



การพยากรณ์การใช้พลังงานภายในอาคาร SGtech อย่างชาญฉลาดด้วยการเรียนรู้เชิงลึก



วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวร
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาสมาร์ตกริตเทคโนโลยี
ปีการศึกษา 2566
ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร

การพยากรณ์การใช้พลังงานภายในอาคาร SGtech อย่างชาญฉลาดด้วยการเรียนรู้เชิงลึก



วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวร
เพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรวิทยาศาสตรมหาบัณฑิต
สาขาวิชาสมาร์ตกริดเทคโนโลยี
ปีการศึกษา 2566
ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร

วิทยานิพนธ์ เรื่อง "การพยากรณ์การใช้พลังงานภายในอาคาร SGtech อย่างชาญฉลาดด้วยการ
เรียนรู้เชิงลึก"

ของ สรวุฒิ จิตตานนท์

ได้รับการพิจารณาให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาสมาร์ตกริดเทคโนโลยี

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการสอบวิทยานิพนธ์
(รองศาสตราจารย์ ดร.บุญยัง ปลั่งกลาง)

..... ประธานที่ปรึกษาวิทยานิพนธ์
(ดร.จักรกฤษ เต็มฤทธิกุล)

..... กรรมการที่ปรึกษาวิทยานิพนธ์
(ผู้ช่วยศาสตราจารย์ ดร.ยอดธง เม่นสิน)

..... กรรมการผู้ทรงคุณวุฒิภายใน
(รองศาสตราจารย์ ดร.ประพิธาร์ ธารักษ์)

อนุมัติ

.....
(รองศาสตราจารย์ ดร.กรรองกาญจน์ ชูทิพย์)

คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การพยากรณ์การใช้พลังงานภายในอาคาร SGtech อย่างชาญฉลาด ด้วยการเรียนรู้เชิงลึก
ผู้วิจัย	สรุทธิ จิตตานนท์
ประธานที่ปรึกษา	ดร.จักรกฤษ เต็มฤทธิกุล
กรรมการที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร.ยอดธง เม่นสิน
ประเภทสารนิพนธ์	วิทยานิพนธ์ วท.ม. สมาร์ทกริดเทคโนโลยี, มหาวิทยาลัยนเรศวร, 2566
คำสำคัญ	การเรียนรู้เชิงลึก, การพยากรณ์ความต้องการใช้พลังงาน, การปล่อย ก๊าซคาร์บอนไดออกไซด์

บทคัดย่อ

ปัจจุบันความต้องการใช้พลังงานไฟฟ้าเพิ่มขึ้นอย่างต่อเนื่อง ส่งผลโดยตรงต่อปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์อันเนื่องมาจากกระบวนการผลิตไฟฟ้า ซึ่งถือเป็นก๊าซเรือนกระจกที่ส่งผลต่อการเกิดปรากฏการณ์เรือนกระจก ดังนั้นการบริหารจัดการการใช้พลังงานไฟฟ้าให้มีประสิทธิภาพจึงถือเป็นปัจจัยที่สำคัญที่สามารถช่วยลดการปล่อยก๊าซคาร์บอนไดออกไซด์ได้ การพยากรณ์หาปริมาณความต้องการของการใช้ไฟฟ้าล่วงหน้าได้อย่างแม่นยำนั้นถือเป็นสิ่งสำคัญที่จะทำให้สามารถปรับเปลี่ยนพฤติกรรมการใช้ไฟฟ้าให้เหมาะสมกับช่วงเวลาต่าง ๆ ได้ ดังนั้นวิทยานิพนธ์นี้จึงมีวัตถุประสงค์ที่จะสร้างแบบจำลองการเรียนรู้เชิงลึกสำหรับการพยากรณ์หาค่าความต้องการใช้ไฟฟ้าที่มีความแม่นยำ โดยใช้ข้อมูลการใช้พลังงานไฟฟ้าในอดีตภายในวิทยาลัยพลังงานทดแทนและสมาร์ทกริดเทคโนโลยี มาทำการปรับค่าไฮเปอร์พารามิเตอร์และฝึกสอนแบบจำลอง รวมถึงใช้ปัจจัยอื่น ๆ ส่งผลต่อการพยากรณ์ประกอบไปด้วย อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ ทิศทางลม วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน จากการทดลอง พบว่าแบบจำลองที่สามารถพยากรณ์หาค่าความต้องการการใช้ไฟฟ้าที่มีผลลัพธ์ค่าความผิดพลาดน้อยที่สุด คือการใช้ข้อมูลความต้องการใช้พลังงานไฟฟ้าในอดีตร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน

Title	INTELLIGENT PREDICTION OF SGTECH BUILDING ENERGY CONSUMPTION BASED ON DEEP LEARNING
Author	Sorawut Jittanon
Advisor	Chakkrit Termritthikun, Ph.D.
Co-Advisor	Assistant Professor Yodthong Mensin, Ph.D.
Academic Paper	M.S. Thesis in Smart Grid Technology, Naresuan University, 2023
Keywords	carbon dioxide emission, deep learning, energy forecasting

ABSTRACT

Nowadays the increasing demand for electrical energy directly contributes to the release of carbon dioxide emissions which is a major source of greenhouse effect. The efficient management of electricity usage becomes a crucial factor that can help reduce carbon dioxide emissions. Accurate forecasting of future electricity demand is essential for optimizing usage behaviors across different time periods. As a result, this thesis aims to create a deep learning model to accurately forecast electricity demand using historical electricity consumption data within the school of Renewable Energy and Smart Grid Technology (SGtech). The model involves tuning hyperparameter and training the forecasting model using various influencing factors, including temperature, dew point, weather condition, wind direction, SGtech's working days, and time of day. The result of this model is the utilization of past electricity demand data coupled with the SGtech's working days and time of day, resulting in a highly accurate prediction model with minimal error values.

ประกาศขอบคุณการ

วิทยานิพนธ์ฉบับนี้สามารถสำเร็จไปได้ด้วยดี โดยทางผู้วิจัยได้รับความอนุเคราะห์เป็นอย่างสูง จาก รองศาสตราจารย์ ดร.บุญยัง ปลั่งกลาง ที่กรุณาสละเวลามาเป็นกรรมการสอบวิทยานิพนธ์ ให้ คำแนะนำและข้อเสนอแนะเพิ่มเติมเกี่ยวกับการดำเนินการทำวิทยานิพนธ์นี้ รวมถึงความช่วยเหลือเป็นอย่างดีจาก ดร.จักรกฤษ เต็มฤทธิกุล ประธานที่ปรึกษาวิทยานิพนธ์ และ ผู้ช่วยศาสตราจารย์ ดร.ยอดธง เม่นสิน กรรมการที่ปรึกษาวิทยานิพนธ์ ที่กรุณาให้คำปรึกษา แนะนำแนวทางการดำเนินงาน ตรวจสอบ และแก้ไขข้อบกพร่องต่าง ๆ ตลอดจนให้คำแนะนำอื่น ๆ ที่ช่วยให้การศึกษาและการทำวิทยานิพนธ์ของผู้วิจัยลุล่วงไปได้ด้วยดี ผู้วิจัยรู้สึกซาบซึ้งและขอขอบคุณอาจารย์ทุกท่านเป็นอย่างสูงไว้ ณ ที่นี้

ขอขอบคุณคณาจารย์และนักวิจัยของวิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยีทุกท่านที่ได้ให้ความช่วยเหลือในด้านต่าง ๆ ทั้ง การชี้แนะแนวทางการศึกษา แผนการทำวิทยานิพนธ์ การจัดกิจกรรมให้ความรู้ในด้านต่าง ๆ รวมถึงการให้ข้อมูลที่จำเป็นสำหรับการดำเนินการทำวิทยานิพนธ์แก่ผู้วิจัย

สุดท้ายขอขอบคุณครอบครัวผู้ให้การสนับสนุนอยู่เบื้องหลังการศึกษาและทำวิทยานิพนธ์ของผู้วิจัยตลอดเวลาการดำเนินงาน สำหรับกำลังใจและความห่วงใยตลอดมาจนเป็นแรงใจสำคัญที่ทำให้ผู้วิจัยสามารถดำเนินงานทุกอย่างจนเสร็จสิ้น

สรุจติ จิตตานนท์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
ประกาศคุุณูปการ	จ
สารบัญ	ฉ
สารบัญตาราง.....	ณ
สารบัญภาพ.....	ญ
บทที่ 1 บทนำ.....	1
ที่มาและความสำคัญ.....	1
วัตถุประสงค์.....	3
สมมติฐาน.....	3
ขอบเขตของการวิจัย.....	3
ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	4
สมาร์ตกริด (Smart Grid).....	4
การตอบสนองด้านโหลด (Demand Response).....	5
ระบบบริหารจัดการพลังงาน (Energy Management System).....	6
ข้อมูลอนุกรมเวลา (Time Series Data).....	8
การพยากรณ์การใช้พลังงาน (Energy Consumption Forecasting)	9
วิธีการพยากรณ์แบบดั้งเดิม (Traditional Method).....	10

ค่าเฉลี่ยเคลื่อนที่ (Moving Average).....	10
แบบจำลอง Holt—Winter (Holt-Winter Model).....	12
แบบจำลองการถดถอยอัตโนมัติ (Autoregressive Model)	13
แบบจำลองรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average Model)	13
ปัญญาประดิษฐ์ (Artificial Intelligence).....	15
การเรียนรู้ของเครื่อง (Machine learning).....	15
แบบจำลอง XGBoost (eXtreme Gradient Boosting Model).....	16
การเรียนรู้เชิงลึก (Deep Learning).....	17
โครงข่ายประสาทเทียม (Neural Network).....	18
ฟังก์ชันกระตุ้น (Activation Function).....	21
การฝึกสอนและทดสอบแบบจำลอง (Training and Testing Model).....	25
โครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent Neural Network)	27
Long Short-Term Memory Model (LSTM).....	28
แบบจำลองทรานส์ฟอร์มเมอร์ (Transformer Model).....	32
แบบจำลอง N-BEATS (Neural Basis Expansion Analysis for interpretable Time Series forecasting Model)	38
แบบจำลอง N-HITS (Neural Hierarchical Interpolation for Time Series Forecasting Model)	39
แบบจำลอง TFT (Temporal Fusion Transformer Model).....	40
บทที่ 3 วิธีดำเนินการวิจัย.....	43
การเตรียมข้อมูลสำหรับการฝึกสอนแบบจำลอง	43

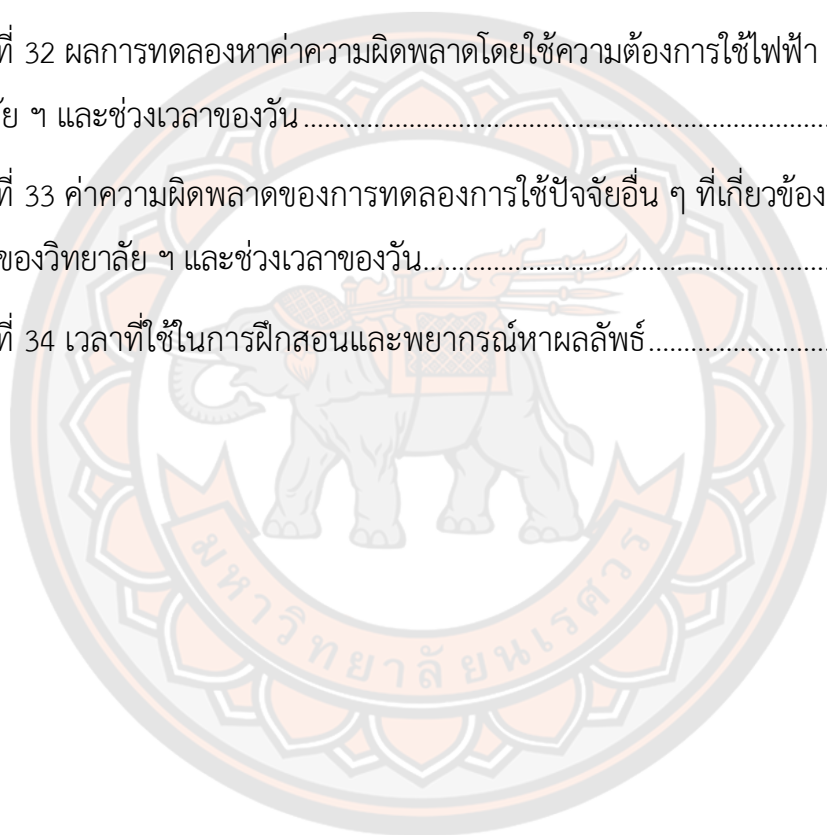
การพิจารณาเลือกปัจจัยที่ส่งผลแต่ความต้องการใช้ไฟฟ้า	44
การจัดการข้อมูลด้วยวิธีการเข้ารหัสป้าย	50
การวัดประสิทธิภาพของแบบจำลอง	55
บทที่ 4 ผลการดำเนินการวิจัย	58
ผลการทดลองค้นหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม	58
ผลการทดลองการใช้ปัจจัยอื่น ๆ ที่คาดว่าจะส่งผลต่อการพยากรณ์ความต้องการใช้ พลังงานไฟฟ้า	66
เปรียบเทียบผลการทดลองของชุดปัจจัย วันทำการของวิทยาลัย ฯ และ ช่วงเวลาของ วัน ร่วมกับปัจจัยอุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลม	93
แบ่งช่วงดัชนีเวลาของการใช้ปัจจัยความต้องการใช้ไฟฟ้าร่วมกับปัจจัยวันทำการของ วิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน	95
เปรียบเทียบผลการพยากรณ์กับแบบจำลอง N-BEATS และแบบจำลอง N-HiTs	99
การเปรียบเทียบเวลาที่ใช้ในการฝึกสอนแบบจำลองและพยากรณ์หาผลลัพธ์	104
บทที่ 5 สรุปและอภิปรายผลการทดลอง	105
สรุปผลการทดลอง	105
อภิปรายผลการทดลอง	106
ข้อจำกัดและแนวทางการแก้ไข	107
ข้อเสนอแนะและการนำไปใช้งานในอนาคต	107
บรรณานุกรม	108
ประวัติผู้วิจัย	113

