Sep 1, 2022 ...	136.830	163.900	292.330
19	Sep 1, 2022 ...	43.600	105.190	226.150
20	Sep 1, 2022 ...	16.750	60.730	169.220
21	Sep 1, 2022 ...	8.840	48.200	146.090
22	Sep 1, 2022 ...	3.650	47.260	145.800
23	Sep 1, 2022 ...	0.370	39.800	141.480
24	Sep 1, 2022 ...	0.630	39.520	141.410
25	Sep 2, 2022 ...	0.440	42.160	142.930

ภาพที่ 3.13 ตัวอย่างแสดงฟังก์ชัน Auto Modle

โดยผู้ทำการวิจัยได้ทำการพยากรณ์ข้อมูลโดยโปรแกรมจะรันอัลกอริทึมหลายๆอัลกอริทึมจะมีผลลัพธ์ ในการพยากรณ์ ที่ตั้งค่า ให้เป็นการเรียนรู้หรือจากข้อมูล Data 60 เปอร์เซ็นต์ ของจำนวน ข้อมูล ทั้งหมด 2176 แถวโดยให้สัมพันธ์กับเวลา โดยจะพยากรณ์ ข้อมูล 40 เปอร์เซ็นต์ที่เหลือ โดยจะพยากรณ์ไปข้างหน้า จากนั้นก็จะได้ผล Results ตามภาพด้านล่าง

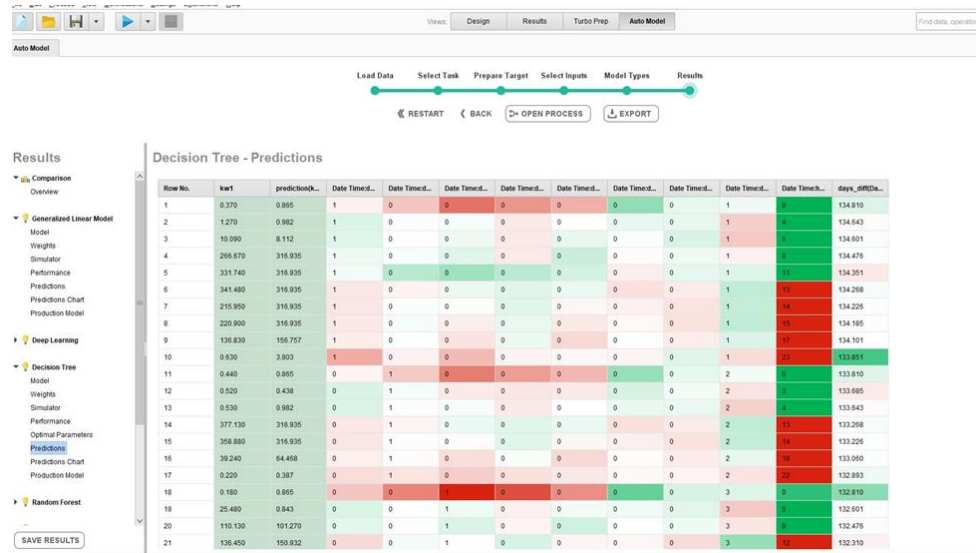


ภาพที่ 3.14 ตัวอย่างแสดงขั้นตอนการรันหลายอัลกอริทึม

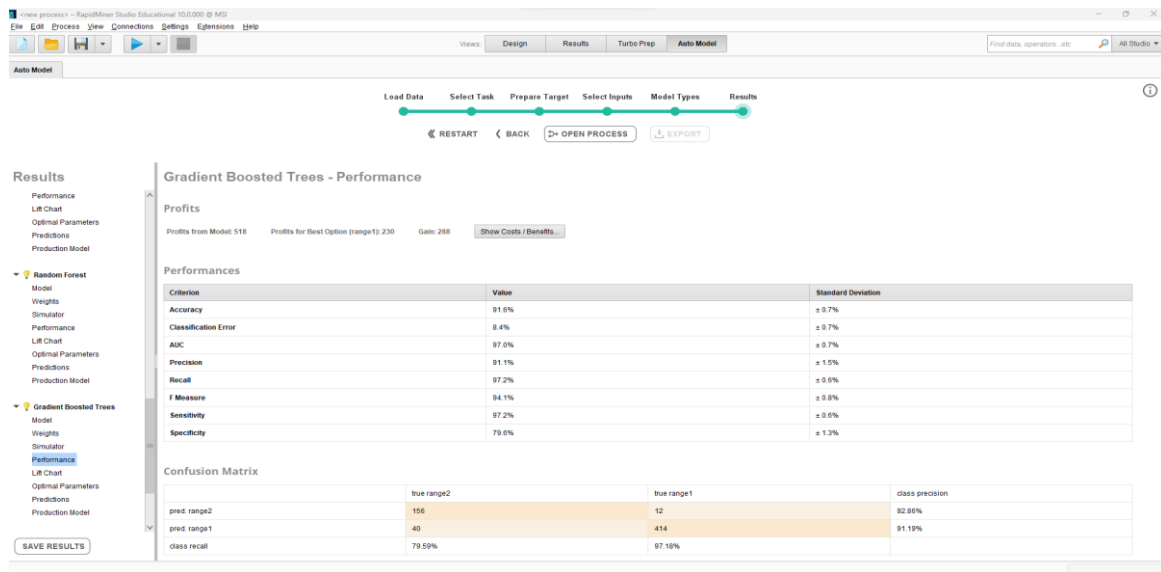
จากการทดสอบการทำงานตัวแบบในการพยากรณ์หลายตัวพร้อมกัน ผู้ทำการวิจัยจะเลือกตัวแบบที่ได้จากโปรแกรมที่ทำการเลือกความเหมาะสมกับตัวชุดข้อมูลซึ่งมีทั้งหมด 8 ตัวแบบ ได้แก่ Naive Bayes, Generalized linear Model, Fast Large Margin, Deep Learning, Decision Tree, Random Forest, Gradient Booster Trees, Support Vector Machine ตัวโปรแกรมจะทำการเอาชุดข้อมูลไปทำการรันผลของการพยากรณ์ของแต่ละตัวแบบในการพยากรณ์หลังจากที่ได้ผล Results ตามภาพขั้นตอนต่อไป จะมาหาตัวแบบที่เหมาะสมกับชุดข้อมูลของเราโดยที่เราจะมาดูจากผลลัพธ์ในการจัดกลุ่มการพยากรณ์ตัวแบบ โดยจะดูจากค่าต่างๆที่ทางโปรแกรมได้แสดงผลประสิทธิภาพ ที่มีความสำคัญต่อการตัดสินใจเลือกตัวแบบในการพยากรณ์ ตามทฤษฎีข้อมูลหัวข้อที่ 2.3.8 มีดังนี้

- ค่า Accuracy คือค่าความแม่นยำของตัวแบบ ซึ่งค่า Accuracy ยิ่งมากความแม่นยำในการพยากรณ์ยิ่งสูง
- ค่า Classification Error คือ ค่าการจัดกลุ่มผิดพลาด ซึ่งค่า Classification Error ยิ่งมีค่าน้อยความสมบูรณ์ของการพยากรณ์ก็ยิ่งมีประสิทธิภาพมากขึ้น
- ค่าความแม่นยำ (Precision) คือ การคำนวณเทียบกับคำตอบทั้งหมดที่ผิด ว่าผลการทำนายถูกต้องเท่าใด

โดยงานวิจัยนี้จะพิจารณาประสิทธิภาพจากตัวข้อมูลที่พยากรณ์จากค่าทั้งสองค่านี้โดยที่ ค่า Accuracy จะต้องมีความมากที่สุด และค่า Classification Error น้อยที่สุด จากตัวแบบที่ทางโปรแกรม Rapidminer รันพร้อมกัน หลังการการพิจารณาค่า Classification Error ที่มีเปอร์เซ็นต์ที่น้อยสุดก็ให้เลือกอัลกอริทึมนั้น และจะได้ผลดังภาพด้านล่าง




ภาพที่ 3.15 แสดงตัวอย่าง การพยากรณ์ ชุดข้อมูลปริมาณการใช้ไฟฟ้า



ภาพที่ 3.16 แสดง Performance ของตัวแบบพยากรณ์

หลังจากที่ผู้วิจัยได้ผลการพยากรณ์ โดยที่ผลการพยากรณ์นั้นจะได้ปริมาณการใช้ไฟฟ้าระยะเวลา 1 เดือนซึ่งข้อมูลพยากรณ์จะเป็นข้อมูลในเดือนถัดไป หลังจากนั้นให้ทำการนำข้อมูลออกมาเพื่อใช้งานโดยทางโปรแกรมจะมีฟังก์ชันการ export ชุดข้อมูลพยากรณ์ ออกมาเป็นในรูปแบบ ไฟล์ Excel จะได้ข้อมูลดังภาพ แผนภูมิปริมาตรด้านล่าง ภาพที่ 3.16



ภาพที่ 3.17 แสดงแผนภูมิปริมาณผลลัพธ์ชุดข้อมูลการพยากรณ์

บทที่ 4

ผลการดำเนินงานวิจัย


ผลการศึกษาจากการดำเนินการทางวิจัย เพื่อหารูปแบบการพยากรณ์ ปริมาณการใช้พลังงานไฟฟ้าภายในอาคารที่เหมาะสมในแต่ละชุดข้อมูลมิเตอร์ ซึ่งชุดข้อมูลที่หามาได้นั้นเป็นชุดข้อมูลจริงที่ได้ทำการเก็บข้อมูลผ่านโปรแกรม xView และนำมาหารูปแบบการพยากรณ์ที่เหมาะสมโดยใช้วิธีการทำเหมืองข้อมูล โดยใช้โปรแกรม RapidMiner เป็นเครื่องมือในการสร้างรูปแบบพยากรณ์ ข้อมูลที่นำมาพยากรณ์ จะถูกแบ่งออกเป็น 3 ชุดข้อมูลโดยที่ชุดข้อมูลจะเป็นปริมาณการใช้พลังงานไฟฟ้าของแต่ละมิเตอร์ไฟฟ้าภายในอาคาร มีผลลัพธ์ดังนี้

- 4.1 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1
- 4.2 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2
- 4.3 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

4.1 ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

4.1.1 ผลของการเปรียบเทียบแบบจำลองการทำนายปริมาณการใช้พลังงานไฟฟ้าที่เหมาะสมกับชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1


จากการสร้างตัวแบบทดสอบเปรียบเทียบประสิทธิภาพของข้อมูลจะพบได้ว่า ชุดข้อมูลที่ทางโปรแกรมได้ทำการรันตัวแบบหลายๆตัวพร้อมกันนั้นก็จะมี Naive Bayes, Generalized linear Model , Fast Large Margin , Deep Learning , Decision Tree , Random Forest , Gradient Booster Trees, Support Vector Machine และทำการตรวจสอบ ประสิทธิภาพของโมเดลแบบจำลอง (Performance) เพื่อเปรียบเทียบ



ภาพที่ 4.1 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1


ตัวแบบ Naive Bayes จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูลหัวข้อที่ 2.3.8 เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.2 มีค่าที่สำคัญต่อการตัดสินใจในการเลือกตัวแบบจำลองไปพยากรณ์ นั้นมีทั้งหมด 4 ค่าในการพิจารณา ได้แก่ ความถูกต้องของพยากรณ์ (Accuracy) , ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) ค่าความแม่นยำ (Precision) และ ค่าระลึก (Recall)

ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $69.3\% \pm 2.8\%$,ค่า Classification error มีค่าเท่ากับ $30.7\% \pm 2.8\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $69.3\% \pm 2.8\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 2\%$




ภาพที่ 4.2 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

ตัวแบบ Generalized linear Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.3 ผลของค่าประสิทธิภาพ (Performance)ค่าAccuracy มีค่าเท่ากับ $69.3\% \pm 3.2\%$,ค่า Classification error มีค่าเท่ากับ $30.7\% \pm 3.2\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $72.5\% \pm 3.3\%$ และค่า Recall มีค่าเท่ากับ $89.8\% \pm 2.1\%$




ภาพที่ 4.3 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

ตัวแบบ Fast Large Margin Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.4 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $69.3\% \pm 2.8\%$,ค่า Classification error มีค่าเท่ากับ $30.7\% \pm 2.8\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $69.3\% \pm 2.8\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$



ภาพที่ 4.4 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

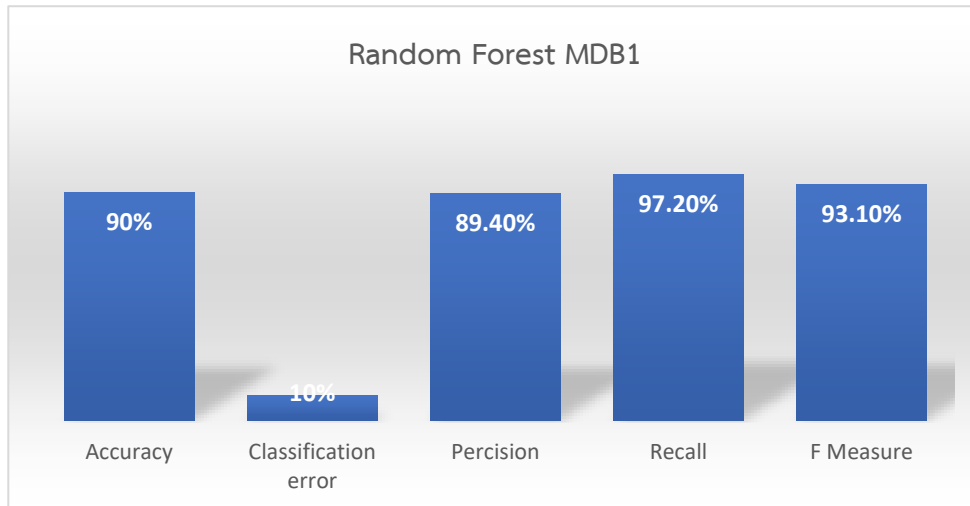
ตัวแบบ Deep Learning Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.5 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $76.4\% \pm 2.9\%$,ค่า Classification error มีค่าเท่ากับ $23.6\% \pm 2.9\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $74.6\% \pm 3.0\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$



ภาพที่ 4.5 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1


ตัวแบบ Decision Tree Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดล

แบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.6 ผลของค่า ประสิทธิภาพ (Performance)ค่าAccuracy มีค่าเท่ากับ $91.0\% \pm 1.9\%$,ค่า Classification error มีค่าเท่ากับ $9.0\% \pm 1.9\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $89.3\% \pm 2.2\%$ และค่า Recall มีค่าเท่ากับ $98.8\% \pm 1.2\%$



ภาพที่ 4.6 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

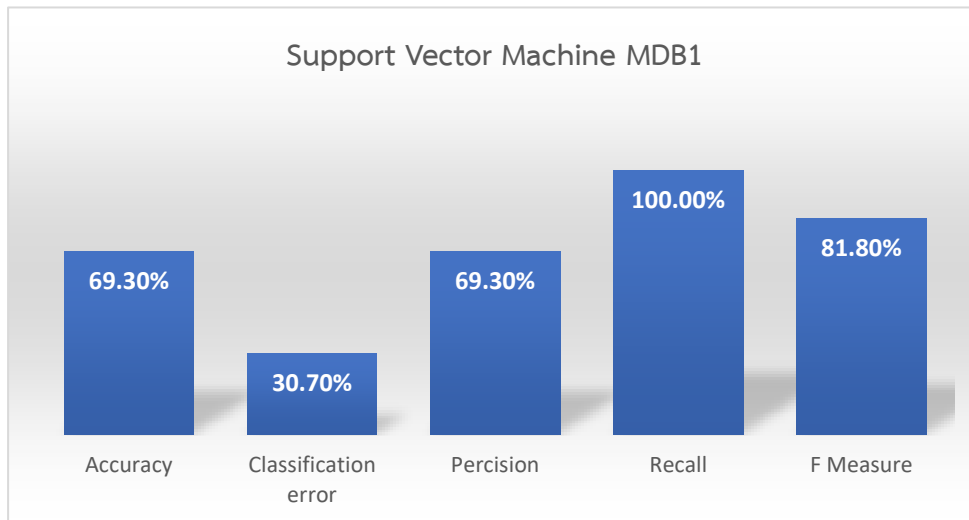
ตัวแบบ Random Forest Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.7 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $90.0\% \pm 1.9\%$,ค่า Classification error มีค่าเท่ากับ $10.0\% \pm 1.9\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $89.4\% \pm 2.8\%$ และค่า Recall มีค่าเท่ากับ $97.2\% \pm 0.8\%$



ภาพที่ 4.7 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

ตัวแบบ Gradient Booster Trees Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพ

ที่ 4.8 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $91.6\% \pm 0.7\%$,ค่า Classification error มีค่าเท่ากับ $8.4\% \pm 0.7\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $91.1\% \pm 1.5\%$ และค่า Recall มีค่าเท่ากับ $97.2\% \pm 0.6\%$



ภาพที่ 4.8 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

ตัวแบบ Support Vector Machine Model จากการทดสอบการทำงานของตัวแบบพยากรณ์พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.9 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $69.30\% \pm 2.8\%$,ค่า Classification error มีค่าเท่ากับ $30.7\% \pm 2.8\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $69.30\% \pm 2.8\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$

จากการรันตัวแบบทั้ง 8 ตัวแบบที่ทางโปรแกรมได้ทำการคัดเลือกความเหมาะสมให้กับชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 โดยตัวแบบที่ทำการแสดงผลนั้นพบว่า มีผลลัพธ์ค่าความสัมพันธ์ต่างๆ การตัดสินใจเลือกตัวแบบนั้นวัดค่าประสิทธิภาพหลักๆ จากค่าความเหมาะสมของการจัดกลุ่ม นำมาจัดตารางได้ดังนี้

ตารางที่ 4.1 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 1

model	Accuracy	Classification error	Precision	total Time
Naive Bayes	69.30%	30.70%	69.30%	10 s
Generalized linear	69.30%	30.70%	69.80%	12 s
Fast Large Margin	69.30%	30.70%	69.30%	12 s
Deep Learning	76.40%	23.60%	74.60%	14 s
Decision Tree Model	91.00%	9.00%	89.30%	8 s
Random Forest	90%	10%	89.40%	1 min 17 s
Gradient Booster Trees	91.60%	8.40%	91.10%	34 s
Support Vector Machine	69.30%	30.70%	69.30%	33 s

จากการวิเคราะห์ผลลัพธ์ที่ได้ จากการรันตัวแบบการพยากรณ์ทั้ง 8 ตัว ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1พบว่า ตัวแบบ Decision Tree Model มีระยะเวลาในการรันข้อมูล (Total Time) ดีที่สุดในโดยมีค่า total time เท่ากับ 8 s และในส่วน ของความถูกต้องของพยากรณ์ (Accuracy) , ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) และ ค่าความแม่นยำ (Precision) พบว่า ตัวแบบ Gradient Booster Trees มีความเหมาะสมมากที่สุดโดย ค่าAccuracy มีค่าเท่ากับ 91.60% ,ค่า Classification error มีค่าเท่ากับ 8.4 % ค่าความแม่นยำ (Precision) มีค่าเท่ากับ 91.10% จากจุดประสงค์งานวิจัยนี้ต้องการความแม่นยำของการพยากรณ์เป็นหลักจึงตัดสินใจจากความแม่นยำของชุดข้อมูล ดังนั้นตัวแบบการพยากรณ์ที่เหมาะสมกับข้อมูลมิเตอร์ตัวที่ 1 คือGradient Booster Trees เพราะ มีค่า Accuracy และ Precision มากที่สุดและมีค่า Classification error น้อยที่สุด

Gradient Booster Trees จากทฤษฎีข้อที่ 2.3.5 เป็นเทคนิคที่เรียนรู้ข้อมูลจากการถดถอย (Regression) และการจำแนกประเภท (Classification) จึงเหมาะกับชุดข้อมูลที่จัดให้มีการเรียนรู้ถดถอยจากขั้นตอนการสร้างตัวแบบ (Model) หัวข้อที่ (3.3.4) แบ่งชุดข้อมูลที่ไว้ในการเรียนรู้กับส่วนที่ไว้ใช้พยากรณ์ในอัตราส่วน 60 : 40 ใช้ชุดข้อมูล 60% นั้นไว้สำหรับการเรียนรู้ชุดข้อมูลย้อนหลัง ส่วน ข้อมูลอีก 40% นั้นไว้สำหรับการพยากรณ์ เนื่องจากตัวแบบจำลองจะสร้างพื้นฐานแตกแขนงคล้ายๆกับ Decision tree แต่จะการปรับปรุงประสิทธิภาพโดยการสุ่มสร้าง Decision tree หลายร้อยแบบจำลอง ทำซ้ำ และประเมินผลแต่ละแบบจำลองจนกว่า จะได้Decision tree ที่สมบูรณ์ที่สุด จึงทำให้ความถูกต้องของพยากรณ์ (Accuracy) ของค่าที่ได้จากการพยากรณ์

4.1.2 ผลลัพธ์ของการนำชุดข้อมูลไปเปรียบเทียบค่าความคลาดเคลื่อนกับข้อมูลจริงที่ได้เก็บข้อมูลมาชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1


จากชุดข้อมูลที่ได้จากการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 ของตัวแบบการพยากรณ์ที่ได้ทำการเลือกตัวแบบไว้ พบว่าผลลัพธ์ในการเทียบชุดข้อมูลพยากรณ์ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 นั้นเปรียบเทียบ ข้อมูลพยากรณ์ กับ ตัวชุดข้อมูลจริง ต่อช่วงระยะเวลารายชั่วโมง จำนวนทั้งหมด 869 ชั่วโมง จากทฤษฎีที่หัวข้อที่ (2.3.9) ชุดข้อมูลที่ได้จากการพยากรณ์จะต้องมีการวัดค่าความผิดพลาดเพื่อที่จะตรวจสอบผลการพยากรณ์เกินจริง (Over forecast) และค่าพยากรณ์ที่ต่ำกว่าความเป็นจริง (Under forecast) และเพื่อง่ายต่อการวิเคราะห์ที่ได้ง่ายจึงใช้วิธีการวัดความผิดพลาดเป็นเปอร์เซ็นต์ มาพิจารณาโดยที่ถ้ามีค่า MAPE น้อยจะมีความถูกต้องมากที่สุด

การวิเคราะห์ชุดการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 ที่จากพยากรณ์จากปริมาณการใช้ไฟฟ้า (kW) ในหนึ่งชั่วโมง พบว่าชุดข้อมูลตัวแบบพยากรณ์ Gradient Booster Trees มีค่า MAPE น้อยที่สุดจากตัวแบบทั้งหมดดังตารางที่ 4.2

ตารางที่ 4.2 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE) ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

model	MDB1
Naive Bayes	40.70%
Generalized linear	50.70%
Fast Large Margin	40.70%
Deep Learning	29.60%
Decision Tree Model	11.00%
Random Forest	10%
Gradient Booster Trees	7.40%
Support Vector Machine	40.70%

จากตารางที่ 4.2 พบว่ารูปแบบการพยากรณ์ที่เหมาะสมกับการพยากรณ์ข้อมูลการใช้ไฟฟ้าของมิเตอร์ตัวที่ 1 คือ ตัวแบบ Gradient Booster Trees เพราะมีค่าประสิทธิภาพจากตัวแบบมีความเหมาะสมมากที่สุดโดย ค่าAccuracy มีค่าเท่ากับ 91.60% ,ค่า Classification error มีค่าเท่ากับ 8.4 % ค่าความแม่นยำ (Precision) มีค่าเท่ากับ 91.10% และมีค่า ความคลาดเคลื่อนจากการเปรียบเทียบค่าความคลาดเคลื่อนสมบูรณ์ (MAPE) น้อยที่สุด มีค่าเท่ากับ 7.40 %



ภาพที่ 4.9 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 1 กับ ชุดข้อมูลปริมาณการใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่1

4.1.3 ผลลัพธ์ของการทำพยากรณ์ปริมาณการใช้พลังงานของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

เมื่อเลือกตัวแบบการพยากรณ์ที่เหมาะสมกับ ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 คือตัวแบบ Gradient Booster Trees ต่อมาก็จะนำข้อมูลมาพยากรณ์ ตามที่ได้เลือกไว้ จากการเรียนรู้ข้อมูลย้อนหลังจากชุดข้อมูล 40 เปอร์เซ็นต์ ที่ได้ทำการพยากรณ์ โดยชุดข้อมูลที่ พยากรณ์นั้นจะมีจำนวนที่ได้ 869 ชั่วโมงที่ได้ออกมา ซึ่งเมื่อนำมาคิดเป็นจำนวนวันจะได้ทั้งหมด 36 วัน หรือ 1 เดือน 5 วัน เมื่อข้อมูลพยากรณ์ที่ได้ออกมาแต่ละ มิเตอร์ จะทำการนำข้อมูลพยากรณ์ออกมาในรูปแบบ Excel ตามภาพตารางด้านล่างนี้ ซึ่งแสดง ปริมาณการใช้พลังงานไฟฟ้ามีหน่วยเป็น กิโลวัตต์ ต่อรายชั่วโมง (kW)


ตารางที่ 4.3 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน 24 ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้า ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1

hour	Prediction MDB1 (kw)
1	4.648069143
2	4.595665693
3	4.438891887
4	8.37056548
5	117.6951155
6	310.1038784
7	212.3453982
8	117.1780898
9	53.46464522
10	4.07347575
11	4.065346379
12	7.383857742
13	7.540631548
14	20.32523681
15	74.16481207
16	337.1259295
17	351.8027489
18	352.5293388
19	301.3936079
20	87.34011953
21	34.04086764
22	9.885034235
23	10.1569108
24	8.836338554

4.2 ชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 2

4.2.1 ผลของการเปรียบเทียบแบบจำลองการทำนายปริมาณการใช้พลังที่เหมาะสมกับชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 2

จากการสร้างตัวแบบทดสอบเปรียบเทียบประสิทธิภาพของข้อมูลจะพบได้ว่า ชุดข้อมูลที่ทางโปรแกรมได้ทำการรันตัวแบบหลายๆตัวพร้อมกันนั้นก็จะมี Naive Bayes, Generalized linear Model , Fast Large Margin , Deep Learning , Decision Tree , Random Forest , Gradient Booster Trees, Support Vector Machine และทำการเลือก classification Error ที่มีเปอร์เซ็นต์ความผิดพลาดจากการทำนายชุดข้อมูลน้อยที่สุด ดังภาพด้านล่างนี้ดังนี้

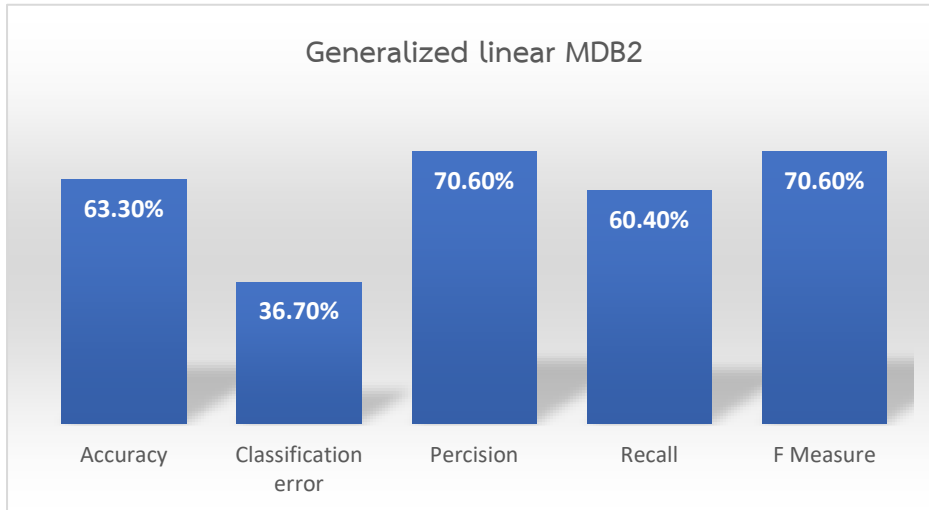


ภาพที่ 4.10 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Naive Bayes จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูลหัวข้อที่ 2.3.8 เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.12