สารบัญตาราง

	หน้า
ตารางที่ 1 ตัวอย่างข้อมูลการใช้พลังงานภายในอาคารในวิทยาลัยพลังงาน ฯ	43
ตารางที่ 2 ข้อมูลปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงาน.....	46
ตารางที่ 3 ข้อมูลสำหรับการฝึกสอนแบบจำลอง	53
ตารางที่ 4 สรุปข้อมูลสำหรับฝึกสอนแบบจำลอง.....	54
ตารางที่ 5 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 1 ทั้ง 5 ครั้ง	59
ตารางที่ 6 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 2 ทั้ง 5 ครั้ง	60
ตารางที่ 7 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 3 ทั้ง 5 ครั้ง	61
ตารางที่ 8 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 4 ทั้ง 5 ครั้ง	63
ตารางที่ 9 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 5 ทั้ง 5 ครั้ง	64
ตารางที่ 10 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 6 ทั้ง 5 ครั้ง	65
ตารางที่ 11 ค่าความผิดพลาดของการทดลองปรับไฮเปอร์พารามิเตอร์ทั้ง 6 ชุด.....	66
ตารางที่ 12 รูปแบบการทดลองปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงานร่วมกับปัจจัยที่เกี่ยวข้อง 1 ปัจจัย.....	67
ตารางที่ 13 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและอุณหภูมิ ..68	
ตารางที่ 14 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและอุณหภูมิจุดน้ำค้าง.....	69
ตารางที่ 15 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและสภาพอากาศ	71
ตารางที่ 16 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและทิศทางลม	72

ตารางที่ 17 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและวันทำการของวิทยาลัย ฯ.....	73
ตารางที่ 18 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและช่วงเวลาของวัน	74
ตารางที่ 19 รูปแบบการทดลองปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงานร่วมกับปัจจัยที่เกี่ยวข้อง 2 ปัจจัย.....	75
ตารางที่ 20 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และอุณหภูมิจุดน้ำค้าง.....	76
ตารางที่ 21 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และสภาพอากาศ.....	77
ตารางที่ 22 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และทิศทางลม.....	79
ตารางที่ 23 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และวันทำการของวิทยาลัย ฯ.....	79
ตารางที่ 24 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และช่วงเวลาของวัน.....	81
ตารางที่ 25 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง สภาพอากาศ.....	82
ตารางที่ 26 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และทิศทางลม.....	84
ตารางที่ 27 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และวันทำการของวิทยาลัย ฯ.....	85
ตารางที่ 28 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และช่วงเวลาของวัน	86

ตารางที่ 29 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และทิศทางลม.....	87
ตารางที่ 30 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และวันทำการของวิทยาลัย ฯ.....	89
ตารางที่ 31 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และช่วงเวลาของวัน	90
ตารางที่ 32 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน	92
ตารางที่ 33 ค่าความผิดพลาดของการทดลองการใช้ปัจจัยอื่น ๆ ที่เกี่ยวข้อง กับคู่ปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน.....	95
ตารางที่ 34 เวลาที่ใช้ในการฝึกสอนและพยากรณ์หาผลลัพธ์.....	104



สารบัญภาพ

	หน้า
ภาพที่ 1 เสาหลักของแผนพัฒนาระบบไฟฟ้าระยะปานกลาง.....	5
ภาพที่ 2 แผนภาพแสดงปริมาณกำลังไฟฟ้า (MW) ในการทำการตอบสนองด้านโหลด	6
ภาพที่ 3 แผนภาพอธิบายความเชื่อมโยงระหว่างปัญญาประดิษฐ์ (Artificial Intelligence) การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning).....	18
ภาพที่ 4 โครงสร้างเซลล์ประสาททางชีววิทยาของมนุษย์.....	19
ภาพที่ 5 โครงสร้างของเซลล์ประสาทเทียม.....	19
ภาพที่ 6 ส่วนประกอบของโครงข่ายประสาทเทียม.....	20
ภาพที่ 7 ส่วนประกอบของโครงข่ายประสาทเทียมที่มีความซับซ้อนมากขึ้น	21
ภาพที่ 8 กราฟของฟังก์ชันกระตุ้นซิกมอยด์.....	22
ภาพที่ 9 กราฟของฟังก์ชันกระตุ้นไฮเปอร์โบลิกแทนก์เจนท์ (tanh).....	23
ภาพที่ 10 กราฟของฟังก์ชันกระตุ้นเรคตีไฟด์ลิเนียยูนิต (ReLU).....	24
ภาพที่ 11 กราฟของฟังก์ชันลิกกี้เรคตีไฟด์ลิเนียยูนิต (Leaky ReLU).....	25
ภาพที่ 12 ภาพแสดงการแบ่งข้อมูลสำหรับฝึกสอนและทดสอบ	25
ภาพที่ 13 ภาพแสดงการแบ่งข้อมูลสำหรับฝึกสอน ทดสอบ และ Validation.....	26
ภาพที่ 14 การแบ่งข้อมูลสำหรับทำ K-Fold Cross Validation กรณี K = 5.....	26
ภาพที่ 15 โครงสร้างการทำงานของ Recurrent Neural Network.....	27
ภาพที่ 16 โครงสร้างการทำงานของ Long Short-Term Memory	29
ภาพที่ 17 ภาพแสดงส่วนของ Long Term Memory และ Short Term Memory.....	30
ภาพที่ 18 ภาพแสดง Forget Gate Input Gate และ Output Gate	30

ภาพที่ 19 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์.....	33
ภาพที่ 20 ภาพแสดงการหลักการทำงานในขั้นตอน Input Embedding	34
ภาพที่ 21 โครงสร้างของ Scaled Dot-Product Attention	35
ภาพที่ 22 โครงสร้างของ Multi-Head Attention.....	37
ภาพที่ 23 สถาปัตยกรรมของแบบจำลอง TFT (Temporal Fusion Transformer Model) .	41
ภาพที่ 24 ข้อมูลความต้องการใช้ไฟฟ้าเป็นรายชั่วโมงของอาคาร NDIR ที่มีลักษณะการใช้ไฟฟ้าแบบโพรซิวเมอร์.....	44
ภาพที่ 25 แผนที่ความร้อน (Heatmap) ของค่าสหสัมพันธ์ของปัจจัยที่คาดว่าจะมีผลต่อการพยากรณ์.....	45
ภาพที่ 26 ปริมาณอุณหภูมิแต่ละช่วงของปัจจัยที่เกี่ยวข้องอุณหภูมิ	47
ภาพที่ 27 ปริมาณอุณหภูมิจุดน้ำค้างแต่ละช่วงของปัจจัยที่เกี่ยวข้องอุณหภูมิจุดน้ำค้าง .	48
ภาพที่ 28 ปริมาณสภาพอากาศแต่ละชนิดของปัจจัยที่เกี่ยวข้องสภาพอากาศ	49
ภาพที่ 29 ปริมาณทิศทางลมแต่ละทิศของปัจจัยที่เกี่ยวข้องทิศทางลม	50
ภาพที่ 30 การจัดการข้อมูลด้วยวิธีการเข้ารหัสสายของข้อมูลทิศทางลม.....	51
ภาพที่ 31 การจัดการข้อมูลด้วยวิธีการเข้ารหัสสายของข้อมูลสภาพอากาศ.....	52
ภาพที่ 32 ข้อมูลความต้องการไฟฟ้ารายชั่วโมงหลังจากรวมกับปัจจัยที่เกี่ยวข้อง.....	55
ภาพที่ 33 ผลการคำนวณหาค่าความผิดพลาด MAE MSE และ RMSE ด้วยค่าสมมติ	56
ภาพที่ 34 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 1.....	58
ภาพที่ 35 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 2.....	60
ภาพที่ 36 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 3	61
ภาพที่ 37 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 4.....	62
ภาพที่ 38 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 5.....	63

ภาพที่ 39 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 6	65
ภาพที่ 40 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและอุณหภูมิ.....	68
ภาพที่ 41 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและอุณหภูมิจุดน้ำค้าง	69
ภาพที่ 42 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและสภาพอากาศ	70
ภาพที่ 43 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและทิศทางลม	71
ภาพที่ 44 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและวันทำการของวิทยาลัย ฯ.....	72
ภาพที่ 45 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและช่วงเวลาของวัน.....	73
ภาพที่ 46 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และอุณหภูมิจุดน้ำค้าง	76
ภาพที่ 47 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และสภาพอากาศ.....	77
ภาพที่ 48 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และทิศทางลม.....	78
ภาพที่ 49 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และวันทำการของ วิทยาลัย.....	80
ภาพที่ 50 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และช่วงเวลาของวัน....	81
ภาพที่ 51 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ น้ำค้าง และสภาพอากาศ	82
ภาพที่ 52 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ น้ำค้าง และทิศทางลม..	83
ภาพที่ 53 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ น้ำค้าง และวันทำการของ วิทยาลัย ฯ	84
ภาพที่ 54 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ น้ำค้าง และช่วงเวลาของ วัน	86
ภาพที่ 55 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และทิศทางลม	87
ภาพที่ 56 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และวันทำการของ วิทยาลัย ฯ	88

ภาพที่ 57 ผลการทดลองคูปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และช่วงเวลาของวัน	90
ภาพที่ 58 ผลการทดลองคูปัจจัยความต้องการใช้ไฟฟ้า วันทำการของวิทยาลัย ฯ และ ช่วงเวลาของวัน.....	91
ภาพที่ 59 ภาพเปรียบเทียบการใช้ปัจจัยอื่น ๆ ที่เกี่ยวข้อง กับคูปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน.....	94
ภาพที่ 60 ผลการทดลองช่วงที่ 1 ช่วงเวลา 16.00 น. วันที่ 18 มีนาคม 2565 ถึงช่วงเวลา 20.00 น. วันที่ 21 มีนาคม 2565	96
ภาพที่ 61 ผลการทดลองช่วงที่ 2 ช่วงเวลา 6.00 น. วันที่ 22 มีนาคม 2565 ถึงช่วงเวลา 10.00 น. วันที่ 25 มีนาคม 2565	97
ภาพที่ 62 ผลการทดลองช่วงที่ 3 ช่วงเวลา 11.00 น. วันที่ 25 มีนาคม 2565 ถึงช่วงเวลา 15.00 น. วันที่ 28 มีนาคม 2565	98
ภาพที่ 63 ผลการทดลองช่วงที่ 4 ช่วงเวลา 16.00 น. วันที่ 28 มีนาคม 2565 ถึงช่วงเวลา 20.00 น. วันที่ 31 มีนาคม 2565	99
ภาพที่ 64 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ช่วงที่ 1.....	100
ภาพที่ 65 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ช่วงที่ 2.....	101
ภาพที่ 66 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ช่วงที่ 3.....	102
ภาพที่ 67 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ช่วงที่ 4.....	103

บทที่ 1

บทนำ

ที่มาและความสำคัญ

ปัจจุบันปัญหาสภาวะโลกร้อนเป็นประเด็นสำคัญของโลกที่ทุกประเทศและทุกหน่วยงานมีส่วนเกี่ยวข้อง เนื่องจากการเพิ่มขึ้นของอุณหภูมิโลกอย่างต่อเนื่องจากการปล่อยก๊าซเรือนกระจกออกจากกิจกรรมต่าง ๆ ได้แก่ การผลิตพลังงาน คมนาคม เกษตรกรรม และอุตสาหกรรม โดยมีการปล่อยก๊าซเรือนกระจกทั้งคาร์บอนไดออกไซด์ (Carbon Dioxide) มีเทน (Methane) ไนตรัสออกไซด์ (Nitrous Oxide) และก๊าซกลุ่มฟลูออรีน (Fluorinated Gases) สู่สภาพแวดล้อมจำนวนมาก

ก๊าซคาร์บอนไดออกไซด์จัดเป็นหนึ่งในก๊าซเรือนกระจกที่ส่งผลกระทบต่อสภาวะโลกร้อนมากที่สุด อย่างไรก็ตามก๊าซคาร์บอนไดออกไซด์ไม่ได้ส่งผลกระทบโดยตรงต่อการเพิ่มขึ้นอย่างมีนัยสำคัญต่ออุณหภูมิโลก ปริมาณของก๊าซคาร์บอนไดออกไซด์นั้นมีการปล่อยออกมาเป็นจำนวนมาก ส่งผลให้เกิดปรากฏการณ์เรือนกระจก ดังนั้นทำให้ก๊าซคาร์บอนไดออกไซด์จำเป็นต้องมีการควบคุมจัดการอย่างเข้มงวดและมีประสิทธิภาพ

การบริหารจัดการและผลิตไฟฟ้าเพื่อใช้งาน ต้องคำนึงถึงปัจจัยเพื่อลดปัญหาการเกิดก๊าซคาร์บอนไดออกไซด์ ซึ่งเป็นหนึ่งในก๊าซเรือนกระจกที่ส่งผลกระทบต่อสภาพอากาศ สำหรับการผลิตไฟฟ้าในอดีตใช้ระบบผลิตไฟฟ้าแบบรวมศูนย์ (Centralized Generation) และมีการใช้เชื้อเพลิงฟอสซิลเป็นหลัก ซึ่งก่อให้เกิดการปล่อยก๊าซคาร์บอนไดออกไซด์ จากนั้นได้เปลี่ยนเป็นการผลิตไฟฟ้าแบบกระจายตัว (Distributed Generation) ให้อยู่ใกล้กับบริเวณพื้นที่ใช้งานและใช้พลังงานทดแทนซึ่งไม่มีการปล่อยก๊าซคาร์บอนไดออกไซด์ในกระบวนการผลิตสำหรับการผลิตไฟฟ้าเป็นหลัก ไม่ว่าจะเป็นพลังงานแสงอาทิตย์ พลังงานลม และพลังงานน้ำ เป็นต้น รวมถึงการบริหารจัดการการใช้ไฟฟ้าอย่างมีประสิทธิภาพและรองรับความผันผวนของพลังงานไฟฟ้าที่มาจากพลังงานทดแทนได้ รวมถึงเป็นการติดตั้งระบบกักเก็บพลังงานส่วนเกินไว้ใช้ในเวลาที่ไม่สามารถผลิตไฟฟ้าจากแหล่งพลังงานทดแทนได้ เพื่อลดการเดินเครื่องของโรงไฟฟ้าพลังงานฟอสซิล รวมถึงการเริ่มพึ่งพาการผลิตไฟฟ้าด้วยตัวเองของผู้บริโภคทั้งรายเล็กตามบ้านเรือนและโรงงานอุตสาหกรรม หรือการทำเป็นโครงข่ายไฟฟ้าขนาดเล็ก เพื่อบริหารจัดการการใช้ไฟฟ้าด้วยตัวเอง ซึ่งเรียกว่าไมโครกริด (Microgrid)

การบริหารจัดการการใช้ไฟฟ้าให้มีประสิทธิภาพ ทนสมัยและอัจฉริยะ เพื่อที่จะสามารถใช้งานพลังงานได้อย่างคุ้มค่า และมีความมั่นคงของระบบที่ดี จึงจำเป็นต้องมีการเก็บข้อมูลต่าง ๆ ที่สามารถนำมาใช้ประโยชน์ ได้แก่ ปริมาณการใช้ไฟฟ้าของแต่ละพื้นที่ แต่ละเวลา รวมไปถึงอุณหภูมิ ความชื้น

ความเข้มแสง หรือความเร็วลม เป็นต้น โดยข้อมูลดังกล่าวนี้สามารถนำมาวิเคราะห์เพื่อที่จะพยากรณ์ตัวแปรต่าง ๆ ที่จะส่งผลต่อการจัดการระบบไฟฟ้าทั้งด้านปริมาณพลังงานไฟฟ้าที่จะผลิตได้ และปริมาณการใช้พลังงานในแต่ละวัน เพื่อที่จะสามารถเตรียมมาตรการต่าง ๆ เพื่อรับมือกับการใช้ไฟฟ้าในแต่ละวันได้อย่างแม่นยำมากยิ่งขึ้น โดยเฉพาะอย่างยิ่งหากการพยากรณ์หาความต้องการใช้พลังงานนั้นมีความแม่นยำสูงใกล้เคียงกับปริมาณการใช้พลังงานจริง ส่งผลให้เกิดความมั่นคงของระบบไฟฟ้า และสามารถบริหารปริมาณการใช้พลังงานได้อย่างมีประสิทธิภาพ ด้วยเหตุผลนี้ จึงจำเป็นต้องใช้เครื่องมือที่มีความทันสมัยและอัจฉริยะเพื่อพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าได้อย่างแม่นยำ

ปัญญาประดิษฐ์ (Artificial Intelligence) คือวิธีการสร้างปัญญาให้กับคอมพิวเตอร์ให้มีความสามารถเช่นเดียวกับมนุษย์ กล่าวคือ ปัญญาที่ถูกประดิษฐ์ขึ้น เนื่องจากปัญญาประดิษฐ์นั้นเป็นเครื่องมือที่สามารถจัดการกับข้อมูลได้อย่างมีประสิทธิภาพ ทั้งสามารถวิเคราะห์ข้อมูลเป็นจำนวนมากได้อย่างแม่นยำ สามารถเรียนรู้ซ้ำ ๆ ได้แบบอัตโนมัติ และสามารถหาความสัมพันธ์ที่ซ่อนอยู่ในข้อมูลเพื่อนำมาใช้ประโยชน์ ปัญญาประดิษฐ์จัดเป็นเครื่องมือที่สามารถใช้ประโยชน์จากข้อมูลที่มีอยู่เป็นจำนวนมากได้อย่างมีประสิทธิภาพ ปัจจุบันการใช้งานปัญญาประดิษฐ์ได้รับความนิยมอย่างแพร่หลายทั่วโลก โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เพื่อสร้างระบบการพยากรณ์การใช้พลังงานไฟฟ้าจากข้อมูลที่เก็บไว้ในอดีตมาใช้ในการเรียนรู้ของระบบให้สามารถพยากรณ์การใช้พลังงานได้อย่างแม่นยำค่าความคลาดเคลื่อนต่ำ และมีความรวดเร็วในการประมวลผลที่สามารถรับยอมรับได้ จากลักษณะของข้อมูลปริมาณความต้องการใช้ไฟฟ้าที่มีจำนวนมากและมีความซับซ้อนระหว่างของข้อมูลที่มนุษย์ไม่สามารถนำมาคำนวณหาผลลัพธ์ได้ด้วยวิธีการคำนวณแบบปกติ ทั้งในด้านความถูกต้องและครบถ้วนของการคำนวณ รวมถึงด้านระยะเวลาที่ใช้ในการคำนวณเป็นเวลานานอันเนื่องมาจากปริมาณของข้อมูล ดังนั้นปัญญาประดิษฐ์จึงเป็นเครื่องมือที่เหมาะสมสำหรับการนำมาใช้พัฒนาระบบการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้า

ทั้งนี้การศึกษาและพัฒนาระบบการพยากรณ์การดังกล่าวนี้ จำเป็นต้องมีข้อมูลการใช้พลังงานไฟฟ้าย้อนหลังจำนวนมาก และมีพื้นที่ที่สามารถนำระบบมาทดสอบเทียบกับปริมาณการใช้พลังงานไฟฟ้าจริง เพื่อที่จะสามารถประเมินความแม่นยำของระบบได้อย่างถูกต้อง ด้วยเหตุนี้ ทำให้วิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยี มหาวิทยาลัยนเรศวร เหมาะที่จะเป็นสถานที่พัฒนาและทดสอบระบบการพยากรณ์ความต้องการใช้พลังงาน เนื่องจากแต่ละอาคารในวิทยาลัย ๆ ต่างมีพฤติกรรมการใช้พลังงานไฟฟ้าที่แตกต่างกัน เหมาะสำหรับการจำลองพฤติกรรมการใช้พลังงานจริงของผู้บริโภค และสามารถทดสอบระบบโดยการเปรียบเทียบกับข้อมูลปริมาณการใช้พลังงานไฟฟ้าจริงของภายในวิทยาลัย ๆ ได้โดยตรง รวมถึงยังสอดคล้องกับหนึ่งในเป้าหมายของวิทยาลัยพลังงานทดแทน ๆ ที่จะสร้างระบบนิเวศน์ที่สามารถใช้ผลิตพลังงานไฟฟ้าใช้งานภายในพื้นที่ด้วย

ตัวเอง โดยพึ่งพาการเชื่อมต่อโครงข่ายไฟฟ้าภายนอกให้น้อยที่สุด เพื่อเป็นต้นแบบแก่หน่วยงานอื่น ที่สนใจในสามารถเข้ามาศึกษาระบบต่อไป

วัตถุประสงค์

1. เพื่อพัฒนาระบบการพยากรณ์การใช้พลังงานไฟฟ้าสำหรับใช้งานในอาคารของวิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยี
2. เพื่อเปรียบเทียบประสิทธิภาพ ด้านความแม่นยำและความเร็วในการประมวลผลของแบบจำลองที่ใช้ในปัจจุบันและแบบจำลองการเรียนรู้เชิงลึก

สมมติฐาน

สามารถพัฒนาระบบที่พยากรณ์ปริมาณการใช้ไฟฟ้าของแต่ละอาคารของวิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยี โดยใช้แบบจำลองการเรียนรู้เชิงลึก

ขอบเขตของการวิจัย

ใช้ข้อมูลการใช้พลังงานไฟฟ้าของอาคาร NDIR วิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยีสำหรับอาคารที่มีการใช้พลังงานไฟฟ้าแบบบริโภคอย่างเดียว ตั้งแต่วันที่ 1 มกราคม 2565 ถึง 31 ธันวาคม 2565 เพื่อพัฒนาระบบการพยากรณ์การใช้พลังงานภายในวิทยาลัย ฯ

ประโยชน์ที่คาดว่าจะได้รับ

1. ได้ระบบการพยากรณ์การใช้พลังงานภายในอาคารของวิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยี เพื่อที่จะสามารถนำไปใช้ในการวางแผนการจัดการการใช้พลังงานภายในวิทยาลัยฯ
2. สามารถนำระบบที่พัฒนาไปทดลองกับพื้นที่อื่น ๆ และพัฒนาต่อยอดเพื่อที่จะทำให้ระบบสามารถใช้งานได้ครอบคลุมทุกพื้นที่

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

ในวิทยานิพนธ์นี้ศึกษาเกี่ยวกับการพยากรณ์หาค่าความต้องการใช้พลังงานไฟฟ้าด้วยการเรียนรู้เชิงลึก ซึ่งในบทนี้อธิบายถึงหลักการ ทฤษฎี และเทคโนโลยีที่มีความสำคัญ ประกอบไปด้วยเทคโนโลยีด้านการจัดการกับความความต้องการใช้พลังงานที่ใช้ในปัจจุบันรวมถึงแผนการจัดการพลังงานในอนาคตของประเทศไทย ทฤษฎีของการพยากรณ์การใช้พลังงาน รวมถึงเทคนิคการพยากรณ์การใช้พลังงานตั้งแต่ในอดีตถึงปัจจุบัน

สมาร์ตกริด (Smart Grid)

สมาร์ตกริด หรือ ระบบโครงข่ายไฟฟ้าอัจฉริยะ คือการพัฒนาาระบบไฟฟ้าให้สามารถใช้งานได้อย่างชาญฉลาด มีประสิทธิภาพ ใช้ทรัพยากรลดลง มีความปลอดภัย เชื่อถือได้ รวมถึงมีความยั่งยืน และเป็นมิตรต่อสิ่งแวดล้อม ซึ่งการจะทำให้ระบบไฟฟ้ามีความสามารถดังกล่าวได้ จำเป็นต้องอาศัยเทคโนโลยีหลากหลายชนิด ทั้งเทคโนโลยีด้านการสื่อสาร เทคโนโลยีสารสนเทศ ระบบเซ็นเซอร์ ระบบเก็บข้อมูล และเทคโนโลยีทางด้านการควบคุมอัตโนมัติ เพื่อให้ระบบไฟฟ้า สามารถสื่อสารและสั่งการไปยังส่วนต่าง ๆ ภายในระบบไฟฟ้าได้อย่างอัตโนมัติ โดยเทคโนโลยีเหล่านี้จะต้องเกิดขึ้นในทุก ๆ ส่วนของระบบไฟฟ้า ไม่ว่าจะเป็น ฝ่ายการผลิต ระบบส่งและจำหน่าย รวมถึงผู้ใช้ไฟฟ้า

ด้านการผลิตไฟฟ้าต้องปรับเปลี่ยนจากการใช้ระบบการผลิตไฟฟ้าแบบรวมศูนย์ (Centralized Generation) ไปเป็นการผลิตไฟฟ้าแบบกระจายตัว (Distributed Generation) ให้มากขึ้นเพื่อลดการสูญเสียพลังงานไฟฟ้าโดยเปล่าประโยชน์จากการส่งจ่ายในระยะทางที่ไกล ทางด้านผู้ใช้ไฟฟ้าจะต้องเปลี่ยนพฤติกรรมการใช้ไฟฟ้า และใช้การผลิตไฟฟ้าจากแหล่งพลังงานทดแทนเพื่อลดปริมาณความต้องการไฟฟ้าจากระบบไฟฟ้าหลัก นอกจากนี้ เทคโนโลยีที่เกี่ยวกับการบริหารจัดการการใช้พลังงานจัดเป็นส่วนสำคัญอีกส่วนหนึ่ง

ในประเทศไทยได้วางแผนในการพัฒนาระบบไฟฟ้าให้มีความอัจฉริยะมากขึ้นดัง “แผนแม่บทการพัฒนาระบบโครงข่ายสมาร์ตกริดของประเทศไทย พ.ศ. 2558-2579”(1) โดยมีการแบ่งแผนออกเป็น 4 ระยะ ได้แก่ ระยะเตรียมการ ระยะสั้น ระยะปานกลาง และระยะยาว ปัจจุบันประเทศไทยได้เข้าสู่แผนระยะปานกลาง ตั้งแต่ปี พ.ศ. 2565-2574 โดยในแผนระยะปานกลางนี้จะมีเสาหลัก 5 เสา สำหรับการพัฒนาระบบไฟฟ้าในประเทศไทย คือ เสาหลักที่ 1 การตอบสนองด้านโหลดและระบบบริหารจัดการพลังงาน (Demand Response and Energy Management System) เสาหลักที่ 2 การพยากรณ์ไฟฟ้าที่ผลิตได้จากพลังงานหมุนเวียน (Renewable Energy Forecasting) เสา

หลักที่ 3 ระบบไมโครกริดและโพรซูเมอร์ (Microgrid and Prosumer) เสหลักที่ 4 ระบบกักเก็บพลังงาน (Energy Storage System) และเสหลักที่ 5 การบูรณาการยานยนต์ไฟฟ้า (Electrical Vehicle Integration)



ภาพที่ 1 เสหลักของแผนพัฒนาระบบไฟฟ้าระยะปานกลาง

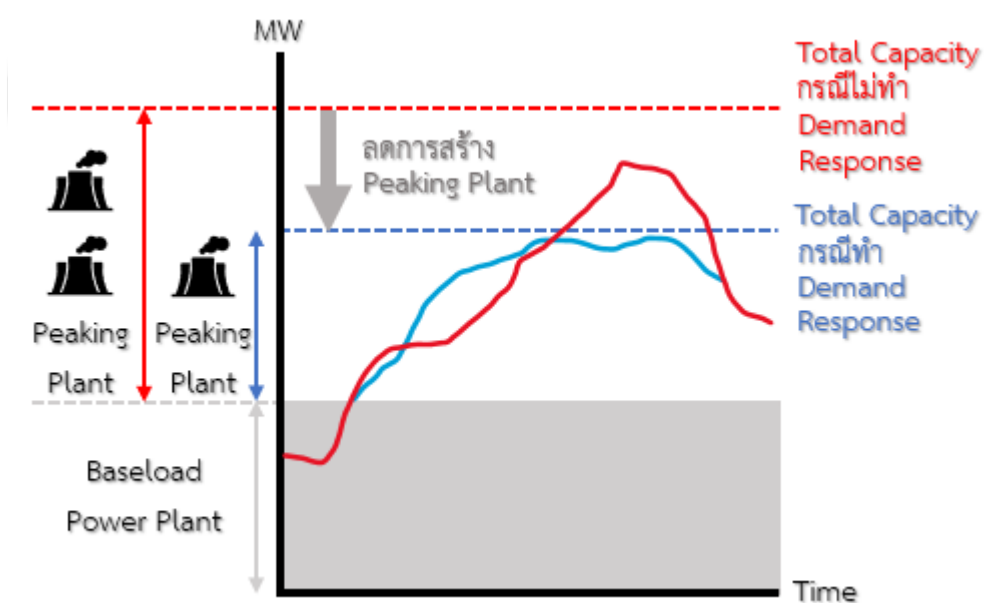
(ที่มา: <http://www.eppo.go.th/index.php/th/component/k2/item/17705-news-210165-01>)

การตอบสนองด้านโหลด (Demand Response)

การตอบสนองด้านโหลด (Demand Response: DR) คือการบริหารจัดการทางด้านอุปสงค์ (Demand) ของปริมาณไฟฟ้า หรือความต้องการใช้ไฟฟ้าของผู้บริโภค โดยต้องการเปลี่ยนแปลงพฤติกรรมและรูปแบบการใช้ไฟฟ้าไปจากปกติของผู้บริโภคให้สอดคล้องกับความต้องการใช้ไฟฟ้าโดยรวมในขณะนั้น (2-4) วัตถุประสงค์หลักของการทำการตอบสนองด้านโหลดคือ การที่สามารถจัดการกับความต้องการใช้ไฟฟ้าในช่วงเวลาที่มีความต้องการไฟฟ้าสูงสุด (Peak Demand) ได้ โดยไม่ต้องพึ่งพาการเดินเครื่องโรงไฟฟ้าหรือแม้กระทั่งการก่อสร้างโรงไฟฟ้าสำหรับจ่ายไฟฟ้าในช่วงที่มีความต้องการไฟฟ้าสูงสุด (Peaking Plant) ซึ่งมีต้นทุนสูงกว่าการเดินเครื่องโรงไฟฟ้าที่ผลิตไฟฟ้าตาม