มีค่าที่สำคัญต่อการตัดสินใจในการเลือกตัวแบบจำลองไปพยากรณ์ นั้นมีทั้งหมด 4 ค่าในการพิจารณา ได้แก่ ความถูกต้องของพยากรณ์ (Accuracy),ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) ค่าความแม่นยำ(Precision) และ ค่าระลึก (Recall)

ผลของค่าประสิทธิภาพ (Performance)ค่าAccuracy มีค่าเท่ากับ $73.6\% \pm 1.1\%$,ค่า Classification error มีค่าเท่ากับ $26.4\% \pm 1.1\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $73.6\% \pm 1.1\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$




ภาพที่ 4.11 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Generalized linear Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.13 ผลของค่าประสิทธิภาพ (Performance)ค่าAccuracy มีค่าเท่ากับ $63.3\% \pm 2.6\%$,ค่า Classification error มีค่าเท่ากับ $36.7\% \pm 2.6\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $85.1\% \pm 2.6\%$ และค่า Recall มีค่าเท่ากับ $60.4\% \pm 2.6\%$




ภาพที่ 4.12 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Fast Large Margin Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.14 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $65.1\% \pm 3.0\%$,ค่า Classification error มีค่าเท่ากับ $34.9\% \pm 3.0\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $71.7\% \pm 1.9\%$ และค่า Recall มีค่าเท่ากับ $86.9\% \pm 2.7\%$




ภาพที่ 4.13 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Deep Learning Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.3 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $79.3\% \pm 1.5\%$, ค่า Classification error มีค่าเท่ากับ $20.7\% \pm 1.5\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $78.4\% \pm 1.5\%$ และค่า Recall มีค่าเท่ากับ $99.1\% \pm 0.9\%$




ภาพที่ 4.14 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Decision Tree Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.16 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $93.4\% \pm 0.9\%$,ค่า Classification error มีค่าเท่ากับ $6.6\% \pm 0.9\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $97.8\% \pm 1.3\%$ และค่า Recall มีค่าเท่ากับ $93.3\% \pm 1.3\%$



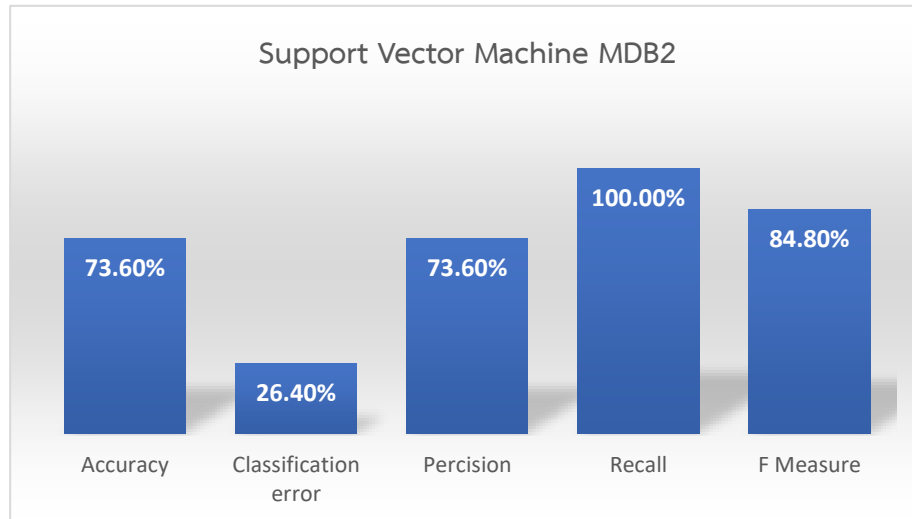
ภาพที่ 4.15 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Random Forest Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูลหัวข้อที่ 2.3.8 เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.16 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $92.5\% \pm 2.0\%$,ค่า Classification error มีค่าเท่ากับ $7.5\% \pm 2.0\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $92.8\% \pm 2.4\%$ และค่า Recall มีค่าเท่ากับ $97.4\% \pm 1.0\%$



ภาพที่ 4.16 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Gradient Booster Trees Model จากการทดสอบการทำงานของตัวแบบพยากรณ์พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.18 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $95.8\% \pm 1.2\%$,ค่า Classification error มีค่าเท่ากับ $4.2\% \pm 1.2\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $97.2\% \pm 2.1\%$ และค่า Recall มีค่าเท่ากับ $97.2\% \pm 0.6\%$



ภาพที่ 4.17 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

ตัวแบบ Support Vector Machine Model จากการทดสอบการทำงานของตัวแบบพยากรณ์พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.19 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $73.6\% \pm 1.1\%$,ค่า Classification error มีค่าเท่ากับ $26.4\% \pm 1.1\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $73.6\% \pm 1.1\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$

จากการรันตัวแบบทั้ง 8 ตัวแบบที่ทางโปรแกรมได้ทำการคัดเลือกความเหมาะสมให้กับชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 โดยตัวแบบที่ทำการแสดงประสิทธิผลนั้นพบว่า มีผลลัพธ์ค่าความสัมพันธ์ต่างๆ การตัดสินใจเลือกตัวแบบนั้นวัดค่าประสิทธิภาพหลักๆ จากค่าความเหมาะสมของการจัดกลุ่ม นำมาจัดตารางได้ดังนี้

ตารางที่ 4.4 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 2

model	Accuracy	Classification error	Precision	total Time
Naive Bayes	73.60%	26.40%	73.60%	11 s
Generalized linear	63.30%	36.70%	70.60%	12 s
Fast Large Margin	65.10%	34.90%	71.70%	11 s
Deep Learning	79.30%	20.70%	78.40%	14 s
Decision Tree Model	93.40%	6.60%	97.80%	8 s
Random Forest	92.5%	7.50%	92.80%	1 min 40 s
Gradient Booster Trees	95.80%	4.20%	97.20%	33 s
Support Vector Machine	73.60%	26.40%	73.60%	30 s

จากการวิเคราะห์ผลลัพธ์ที่ได้ จากการรันตัวแบบการพยากรณ์ทั้ง 8 ตัว ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1พบว่า ตัวแบบ Decision Tree Model มีระยะเวลาในการรันข้อมูล (Total Time) ดีที่สุดในโดยมีค่า total time เท่ากับ 8 s และในส่วน ของความถูกต้องของพยากรณ์ (Accuracy) , ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) และ ค่าความแม่นยำ (Precision) พบว่า ตัวแบบ Gradient Booster Trees มีความเหมาะสมมากที่สุดโดย ค่าAccuracy มีค่าเท่ากับ 95.80% , ค่า Classification error มีค่าเท่ากับ 4.20% ค่าความแม่นยำ (Precision) มีค่าเท่ากับ 97.20%จากจุดประสงค์งานวิจัยนี้ต้องการความแม่นยำของการพยากรณ์เป็นหลักจึงตัดสินใจเลือกความแม่นยำของชุดข้อมูล ดังนั้นตัวแบบการพยากรณ์ที่เหมาะสมกับข้อมูลมิเตอร์ตัวที่ 1 คือGradient Booster Trees เพราะ มีค่า Accuracy และ Precision มากที่สุดและมีค่า Classification error น้อยที่สุด

Gradient Booster Trees จากทฤษฎีข้อที่ 2.3.5 เป็นเทคนิคที่เรียนรู้ข้อมูลจากการถดถอย (Regression) และการจำแนกประเภท (Classification) จึงเหมาะกับชุดข้อมูลที่จัดให้มีการเรียนรู้ถดถอยจากขั้นตอนการสร้างตัวแบบ (Model) หัวข้อที่ (3.3.4) แบ่งชุดข้อมูลที่ไว้ในการเรียนรู้กับส่วนที่ไว้ใช้พยากรณ์ในอัตราส่วน 60 : 40 ใช้ชุดข้อมูล 60% นั้นไว้สำหรับการเรียนรู้ชุดข้อมูลย้อนหลัง ส่วน ข้อมูลอีก 40% นั้นไว้สำหรับการพยากรณ์ เนื่องจากตัวแบบจำลองจะสร้างพื้นฐานแตกแขนงคล้ายๆกับ Decision tree แต่จะการปรับปรุงประสิทธิภาพโดยการสุ่มสร้าง Decision tree หลายร้อยแบบจำลอง ทำซ้ำ และประเมินผลแต่ละแบบจำลองจนกว่า จะได้Decision tree ที่สมบูรณ์ที่สุด จึงทำให้ความถูกต้องของพยากรณ์ (Accuracy) ของค่าที่ได้จากการพยากรณ์

4.2.2 ผลลัพธ์ของการนำชุดข้อมูลไปเปรียบเทียบค่าความคลาดเคลื่อนกับข้อมูลจริงที่ได้เก็บข้อมูลมาชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2


จากชุดข้อมูลที่ได้จากการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2 ของตัวแบบการพยากรณ์ที่ได้ทำการเลือกตัวแบบไว้ พบว่าผลลัพธ์ในการเทียบชุดข้อมูลพยากรณ์ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2 นั้นเปรียบเทียบ ข้อมูลพยากรณ์ กับ ตัวชุดข้อมูลจริง ต่อช่วงระยะเวลารายชั่วโมง จำนวนทั้งหมด 869 ชั่วโมง จากทฤษฎีที่หัวข้อที่ (2.3.9) ชุดข้อมูลที่ได้จากการพยากรณ์จะต้องมีการวัดค่าความผิดพลาดเพื่อที่จะตรวจสอบผลการพยากรณ์เกินจริง (Over forecast) และค่าพยากรณ์ที่ต่ำกว่าความเป็นจริง (Under forecast) และเพื่อง่ายต่อการวิเคราะห์ที่ได้ง่ายจึงใช้วิธีการวัดความผิดพลาดเป็นเปอร์เซ็นต์ มาพิจารณาโดยที่ถ้ามีค่า MAPE น้อยจะมีความถูกต้องมากที่สุด

การวิเคราะห์ชุดการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 ที่จากพยากรณ์จากปริมาณการใช้ไฟฟ้า (kW) ในหนึ่งชั่วโมง พบว่าชุดข้อมูลตัวแบบพยากรณ์ Gradient Booster Trees มีค่า MAPE น้อยที่สุดจากตัวแบบทั้งหมดดังตารางที่ 4.5

ตารางที่ 4.5 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE) ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

model	MDB2
Naive Bayes	46.40%
Generalized linear	36.70%
Fast Large Margin	35.90%
Deep Learning	30.70%
Decision Tree Model	6.60%
Random Forest	7.50%
Gradient Booster Trees	5.20%
Support Vector Machine	46.40%

จากตารางที่ 4.5 พบว่ารูปแบบการพยากรณ์ที่เหมาะสมกับการพยากรณ์ข้อมูลการใช้ไฟฟ้าของมิเตอร์ตัวที่ 2 คือ ตัวแบบ Gradient Booster Trees เพราะมีค่าประสิทธิภาพจากตัวแบบมีความเหมาะสมมากที่สุดโดย ค่าAccuracy มีค่าเท่ากับ 95.80% ,ค่า Classification error มีค่าเท่ากับ 4.20% ค่าความแม่นยำ (Precision) มีค่าเท่ากับ 97.20% และมีค่า ความคลาดเคลื่อนจากการเปรียบเทียบค่าความคลาดเคลื่อนสมบูรณ์ (MAPE) น้อยที่สุด มีค่าเท่ากับ 5.20%



ภาพที่ 4.18 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 2 กับ ชุดข้อมูลปริมาณการใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่ 2

4.2.3 ผลลัพธ์ของการทำพยากรณ์ปริมาณการใช้พลังงานของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

เมื่อเลือกตัวแบบการพยากรณ์ที่เหมาะสมกับ ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2 คือตัวแบบ Gradient Booster Trees ต่อมาก็จะนำข้อมูลมาพยากรณ์ ตามที่ได้เลือกไว้ จากการเรียนรู้ข้อมูลย้อนหลังจากชุดข้อมูล 40 เปอร์เซ็นต์ ที่ได้ทำการพยากรณ์ โดยชุดข้อมูลที่ พยากรณ์นั้นจะมีจำนวนที่ได้ 869 ชั่วโมงที่ได้ออกมา ซึ่งเมื่อนำมาคิดเป็นจำนวนวันจะได้ทั้งหมด 36 วัน หรือ 1 เดือน 5 วัน เมื่อข้อมูลพยากรณ์ที่ได้ออกมาแต่ละ มิเตอร์ จะทำการนำข้อมูลพยากรณ์ออกมาในรูแบบ Excel ตามภาพตารางด้านล่างนี้ ซึ่งแสดง ปริมาณการใช้พลังงานไฟฟ้ามีหน่วยเป็น กิโลวัตต์ ต่อรายชั่วโมง (kW)


ตารางที่ 4.6 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน 24 ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้า ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

hour	prediction MDB2 (kw)
1	36.28431215
2	36.34730711
3	37.81274089
4	43.85746765
5	163.5752331
6	302.7508706
7	245.8357072
8	163.4395363
9	121.171971
10	44.00920731
11	43.61514418
12	36.64089252
13	37.86893721
14	43.90069412
15	83.29298351
16	316.1536531
17	322.8917985
18	325.1218312
19	295.1645457
20	141.8280529
21	74.66854898
22	58.5890832
23	58.19502006
24	63.57078657

4.3 ชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 3

4.3.1 ผลของการเปรียบเทียบแบบจำลองการทำนายปริมาณการใช้พลังที่เหมาะสมกับชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 3


จากการสร้างตัวแบบทดสอบเปรียบเทียบประสิทธิภาพของข้อมูลจะพบได้ว่า ชุดข้อมูลที่ทางโปรแกรมได้ทำการรันตัวแบบหลายๆตัวพร้อมกันนั้นก็จะมี Naive Bayes, Generalized linear Model , Fast Large Margin , Deep Learning , Decision Tree , Random Forest , Gradient Booster Trees, Support Vector Machine และทำการเลือก classification Error ที่มีเปอร์เซ็นต์ความผิดพลาดจากการทำนายชุดข้อมูลน้อยที่สุด