ความต้องการมาตรฐานของประเทศ (Baseload Power Plant) ที่มีการเดินเครื่องอย่างต่อเนื่องอยู่เป็นปกติ อีกทั้งโรงไฟฟ้าที่มีไว้สำหรับจ่ายไฟฟ้าในช่วงที่มีความต้องการสูงสุดนั้น จะมีเวลาการเดินเครื่องต่อเนื่องไม่นาน ถือว่าไม่มีความคุ้มค่าในการก่อสร้างโรงไฟฟ้าเพื่อผลิตไฟฟ้าใช้งานในช่วงเวลาดังกล่าว แต่จะทำการลดปริมาณการใช้ไฟฟ้าในส่วนที่สามารถลดได้เพื่อให้สามารถใช้ไฟฟ้าได้อย่างเพียงพอตามความต้องการ (5)

การทดแทนการเดินเครื่องของโรงไฟฟ้าสำหรับจ่ายกำลังไฟฟ้าในช่วงที่มีความต้องการสูงสุดนั้น จำเป็นต้องลดการใช้ไฟฟ้าลงปริมาณที่สูงพอที่จะนำมาทดแทนกำลังไฟฟ้าที่ต้องการได้ โดยสามารถใช้วิธีการลดปริมาณการใช้ไฟฟ้าได้อย่างมีประสิทธิภาพ จำเป็นต้องมีการปรับเปลี่ยนพฤติกรรมการใช้ไฟฟ้าในเวลาที่ต้องการ จึงต้องรวบรวมผู้ที่สามารถดำเนินการลดการใช้ไฟฟ้าในเวลาที่ต้องการจำนวนมากเพื่อเข้าร่วมโครงการการตอบสนองด้านโหลด และมีค่าตอบแทนสำหรับการลดการใช้ไฟฟ้าตามจำนวนที่ลดได้ โดยการที่จะเข้าร่วมโครงการการตอบสนองด้านโหลด ผู้เข้าร่วมจะต้องมีประวัติพฤติกรรมการใช้ไฟฟ้าที่แน่นอน เป็นที่เชื่อได้ว่าสามารถลดปริมาณการใช้ไฟฟ้าลงได้เมื่อมีการร้องขอจากโครงการ (6)



ภาพที่ 2 แผนภาพแสดงปริมาณกำลังไฟฟ้า (MW) ในการทำการตอบสนองด้านโหลด

(ที่มา: <https://thai-smartgrid.com/เกี่ยวกับสมาร์ทกริด/tech-basic-related-smartgrid/dr/>)

ระบบบริหารจัดการพลังงาน (Energy Management System)

ระบบบริหารจัดการพลังงาน (Energy Management System: EMS) คือระบบที่ใช้สำหรับควบคุมการผลิต และการใช้พลังงานให้มีประสิทธิภาพมากที่สุด โดยในทางด้านพลังงานไฟฟ้านั้นจะ

เน้นการจัดการกับผู้ที่ใช้ไฟฟ้าในบริเวณที่เจ้าของพื้นที่ใช้งานเอง (7-9) ไม่ว่าจะเป็นอาคารบ้านเรือน โรงงานอุตสาหกรรม หรืออาคารพาณิชย์ต่าง ๆ ให้เหมาะสมกับสภาพแวดล้อมและสถานการณ์ เวลา นั้น ๆ ซึ่งการที่จะสามารถบริหารจัดการพลังงานนั้นจำเป็นต้องมีอุปกรณ์ต่าง ๆ ทั้งอุปกรณ์ตรวจวัด (Sensor) มิเตอร์อัจฉริยะ (Smart Meter) และระบบควบคุมอัตโนมัติ (Controller) เพื่อรวบรวมข้อมูลสำหรับใช้ในระบบการจัดการพลังงาน แล้วทำการวิเคราะห์และพยากรณ์ความต้องการใช้ไฟฟ้า เพื่อให้สามารถใช้ไฟฟ้าได้อย่างเหมาะสม รวมถึงสามารถเข้าถึงและสั่งการการทำงานของอุปกรณ์ต่าง ๆ ในระบบจากระยะไกลผ่านทางอุปกรณ์เคลื่อนที่ได้ การติดตั้งระบบผลิตไฟฟ้าจากพลังงาน หมุนเวียนและระบบกักเก็บพลังงานยังช่วยให้ระบบการบริหารจัดการพลังงานสามารถจัดการการใช้ ไฟฟ้าได้ดียิ่งขึ้น ซึ่งระบบบริหารจัดการพลังงานนั้นจะขึ้นอยู่กับความเหมาะสมในด้านเศรษฐศาสตร์ เป็นสำคัญ คือการที่ลดค่าใช้จ่ายในด้านของไฟฟ้าให้ได้มากที่สุด แต่จะต้องไม่ส่งผลกระทบต่อในด้านอื่น ๆ ของระบบรวมถึงการดำเนินชีวิตของผู้ใช้งานด้วย โดยหลักการทำงานและความซับซ้อนของระบบ บริหารจัดการพลังงานขึ้นอยู่กับขนาดของระบบไฟฟ้าที่ผู้ติดตั้งใช้งานอยู่ (10)

ระบบบริหารจัดการพลังงานในบ้านเรือน (Home Energy Management System: HEMS) และระบบจัดการพลังงานในอาคาร (Building Energy Management System: BEMS) เป็นระบบที่ เชื่อมโยงอุปกรณ์ไฟฟ้าและระบบต่าง ๆ ภายในบ้านหรืออาคารเข้าด้วยกัน โดยเชื่อมต่อไปยังระบบ ความคุมส่วนกลาง เมื่อมีการเปลี่ยนแปลงจากสภาวะภายนอกที่มีผลต่อระบบไฟฟ้าหรือมีผลต่อการ ทำงานของอุปกรณ์ไฟฟ้าภายใน ระบบควบคุมจะทำการวิเคราะห์หาวิธีที่เหมาะสมที่สุด เช่น การลด โหลดที่ไม่มีความจำเป็น หรือการนำไฟฟ้าที่เก็บไว้ในระบบกักเก็บพลังงานมาใช้ ในบางกรณีหากมีการ ใช้ไฟฟ้าน้อยลงระบบควบคุมจะทำการสั่งการให้นำไฟฟ้าไปเก็บไว้ในระบบกักเก็บหรือสามารถ ตัดสินใจนำไฟฟ้าออกสู่ระบบไฟฟ้าหลักเพื่อจำหน่ายได้หากวิเคราะห์ออกมาว่ามีความคุ้มค่ามากกว่า ทั้งนี้ทั้งระบบบริหารจัดการพลังงานในบ้านเรือนและในอาคารก็มีความแตกต่างกันในด้านของความ ซับซ้อนของระบบ เนื่องจากภายในอาคารพาณิชย์มีจำนวนอุปกรณ์ไฟฟ้าและความซับซ้อนของระบบ ไฟฟ้าที่มากกว่าในบ้านเรือน

ระบบบริหารจัดการพลังงานในโรงงานอุตสาหกรรม (Factory Energy Management System: FEMS) เป็นระบบจัดการพลังงานที่สามารถควบคุมระบบต่าง ๆ ภายในโรงงานอุตสาหกรรม ได้ ไม่เพียงแต่อุปกรณ์ไฟฟ้าทั่วไปเท่านั้น แต่สามารถควบคุมทั้งกระบวนการผลิตของโรงงาน อุตสาหกรรมได้ รวมถึงบริหารจัดการการใช้พลังงานได้อย่างเหมาะสม อย่างไรก็ตามระบบบริหาร จัดการในโรงงานอุตสาหกรรมจะมีความซับซ้อนมากกว่าภายในบ้านและอาคารพาณิชย์ เนื่องจาก โรงงานแต่ละแห่งมีกระบวนการผลิตที่แตกต่างกันทำให้พฤติกรรมการใช้พลังงานแตกต่างกัน ดังนั้น ระบบดังกล่าวจึงจัดเป็นระบบที่จะสามารถช่วยในด้านอุตสาหกรรมให้มีด้านกระบวนการผลิตได้มี ประสิทธิภาพยิ่งขึ้น

ทั้งการตอบสนองด้านโหลดและระบบบริหารจัดการพลังงานนั้นจำเป็นที่จะต้องสามารถทราบถึงปริมาณความต้องการใช้ไฟฟ้าล่วงหน้า เพื่อเตรียมความพร้อมสำหรับการลดการใช้พลังงานไฟฟ้าในเวลาที่เป็นและเข้าร่วมกับการทำการตอบสนองด้านโหลด หรือการควบคุมปริมาณการใช้ไฟฟ้าให้เหมาะสมของผู้ใช้ไฟฟ้าที่ต้องการใช้ระบบการบริหารจัดการพลังงาน ดังนั้นการที่สามารถพยากรณ์หาค่าความต้องการพลังงานไฟฟ้าล่วงหน้าได้นั้นมีความจำเป็นอย่างยิ่ง สำหรับการพยากรณ์หาค่าในอนาคตได้นั้น จำเป็นต้องมีชุดข้อมูลย้อนหลังสำหรับนำมาใช้วิเคราะห์หาลักษณะต่าง ๆ หรือทำการสร้างกระบวนการสำหรับการสร้างแบบจำลองเพื่อการพยากรณ์ ซึ่งลักษณะของชุดข้อมูลที่ใช้ในการพยากรณ์หาค่าความต้องการไฟฟ้าไม่ว่าจะเป็น ข้อมูลการใช้ไฟฟ้าย้อนหลัง และปัจจัยภายนอก เช่น อุณหภูมิ ความดัน หรือความชื้น ล้วนแต่เป็นข้อมูลที่มีลักษณะสัมพันธ์กับเวลา ดังนั้นจึงจำเป็นต้องมีการเรียนรู้และศึกษาลักษณะข้อมูลดังกล่าวเพื่อเพิ่มประสิทธิภาพการพยากรณ์ให้มีความแม่นยำมากขึ้น

ข้อมูลอนุกรมเวลา (Time Series Data)

ข้อมูลอนุกรมเวลาเป็นข้อมูลที่เก็บข้อมูลรวมกันในช่วงเวลาต่าง ๆ โดยข้อมูลอนุกรมเวลาถูกใช้งานอย่างแพร่หลายในหลายด้านเพื่อเข้าใจพฤติกรรมของข้อมูลในขณะนั้น ๆ ต่อเวลา เพื่อทำการวิเคราะห์และพยากรณ์ข้อมูลที่จะเกิดขึ้นในอนาคตได้ (11) โดยข้อมูลอนุกรมเวลานั้นช่วยให้สามารถสังเกตการเปลี่ยนแปลงและแนวโน้ม (Trend) ของข้อมูลได้เมื่อเวลาผ่านไป

ข้อมูลอนุกรมเวลา มีความสามารถในการตรวจจับโครงสร้างทางเวลาของชุดข้อมูล โดยสามารถจำแนกส่วนประกอบออกเป็น 4 ส่วน เพื่อให้สามารถทำความเข้าใจเกี่ยวกับรูปแบบและโครงสร้างภายในชุดข้อมูลอนุกรมเวลาได้อย่างลึกซึ้ง (12) และส่งผลให้การพยากรณ์มีความแม่นยำมากขึ้น โดยส่วนแรกคือ แนวโน้ม เป็นส่วนประกอบของข้อมูลอนุกรมเวลาที่แสดงถึงทิศทางหรือการเคลื่อนที่ในระยะยาวที่สังเกตได้ในข้อมูล โดยจะมีค่าเพิ่มขึ้นหรือลดลงเรื่อย ๆ เมื่อเวลาผ่านไป การระบุแนวโน้มได้จึงเป็นสิ่งสำคัญสำหรับการเข้าใจพฤติกรรมของชุดข้อมูล ทำให้สามารถพยากรณ์ข้อมูลในอนาคตได้มีประสิทธิภาพ ส่วนถัดมาคือ ฤดูกาล (Seasonality) เป็นการเปลี่ยนแปลงข้อมูลที่มีลักษณะการเพิ่มขึ้นหรือลดลงของวงรอบระยะเวลาหนึ่งที่แน่นอน หรืออาจเรียกว่าการเปลี่ยนแปลงตามฤดูกาล หน่วยของระยะเวลาสำหรับข้อมูลสามารถเป็นได้หลายรูปแบบ ได้แก่ รายชั่วโมง รายวัน รายสัปดาห์ รายเดือน รายไตรมาส หรือรายปี โดยการเปลี่ยนแปลงตามฤดูกาลนั้นสามารถกำหนดระยะเวลาการเกิดซ้ำในรอบหนึ่ง ๆ ได้ค่อนข้างแน่นอน ส่วนประกอบถัดมาคือ วัฏจักร (Cycle) เป็นวงรอบการเกิดซ้ำของข้อมูลที่มีการเพิ่มขึ้นและลดลงสลับกันไปเมื่อเวลาผ่านไปเช่นเดียวกับฤดูกาลแต่ มักจะเกิดในวงรอบที่มีระยะเวลายาวกว่าและมีความผันผวน โดยรูปแบบของข้อมูลที่เกิดขึ้นอาจได้รับผลกระทบจากปัจจัยภายนอกอื่น ๆ ไม่ว่าจะเป็นปัจจัยทางเศรษฐกิจ ปัจจัยจากเทคโนโลยี หรือปัจจัย

จากการกำหนดนโยบายต่าง ๆ เนื่องจากการนับเวลาของวัฏจักรนั้นไม่มีระยะเวลาที่แน่นอน เหมือนกับฤดูกาล ทำให้การกำหนดระยะเวลาจะนับจากจุดสูงสุดหรือจุดต่ำสุดหนึ่งไปยังอีกจุดสูงสุดหรืออีกจุดต่ำสุดหนึ่งจึงจะถือว่าเป็นช่วงของคาบเวลา ส่วนประกอบสุดท้ายของข้อมูลแบบอนุกรมเวลาคือ ความผันผวนที่ไม่สม่ำเสมอ (Irregular Fluctuation) เป็นส่วนที่ทำให้ข้อมูลอนุกรมเวลามีค่าผิดปกติไปจากรูปแบบที่เคยเป็น ซึ่งไม่สามารถอธิบายได้จากส่วนประกอบอื่น ๆ ของข้อมูลอนุกรมเวลาที่กล่าวไปก่อนหน้านี้ ความผันผวนที่ไม่สม่ำเสมอมักเกิดจากเหตุการณ์ที่ไม่คาดฝัน หรือข้อผิดพลาดต่าง ๆ