ภาพที่ 4.19 แสดง performances ของตัวแบบ Naive Bayes ของชุดข้อมูลมีเตอร์ไฟฟ้าตัวที่ 3


ตัวแบบ Naive Bayes จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูลหัวข้อที่ 2.3.8 เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.22 มีค่าที่สำคัญต่อการตัดสินใจในการเลือกตัวแบบจำลองไปพยากรณ์ นั้นมีทั้งหมด 4 ค่าในการพิจารณา ได้แก่ ความถูกต้องของพยากรณ์ (Accuracy) , ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) ค่าความแม่นยำ (Precision) และ ค่าระลึก (Recall)

ผลของค่าประสิทธิภาพ (Performance)ค่าAccuracy มีค่าเท่ากับ $95.2\% \pm 1.3\%$,ค่า Classification error มีค่าเท่ากับ $4.8\% \pm 1.3\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $95.2\% \pm 1.3\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$




ภาพที่ 4.20 แสดง performances ของตัวแบบ Generalized linear Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

ตัวแบบ Generalized linear Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.23 ผลของค่าประสิทธิภาพ (Performance) ค่า Accuracy มีค่าเท่ากับ $95.3\% \pm 1.6\%$,ค่า Classification error มีค่าเท่ากับ $4.7\% \pm 1.6\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $96.2\% \pm 1.3\%$ และค่า Recall มีค่าเท่ากับ $99.0\% \pm 0.8\%$




ภาพที่ 4.21 แสดง performances ของตัวแบบ Fast Large Margin Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

ตัวแบบ Fast Large Margin Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.24 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $93.9\% \pm 0.7\%$,ค่า Classification error มีค่าเท่ากับ $6.1\% \pm 0.7\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $97.2\% \pm 1.0\%$ และค่า Recall มีค่าเท่ากับ $96.3\% \pm 0.7\%$




ภาพที่ 4.22 แสดง performances ของตัวแบบ Deep Learning Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

ตัวแบบ Deep Learning Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่า ประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.25 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $97.3\% \pm 0.9\%$,ค่า Classification error มีค่าเท่ากับ $2.7\% \pm 0.9\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $98.3\% \pm 0.8\%$ และค่า Recall มีค่าเท่ากับ $98.8\% \pm 1.3\%$



ภาพที่ 4.23 แสดง performances ของตัวแบบ Decision Tree Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3


ตัวแบบ Decision Tree Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.26 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $96.1\% \pm 0.4\%$,ค่า Classification error มีค่าเท่ากับ $3.9\% \pm 0.4\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $99.7\% \pm 0.5\%$ และค่า Recall มีค่าเท่ากับ $93.3\% \pm 0.5\%$



ภาพที่ 4.24 แสดง performances ของตัวแบบ Random Forest Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3


ตัวแบบ Random Forest Model จากการทดสอบการทำงานของตัวแบบพยากรณ์ พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.27 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $98.9\% \pm 0.4\%$,ค่า Classification

error มีค่าเท่ากับ $1.1\% \pm 0.4\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $99.0\% \pm 0.5\%$ และค่า Recall มีค่าเท่ากับ $99.8\% \pm 0.2\%$



ภาพที่ 4.25 แสดง performances ของตัวแบบ Gradient Booster Trees Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

ตัวแบบ Gradient Booster Trees Model จากการทดสอบการทำงานของตัวแบบพยากรณ์พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.28 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $97.3\% \pm 0.7\%$,ค่า Classification error มีค่าเท่ากับ $2.7\% \pm 0.7\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $98.8\% \pm 0.8\%$ และค่า Recall มีค่าเท่ากับ $98.3\% \pm 0.0\%$



ภาพที่ 4.26 แสดง performances ของตัวแบบ Support Vector Machine Model ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

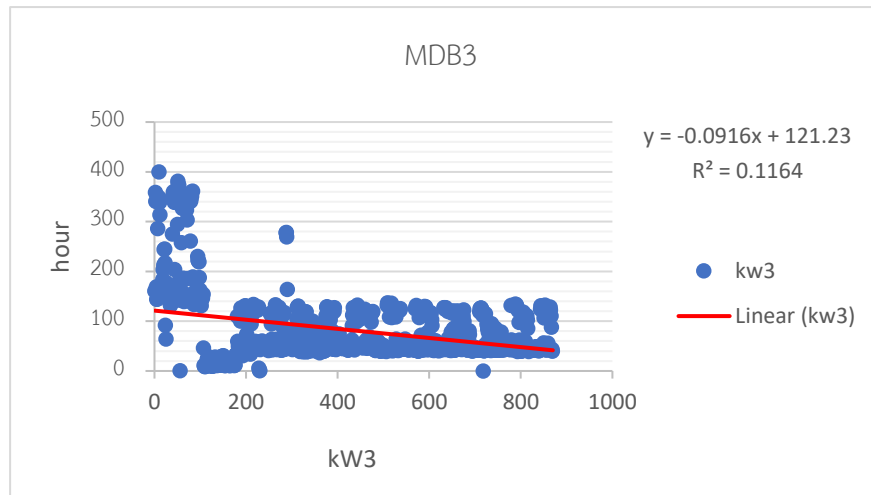
ตัวแบบ Support Vector Machine Model จากการทดสอบการทำงานของตัวแบบพยากรณ์พบว่าประสิทธิภาพของโมเดลแบบจำลองตามทฤษฎีข้อมูล เพื่อแสดงจุดเด่นจุดด้อยของตัวแบบจำลอง ดังภาพที่ 4.29 ผลของค่าประสิทธิภาพ (Performance) ค่าAccuracy มีค่าเท่ากับ $95.2\% \pm 1.3\%$,ค่า Classification error มีค่าเท่ากับ $4.8\% \pm 1.3\%$ ค่าความแม่นยำ (Precision) มีค่าเท่ากับ $95.2\% \pm 1.3\%$ และค่า Recall มีค่าเท่ากับ $100\% \pm 0\%$

จากการรันตัวแบบทั้ง 8 ตัวแบบที่ทางโปรแกรมได้ทำการคัดเลือกความเหมาะสมให้กับชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3 โดยตัวแบบที่ทำการแสดงประสิทธิภาพนั้นพบว่าผลลัพธ์ค่าความสัมพันธ์ต่างๆ การตัดสินใจเลือกตัวแบบนั้นวัดค่าประสิทธิภาพหลักๆ จากค่าความเหมาะสมของการจัดกลุ่ม นำมาจัดตารางได้ดังนี้

ตารางที่ 4.7 แสดงผลลัพธ์ในการเปรียบเทียบค่าประสิทธิภาพต่างๆจากการรันตัวแบบทั้งหมดของชุดข้อมูล มิเตอร์ไฟฟ้าตัวที่ 3

Model	Accuracy	Classification error	Precision	total Time
Naive Bayes	95.60%	4.80%	95.20%	8 s
Generalized linear	95.30%	4.70%	96.20%	7 s
Fast Large Margin	93.90%	6.10%	97.20%	9 s
Deep Learning	97.30%	2.70%	98.30%	12 s
Decision Tree Model	96.10%	3.90%	96.70%	7 s
Random Forest	98.9%	1.1%	99.0%	44 s
Gradient Booster Trees	96.90%	2.70%	98.80%	35 s
Support Vector Machine	95.20%	4.80%	95.20%	16 s

จากการวิเคราะห์ผลลัพธ์ที่ได้ จากการรันตัวแบบการพยากรณ์ทั้ง 8 ตัว ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3พบว่า ตัวแบบ Generalized linear และ Decision Tree Model มีระยะเวลาในการรันข้อมูล (Total Time) ดีที่สุดในโดยมีค่า total time เท่ากับ 7 s และในส่วน ของความถูกต้องของพยากรณ์ (Accuracy) , ค่าความผิดพลาดของการจัดกลุ่ม(Classification error) และ ค่าความแม่นยำ (Precision) พบว่า ตัวแบบทั้งหมดมีค่าประสิทธิภาพที่มีความสมบูรณ์ใกล้เคียงกัน เนื่องมาจากชุดข้อมูลที่มีค่าปริมาณของชุดข้อมูลเกาะกลุ่มกันดังภาพที่(4.30) โดยที่ตัวแบบ Random Forest มีความเหมาะสมมากที่สุดโดย ค่า Accuracy มีค่าเท่ากับ 95.80% , ค่า Classification error มีค่าเท่ากับ 4.20% ค่าความแม่นยำ (Precision) มีค่าเท่ากับ 97.20% จากจุดประสงค์ของการศึกษานี้ต้องการความแม่นยำของการพยากรณ์เป็นหลักจึงตัดสินใจจากความแม่นยำของชุดข้อมูล ดังนั้นตัวแบบการพยากรณ์ที่เหมาะสมกับข้อมูลมิเตอร์ตัวที่ 3 คือ Random Forest เพราะ มีค่า Accuracy และ Precision มากที่สุดและมีค่า Classification error น้อยที่สุด



ภาพที่ 4.27 แสดงชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่3ที่นำมาพยากรณ์

Random Forest จากทฤษฎีข้อที่ 2.3.6 เป็นเทคนิคที่เรียนรู้ข้อมูลจากการถดถอย (Regression) และการจำแนกประเภท (Classification) จึงเหมาะกับชุดข้อมูลที่จัดให้มีการเรียนรู้ถดถอยจากขั้นตอนการสร้างตัวแบบ (Model) หัวข้อที่ (3.3.4) แบ่งชุดข้อมูลที่ไว้ในการเรียนรู้กับส่วนที่ไว้ใช้พยากรณ์ในอัตราส่วน 60 : 40 ใช้ชุดข้อมูล 60% นั้นไว้สำหรับการเรียนรู้ชุดข้อมูลย้อนหลัง ส่วน ข้อมูลอีก 40% นั้นไว้สำหรับการพยากรณ์ เนื่องจากตัวแบบจำลองจะสร้างพื้นฐานแตกต่างกันคล้ายๆกับ Decision tree โดยให้แต่ละแบบจำลองได้รับชุดข้อมูลย่อยที่ไม่เหมือนกันซึ่งข้อมูลนี้เป็นส่วนหนึ่งของชุดข้อมูลทั้งหมด แล้วทำการพยากรณ์ ข้อมูลในแต่ละ Decision Tree และคำนวณผลด้วยการ vote ที่ถูกเลือกโดย Decision Tree มากที่สุด

4.3.2 ผลลัพธ์ของการนำชุดข้อมูลไปเปรียบเทียบกับค่าความคลาดเคลื่อนกับข้อมูลจริงที่ได้เก็บข้อมูลมาชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2


จากชุดข้อมูลที่ได้จากการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2 ของตัวแบบการพยากรณ์ที่ได้ทำการเลือกตัวแบบไว้ พบว่าผลลัพธ์ในการเทียบชุดข้อมูลพยากรณ์ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2 นั้นเปรียบเทียบ ข้อมูลพยากรณ์ กับ ตัวชุดข้อมูลจริง ต่อช่วงระยะเวลารายชั่วโมง จำนวนทั้งหมด 869 ชั่วโมง จากทฤษฎีที่หัวข้อที่ (2.3.9) ชุดข้อมูลที่ได้จากการพยากรณ์จะต้องมีการวัดค่าความผิดพลาดเพื่อที่จะตรวจสอบผลการพยากรณ์เกินจริง (Over forecast) และค่าพยากรณ์ที่ต่ำกว่าความเป็นจริง (Under forecast) และเพื่อง่ายต่อการวิเคราะห์ที่ได้ง่ายจึงใช้วิธีการวัดความผิดพลาดเป็นเปอร์เซ็นต์ มาพิจารณาโดยที่ถ้ามีค่า MAPE น้อยจะมีความถูกต้องมากที่สุด

การวิเคราะห์ชุดการพยากรณ์ของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 1 ที่จากพยากรณ์จากปริมาณการใช้ไฟฟ้า (kW) ในหนึ่งชั่วโมง พบว่าชุดข้อมูลตัวแบบพยากรณ์ Gradient Booster Trees มีค่า MAPE น้อยที่สุดจากตัวแบบทั้งหมดดังตารางที่ 4.8

ตารางที่ 4.8 ตารางแสดงผลการหาค่าความคลาดเคลื่อนเปอร์เซ็นต์ (MAPE)

Model	MDB3
Naive Bayes	5.80%
Generalized linear	5.70%
Fast Large Margin	6.10%
Deep Learning	2.70%
Decision Tree Model	3.90%
Random Forest	1.15%
Gradient Booster Trees	2.70%
Support Vector Machine	4.80%

จากตารางที่ 4.8 พบว่ารูปแบบการพยากรณ์ที่เหมาะสมกับการพยากรณ์ข้อมูลการใช้ไฟฟ้าของมิเตอร์ตัวที่ 3 คือ ตัวแบบ Random Forest เพราะมีค่าประสิทธิภาพจากตัวแบบมีความเหมาะสมมากที่สุด โดย ค่าAccuracy มีค่าเท่ากับ 98.9% ,ค่า Classification error มีค่าเท่ากับ 1.1% ค่าความแม่นยำ (Precision) มีเท่ากับ 99.0% และมีค่า ความคลาดเคลื่อนจากการเปรียบเทียบค่าความคลาดเคลื่อนสมบูรณ์ (MAPE) น้อยที่สุด มีค่าเท่ากับ 1.15%



ภาพที่ 4.28 แสดงแผนภูมิเปรียบเทียบ ชุดข้อมูลพยากรณ์มิเตอร์ไฟฟ้าตัวที่ 3 กับ ชุดข้อมูลปริมาณการใช้ไฟฟ้าของมิเตอร์ไฟฟ้าตัวที่ 3

4.3.3 ผลลัพธ์ของการทำพยากรณ์ปริมาณการใช้พลังงานของชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 2