การเข้าใจลักษณะและคุณสมบัติของข้อมูลอนุกรมเวลาเป็นสิ่งสำคัญสำหรับการวิเคราะห์และสร้างแบบจำลอง โดยวิธีการทางสถิติและแบบจำลองต่าง ๆ ถูกนำมาใช้ในการอธิบายรูปแบบและการเคลื่อนไหวภายในข้อมูล เช่น การปรับเรียบด้วยเส้นโค้งเลขชี้กำลัง (Exponential Smoothing) และแบบจำลองรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average: ARIMA) รวมถึงการใช้เครื่องมืออย่างปัญญาประดิษฐ์ (Artificial Intelligence) การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning)

ข้อมูลอนุกรมเวลาถูกประยุกต์ใช้ในหลายสาขา ไม่ว่าจะเป็นด้านการเงินใช้ในการวิเคราะห์ราคาหุ้น ค่าเงิน หรือสินทรัพย์ต่าง ๆ เพื่อหาแนวโน้มของราคาในอนาคตสำหรับการลงทุน ในด้านเศรษฐศาสตร์ใช้ข้อมูลอนุกรมเวลาในการพยากรณ์ตัวชี้วัดเศรษฐกิจ เช่น ผลิตภัณฑ์มวลรวมในประเทศ อัตราเงินเฟ้อ หรืออัตราการว่างงาน ในด้านการบริหารและกำหนดนโยบายสำหรับผู้ประกอบการ และหน่วยงานของรัฐบาล นอกจากนี้ข้อมูลอนุกรมเวลายังเป็นสิ่งสำคัญสำหรับการพยากรณ์อากาศ การจำลองสภาพภูมิอากาศ และการศึกษาแนวโน้มของภูมิอากาศในระยะยาว

การพยากรณ์การใช้พลังงานนั้น ข้อมูลที่ใช้สำหรับวิเคราะห์คือข้อมูลที่มีลักษณะสัมพันธ์ต่อเวลา ไม่ว่าจะเป็นปริมาณการใช้พลังงานย้อนหลัง ปริมาณการผลิตพลังงานย้อนหลัง อุณหภูมิ ความดัน หรือความชื้น ณ เวลาต่าง ๆ ดังนั้นการใช้วิธีการวิเคราะห์อนุกรมเวลาเข้ามาช่วยเพิ่มประสิทธิภาพการพยากรณ์การใช้พลังงานได้

การพยากรณ์การใช้พลังงาน (Energy Consumption Forecasting)

การพยากรณ์การใช้พลังงานเป็นเครื่องมือสำคัญสำหรับวางแผนด้านนโยบายการใช้พลังงาน เพื่อให้สามารถตัดสินใจอย่างมีประสิทธิภาพเกี่ยวกับการผลิตพลังงาน การส่งจ่ายพลังงาน และการบริโภคพลังงาน โดยการพยากรณ์ความต้องการพลังงานและการจัดหาพลังงานในอนาคตจากข้อมูลการใช้พลังงานในอดีต (13)

การพยากรณ์การใช้พลังงานไฟฟ้าเป็นหนึ่งในการพยากรณ์พลังงานที่เน้นการหาปริมาณการใช้พลังงานไฟฟ้าที่มีความสำคัญสำหรับผู้ให้บริการไฟฟ้า ผู้ประกอบการ ผู้บริโภค รวมถึงผู้กำหนดนโยบายและมาตรการต่าง ๆ เพื่อให้มั่นใจได้ว่าจะมีการส่งมอบไฟฟ้าที่เชื่อถือได้

การพยากรณ์การใช้พลังงานไฟฟ้าให้มีประสิทธิภาพ ต้องพิจารณาปัจจัยหลักหลายประการ ได้แก่ เป็นรูปแบบการใช้ในอดีต การแปรผันตามฤดูกาล ตัวชี้วัดทางเศรษฐกิจ การ ความก้าวหน้าทางเทคโนโลยี และมาตรการประหยัดพลังงาน โดยการพิจารณาปัจจัยเหล่านี้ ผู้ทำการพยากรณ์สามารถระบุแนวโน้ม รูปแบบ และปัจจัยที่สร้างผลกระทบต่อการใช้ไฟฟ้าได้อย่างแม่นยำ จึงช่วยให้การพยากรณ์เป็นไปได้อย่างแม่นยำ (10, 14)

วิธีการพยากรณ์แบบดั้งเดิม (Traditional Method)

การพยากรณ์การใช้พลังงานในอดีตได้มีการเลือกใช้หลายวิธีการ โดยส่วนใหญ่จะเน้นการใช้กระบวนการด้านสถิติในการวิเคราะห์ข้อมูลในอดีต โดยมีวิธีการที่ได้รับความนิยมคือ การวิเคราะห์แนวโน้ม (Trend Analysis) โดยใช้การวิเคราะห์ข้อมูลในอดีตเพื่อระบุและพยากรณ์แนวโน้มในการใช้หรือผลิตพลังงานในระยะยาว โดยการวิเคราะห์แนวโน้มสามารถช่วยประมาณการเพิ่มขึ้นหรือลดลงของความต้องการพลังงานโดยรวมได้ วิธีการถัดมาคือ การวิเคราะห์การถดถอย (Regression Analysis) เป็นเทคนิคทางสถิติที่วิเคราะห์ความสัมพันธ์ระหว่างตัวแปรตามและตัวแปรอิสระ ในการพยากรณ์พลังงาน เทคนิคนี้สามารถใช้ในการระบุปัจจัยที่มีผลต่อความต้องการพลังงาน เช่น ประชากร ผลิตภัณฑ์มวลชน สภาพอากาศ หรือกิจกรรมอุตสาหกรรม โดยการวิเคราะห์ข้อมูลในอดีตและปรับแบบจำลองการถดถอย สามารถพยากรณ์ความต้องการพลังงานในอนาคตได้โดยอิงค่าของตัวแปรเหล่านี้ หรือการพยากรณ์แบบอนุमान (Analogous Forecasting) คือการระบุรอบเวลาหรือรูปแบบในอดีตที่คล้ายคลึงกัน และใช้รูปแบบการใช้หรือการผลิตพลังงานในอดีตเป็นพื้นฐานสำหรับการพยากรณ์ในอนาคต วิธีการนี้อูมานว่าเงื่อนไขที่คล้ายคลึงกันในอดีตจะนำไปสู่ผลลัพธ์ของพลังงานที่คล้ายคลึงกันในอนาคต การพยากรณ์แบบอนุमानสามารถเป็นประโยชน์ได้เมื่อไม่ปรากฏข้อมูลในอดีตหรือเมื่อมีการเปลี่ยนแปลงสำคัญในสภาพแวดล้อม

ค่าเฉลี่ยเคลื่อนที่ (Moving Average)

ค่าเฉลี่ยเคลื่อนที่ (Moving Average) เป็นเทคนิคทางสถิติที่ใช้กันอย่างแพร่หลายในการลดความแปรปรวนแบบสุ่ม (Random Variation) ที่บางครั้งเรียกว่าสัญญาณรบกวน (Noise) ในชุดข้อมูลอนุกรมเวลาและใช้เพื่อประมาณค่าแนวโน้มและแบบรูป (Pattern) ของชุดข้อมูล โดยเทคนิคนี้ทำงานด้วยการคำนวณหาค่าเฉลี่ยของข้อมูลในอดีตที่คงที่และใช้ค่าเฉลี่ยในการพยากรณ์ค่าของข้อมูลในอนาคต โดยในการใช้งานด้านการพยากรณ์การเลือกใช้ประเภทของค่าเฉลี่ยเคลื่อนที่ขึ้นอยู่กับ

หลายปัจจัย เช่น ลักษณะของชุดข้อมูลแบบลำดับเวลา เวลาที่ใช้พยากรณ์ หรือระดับความแม่นยำที่ต้องการ ประเภทของค่าเฉลี่ยเคลื่อนที่ที่ได้รับความนิยม ประกอบด้วยประเภท 3 ประเภท ได้แก่

ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (Simple Moving Average: SMA) ใช้สำหรับการพยากรณ์ระยะสั้น โดยที่ข้อมูลมีลักษณะแบบคงที่และไม่เป็นผลต่อการเปลี่ยนแปลงโดยกะทันหัน การคำนวณและการตีความค่าเฉลี่ยเคลื่อนที่อย่างง่ายนั้นมีความเข้าใจง่ายและกระชับ แต่อาจไม่สามารถจับความเปลี่ยนแปลงของแนวโน้มหรือฤดูกาลในข้อมูลได้ดีเท่าที่ควร โดยที่ค่าเฉลี่ยเคลื่อนที่อย่างง่าย มีสมการคณิตศาสตร์ดังสมการที่ (2.1)

$$SMA_{(n)} = \frac{X_1 + X_2 + \dots + X_n}{n} \quad (2.1)$$

โดยที่ X คือข้อมูลแบบอนุกรมเวลา และ n คือ จำนวนข้อมูล

ค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก (Weighted Moving Average: WMA) เป็นตัวเลือกที่เหมาะสมสำหรับสถานการณ์ที่การสังเกตล่าสุดมีความสำคัญมากกว่าข้อมูลในอดีต ค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก สามารถใช้สำหรับการพยากรณ์ระยะสั้นหรือระยะยาวขึ้นอยู่กับความยาวและน้ำหนักของหน้าต่างที่เคลื่อนไหว อย่างไรก็ตาม ค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนักอาจมีความซับซ้อนในการคำนวณและการตีความมากกว่าค่าเฉลี่ยเคลื่อนที่อย่างง่าย โดยมีสมการคณิตศาสตร์ดังสมการที่ (2.2)

$$WMA_{(n)} = \frac{W_1X_1 + W_2X_2 + \dots + W_nX_n}{W_1 + W_2 + \dots + W_n} \quad (2.2)$$

โดยที่ X คือข้อมูลแบบอนุกรมเวลา W คือ ค่าถ่วงน้ำหนัก และ n คือ จำนวนข้อมูล

ค่าเฉลี่ยเคลื่อนที่แบบเลขชี้กำลัง (Exponential Moving Average: EMA) เหมาะสำหรับสถานการณ์ที่การสังเกตล่าสุดมีผลกระทบมากกว่าข้อมูลในอดีต ค่าเฉลี่ยเคลื่อนที่แบบเลขชี้กำลัง มีความตอบสนองต่อการเปลี่ยนแปลงในข้อมูลมากกว่าค่าเฉลี่ยเคลื่อนที่อย่างง่ายหรือค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก และสามารถจับความเปลี่ยนแปลงทั้งในระยะสั้นและระยะยาวได้ อย่างไรก็ตามค่าเฉลี่ยเคลื่อนที่ชนิดนี้ อาจมีความไวต่อสัญญาณรบกวนในข้อมูลมากกว่าค่าเฉลี่ยเคลื่อนที่อย่างง่าย หรือค่าเฉลี่ยเคลื่อนที่ถ่วงน้ำหนัก และอาจจะยากต่อการตีความมากกว่า โดย EMA มีสมการคณิตศาสตร์ดังสมการที่ (2.3)

$$EMA_{(n)} = \alpha X_n + (1 - \alpha)EMA_{n-1} \quad (2.3)$$

โดยที่ X คือข้อมูลแบบอนุกรมเวลา n คือ จำนวนข้อมูล และ α คือ ประกอบปรับเรียบ

แบบจำลอง Holt—Winter (Holt-Winter Model)

แบบจำลอง Holt-Winters (15) เป็นการพัฒนาเทคนิค การปรับเรียบด้วยเส้นโค้งเลขชี้กำลัง (Exponential Smoothing) ที่ได้รับความนิยม ซึ่งสามารถจัดการข้อมูลอนุกรมเวลาที่มีแนวโน้มและฤดูกาลได้ แบบจำลองนี้มีพื้นฐานในแนวคิดที่ค่าคาดหวังของชุดข้อมูลในอนาคตขึ้นอยู่กับค่าปัจจุบันและค่าในอดีตของชุดข้อมูล รวมถึงแนวโน้มและรูปแบบฤดูกาลที่ผ่านมา

แบบจำลอง Holt-Winters ประกอบด้วย 3 ส่วนประกอบ โดยส่วนประกอบแรกคือ ระดับ (Level) แทนระดับพื้นฐานของชุดข้อมูลในแต่ละเวลาและถูกเพิ่มโดยใช้ระดับก่อนหน้าและความแตกต่างจากส่วนฤดูกาล แนวโน้ม (Trend) แทนอัตราการเปลี่ยนแปลงของชุดข้อมูลตามเวลาและถูกเพิ่มโดยใช้แนวโน้มก่อนหน้าและความแตกต่างจากส่วนระดับ และฤดูกาล (Seasonality) แทนการแปรผันซ้ำตามรอบในชุดข้อมูลตามเวลาและถูกเพิ่มโดยใช้ส่วนระดับและแนวโน้มก่อนหน้าและความแตกต่างจากส่วนระดับและแนวโน้ม

แบบจำลอง Holt-Winters ใช้ตัวประกอบปรับเรียบ (Smoothing Factor) 3 ตัวคือ α สำหรับส่วนระดับ β สำหรับส่วนแนวโน้ม และ γ สำหรับส่วนฤดูกาล ตัวประกอบเหล่านี้ควบคุมน้ำหนักที่จะให้กับสังเกตปัจจุบันเมื่อเทียบกับค่าเรียบเนียนในอดีตสำหรับแต่ละส่วนประกอบ ค่าตัวแปรเหล่านี้มักถูกเลือกผ่านการทดลองและควบคุมหรือผ่านกระบวนการปรับแต่งทางเชิงรูปภาพ เช่น การลดค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์ มีดังสมการที่ (2.4, 2.5, 2.6)

$$L_n = \alpha(Y_n - S_{n-m}) + (1 - \alpha)(L_{n-1} + T_{n-1}) \quad (2.4)$$

$$T_n = \beta(L_n - L_{n-1}) + (1 - \beta)T_{n-1} \quad (2.5)$$

$$S_n = \gamma(Y_n - L_n - T_n) + (1 - \gamma)S_{n-m} \quad (2.6)$$

โดยที่ L คือค่าการพยากรณ์ของส่วนประกอบระดับ T คือค่าการพยากรณ์ของส่วนประกอบแนวโน้ม S แทนค่าการพยากรณ์ของส่วนประกอบฤดูกาล n แทนเวลา m แทนความยาวของวงจรฤดูกาล α คือ ตัวประกอบปรับเรียบ β คือ ตัวประกอบปรับเรียบ และ γ คือ ตัวประกอบปรับเรียบ