เมื่อเลือกตัวแบบการพยากรณ์ที่เหมาะสมกับ ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3 คือตัวแบบ Gradient Booster Trees ต่อมาก็จะนำข้อมูลมาพยากรณ์ ตามที่ได้เลือกไว้ จากการเรียนรู้ข้อมูลย้อนหลังจากชุดข้อมูล 40 เปอร์เซ็นต์ ที่ได้ทำการพยากรณ์ โดยชุดข้อมูลที่ พยากรณ์นั้นจะมีจำนวนที่ได้ 869 ชั่วโมงที่ได้ออกมา ซึ่งเมื่อนำมาคิดเป็นจำนวนวันจะได้ทั้งหมด 36 วัน หรือ 1 เดือน 5 วัน เมื่อข้อมูลพยากรณ์ที่ได้ออกมาแต่ละ มิเตอร์ จะทำการนำข้อมูลพยากรณ์ออกมาในรูปแบบ Excel ตามภาพตารางด้านล่างนี้ ซึ่งแสดง ปริมาณการใช้ พลังงานไฟฟ้ามีหน่วยเป็น กิโลวัตต์ ต่อรายชั่วโมง (kW)

ตารางที่ 4.9 ตารางแสดง ตัวอย่างชุดข้อมูลที่ได้จากการพยากรณ์ใน 24 ชั่วโมง ปริมาณการใช้พลังงานไฟฟ้า ชุดข้อมูลมิเตอร์ไฟฟ้าตัวที่ 3

hour	prediction MDB3 (kw)
1	211.6456678
2	355.4511072
3	354.8512766
4	163.8649914
5	141.9568481
6	139.4429737
7	214.05437
8	346.6069182
9	362.8894922
10	382.2657146
11	361.0964663
12	284.3876066
13	172.9579756
14	158.4927849
15	152.4371013
16	149.4021488
17	147.0235274
18	175.7503064
19	215.8625088
20	225.7865428

ตารางที่ 4.9 (ต่อ)

hour	prediction MDB3 (kw)
21	227.7418026
22	237.8383985
23	239.2364987
24	222.958753

บทที่ 5

สรุปผลงานวิจัย และข้อเสนอแนะ

5.1 สรุปผลการศึกษา

จากการศึกษาการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าภายในอาคารด้วยวิธีการทำเหมืองข้อมูล ได้ทำการศึกษาอาคารสำนักงานขนาดกลางแห่งหนึ่ง ที่มีปัญหาทางด้านการจัดการพลังงานที่มีแนวโน้มในการใช้พลังงานที่มีความไม่แน่นอน ก่อให้เกิดปัญหาทางด้านการจัดการพลังงานและใช้จ่ายที่สูงจากการจัดการพลังงานที่ไม่แน่นอนขึ้นตามมา จึงได้มีการนำเทคโนโลยีในการเก็บข้อมูลปริมาณการใช้พลังงานไฟฟ้าภายในอาคารสำนักงาน และนำข้อมูลมาพยากรณ์ปริมาณการใช้ไฟฟ้าในเดือนถัดไป เพื่อแสดงให้เห็นทราบถึงปริมาณการใช้พลังงานไฟฟ้าและเห็นพฤติกรรมการใช้ไฟฟ้าในแต่ละชั่วโมงในเดือนถัดไปได้ โดยใช้ข้อมูลความต้องการไฟฟ้าในแต่ละชั่วโมง ที่เก็บข้อมูลมาจากระบบ SCADA Software ผ่านโปรแกรม xView ซึ่งข้อมูลความต้องการทางไฟฟ้าภายในสำนักงานประกอบด้วย ข้อมูลของมิเตอร์ไฟฟ้า จำนวนทั้งหมด 3 ตัว และจากนั้นนำข้อมูลที่ได้มาพยากรณ์ปริมาณ ด้วยใช้วิธีการทำเหมืองข้อมูลโดยใช้เครื่องมือโปรแกรมที่ชื่อว่า RapidMiner โดยจะแบ่งชุดข้อมูลที่จะนำมาใช้พยากรณ์แบ่งออกเป็น 3 ชุด ตามมิเตอร์ไฟฟ้าตั้งข้อมูลทีกล่าวไว้ข้างต้น โดยจะใช้ชื่อชุดข้อมูล MDB1, MDB2 และ MDB3 ตามลำดับ โดยตัวแปรที่จะนำมาใช้ในการเรียนรู้ข้อมูลมี 4 ตัวแปร ได้แก่ เวลา (Date Time), ความต้องการพลังงานไฟฟ้า (kW), ค่าการใช้พลังงานไฟฟ้าทั้งหมด (kWh) และ ค่าความต้องการไฟฟ้าสูงสุด (Max Demand) เพื่อที่จะสร้างตัวแบบการพยากรณ์ที่มีความเหมาะสมกับชุดข้อมูลมากที่สุด โดยคัดเลือกจากตัวแบบทั้ง 8 ตัวแบบที่ทางโปรแกรมได้ประมวลผลออกมา ได้แก่ Naive Bayes, Generalized linear Model Fast Large Margin, Deep Learning, Decision Tree, Random Forest, Gradient Booster Trees และ Support Vector Machine และหาความผิดพลาดจากการพยากรณ์

และผลจากการศึกษาการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าภายในอาคารสำนักงาน โดยการศึกษาครั้งนี้ได้เลือกตัวแบบการพยากรณ์เป็นจำนวน 8 ตัวแบบ โดยในการเลือกตัวแบบพยากรณ์ที่เหมาะสมนั้นจะวัดจากค่าประสิทธิภาพที่สำคัญทั้งหมด 3 ตัว คือ Accuracy, Classification error, Precision และ ความผิดพลาดเป็นเปอร์เซ็นต์ (Mean Absolute Error :MAPE) ผลลัพธ์ของการหาตัวแบบพยากรณ์ที่เหมาะสมกับชุดข้อมูลของแต่ละมิเตอร์ไฟฟ้า ดังตารางที่ 5.1

ตารางที่ 5.1 แสดงการเปรียบเทียบค่า Accuracy, Precision, classification ErrorและMAPE

performants	MDB1	MDB2	MDB3
Model	Gradient Booster Trees	Gradient Booster Trees	Random Forest
Accuracy	91.60%	95.80%	98.90%
Classification error	8.40%	4.20%	1.10%
Precision	91.10%	97.20%	99.00%
MAPE	7.4%	5.20%	1.15%

ตามตารางที่ 5.1 จึงทำการสรุปได้ว่า ตัวแบบที่เหมาะสมสำหรับการพยากรณ์ที่เหมาะสมกับชุดข้อมูลแต่ละมิเตอร์ไฟฟ้าแต่ละตัวนั้นได้ข้อมูลดังนี้ มิเตอร์ไฟฟ้าตัวที่1และมิเตอร์ไฟฟ้าตัวที่2 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Gradient Booster Trees ส่วนมิเตอร์ไฟฟ้าตัวที่3 ตัวแบบการพยากรณ์ที่เหมาะสม ได้แก่ Random Forest ซึ่งการที่มีมิเตอร์ไฟฟ้าตัวที่ 3 ใช้ตัวแบบที่แตกต่างกันเพราะ ข้อมูลของมิเตอร์ไฟฟ้าตัวที่ 3 มีความเกาะกลุ่มมากกว่า มิเตอร์ไฟฟ้าตัวที่ 1 และ 2 ผลลัพธ์ของการเลือกตัวแบบการพยากรณ์เลยแตกต่างกัน

5.2 ปัญหาและอุปสรรคและข้อเสนอแนะ

5.2.1 ปัญหาและอุปสรรคจากการรวบรวมข้อมูล

เนื่องจากการรวบรวมข้อมูลของสถานที่ ที่ใช้เป็นกรณีศึกษานั้นค่อนข้างที่จะเข้มงวดและมีระยะเวลาจำกัด สืบเนื่องมาจากสัญญาของการควบคุมและจัดการระบบเก็บข้อมูลภายในตัวอาคารสำนักงาน จึงสามารถเก็บข้อมูลได้แค่ประเภท ปริมาณการใช้ไฟฟ้าเท่านั้น และ ไม่สามารถเก็บข้อมูลที่หน้าสนใจที่มีผลต่อการใช้พลังงานไฟฟ้าอื่นๆได้ เช่น ข้อมูลของการใช้อุปกรณ์ในส่วนต่างๆ ลิฟท์ เครื่องปรับอากาศ หลอดไฟ เป็นต้น ซึ่งถ้ามีข้อมูลที่เป็นตัวแปรอื่นๆ ก็จะสามารถนำมาวิเคราะห์ผลการพยากรณ์ได้

5.2.2 ข้อเสนอแนะ

(1) จากปัญหาทางด้านการเก็บข้อมูล ยังสามารถเพิ่มเติมตัวแปรที่มีผลต่อการใช้พลังงานไฟฟ้าอื่นอีกมาก เช่น การลงรายละเอียดไปยังตัวโหลด เครื่องอำนวยความสะดวก ระบบปรับอากาศ ระบบแสงสว่างของภายในตัวอาคารนั้นๆหรือ ชุดข้อมูลประเภทอื่น อุณหภูมิ จำนวนผู้ใช้อาคาร เป็นต้น หรือ เพิ่มส่วนรายละเอียดช่วงเวลาที่ถี่ขึ้น เช่น การเป็นข้อมูลเป็นนาทิจึงหา พลังงานไฟฟ้าสูงสุดในช่วงเวลา Peak (kW) เพื่อที่เกิดเป็นองค์ความรู้ใหม่ที่จะนำมาใช้ในการจัดการพลังงาน ทั้งนี้ต้องศึกษาถึงผลกระทบของการควบคุมและการเลือกตัวแปรแต่ละตัวแปรที่เหมาะสม

(2) การสร้างตัวแบบสำหรับการพยากรณ์ปริมาณการใช้ไฟฟ้า ถูกสร้างมาจากเครื่องที่ชื่อว่า RapidMiner ซึ่งเป็นโปรแกรมที่เบื้องต้นและใช้ง่ายต่อผู้เริ่มต้นในการทำเหมืองข้อมูล อาจลองเปลี่ยนวิธีการในการพยากรณ์ที่มีความซับซ้อนมากขึ้น หรือเปลี่ยนตัวแบบพยากรณ์ไปใช้ตัวแบบที่แตกต่างกัน

(3) วิธีการสร้างตัวแบบในการพยากรณ์ปริมาณการใช้ไฟฟ้า สามารถนำไปประยุกต์ใช้ ในตัวแบบอาคารประเภทอื่นที่แตกต่างกัน เพราะอาคารแต่ละประเภทมีพฤติกรรมการใช้ไฟฟ้าในแต่ละช่วงเวลาที่แตกต่างกัน เพื่อที่จะรับรู้ปริมาณการใช้ไฟฟ้าในอนาคต และวางแผนในการจัดการปริมาณการใช้ไฟฟ้าต่อไปได้

บรรณานุกรม

บรรณานุกรม

- [1] นภััสสร สัจจรวิตร, “การประยุกต์ใช้เทคนิคอัลกอริทึมในการทำเหมืองข้อความเพื่อ วิเคราะห์ทัศนคติ ของ ผู้ใช้ที่มีต่อการเลือกซื้อโพลีแลมด้านา บน ทวิตเตอร์”, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ ,2562.
- [2] วริภัทรา เจริญกิจสุพัฒน์ และ เอกสิทธิ์ พัทธวงศ์ศักดิ์ งานวิจัยเรื่องการพยากรณ์การเกิดภัยแล้งใน ประเทศไทยด้วยวิธีการเรียนรู้ของเครื่อง A Large-Scale Drought Forecasting with Machine Learning
- [3] วุฒิพงษ์ นิลจันทร์ และ นิตติ เอี่ยมชื่น, “การคาดการณ์ปริมาณการใช้ไฟฟ้าภาคเหนือตอนบนของประเทศไทยหน่วยวิจัยเพื่อการพัฒนานวัตกรรมเชิงพื้นที่”,สาขาวิชาภูมิสารสนเทศศาสตร์,คณะเทคโนโลยีสารสนเทศและการสื่อสาร,มหาวิทยาลัยพะเยา,2562.
- [4] ธนะวัฒน์ วรรณประภา, “เทคนิคการทำเหมืองข้อมูลมาใช้ในการคัดกรองบุคคลที่มีแนวโน้ม สัมฤทธิ์ ผลสำหรับการเรียนระดับปริญญาตรี”,มหาวิทยาลัยธุรกิจบัณฑิต,2564.
- [5] คงฤทธิ์ โกมาสถิต, “วิธีการพยากรณ์อุปสงค์พลังงานไฟฟ้า (Electrical Energy Consumption) ของ ประเทศไทยในระยะยาวด้วยวิธีโครงข่ายประสาทเทียม (Artificial Neural Network)”,คณะ วิศวกรรมศาสตร์ ,จุฬาลงกรณ์มหาวิทยาลัย,2555.
- [6] อัครช บรจรังศิลป์, “การพยากรณ์การใช้พลังงานไฟฟ้าในอุตสาหกรรมขนาดใหญ่”,มหาวิทยาลัย ศิลปากร,2550.
- [7] ธนิตเชษฐ์ คำศรีสุข, “การวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าภายในบ้านสำหรับบ้าน อัจฉริยะ ด้วยวิธีการ เหมืองข้อมูล”, มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี,2562.

ภาคผนวก

ภาคผนวก ก

ชุดข้อมูลพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
1	4.648069143	36.28431215	211.6456678
2	4.595665693	36.34730711	355.4511072
3	4.438891887	37.81274089	354.8512766
4	8.37056548	43.85746765	163.8649914
5	117.6951155	163.5752331	141.9568481
6	310.1038784	302.7508706	139.4429737
7	212.3453982	245.8357072	214.05437
8	117.1780898	163.4395363	346.6069182
9	53.46464522	121.171971	362.8894922
10	4.07347575	44.00920731	382.2657146
11	4.065346379	43.61514418	361.0964663
12	7.383857742	36.64089252	284.3876066
13	7.540631548	37.86893721	172.9579756
14	20.32523681	43.90069412	158.4927849
15	74.16481207	83.29298351	152.4371013
16	337.1259295	316.1536531	149.4021488
17	351.8027489	322.8917985	147.0235274
18	352.5293388	325.1218312	175.7503064
19	301.3936079	295.1645457	215.8625088
20	87.34011953	141.8280529	225.7865428
21	34.04086764	74.66854898	227.7418026
22	9.885034235	58.5890832	237.8383985
23	10.1569108	58.19502006	239.2364987
24	8.836338554	63.57078657	222.958753
25	8.979783092	66.00235369	215.5104328
26	9.066968713	66.00235369	166.7075173
27	146.5544841	226.6628435	160.1858115
28	135.0041267	175.594886	147.1965408
29	121.6214113	170.0832451	148.4788531
30	24.27808011	52.70297313	165.6954648

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
31	25.94979877	50.30598293	170.4102688
32	16.51145259	45.70188315	163.6085297
33	6.511222579	44.29919217	165.1751394
34	4.081005014	41.42736065	134.6312616
35	1.409347295	41.68891017	126.6710237
36	1.265943817	41.24569122	137.8748202
37	4.173777611	35.28892062	140.5867773
38	18.35850598	58.54780034	180.1527397
39	15.93588809	33.23658731	208.6786697
40	18.48591402	45.67605659	353.4677127
41	18.78037695	42.87184741	383.9237998
42	23.47422896	44.68968761	382.0456211
43	24.71786367	45.55775236	336.1161064
44	6.656524405	31.76926985	237.837887
45	2.284560459	54.56555623	143.9082212
46	23.08083752	53.86394772	141.9739626
47	1.434576628	45.53497109	141.3731631
48	3.362616469	39.85922975	140.4879929
49	2.223378115	39.50162804	144.3233556
50	1.594590859	41.03397112	210.2220137
51	325.2963584	319.9985556	361.1015585
52	301.9768779	295.9800505	366.0561989
53	156.4972391	173.2256899	360.7164619
54	88.34166087	134.6448405	353.6414582
55	2.207750197	62.85185686	79.26843778
56	0.523241637	39.9228851	18.70218728
57	0.476126132	40.1346936	136.0941011
58	334.1670156	315.5792796	190.5263793

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
59	337.9950793	321.2305287	207.8938793
60	343.8102706	323.3752254	336.6884377
61	348.6891444	327.5982818	336.3251329
62	349.8394264	319.7935335	340.5542453
63	277.4245435	276.2816591	223.9529854
64	89.83023033	128.8511174	137.0246613
65	1.462539257	45.74514969	145.9201381
66	0.047532694	44.48395597	153.8285967
67	0.127808349	44.3490493	215.8575901
68	114.5787135	168.4677531	345.2440622
69	266.3440692	278.5954611	340.1913169
70	319.4056233	308.0387419	312.7812317
71	325.9671054	311.1117113	312.48042
72	322.0065916	305.1853189	201.9328321
73	89.41653893	133.2122217	159.5784203
74	2.727486343	52.8710176	139.3562454
75	0.902661808	49.66394938	140.7267787
76	0.294632748	49.01873895	140.7714135
77	2.198948928	39.57882609	139.18325
78	2.251352378	40.5586046	209.9996223
79	2.439913687	43.10036355	324.0036705
80	306.6754068	288.0614413	337.9111796
81	310.5034706	290.8843327	354.4536333
82	317.5346527	291.0232985	357.8187275
83	321.1447133	292.1264597	353.9205082
84	299.739051	290.0746154	186.8622376
85	241.6855531	247.6173928	158.6522901
86	124.1952372	163.9627763	145.0012616
87	1.623110344	40.49925181	145.4411329
88	3.426407998	33.42156014	146.4287814

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
89	3.390886729	33.58105173	141.1957325
90	3.368426041	36.31885252	136.0898906
91	53.08277858	84.79085907	153.4506342
92	303.3072165	281.3627139	224.6717665
93	308.3632531	282.1912603	222.084116
94	137.1067819	156.8144024	231.769632
95	13.03440728	60.39592416	231.5298916
96	2.450003222	47.88082079	232.5872503
97	3.496358051	38.17010387	222.8774011
98	3.418929722	40.4788505	227.2405868
99	32.85336426	63.74646337	221.6448679
100	114.9748638	138.3988298	134.0940128
101	146.8508115	160.9699422	137.3610233
102	166.7219528	163.9679493	122.7246359
103	157.7555051	139.5513875	134.9156393
104	106.6893424	82.94299191	135.6190964
105	65.77493428	66.13628613	109.6272873
106	9.094942417	50.02342869	143.1467795
107	3.88010393	44.43758046	18.74661981
108	0.848442052	37.93173583	10.56256553
109	0.813472935	40.14594008	10.14617016
110	2.846677951	32.40722524	10.87119532
111	17.50627308	27.88598433	9.496035331
112	21.05562953	38.74742714	12.26349429
113	6.369390525	42.17925685	12.35327822
114	4.284579075	43.70762525	12.31349444
115	3.471772706	44.60282312	20.85431297
116	2.706221036	41.32044377	23.23571971
117	16.67274825	47.54089025	24.73748089
118	137.1550881	161.3067129	25.38673128

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
119	349.2459083	304.2930385	25.55208216
120	355.3963291	307.4276149	11.98232271
121	357.418524	307.001996	24.68356986
122	352.4217249	299.5783761	24.6274948
123	136.8425137	167.8846007	27.527221
124	72.36209112	125.9675908	9.947337469
125	5.449964682	70.76669517	7.721165317
126	4.33982748	56.53962561	9.485065981
127	3.221124427	54.13328624	10.11243264
128	6.95169638	53.24156141	10.58581367
129	3.124068721	40.819355	16.01161932
130	3.008907112	44.33649439	23.2995081
131	70.35026094	93.68960536	26.76815081
132	139.7520194	166.4344477	27.10541024
133	291.6428678	276.6137234	26.43827829
134	349.4628268	297.9178054	20.63979342
135	357.9480836	303.9290126	12.82342644
136	71.94724533	104.2324202	9.461501178
137	3.515456059	47.83321168	11.62295272
138	0.476193547	41.79900018	11.74823666
139	0.475869634	42.29708208	17.36501304
140	280.8896283	282.0760077	25.20287614
141	346.5578389	307.7277771	28.92110216
142	350.4759046	310.3883283	21.77316573
143	348.213365	311.4847075	21.49020604
144	269.2044404	262.7739821	21.29045625
145	89.14695523	106.5077296	13.39411074
146	33.81349816	48.84821328	13.23657904
147	3.682124216	41.2354171	17.11301857
148	3.548251368	46.41750438	26.39724424

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
150	126.68001	170.441873	29.28262335
151	372.1233865	325.2185385	19.84335649
152	381.4156118	328.8796327	14.51531838
153	108.6988214	120.8629373	9.205939403
154	63.92646988	52.29743045	7.923383149
155	11.48157335	45.40701408	10.63357891
156	11.49656678	45.37978625	10.72336283
157	11.32149827	48.53016151	11.00075574
158	20.59977396	53.67453461	11.05549536
159	282.4668798	286.0353052	11.93623249
160	356.4843555	314.3122159	18.00462108
161	357.8879711	317.6176265	19.6285425
162	356.3748646	310.8201169	19.40082347
163	335.2146775	297.7229998	17.75794607
164	148.164185	153.7207623	13.67700179
165	78.46837289	110.5143936	14.31952654
166	9.245755794	44.66378129	12.1282072
167	1.465381852	38.03666387	10.70626502
168	1.097729137	41.32325887	10.87955118
169	213.7082702	168.7381015	12.125888
170	141.88114	86.46701242	13.03855851
171	23.914781	49.59229821	10.03312722
172	14.50965434	51.98108311	12.46116331
173	16.7771039	48.33703936	11.48195543
174	19.09397381	48.59551042	12.0875614
175	5.369960962	49.29945435	11.15228053
176	1.073551352	38.19544684	10.99913925
177	0.923970416	40.55597846	25.70076541
178	0.897466733	40.69203712	32.16115525
179	21.18489299	60.02255479	37.81616731

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
180	15.46148367	31.9595702	36.83392815
181	26.10030392	60.24416943	83.23791277
182	18.98415651	52.24690014	53.7614368
183	17.0864601	38.68901626	45.36246806
184	2.394785221	39.1706721	33.27612941
185	3.417028839	40.53970901	33.36591334
186	16.36153398	66.64548511	35.13584225
187	364.5159428	333.7334426	53.87798284
188	369.7104169	366.1674812	100.0928782
189	364.5552219	379.2686353	128.5912299
190	326.9313594	393.9213293	43.75172965
191	282.0675094	375.3845432	40.63965044
192	149.9462045	299.264721	34.00955607
193	21.65561625	243.9150762	33.9594238
194	5.30973949	227.8038912	55.55587568
195	5.314655993	206.1728219	101.6782284
196	8.180322218	199.1879272	122.0178544
197	1.200947743	44.6518702	125.4642484
198	281.448944	279.9520673	127.1421009
199	343.0480866	309.0781099	128.6325079
200	342.1962914	312.133131	109.2883644
201	353.8267828	311.9570209	80.11999887
202	338.4673317	294.8294449	56.29963791
203	162.25154	189.5032066	46.7262671
204	86.99235381	114.9169253	43.71908162
205	6.889813618	42.37701056	42.67061609
206	6.107999847	40.83796102	41.0899956
207	3.898398706	42.38262454	34.4746802
208	3.429200337	37.007689	34.56446412
209	2.708131735	37.007689	34.62969378

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
210	361.8510164	315.0265208	34.59281782
211	365.5183477	318.8958297	102.2751193
212	177.4087751	214.2204694	120.1390524
213	5.082764591	57.70497671	121.8689874
214	2.77709308	49.43823796	121.8834704
215	3.92958809	46.14041566	121.9926157
216	13.79007966	46.72727092	123.4806869
217	2.68801043	35.81581129	124.6441999
218	2.968196379	37.76284171	123.2380085
219	3.202662931	37.76284171	60.57847832
220	309.4671596	286.8066649	48.6738143
221	325.2226972	297.7796138	41.42385371
222	285.3690465	292.3451217	41.22366377
223	244.7541836	261.4051948	41.06613208
224	59.25985919	79.61925927	55.72668118
225	11.69414833	12.13965658	136.2406637
226	9.693759375	5.967230542	131.8938908
227	0.579942722	5.260622125	138.6341534
228	5.118811256	8.445049646	38.59651882
229	5.338141697	9.575075071	20.94092526
230	5.114436167	14.11867674	19.97327355
231	115.410667	147.8811733	42.14043217
232	245.8122029	242.98214	42.5240251
233	307.7868493	293.4479699	50.83010587
234	310.5234144	295.1539025	71.78707312
235	22.88981716	9.230264795	60.09308546
236	11.17326585	2.108945915	62.21048538
237	3.99972398	37.44155736	41.27729316
238	3.99972398	37.44155736	43.56500172

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
239	4.951964447	38.16738027	67.97533767
240	28.80467673	42.59233673	49.27288186
241	31.90676874	46.51735127	56.67582423
242	136.4995278	136.0063109	56.28952696
243	136.3049708	136.3622423	56.19742092
244	80.71331648	67.48647874	56.99184723
245	10.77729483	33.32610413	57.40060258
246	10.14534797	40.15415124	58.12258589
247	0.387052242	41.97436451	42.40565215
248	1.989989225	42.6254073	40.8599542
249	15.6205464	30.73080784	39.11363886
250	28.80343834	46.02103647	44.50811537
251	1.531995066	39.14659763	44.53228777
252	0.920565126	36.92895434	44.50531927
253	1.617132757	37.74186426	114.8401924
254	1.469815348	38.82875991	112.4329103
255	1.492911909	38.82875991	95.3216324
256	209.5334775	237.2807403	71.0572561
257	238.9598811	255.3184992	47.30166274
258	123.5275061	137.2840484	47.52187136
259	57.35890881	96.34409812	47.69011549
260	18.78756218	57.5549611	59.25420527
261	16.89767364	56.55743881	119.837818
262	26.50291834	56.55743881	121.0656862
263	0.742623905	40.25045059	123.0561876
264	0.113507175	42.10280686	121.0725936
265	8.71180302	44.19944825	80.69678201
266	51.2716022	75.89061429	45.47497002
267	130.4829704	169.059287	42.29777403
268	283.7714355	280.3123999	41.50954863

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
269	281.7888988	280.6940265	44.09179883
270	280.8393074	279.8637683	55.82114049
271	278.7958093	271.333668	120.461765
272	87.43817317	102.4786508	127.1294505
273	16.67604507	51.75661219	118.657251
274	0.051920829	48.23014235	52.21435522
275	6.918535769	45.81680523	42.85334295
276	6.790320933	45.92558562	42.03641128
277	6.394972488	45.18327147	40.76687164
278	16.52926577	46.39890265	37.03489155
279	132.5117836	175.0560011	48.2039857
280	334.7784389	282.8066135	83.10332987
281	332.4850288	287.704531	121.963976
282	335.4396494	274.1217805	121.6410299
283	308.4542239	238.773552	114.1938223
284	130.2980686	59.30343733	47.121572
285	102.0170995	57.68337061	60.03269043
286	83.41247594	53.6190336	93.92642095
287	4.776654797	43.31884488	264.235352
288	4.202913629	43.31884488	260.7692169
289	1.431655234	44.53447606	240.8479047
290	34.0267692	77.34727578	142.0247064
291	106.5111988	160.7614044	95.99690532
292	236.8453902	271.7479445	62.9476172
293	230.1705902	249.3492785	41.72684714
294	199.5780217	220.4509123	41.68997117
295	22.63594781	49.62806342	41.59270632
296	9.835513451	40.91710861	59.55304994
297	42.56629809	75.89514528	55.10752395
298	118.1972205	165.2513745	43.08266677