แบบจำลอง Holt-Winters สามารถใช้สร้างการพยากรณ์ระยะสั้นและระยะยาวสำหรับชุดข้อมูลลำดับเวลาได้ การพยากรณ์ระยะสั้นอิงตามสังเกตการณ์ล่าสุดและมีความตอบสนองต่อการ

เปลี่ยนแปลงของข้อมูลมากขึ้น ในขณะที่การพยากรณ์ระยะยาวอิงตามรูปแบบประวัติศาสตร์ในข้อมูล และมีความตอบสนองต่อการเปลี่ยนแปลงน้อยลง โดยหนึ่งในจุดเด่นของแบบจำลอง Holt-Winters คือความสามารถในการตรวจจับรูปแบบแนวโน้มและฤดูกาลในข้อมูลซึ่งทำให้เหมาะสำหรับการพยากรณ์ชุดข้อมูลลำดับเวลาที่มีวงจรหลายวงต่อปี

แบบจำลองการถดถอยอัตโนมัติ (Autoregressive Model)

แบบจำลองการถดถอยอัตโนมัติ (Autoregressive Model) คือวิธีการสร้างแบบจำลองพฤติกรรมในอนาคตด้วยอนุกรมเวลา โดยใช้ข้อมูลจากพฤติกรรมในอดีต ด้วยการใช้การถดถอยเชิงเส้นของประสิทธิภาพตัวแปรในอนุกรมเวลาปัจจุบันกับอดีต โดยการประมาณค่าพารามิเตอร์ของแบบจำลองการถดถอยอัตโนมัติ เนื่องจากใช้วิธีการเช่นการสร้างแบบจำลองระหว่างค่าตัวแปรที่เลื่อนหลังแบบ (Ordinary least squares regression) หรือการประมาณค่าสมมติฐานสูงสุด (Maximum likelihood estimation) โดยหลังจากประมาณค่าพารามิเตอร์แล้ว แบบจำลองสามารถใช้ในการพยากรณ์ค่าในอนาคตของชุดข้อมูลแบบลำดับเวลาได้

แบบจำลองการถดถอยอัตโนมัติถูกนำมาใช้กันอย่างแพร่หลายในหลายสาขา เช่น เศรษฐศาสตร์ การเงิน วิศวกรรม และการประมวลผลสัญญาณ เพื่อวิเคราะห์และพยากรณ์รูปแบบข้อมูลที่ขึ้นอยู่กับเวลา แบบจำลองเหล่านี้เป็นพื้นฐานสำหรับแบบจำลองที่ซับซ้อนมากขึ้นเช่น Autoregressive moving average (ARMA) และ Autoregressive integrated moving average (ARIMA) ซึ่งรวมองค์ประกอบเพิ่มเติมเพื่อจับความเคลื่อนไหวในข้อมูล

แบบจำลองการถดถอยอัตโนมัติเป็นผลงานของนักเศรษฐศาสตร์ชื่อ Ragnar Frisch ซึ่งได้นำเสนอแนวคิดเกี่ยวกับแบบจำลองนี้ในปี ค.ศ. 1926 แบบจำลองการถดถอยอัตโนมัติเป็นเทคนิคในการวิเคราะห์ทางสถิติที่ใช้ในการพยากรณ์ค่าในอนาคตโดยใช้ค่าที่ผ่านมาในชุดข้อมูลอนุกรมเวลา โดยการคิดค้นแบบจำลองการถดถอยอัตโนมัติได้มีส่วนสำคัญในการพัฒนาการวิเคราะห์และการพยากรณ์รูปแบบข้อมูลที่ขึ้นอยู่กับเวลา แบบจำลองนี้ได้เสนอเครื่องมือที่มีประสิทธิภาพสูงให้แก่นักวิจัยและผู้ประกอบการในการเข้าใจและพยากรณ์พฤติกรรมของข้อมูลแบบลำดับเวลา ตลอดเวลาที่มีการปรับปรุงและขยายขอบเขตของแบบจำลองการถดถอยอัตโนมัติซึ่งเป็นการพัฒนาแบบละเอียดมากขึ้นเพื่อจับความสัมพันธ์ที่ซับซ้อนและความเคลื่อนไหวภายในข้อมูลแบบลำดับเวลา

แบบจำลองรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่ (Autoregressive Integrated Moving Average Model)

แบบจำลองรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่ หรือแบบจำลองอาร์ไอมา (ARIMA) เป็นแบบจำลองสำหรับวิเคราะห์รูปแบบข้อมูลอนุกรมเวลาที่ได้รับนิยาม (16, 17) โดยอาศัยหลักการ

การกำจัดสัญญาณรบกวนออกจากข้อมูล ด้วยการรวมกันจาก 3 องค์ประกอบหลัก โดยส่วนประกอบแรกคือการถดถอยในตัว (Autoregression: AR) การรวมเบ็ดเสร็จ (Integrated: I) และค่าเฉลี่ยเคลื่อนที่ (Moving Average: MA)

องค์ประกอบถดถอยในตัว (Autoregressive Component) เป็นการเก็บค่าตัวแปรต่อเนื่องระหว่างค่าของข้อมูลในอดีตหลาย ๆ ค่า ส่วนประกอบนี้จะตีความความสัมพันธ์ของค่าปัจจุบันกับค่าก่อนหน้า โดยแบบจำลองอาร์มีตัวแปร "p" ระบุจำนวนค่าข้อมูลในอดีตที่เลื่อนมาที่จะใช้ในแบบจำลอง ดังสมการที่ (2.7)

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t \quad (2.7)$$

โดยที่ y_t คือค่าของข้อมูลปัจจุบัน c คือค่าคงที่ ϕ คือสัมประสิทธิ์การถดถอยในตัว (Autoregressive Coefficients) และ ε_t คือค่าผิดพลาด

องค์ประกอบค่าเฉลี่ยเคลื่อนที่ (Moving Average Component) เป็นส่วนที่แสดงความสัมพันธ์ระหว่างค่าปัจจุบันและค่าความคลาดเคลื่อนของค่าที่พยากรณ์มาก่อนหน้า ส่วนประกอบนี้จะแสดงถึงสุ่มหรือสัญญาณรบกวนในชุดข้อมูลชุดเวลา โดยที่ "q" แทนลำดับขององค์ประกอบค่าเฉลี่ยเคลื่อนที่ ดังสมการที่ (2.8)

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.8)$$

โดยที่ y_t คือค่าของข้อมูลปัจจุบัน μ คือค่าเฉลี่ยของอนุกรมเวลา θ คือสัมประสิทธิ์ของค่าเฉลี่ยเคลื่อนที่ (Moving Average Coefficient) และ ε_t คือค่าความผิดพลาด

องค์ประกอบการรวม (Integrated Component) ใช้ในการทำการหาค่าอนุพันธ์ของชุดข้อมูลชุดเวลา เพื่อให้ชุดข้อมูลชุดเวลาที่มีความคงที่ ซึ่งหมายถึงคุณสมบัติทางสถิติคงที่ตลอดเวลา การทำให้ข้อมูลมีความคงที่ช่วยให้การวิเคราะห์และการพยากรณ์ชุดข้อมูลอนุกรมเวลาทำได้ง่ายขึ้น และมีตัวแปร "d" แทนองค์ประกอบการรวม ดังสมการที่ (2.9)

$$\Delta y_t = y_t - y_{t-1} \quad (2.9)$$

โดยที่ y_t คือค่าของข้อมูลปัจจุบัน

แบบจำลองอาร์มาถูก ใช้ในการพยากรณ์และวิเคราะห์ชุดข้อมูลแบบลำดับเวลาในหลายสาขา เช่น เศรษฐศาสตร์ การเงิน การพยากรณ์ยอดขาย และการพยากรณ์สภาพอากาศ (18) แบบจำลองเหล่านี้นำเสนอโครงสร้างที่หลากหลายสำหรับจับลักษณะการเคลื่อนที่ในชุดข้อมูลแบบลำดับเวลา

เทคนิคการพยากรณ์ที่ได้กล่าวมาข้างต้นล้วนใช้วิธีการด้านสถิติ (Statistical Method) ซึ่งมีข้อจำกัดหลายประการ เช่น จำเป็นต้องใช้ข้อมูลในอดีตเป็นจำนวนมาก สำหรับการใช้หลักการของสมการเชิงเส้นเข้ามาวิเคราะห์ข้อมูลนั้นมีข้อจำกัด เนื่องจากข้อมูลในโลกจริงนั้นมีความแปรปรวน ไม่มีลักษณะเป็นเชิงเส้นอย่างชัดเจน ทำให้เทคนิคการพยากรณ์นี้มีความนิยมน้อยลง

ปัจจุบันในการพยากรณ์การใช้ไฟฟ้าหรือการพยากรณ์อื่น ๆ นั้น วิธีที่มีความนิยมอย่างแพร่หลายนั้นคือการใช้เทคโนโลยีของปัญญาประดิษฐ์ (Artificial Intelligence) ในการทำให้คอมพิวเตอร์สามารถคิดคำนวณหาค่าที่จะพยากรณ์ได้ จึงจำเป็นต้องมีการพัฒนาระบบที่สามารถพยากรณ์ค่าความต้องการใช้ไฟฟ้าได้อย่างแม่นยำ เพื่อที่จะช่วยให้ทั้งการตอบสนองด้านโหลด และระบบบริหารจัดการพลังงานนั้นสามารถทำงานได้อย่างมีประสิทธิภาพมากที่สุด

ปัญญาประดิษฐ์ (Artificial Intelligence)

ปัญญาประดิษฐ์หรือเอไอ (AI) เกิดจากการรวมกันของคำศัพท์ 2 คำ คือ “Artificial” ที่มีความหมายว่าสิ่งเทียม หรือสิ่งที่ประดิษฐ์ขึ้นมา และ “Intelligence” ที่มีความหมายว่าความเฉลียวฉลาดหรือปัญญา เมื่อนำมารวมกับจึงมีความหมายโดยรวมว่า ปัญญาที่ถูกประดิษฐ์ขึ้นมา โดยมีความต้องการที่จะให้ปัญญาที่ประดิษฐ์มีความสามารถที่จะเรียนรู้ และคิดเองได้ดังเช่นมนุษย์

เทคโนโลยีปัญญาประดิษฐ์นั้นถูกสร้างขึ้นโดยที่มีพื้นฐานมาจากหลากหลายสาขาวิชา ไม่ว่าจะเป็นวิทยาการคอมพิวเตอร์ วิทยาศาสตร์ ชีววิทยา จิตวิทยา ภาษาศาสตร์ คณิตศาสตร์ และวิศวกรรมศาสตร์ เพื่อสร้างปัญญาประดิษฐ์ให้มีความสามารถในการประมวลผลได้เช่นเดียวกับความคิดของมนุษย์ กล่าวคือมีกลไกการทำงานให้เหมือนกับการทำงานของสมองมนุษย์ที่มีความซับซ้อน จนสามารถคิดหรือทำงานต่าง ๆ ได้เช่นเดียวกับมนุษย์

การเรียนรู้ของเครื่อง (Machine learning)

การเรียนรู้ของเครื่อง (Machine learning) คือศาสตร์แขนงหนึ่งที่ทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้ด้วยตนเอง เมื่อมีข้อมูลเข้าสามารถพยากรณ์หรือตัดสินใจได้โดยปราศจากการทำงานตามลำดับคำสั่งโปรแกรม (19) การเรียนรู้ของเครื่องสามารถจำแนกได้ 4 ประเภทหลักๆ คือ

การเรียนรู้แบบภายใต้การดูแล (Supervised Learning) คือการเรียนรู้ที่มีมนุษย์คอยแยกประเภทหรือบอกผลลัพธ์ด้วยข้อมูลที่ใช้ฝึก (Training Data) จากนั้นนำข้อมูลที่ใช้ฝึกทำการหาแบบจำลอง (Model) โดยระบบแบบนี้เป็นการเรียนรู้จากข้อมูลเข้า (Input Data) และข้อมูลออก

(Output Data) ไปผ่านอัลกอริทึม (Algorithm) สำหรับสร้างแบบจำลองที่ไวพยากรณ์ผลลัพธ์ เมื่อกระบวนการฝึกเสร็จสิ้น แบบจำลองจะสามารถพยากรณ์ข้อมูลใหม่ได้

การเรียนรู้แบบไม่ภายใต้การดูแล (Unsupervised Learning) เป็นการเรียนรู้ของคอมพิวเตอร์แบบไม่มีผู้แนะนำ โดยต้องการให้สามารถหาวิธีการและผลลัพธ์ออกมาได้เองโดยไม่ต้องมีการให้ข้อมูลจากมนุษย์ ซึ่งการเรียนรู้ที่ไม่มีผู้สอนนั้นคอมพิวเตอร์ไม่สามารถรู้คำตอบที่แน่ชัด มนุษย์ใส่เพียงข้อมูลเข้า (Input Data) ไม่มีข้อมูลออก (Output Data) ให้กับคอมพิวเตอร์เพื่อที่จะนำไปวิเคราะห์และสร้างแบบจำลอง โดยคอมพิวเตอร์จะต้องดำเนินการเรียนรู้หาวิธีการที่เหมาะสมด้วยตัวเอง

การเรียนรู้แบบได้รับการสนับสนุน (Reinforcement Learning) เป็นการเรียนรู้ที่คอมพิวเตอร์เรียนรู้สิ่งต่าง ๆ จากการลองผิดลองถูกเรื่อย ๆ เพื่อที่จะได้ผลลัพธ์ที่ดีที่สุด โดยให้การให้รางวัล (Reward) สำหรับผลลัพธ์ที่ดีและไม่ดีด้วยค่ามากและน้อยต่างกัน เพื่อให้สามารถพัฒนาระบบให้ออกมามีความถูกต้องมากที่สุด

การเรียนรู้แบบกึ่งภายใต้การดูแล (Semi-Supervised Learning) มีหลักการทำงานคล้ายกับการเรียนรู้แบบภายใต้การดูแล แต่จะไม่ใช้ข้อมูลทั้งหมดที่มีให้แบบจำลองเรียนรู้ โดยจะทำการแบ่งข้อมูลส่วนหนึ่งออกมาเพื่อมาใช้เป็นแนวทางในการจัดกลุ่มข้อมูล โดยการทำเช่นนี้จะช่วยเพิ่มความแม่นยำของแบบจำลองมากยิ่งขึ้น