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
299	294.9689565	274.1113488	36.60782575
300	297.0344871	277.644742	44.31904136
301	299.4813384	277.0885506	62.0305137
302	309.2024786	281.5527362	53.74177285
303	327.0394886	262.6409123	48.69830943
304	313.8151699	220.6071498	40.11177267
305	254.9849034	49.23389148	33.21008002
306	241.5982846	43.31067314	45.18912725
307	217.5032861	42.01624872	45.7403125
308	3.493739789	36.87423733	45.575942
309	186.9430465	152.594824	45.2734301
310	240.9863729	55.07427781	58.77361848
311	246.1449921	48.39631807	95.14852236
312	209.563143	46.45063373	115.8716498
313	5.10007817	40.13648574	117.3463994
314	5.068728749	40.14551918	119.794704
315	4.959515964	43.06838515	90.32808846
316	5.895525175	39.92825111	52.04421232
317	17.29624705	34.55103252	43.28776606
318	152.213918	67.96430284	40.12145682
319	206.8211258	88.02656218	40.63257007
320	180.0541097	74.62626238	55.06044216
321	193.9010292	45.76152966	89.00538375
322	241.8225424	47.71833649	108.817567
323	226.9287446	45.44705952	119.1960935
324	203.239875	44.08248947	96.89703184
325	2.977373617	42.2473342	36.0096089
326	3.18324793	45.38818785	33.22197006
327	38.78201208	75.00715024	33.4757216
328	131.0376055	168.5056435	45.89180978

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
329	303.4683322	219.1783651	45.96206923
330	303.0088477	127.9832268	118.7025153
331	278.8052772	50.32840736	119.4357724
332	3.545539795	38.9067648	69.31089894
333	1.243269931	38.91579824	44.98143323
334	9.429062736	48.53764962	41.56614412
335	35.50648485	64.80475339	45.56633712
336	311.6403567	290.0008302	59.28287526
337	314.9449603	276.9478096	108.4850061
338	289.9197465	240.7355678	62.97921011
339	284.6212275	155.4363793	55.35520137
340	176.8205104	49.55595893	44.1425868
341	124.0694018	47.71291745	43.50805299
342	57.90523098	46.92265461	99.88665965
343	3.793873401	45.66692789	97.83509772
344	3.793873401	45.66692789	101.2963549
345	12.42428416	52.81288956	104.0721862
346	57.84675058	86.20608306	103.5884377
347	299.9900787	286.6428009	90.18882195
348	258.6116053	266.7926109	63.15925637
349	77.09812564	64.28648352	48.01180875
350	3.19543703	46.47143929	40.13112294
351	3.214061157	46.87345971	38.7880475
352	123.1503322	161.9921041	38.84496921
353	295.99004	279.1594964	40.19669498
354	302.5182816	276.6222618	49.62411263
355	305.5806398	278.7151368	58.04588621
356	290.7463407	272.6424863	57.88382101
357	157.4601535	133.796578	52.8278424
358	152.2679471	83.82690525	51.97566469

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
359	117.2899286	46.90131727	49.37305416
360	5.060483274	35.99661796	41.85377205
361	5.068243382	39.96178682	38.67413052
362	27.05409859	61.16469756	39.48136487
363	113.719602	146.3394475	40.62131169
364	274.4287104	249.4952107	57.16797755
365	274.86874	250.2503624	49.8041785
366	285.0564228	248.1708033	52.80624624
367	228.3914673	204.4797302	53.00406845
368	169.3880743	47.35266735	44.72327394
369	6.136955221	39.14297909	43.01581597
370	7.8822183	41.08543519	38.75481619
371	34.33353386	42.9421385	42.30866135
372	181.6444624	104.092666	42.27178539
373	264.0303528	140.7697584	93.82525662
374	271.7059486	140.3593476	110.4097719
375	281.1569806	136.2621321	115.1170988
376	235.0990071	59.20439234	119.9889837
377	245.3601979	55.72502086	118.3389301
378	265.6623657	48.88752142	102.4068972
379	271.4395837	43.58673003	71.68841963
380	152.8633098	42.38725446	61.99983616
381	7.033361531	38.173355	51.38161967
382	5.913656345	40.78953805	46.44118414
383	4.232510677	40.84967271	45.37789483
384	163.3749001	34.1204902	114.8938677
385	214.1238468	45.7341461	122.883079
386	248.4048704	61.56911687	122.6723204
387	254.9545539	56.63739059	76.2660806
388	228.3699982	50.08361731	46.40417541

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
389	201.8582576	52.78519859	46.49395933
390	178.8016529	42.96932454	46.64348322
391	1.148144729	40.97405755	60.22284658
392	1.171241291	45.28248854	118.6266106
393	1.185869761	46.1968506	120.0481012
394	38.51296613	77.08636256	49.70847078
395	108.905164	144.7957476	46.98241951
396	291.4711023	298.5133964	38.57706817
397	254.8099854	267.4955054	33.88255672
398	192.6294617	228.8897429	43.42428516
399	92.46551543	142.2000056	70.83926488
400	6.52282229	45.77733395	80.24080065
401	2.709429658	50.90349761	83.53779556
402	32.99059248	69.18842605	83.34562091
403	248.7335481	220.4858943	81.84430426
404	284.4855062	263.4885664	65.06867962
405	283.8262145	268.6584306	48.18281668
406	292.1704718	263.5179533	34.64075766
407	280.3684932	248.53379	32.06007552
408	229.2647783	218.6748806	27.48112449
409	240.3445435	96.53342272	38.1250433
410	251.2620096	50.01941979	45.97479003
411	178.1635199	48.39853823	57.32798739
412	5.375193698	44.19042625	62.06932371
413	5.770797776	50.55218268	63.2115632
414	264.2844368	213.536824	63.83983065
415	296.7358946	246.2923339	41.89634071
416	296.7358946	252.7615382	41.62762177
417	332.3885337	254.0895024	44.96747733
418	255.1143507	208.0745079	44.96747733

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
419	251.4225399	61.96041583	47.30341962
420	252.6347392	58.2347064	55.44558671
421	180.079202	55.58459962	47.71138648
422	294.1895246	147.1005109	44.67053766
423	312.7855875	142.8947696	44.61384133
424	245.3392995	96.23237251	50.85464017
425	234.2410631	31.18779932	49.85091656
426	246.8070292	18.69972212	45.31193795
427	4.820030038	26.08069472	47.55775286
428	4.823912923	25.8939753	47.52738057
429	63.01665009	84.05598902	47.46890496
430	159.7240874	136.8435225	46.89849804
431	180.8213027	148.8950732	62.05972378
432	180.8213027	141.4060064	80.17870838
433	175.7572306	133.864452	116.7224776
434	23.85906114	34.18737398	117.3778183
435	61.97585829	31.88155755	97.86615908
436	5.055868158	37.23941649	52.54770708
437	4.676634016	40.25376998	50.06195784
438	5.820705774	40.7020491	49.01760257
439	0.315943705	43.97050052	48.98723028
440	4.170338938	37.57472159	49.00276497
441	37.90501306	42.97894838	82.59889852
442	128.6312059	120.2598458	118.4082848
443	149.2272057	120.2950968	126.3808329
444	144.000188	118.2929072	127.3423781
445	20.99527917	40.93606872	106.6380928
446	27.21846317	45.06551649	49.23544359
447	9.755406519	40.12753781	50.39221689
448	9.706327786	41.06542823	50.39221689

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
449	9.653970947	41.2014869	85.78701291
450	11.38747345	42.22909874	116.5220049
451	16.09150139	32.4075734	121.907834
452	20.08040754	57.2381208	123.2226781
453	0.326424853	56.2018257	47.91435299
454	20.49224307	37.91378857	46.04936342
455	4.302793416	28.82666957	45.86181193
456	9.132986001	24.8331325	119.5909762
457	24.42014935	45.16716037	121.4564727
458	23.81735114	40.62172296	122.5941654
459	3.152818955	49.13100306	123.3083985
460	3.038153208	48.87990776	121.5366738
461	2.642478154	50.72496829	65.23379616
462	245.4482053	252.8128376	60.4436278
463	273.3901481	254.4706613	58.63265501
464	233.1992857	204.6285687	57.40182838
465	249.6936514	187.6263936	45.50284012
466	244.2401082	114.1530894	64.35377855
467	241.1736756	47.16854413	116.2113637
468	28.68090842	68.05795597	116.3703994
469	223.4168497	212.991071	57.43499946
470	265.2223865	242.0711068	52.38348737
471	269.2263271	243.2458534	49.89767238
472	270.3846314	247.980261	77.16827473
473	268.5401876	231.2057267	89.86430246
474	236.9545142	137.6557133	106.1005505
475	1.175484122	37.33972537	106.7394633
476	1.290149869	40.44969972	110.5561267
477	249.2104536	246.9643783	109.2747032
478	266.5227656	248.1391249	82.0956168

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
479	251.9960118	232.8518395	74.67986058
480	228.4713509	52.65134693	62.67392952
481	215.2121295	48.1214243	45.56412731
482	5.061473079	46.51168887	44.28084839
483	6.333770074	48.15062775	40.54558562
484	7.324929051	49.65173472	52.21773198
485	17.75076856	59.86357909	48.95754466
486	115.5274948	128.003893	49.1316112
487	232.7461741	212.6280561	43.67961826
488	253.5668791	257.9071912	38.33274626
489	255.1186296	257.1158425	39.35639278
490	261.3003115	258.1413674	35.09637904
491	238.1466428	239.6335692	32.55303514
492	158.9237575	53.68370649	30.20872775
493	158.9671824	48.26615927	28.89558968
494	119.6330882	44.68918204	19.93267561
495	48.00770835	91.8111636	29.64984251
496	121.4407099	144.7129885	77.60548522
497	227.3210181	212.7152089	75.89759757
498	232.1426453	256.7106425	75.32070305
499	230.276969	256.3970002	73.579538
500	170.5613808	209.9149989	72.19899633
501	91.74214542	94.73858368	69.27984116
502	77.28378615	50.62529401	50.29418875
503	64.85700988	41.58825738	26.8404568
504	7.536316627	39.80580973	35.14741156
505	11.28637087	39.32928526	36.08297319
506	11.1327833	39.58011783	36.32059359
507	71.97132527	67.64510837	35.73252494
508	161.7772478	107.4667374	129.35364

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
509	199.7811824	148.3869053	130.5176964
510	214.3471308	151.915228	131.3902165
511	216.5783677	150.7635166	131.362187
512	133.8283925	79.63735119	45.76311016
513	135.3096016	74.31644842	93.97930382
514	179.3265381	46.84203887	125.9736314
515	181.3149623	43.77833023	125.1064394
516	160.7425372	41.04767884	126.4579256
517	90.73413023	40.76270163	126.7797449
518	10.96542857	38.74322734	82.47100294
519	11.07464136	42.53907357	46.03153049
520	28.21931334	59.063767	43.71719732
521	106.9296559	37.34605269	45.6593099
522	199.9411617	77.6875697	45.60736795
523	176.7553582	65.26857865	115.8766036
524	215.1638246	39.37566839	117.4014974
525	209.4439912	47.52407382	116.7757376
526	11.15761157	33.02026365	116.7477082
527	143.0752428	106.5571921	100.8907674
528	146.8000327	106.5775174	56.81648099
529	133.0045087	97.11176442	53.86699206
530	83.03157774	62.70035362	51.54347439
531	55.18718147	32.54037263	51.02887936
532	10.29087451	4.485958094	43.07020544
533	11.28323418	10.51057244	42.54700816
534	16.65977636	11.74120432	42.38947647
535	6.052286681	33.19174689	125.5012908
536	6.191719767	41.91029299	125.0893091
537	7.938977502	47.9638635	124.4193415
538	347.945904	337.2142886	51.40959299

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
539	339.2136105	322.3797024	48.07381439
540	177.3331332	188.7312351	46.71506976
541	113.7368134	116.8442311	40.82033284
542	60.35626202	59.9363201	40.65750683
543	37.52066712	55.59579212	40.65750683
544	7.04057699	50.93234435	40.35252538
545	14.7004509	50.08507371	40.65792392
546	1.132183382	41.24917399	47.8668358
547	0.968010018	41.18479811	61.12148875
548	6.095684329	43.47915288	59.33444284
549	15.07191981	48.23088167	55.83833888
550	118.7989317	180.0430422	45.34181665
551	346.2625794	322.3157119	44.12649311
552	344.2880425	321.5243632	37.04961468
553	345.6531519	321.2814166	38.16001003
554	314.6369236	285.4423474	38.14742464
555	258.703242	249.9019915	38.42529815
556	140.1552178	166.9318553	40.1155968
557	1.863911674	42.00986611	54.59543768
558	1.227289918	41.77833548	62.80381173
559	15.13056276	47.02747603	62.5974738
560	272.3415645	286.2940539	62.65387377
561	316.3815917	316.2828029	61.01612483
562	320.7890307	317.7064866	58.42601164
563	320.5444023	307.2340444	57.68844594
564	263.0243865	252.4043074	44.33350242
565	6.118921538	47.21039386	46.78713876
566	20.76282902	52.71353424	39.19524571
567	323.6088059	320.3414092	39.0324197
568	6.966621606	44.78218407	39.03894676

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
569	10.99045839	33.75428602	62.29040999
570	11.15463175	33.30809844	138.8532479
571	11.18684973	34.74335959	134.9862924
572	11.18684973	35.01992263	125.2037138
573	120.113162	129.0025042	37.76655382
574	192.2078242	155.1822282	36.2823996
575	160.034198	126.1651243	40.22128779
576	53.26513605	56.83433009	39.936481
577	16.55874158	39.56483229	40.433595
578	13.43609096	35.13648344	115.5360194
579	13.54841519	35.07210756	122.5507078
580	13.49155925	36.55524515	124.5667922
581	14.51096536	37.38627922	122.6633068
582	10.00538532	32.02683284	73.91034498
583	61.74490505	49.0666747	55.48899545
584	49.84495993	49.58772709	40.9997656
585	44.69234584	47.91831871	42.68845956
586	28.33191783	37.47935087	42.72462153
587	39.31044538	35.77503687	60.09985475
588	25.83529827	42.72486877	118.4518318
589	25.67112491	44.38522406	126.0602778
590	27.06039987	47.37117889	126.4072947
591	38.49074726	54.06352155	127.0147176
592	73.15882756	85.03106815	126.5655271
593	298.1374453	298.8748007	125.9001586
594	340.0198809	329.470602	42.74837496
595	363.8339069	329.6161478	44.97395013
596	367.0769552	331.6762944	44.42119712
597	364.0129402	285.8129463	69.48605182
598	276.0785712	65.85595207	58.04445927

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
599	248.3677152	56.38873329	43.39808069
600	205.9186417	56.38873329	43.240549
601	1.906787445	37.69896578	58.76031108
602	1.864620247	40.42045407	110.7400327
603	125.3982212	143.8594227	113.0051922
604	290.8066046	241.648147	113.0051922
605	313.2821353	284.6778193	110.3048557
606	317.8583327	282.9109538	92.29836485
607	308.7773319	269.8515382	55.2310938
608	254.6842179	238.5829554	46.26531391
609	2.550758714	41.64540998	42.32381795
610	255.9925243	227.5365105	39.15197146
611	280.3111842	259.6618012	38.84000431
612	283.5587272	253.9662814	38.77615985
613	267.6611847	227.840915	47.10850639
614	161.2999491	144.9416549	58.28325438
615	93.29627716	85.39120988	60.59972957
616	17.82128825	49.12097076	56.39335807
617	0.617126506	40.94567491	52.45646816
618	0.753320605	44.21748427	43.669643
619	13.21510194	49.93578013	42.93824023
620	242.3960293	225.3533088	41.58008976
621	267.7820602	266.6062421	41.89718185
622	275.4736145	263.8501649	50.88395033
623	284.9443197	264.5871329	41.35886951
624	269.341686	244.2775851	48.85508354
625	162.0553912	153.9681979	48.16603761
626	80.5020356	89.63148876	48.9496523
627	24.58156647	58.96082042	52.45697175
628	14.29846154	50.75001815	44.93130184

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
629	5.606454099	48.37857181	42.51009841
630	0.014898269	36.58396828	44.22542603
631	0.178118867	38.65325565	44.30968926
632	12.52368983	44.34820321	116.3175061
633	239.3116107	205.8991796	124.3596827
634	260.5335012	230.5810862	125.84779
635	260.7516091	230.5853057	120.7459569
636	270.5915008	225.8778079	118.9116584
637	252.0744917	211.214265	46.03843619
638	142.301483	123.7138921	43.12890773
639	72.31378022	79.27083017	61.18619504
640	1.448691115	39.11878629	123.9387811
641	4.300581228	37.88159949	125.0171417
642	5.153435384	32.30808253	74.27913597
643	5.130937492	32.24370665	46.31831796
644	6.486451538	33.8425285	45.43909227
645	1.116634184	35.44431865	41.15747548
646	128.0981249	120.5892942	40.86168453
647	104.4229982	60.20453983	40.72195533
648	5.524564029	38.53791	81.51639995
649	7.04253015	39.63888043	115.6088835
650	38.33344621	51.7075412	118.0007759
651	76.80239732	70.40348426	119.4223321
652	81.20010237	82.2891252	117.7748043
653	86.50045724	91.7243669	70.45596845
654	93.24514997	89.25415563	53.20816474
655	83.00164643	61.5455996	36.80111837
656	11.04855019	51.86674969	40.172754
657	5.870358237	43.15485693	40.15229893
658	4.749425698	38.81240793	55.51452671

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
659	20.61964358	46.8716282	83.37326865
660	100.5093849	141.6636788	114.1748999
661	271.5167623	277.3992167	117.5912195
662	272.257695	278.4337859	117.4291543
663	276.4368862	279.1053858	111.2311819
664	292.1210379	272.1163061	92.70537378
665	295.538708	259.598718	66.2510861
666	214.3029061	211.9001931	47.65400901
667	120.7111926	150.6361868	46.05043843
668	6.161986644	45.20860186	44.31766451
669	5.763804494	35.58295501	39.61288567
670	0.696398437	36.88924881	44.38633418
671	0.640517402	39.33133246	44.06016299
672	1.543715313	40.66487447	83.93296615
673	319.0565452	273.4158607	110.9561636
674	316.9432347	278.978768	112.5050453
675	309.1268132	273.429727	117.6397897
676	229.6183701	234.5813725	95.2027259
677	148.6152763	173.8302787	47.18154068
678	28.11184723	71.92155218	48.89170119
679	4.455058664	50.6143874	36.51351688
680	2.205630229	36.71579466	44.15106018
681	2.126745688	38.92083509	44.00602106
682	2.443286526	40.2543771	43.8188683
683	15.39592832	43.81209946	49.07714724
684	289.689135	262.4709816	58.87116982
685	229.2955654	229.7052159	60.07958164
686	151.5220334	173.7343227	69.3711126
687	57.92815593	60.59266482	72.96031356
688	16.88442859	44.91463815	70.18735437

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
689	98.50160475	136.6682283	64.39520945
690	272.956086	266.1951942	53.0983223
691	283.311909	272.688272	45.38983481
692	312.1769077	270.4316994	43.852817
693	306.3072557	265.3102079	36.51723339
694	19.31983656	47.1181068	40.98359206
695	3.970705724	40.14055336	40.91885782
696	91.16902857	139.7708828	40.94923223
697	208.5223572	232.6301853	40.96565313
698	268.063244	260.8058643	47.23197486
699	277.5236848	265.785149	46.84467003
700	287.687565	251.8537361	46.90258964
701	214.236961	180.6384353	47.49556568
702	131.7242834	118.1406766	43.96581852
703	8.56499751	54.38900431	50.71985532
704	28.75232523	55.86933848	46.25919512
705	0.007697171	40.1269432	41.13097833
706	183.3186732	176.7629567	35.22453752
707	246.4303623	165.1513628	43.18290498
708	72.71457319	30.41141067	44.56259266
709	12.33841425	52.37762898	44.36722191
710	13.16227044	44.07056996	110.1834998
711	14.7620308	42.72409511	118.9703656
712	8.147912025	38.46305875	119.8150449
713	9.102440239	39.61901063	121.0018652
714	7.15164745	40.56633259	121.0227425
715	10.98217611	36.49530485	121.0227425
716	88.93679692	43.45180362	114.2260169
717	18.34998951	58.59369141	94.27857685
718	14.120747	47.10333777	41.32937426

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
719	2.651942037	43.50151008	43.1892102
720	4.768661355	44.77002199	43.049481
721	6.098809516	45.3094007	43.1832611
722	6.780606007	47.10138284	59.0882547
723	47.21913373	154.5534954	101.1696161
724	212.2302975	296.2886271	44.93485388
725	230.6767056	297.610099	40.67839495
726	235.9516089	274.7706287	95.1036278
727	0.56832185	45.22193908	97.77777611
728	9.82903699	37.2424196	95.2416415
729	5.711347276	30.18677359	95.30027004
730	5.070794928	28.79508726	84.5104779
731	1.591342466	40.36820368	60.45497475
732	2.293159414	42.09578047	43.7457774
733	318.2092007	296.292485	38.76946058
734	347.0705985	296.0817937	38.70472634
735	183.1044132	167.4270212	38.19988608
736	86.14628514	108.2270307	94.50455219
737	12.44922597	52.207465	42.92290892
738	8.580244422	46.74504707	42.7838777
739	0.398326104	43.87142955	40.58860462
740	2.603443936	33.91541912	40.39471845
741	196.0993811	158.1099853	43.96766447
742	189.7001882	150.9749609	62.21394782
743	8.757116618	36.49842523	86.77393479
744	0.598567443	37.46156727	87.44904221
745	44.44168266	80.76762968	87.04855323
746	196.7021434	164.7595266	86.30425044
747	190.4069964	159.9264004	48.47826217
748	159.2454521	145.6756736	40.18612593

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
749	86.5717391	81.6112406	39.41547074
750	0.360158171	43.41341711	37.80189026
751	2.063734401	37.30307085	42.41116154
752	48.26303333	67.37935354	42.20669809
753	165.8890429	130.1405296	41.84158703
754	166.337349	130.7294057	41.64621628
755	173.6011666	123.8864215	48.98285897
756	1.924930051	41.65891229	61.16539632
757	5.310468628	32.96328797	62.8895001
758	8.514081433	32.38623315	62.8895001
759	0.599358535	39.80291444	44.92051
760	3.571158678	41.72790144	43.69242967
761	3.757253132	46.0718145	41.54179274
762	170.7364082	168.9122514	41.47705849
763	191.7807141	171.013887	41.3666746
764	206.8022983	171.6621493	41.32979863
765	208.9750819	155.6635588	38.1364592
766	68.76300281	42.75359125	50.2657727
767	4.165793973	41.74820732	51.55100927
768	0.637980533	41.94285765	51.5718865
769	2.045586551	35.38652215	49.06198339
770	2.035129216	37.42154964	42.79876455
771	24.50547264	34.47491954	43.42767671
772	24.53776765	67.42606367	41.85701618
773	25.25039974	76.46221188	41.80642272
774	26.76095165	71.71627411	39.77301352
775	15.10538836	41.50435491	44.15421092
776	37.18330043	67.62324877	44.01448172
777	100.9169219	150.8893148	43.87372341
778	180.2475231	214.6137375	62.99252633

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
779	286.9769694	275.2432509	127.2573367
780	289.1231377	294.3631409	69.59251129
781	295.6304973	295.8613789	46.47678607
782	311.1666611	294.0269679	43.94221617
783	37.95027619	93.84406015	43.28675151
784	16.47886137	56.03883077	43.27738856
785	4.859257876	58.54496948	43.08201781
786	5.584750132	48.70754705	64.52958002
787	1.671337369	45.43874313	130.3415352
788	4.035332896	46.50123908	130.2652445
789	19.53737622	50.41528745	130.0138499
790	58.52455049	74.1379159	124.6596575
791	259.4012528	254.4834021	123.9719254
792	359.1576929	318.4088584	45.2858038
793	366.3023907	319.6082353	43.23736572
794	370.1224496	314.8480145	119.1997011
795	257.4898284	243.1834992	118.6307003
796	0.856775239	49.28208674	106.8383368
797	7.775460175	44.32300127	70.8945143
798	7.665733746	44.25862539	45.69892628
799	24.94780182	50.66125781	42.2929548
800	226.9613926	233.5410121	42.70649142
801	317.0975867	289.2624102	42.56676222
802	320.1235471	288.1800091	42.16364764
803	328.3592874	290.0587011	55.59315891
804	325.9952215	276.1593058	112.2781827
805	288.4849829	250.3860954	108.7028942
806	225.2890252	219.2023075	97.20149276
807	59.17500237	100.9403618	47.62584018
808	4.872684608	48.54111053	42.94254653

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
809	2.151245007	42.58659059	42.50627951
810	1.764746852	44.60745939	57.13709782
811	1.764746852	44.71385245	92.27080174
812	35.61235405	70.67089118	113.353181
813	106.4131306	152.2348793	114.6821195
814	189.3373394	224.1526578	112.001527
815	282.3845217	280.4557095	92.48499664
816	295.9928092	274.8509092	39.8005163
817	1.670013151	33.00217281	38.50245544
818	1.539570055	33.00217281	37.66742473
819	1.839470567	36.27737854	42.09964225
820	38.65157719	68.40836566	41.32430137
821	275.3611333	264.2688301	49.08671428
822	271.0776371	262.0324607	62.83674736
823	0.814038318	40.29862658	52.76169828
824	2.051967039	35.05214529	55.61511133
825	2.182410135	34.98776941	51.62481424
826	2.470683173	36.99560732	57.17765544
827	3.075269137	37.48669308	40.98870462
828	43.75003208	59.30671522	41.96975368
829	99.34550494	119.7839437	41.92814468
830	152.8526478	153.8512446	40.52526549
831	174.3892744	155.851428	45.05717433
832	169.1107675	147.2946271	44.77872147
833	109.3610686	68.6783408	42.151132
834	4.909307114	39.62072491	42.07484128
835	14.18501514	37.44277483	44.54388639
836	2.01668662	37.45965317	45.3094696
837	0.594202832	35.60820686	46.92748893
838	0.92885186	37.59954533	50.04126741

hour	predictionMBD1 (kW)	predictionMDB2(kW)	predictionMDB3(kw)
839	37.86745672	47.74267332	41.89696432
840	41.77017915	47.90961688	41.06193361
841	38.43737194	40.43349895	43.77948702
842	2.331047475	38.55566702	44.66058187
843	2.603734658	36.85135303	121.2941438
844	2.296780862	37.30812107	120.6233722
845	5.715135842	40.22588265	121.4250447
846	5.738232403	42.2821979	118.7815118
847	19.1478858	46.50176483	48.65797187
848	215.7275221	236.9257276	46.30528415
849	299.363787	286.1563854	46.6414391
850	295.0591499	264.3458194	61.43877618
851	22.90907704	54.84601608	93.52453618
852	16.50511571	45.17435468	129.7846724
853	0.065612342	39.06178147	123.5253402
854	45.37754346	72.25243705	35.40597621
855	245.5661053	252.3442305	35.32345507
856	328.3890622	301.0517194	35.21543004
857	332.7956018	302.0974848	35.29183427
858	311.9931078	286.3380071	35.66368431
859	147.793783	161.3581169	55.41828111
860	84.66712645	100.4071969	139.0218258
861	9.315682455	49.98189867	144.5710264
862	5.108660517	40.17230252	142.4735365
863	0.23456781	39.42667458	141.6897025
864	3.10320451	47.26435736	137.4430224
865	15.65353674	49.95820359	130.8818436
866	321.6906796	288.7536427	131.4116907
867	324.5722885	288.3449627	101.3028433
868	19.74337601	62.79540775	42.94551524
869	10.07513052	46.82424215	41.44120868

ประวัติผู้เขียน

ชื่อ - นามสกุล

ภาณุเดช คุณชม

ประวัติการศึกษา

พ.ศ. 2555 - 2559 - ปริญญาตรี วิศวกรรมศาสตร์ และเทคโนโลยีอุตสาหกรรม
มหาวิทยาลัยศิลปากร

ประสบการณ์ทำงาน

พ.ศ. 2559 - ปัจจุบัน - R&D Engineering/Service Engineer บริษัท Thai SCADA จำกัด