การเรียนรู้ของเครื่องถูกนำไปประยุกต์ใช้ในหลาย ๆ ด้าน ไม่ว่าจะเป็น การประมวลผลภาพ (Image Processing) การรู้จำเสียง (Speech Recognition) การประมวลผลภาษาธรรมชาติ (Natural Language Processing) หรือการพยากรณ์อนุกรมเวลา (Time Series Forecasting)

แบบจำลอง XGBoost (eXtreme Gradient Boosting Model)

แบบจำลอง XGBoost เป็นเทคนิคการเรียนรู้ของเครื่องที่ใช้กันอย่างแพร่หลายในด้านต่าง ๆ รวมถึงการพยากรณ์อนุกรมเวลา โดยแบบจำลอง XGBoost นั้นมีการพัฒนามาจากเทคนิค Gradient Boosting ใช้กระบวนการ Gradient Boosting ด้วยหลักการการนำต้นไม้การตัดสินใจ (Decision Tree) มาทำการฝึกสอนต่อกันหลาย ๆ ชั้น เพื่อเรียนรู้จากค่าความผิดพลาดของกระบวนการก่อนหน้า จนทำให้การพยากรณ์มีความแม่นยำขึ้นเรื่อย ๆ โดยสมการทางคณิตศาสตร์ของแบบจำลอง XGBoost มีดังสมการที่ (2.10)

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i) \quad (2.10)$$

โดยที่ \hat{y}_i คือค่าพยากรณ์ของข้อมูลลำดับที่ i x_i คือเวกเตอร์ลักษณะ (Feature Vector) K คือจำนวนของต้นไม้การตัดสินใจ และ $f_k(x_i)$ คือค่าการพยากรณ์ของข้อมูลลำดับที่ k

ในการฝึกฝนแบบจำลอง XGBoost โดยใช้กระบวนการ Gradient Boosting นั้นมีการปรับปรุงฟังก์ชันวัตถุประสงค์ (Objective Function) ซึ่งประกอบด้วยฟังก์ชันการสูญเสีย (Loss Function) และการปรับค่าให้เป็นมาตรฐาน (Regularization) เพื่อให้แบบจำลองมีความซับซ้อนเหมาะสมเพื่อป้องกันการเรียนรู้มากเกินไป (Overfitting) โดยฟังก์ชันวัตถุประสงค์มีสมการดังสมการที่ (2.11)


$$L(\emptyset) = \sum_i l(\hat{y}_i, y_i) + \sum_k \Omega(f_k) \quad (2.11)$$

โดยที่ $L(\emptyset)$ คือฟังก์ชันวัตถุประสงค์ $l(\hat{y}_i, y_i)$ คือฟังก์ชันการสูญเสีย และ $\Omega(f_k)$ คือ ฟังก์ชันการปรับค่าให้เป็นมาตรฐาน (Regularization Term)

เนื่องจากแบบจำลอง XGBoost นั้นมีความสามารถในการตรวจจับความสัมพันธ์ของข้อมูลที่มีความเป็นลำดับและสามารถรับมือกับความสัมพันธ์ที่ไม่เป็นเชิงเส้น ทำให้แบบจำลองนี้สามารถจัดการกับความซับซ้อนของข้อมูลที่มีการเปลี่ยนแปลงตามเวลา และสามารถตรวจจับแนวโน้ม ฤดูกาล และความสัมพันธ์ที่ซับซ้อนของข้อมูลได้เป็นอย่างดี จึงทำให้แบบจำลองนี้สามารถใช้งานในด้านการพยากรณ์อนุกรมเวลาได้อย่างมีประสิทธิภาพ

การเรียนรู้เชิงลึก (Deep Learning)


การเรียนรู้เชิงลึก (Deep Learning) คือวิธีการเรียนรู้แบบอัตโนมัติด้วยการเลียนแบบการทำงานของโครงข่ายประสาทของมนุษย์โดยนำระบบโครงข่ายประสาทเทียม (Neural Network) มาซ้อนกันจำนวนหลาย ๆ ชั้น (Layer) และทำการเรียนรู้ข้อมูลตัวอย่าง ซึ่งข้อมูลดังกล่าวจะถูกนำไปใช้ในการตรวจจับรูปแบบ หรือจำแนกข้อมูล โดยทั่วไปวิธีโครงข่ายประสาทเทียมจะเรียนรู้ได้เพียงไม่กี่ชั้น เพื่อที่จะทำให้โครงข่ายประสาทเทียม นั้นสามารถคิดและประมวลผลซับซ้อนได้เหมือนสมองมนุษย์ ซึ่งชั้นที่เป็น Hidden Layer จึงต้องมีจำนวนชั้นที่มากขึ้น เพื่อให้แต่ละโหนดส่งข้อมูลไปประมวลผลต่อ ๆ กัน ทำให้สามารถเรียนรู้กับข้อมูลที่มีซับซ้อนได้มากขึ้น ดังที่จะมีอธิบายต่อไปในหัวข้อของโครงข่ายประสาทเทียม (20-22)



ภาพที่ 3 แผนภาพอธิบายความเชื่อมโยงระหว่างปัญญาประดิษฐ์ (Artificial Intelligence) การเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning)

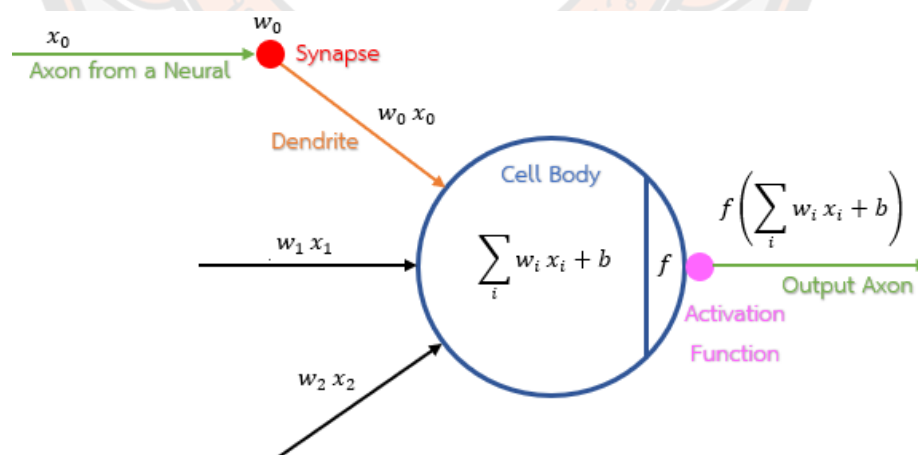
โครงข่ายประสาทเทียม (Neural Network)

โครงข่ายประสาทเทียม (Neural Network) นั้นมีแนวคิดมาจากระบบโครงข่ายประสาทของมนุษย์ก่อนที่จะนำไปใช้เป็นตัวแบบสำหรับสร้างระบบที่ใช้ในการประมวลผลทางคอมพิวเตอร์โดยหลักคณิตศาสตร์ (23) โดยที่องค์ประกอบของโครงข่ายประสาทของมนุษย์ คือ เซลล์ประสาท (Neuron) ซึ่งเป็นหน่วยที่เล็กที่สุดในระบบประสาทประกอบกันเป็นจำนวนมาก ทำหน้าที่ในการประมวลผลและส่งข้อมูลผ่านสัญญาณไฟฟ้าและเคมี โดยส่งผ่านจุดประสานประสาท (Synapse) เชื่อมต่อกับเซลล์ประสาทอื่น ๆ เป็นเครือข่ายประสาทประกอบด้วย เดนไดรต์ (Dendrite) คือส่วนที่ยื่นออกไปจากตัวเซลล์ (Cell Body) ทำหน้าที่ในการรับสัญญาณที่ส่งมาจากเซลล์อื่น ๆ ตัวเซลล์ (Cell Body) คือเซลล์ศูนย์กลางทำหน้าที่ในการรับสัญญาณที่ส่งมาจากเดนไดรต์ และแอกซอน (Axon) คือใยประสาททำหน้าที่ในการส่งสัญญาณที่รับมาจากตัวเซลล์ไปยังเซลล์ประสาทอื่น ๆ ดังที่แสดงในภาพที่ 4



ภาพที่ 4 โครงสร้างเซลล์ประสาททางชีววิทยาของมนุษย์
(ที่มา: <https://cs231n.github.io/neural-networks-1/>)

จากการศึกษาหลักการทำงานของเซลล์ประสาททางชีววิทยาของมนุษย์จึงนำมาสู่การพัฒนาเป็นโครงข่ายประสาทเทียม (Neural Network) สำหรับใช้ในการสร้างแบบจำลอง (Model) สำหรับการคำนวณในคอมพิวเตอร์ โดยจะทำการสร้างเซลล์ประสาทเทียมขึ้นมาจำนวนมากเพื่อนำมารวมกันให้เป็นโครงข่ายประสาทเทียม โดยเซลล์ประสาทเทียมเมื่อเทียบกับเซลล์ประสาทของมนุษย์จะมีลักษณะดังภาพที่ 5




ภาพที่ 5 โครงสร้างของเซลล์ประสาทเทียม
(ที่มา: <https://cs231n.github.io/neural-networks-1/>)

สำหรับสมการของโครงข่ายประสาทเทียมสำหรับการคำนวณจะมีดังสมการที่ (2.12)


$$f(x) = \sum_i w_i x_i + b \quad (2.12)$$

โดยที่ w_i คือ ค่าถ่วงน้ำหนัก x_i คือ ข้อมูลเข้า และ b คือ ค่าไบแอส

ส่วนประกอบของโครงข่ายประสาทเทียมจะประกอบบโหนด (Node) จำนวนมาก ซึ่งถือเป็นตัวแทนของเซลล์ประสาท 1 เซลล์ โดยโครงสร้างของโครงข่ายจะแบ่งออกเป็นชั้น 3 ชั้นหลัก ๆ คือ ชั้นข้อมูลเข้า (Input Layer) เป็นชั้นที่จะมีข้อมูลเข้า (Input Data) โดยที่จำนวนของโหนดขึ้นอยู่กับจำนวนข้อมูลเข้า สำหรับให้แบบจำลองใช้เป็นข้อมูลเข้า สำหรับในวิทยานิพนธ์นี้ข้อมูลเข้าที่จะใช้คือ ปริมาณการใช้พลังงานไฟฟ้าของแต่ละอาคารในวิทยาลัยฯ และปัจจัยอื่น ๆ ที่คาดว่าจะเกี่ยวข้องกับปริมาณการใช้พลังงานไฟฟ้า ชั้นถัดมาคือ ชั้นซ่อน (Hidden Layer) เป็นชั้นที่อยู่ระหว่างชั้นข้อมูลเข้า และชั้นข้อมูลออก ซึ่งในชั้นนี้เป็นชั้นที่ส่งผลต่อประสิทธิภาพของแบบจำลองเป็นอย่างมาก หากมีจำนวนโหนดในชั้นนี้เป็นจำนวนมากจะยิ่งทำให้การคำนวณมีความซับซ้อนมากยิ่งขึ้น หากมีจำนวนชั้นซ่อนมากกว่า 1 ชั้น จะเรียกได้ว่าเป็นการเรียนรู้เชิงลึก โดยส่วนประกอบสำคัญอีกประการในส่วนของชั้นซ่อนคือฟังก์ชันกระตุ้นที่จะอยู่ในทุก ๆ และชั้นสุดท้ายคือ ชั้นข้อมูลออก (Output Layer) เป็นชั้นที่จะนำผลลัพธ์จากการคำนวณในชั้นก่อนหน้าไปใช้เป็นผลลัพธ์ของแบบจำลอง จำนวนของโหนดในชั้นข้อมูลออกคือจำนวนของตัวแปรที่ต้องการหาค่า โดยในวิทยานิพนธ์นี้ข้อมูลออกคือ ปริมาณการใช้พลังงานไฟฟ้าของแต่ละอาคารในวิทยาลัยฯ



ภาพที่ 6 ส่วนประกอบของโครงข่ายประสาทเทียม



ภาพที่ 7 ส่วนประกอบของโครงข่ายประสาทเทียมที่มีความซับซ้อนมากขึ้น


ฟังก์ชันกระตุ้น (Activation Function)

ฟังก์ชันกระตุ้น คือ ฟังก์ชันที่ทำหน้าที่คำนวณผลจากข้อมูลขาเข้า (Input Data) ให้ได้มาซึ่งข้อมูลขาออก (Output Data) เพื่อเป็นผลลัพธ์ของแบบจำลอง โดยส่วนมากฟังก์ชันกระตุ้นที่มีการใช้งานในการสร้างแบบจำลองนั้นจะเป็นฟังก์ชันที่ไม่เป็นเส้นตรง เพื่อให้สอดคล้องกับข้อมูลจากความเป็นจริงที่จะมีพฤติกรรมที่ไม่แน่นอนและไม่เป็นเส้นตรง โดยฟังก์ชันกระตุ้นจะถูกนำไปใส่ไว้ในแต่ละโหนด (Node) ในชั้นซ่อน (Hidden Layer) ซึ่งฟังก์ชันกระตุ้นนั้นมีหลายรูปแบบโดยรูปแบบที่นิยมใช้ในการเรียนรู้เชิงลึกมีดังนี้

ฟังก์ชันกระตุ้นซิกมอยด์ (Sigmoid Activation Function) เป็นฟังก์ชันทางคณิตศาสตร์ โดยฟังก์ชันนี้จะมีลักษณะของกราฟเป็นตัวเอส (S-curve) ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 ฟังก์ชันนี้จะใช้เมื่อต้องการพยากรณ์ความน่าจะเป็นของข้อมูลออก โดยฟังก์ชันกระตุ้นซิกมอยด์สมการคณิตศาสตร์ดังสมการที่ (2.13) และกราฟของฟังก์ชันดังภาพที่ 8

$$\sigma(x) = \frac{1}{(1+e^x)} \quad (2.13)$$

โดยที่ x คือ ข้อมูลเข้า และ e คือ ค่าลอการิทึมธรรมชาติ (Natural Logarithm)




ภาพที่ 8 กราฟของฟังก์ชันกระตุ้นซิกมอยด์

ฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนกเจนท์ (Hyperbolic Tangent Activation Function : tanh) เป็นฟังก์ชันทางคณิตศาสตร์ที่มีลักษณะการทำงานใกล้เคียงกับฟังก์ชันกระตุ้นซิกมอยด์ แต่จะเพิ่มค่าที่มีความเป็นไปได้เป็นค่าระหว่าง -1 ถึง 1 ทำให้ฟังก์ชันกระตุ้นชนิดนี้สามารถจัดการกับข้อมูลที่มีค่าลบเป็นจำนวนมากได้ดี โดยฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนกเจนท์สมการคณิตศาสตร์ดังสมการที่ (2.14) และกราฟของฟังก์ชันดังภาพที่ 9

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.14)$$

โดยที่ x คือ ข้อมูลเข้า และ e คือ ค่าลอการิทึมธรรมชาติ (Natural Logarithm)




ภาพที่ 9 กราฟของฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนก์เจนท์ (tanh)

ฟังก์ชันกระตุ้นเรกติไฟด์ลิเนียยูนิต (Rectified Linear Units Activation Function : ReLU) เป็นฟังก์ชันกระตุ้นที่มีค่าอยู่ระหว่าง 0 ถึง ∞ ทำให้ข้อมูลข้อมูลที่มีค่าเป็นลบหรือศูนย์จะได้ผลลัพธ์เป็นศูนย์ ส่วนข้อมูลที่มีค่ามากกว่าศูนย์จะได้ผลลัพธ์เป็นค่าที่มากกว่าศูนย์ โดยฟังก์ชันกระตุ้นชนิดนี้นิยมใช้ในการทำโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) โดยฟังก์ชันกระตุ้นเรกติไฟด์ลิเนียยูนิต สมการคณิตศาสตร์ดังสมการที่ 2.15 และกราฟของฟังก์ชันดังภาพที่ 10

$$ReLU(x) = \max(0, x) \quad (2.15)$$

โดยที่ x คือ ข้อมูลเข้า

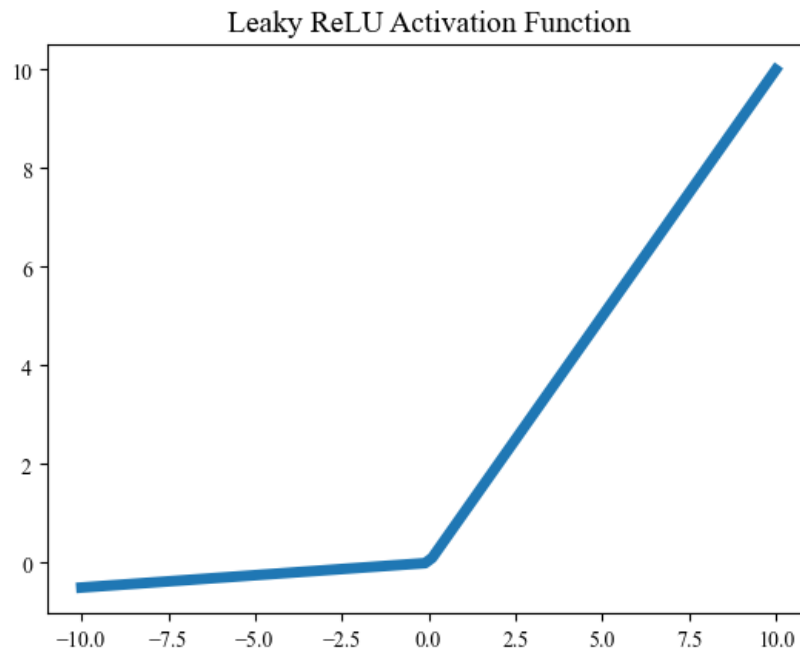


ภาพที่ 10 กราฟของฟังก์ชันกระตุ้นเรคตีไฟด์ลิเนียยูนิต (ReLU)

ฟังก์ชันกระตุ้นลีกี้เรคตีไฟด์ลิเนียยูนิต (Leaky-Rectified Linear Units Activation Function : Leaky ReLU) เป็นฟังก์ชันกระตุ้นที่พัฒนามากจากฟังก์ชันกระตุ้นเรคตีไฟด์ลิเนียยูนิต (ReLU) (24) ค่าผลลัพธ์ที่เป็นไปได้จากที่มีค่าระหว่าง 0 ถึง ∞ เพิ่มเป็นค่าระหว่าง $-\infty$ ถึง ∞ โดยฟังก์ชันกระตุ้นลีกี้เรคตีไฟด์ลิเนียยูนิตมีสมการคณิตศาสตร์ดังสมการที่ 2.16 และกราฟของฟังก์ชันดังภาพที่ 11

$$L(x) = \max(0.1x, x) \quad (2.16)$$

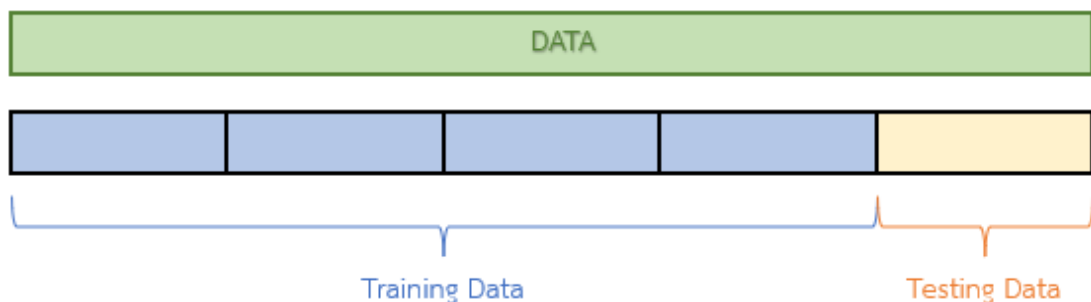
โดยที่ x คือ ข้อมูลเข้า



ภาพที่ 11 กราฟของฟังก์ชันลิกกี้เรคตีไฟด์ลิเนี่ยยูนิต (Leaky ReLU)

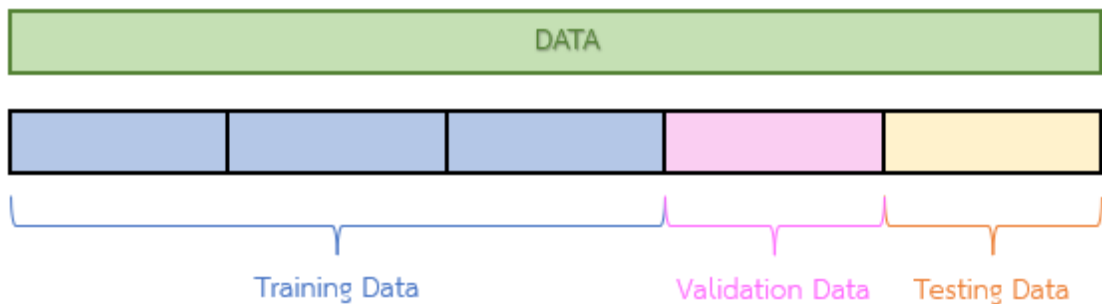
การฝึกสอนและทดสอบแบบจำลอง (Training and Testing Model)

ในการพัฒนาแบบจำลอง (Model) ด้วยการใช้การเรียนรู้ของเครื่อง (Machine Learning) หรือการเรียนรู้เชิงลึก (Deep Learning) เนื่องจากการพัฒนาแบบจำลองให้สามารถพยากรณ์หาข้อมูลในอนาคตจากการเรียนรู้ข้อมูลในอดีต จึงจำเป็นต้องมีข้อมูลจำนวนมากในการนำมาฝึกสอนแบบจำลอง โดยเมื่อมีการฝึกสอนแล้วจำเป็นจะต้องมีการทดสอบเพื่อหาประสิทธิภาพว่าแบบจำลองสามารถทำงานได้ดีตามที่ต้องการหรือไม่ ดังนั้นจึงทำการทดลองให้แบบจำลองพยากรณ์แล้วนำมาเปรียบเทียบกับค่าจริงที่เคยเกิดขึ้น ทำให้จำเป็นต้องแบ่งข้อมูลออกเป็นสองส่วน คือ ข้อมูลสำหรับการฝึกสอน (Training Data) และข้อมูลสำหรับทดสอบ (Testing Data)



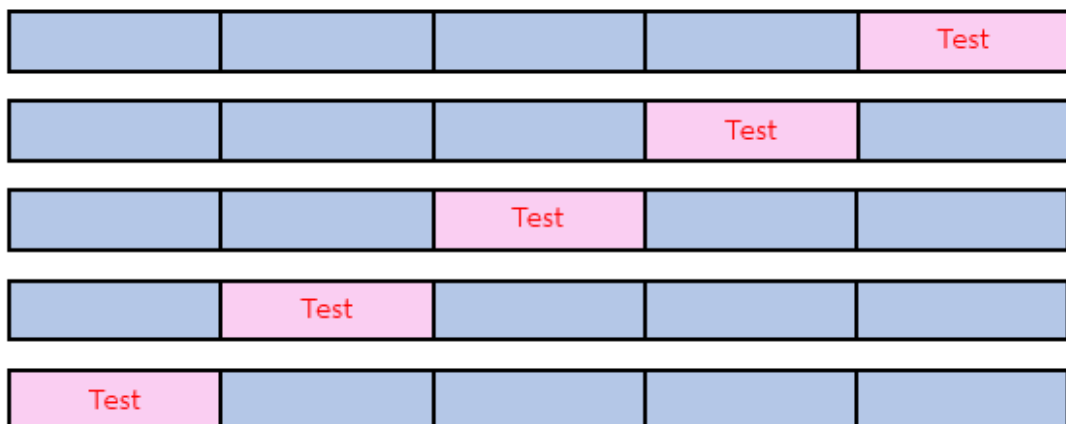
ภาพที่ 12 ภาพแสดงการแบ่งข้อมูลสำหรับฝึกสอนและทดสอบ

นอกจากการแบ่งข้อมูลออกเป็น 2 ส่วน ดังภาพที่ 12 คือข้อมูลสำหรับฝึกสอน และข้อมูลสำหรับทดสอบ ยังสามารถแบ่งข้อมูลเพิ่มขึ้นมาอีกส่วนคือ Validation Data โดยจะแบ่งออกมาจากส่วนของข้อมูลสำหรับฝึกสอน ดังภาพที่ 13 โดยข้อมูลในส่วนของ Validation นี้จะทำหน้าที่ทดสอบหาค่าไฮเปอร์พารามิเตอร์ (Hyperparameters) อื่น ๆ ที่เหมาะสมในการใช้ฝึกสอนแบบจำลอง การแบ่งข้อมูลออกเป็น ส่วน ๆ เพื่อทำการทดสอบหาชุดข้อมูลที่เหมาะสมสำหรับนำไปฝึกสอนแบบจำลอง เรียกว่าวิธีการนี้ว่า “Cross Validation”



ภาพที่ 13 ภาพแสดงการแบ่งข้อมูลสำหรับฝึกสอน ทดสอบ และ Validation

ในการทำ Cross Validation นี้จะทำการสลับส่วนของข้อมูลที่ใช้สำหรับฝึกสอนและทดสอบไปจนครบตามจำนวนที่ถูกระบุไว้ วิธีนี้จะเรียกว่า “K-Fold Cross Validation” โดยจะต้องทำการกำหนดค่า K เพื่อเป็นการแบ่งส่วนข้อมูลออกเป็น K ส่วน แล้วทำการทดสอบข้อมูลทั้งหมด K รอบ เพื่อให้สามารถปรับแต่งค่าไฮเปอร์พารามิเตอร์ได้อย่างแม่นยำ




ภาพที่ 14 การแบ่งข้อมูลสำหรับทำ K-Fold Cross Validation กรณี $K = 5$

หลังจากกำหนดข้อมูลสำหรับการฝึกฝนและทดสอบของแบบจำลอง พร้อมทั้งได้ตัวแปรอื่น ๆ ที่เหมาะสมจากการทำ Cross Validation แล้ว ส่วนถัดไปคือการนำข้อมูลที่ได้มีการเตรียมการเข้าไปในแบบจำลองโครงข่ายประสาทเทียม โดยจำเป็นต้องเลือกโครงข่ายประสาทเทียมที่เหมาะสมและสามารถใช้งานกับรูปแบบของข้อมูลที่มีอยู่ ซึ่งระบบโครงข่ายประสาทเทียมแต่ละชนิดมีความสามารถและความเหมาะสมในการใช้งานที่ต่างกัน

หลังจากกระบวนการฝึกสอนข้อมูลเสร็จสิ้น ขั้นตอนสุดท้ายคือการวัดผลหาค่าประสิทธิภาพของแบบจำลองว่ามีความแม่นยำตามที่ต้องการหรือไม่ สำหรับการหาค่าประสิทธิภาพของแบบจำลอง จะหาค่าความคลาดเคลื่อนของผลลัพธ์ที่ได้จากแบบจำลองที่ผ่านการฝึกสอนแล้ว เพื่อนำมาเปรียบเทียบกับข้อมูลจริงที่เคยเกิดขึ้นจากข้อมูลการทดสอบ

โครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent Neural Network)

โครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent Neural Network) เป็นประเภทของโครงข่ายประสาทเทียมแบบหนึ่งที่ถูกพัฒนาขึ้นมาเพื่อใช้สำหรับข้อมูลที่มีความเป็นลำดับ (Sequence) หรือข้อมูลจำพวกอนุกรมเวลา (Time Serie) เนื่องจากระบบโครงข่ายประสาทเทียมแบบรีเคอร์เร็นนี้ถูกพัฒนาให้สามารถนำข้อมูลออก (Output Data) ในอดีตมาวิเคราะห์เพื่อหาข้อมูลในอนาคตได้ ต่างจากระบบโครงข่ายประสาทเทียมแบบดั้งเดิม (25, 26) โดยจะทำการสร้างเซลล์ประสาทขึ้นมาหลาย ๆ เซลล์ และทำการนำมาต่อกัน (Unroll) เพื่อให้ข้อมูลสามารถผ่านไปยังเซลล์ต่อ ๆ ไปได้



ภาพที่ 15 โครงสร้างการทำงานของ Recurrent Neural Network

(ที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>)


จากภาพที่ 12 พบว่ามีการใช้เซลล์ประสาทของโครงข่ายประสาทเทียมแบบรีเคอร์เร็นหลาย ๆ เซลล์มาต่อกัน โดยมีข้อมูลเข้าและข้อมูลออกแยกกัน แต่ในส่วนของข้อมูลออกแต่ละเซลล์จะถูกนำไปใช้ในเซลล์ถัดไปด้วย โดยทั้งข้อมูลออกจากเซลล์ก่อนหน้าและข้อมูลเข้าใหม่จะถูกนำมาผ่านฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนก์เจนท์ (Tanh) แล้วจึงผ่านข้อมูลออกไป โดยโครงข่ายประสาทเทียมแบบรีเคอร์เร็นมีสมการทางคณิตศาสตร์ดังสมการที่ (2.17)

$$h(t) = x_{(t)}W_{in} + h_{(t-1)}W \quad (2.17)$$

โดยที่ h คือข้อมูลออก x คือข้อมูลเข้า และ W คือค่าถ่วงน้ำหนัก

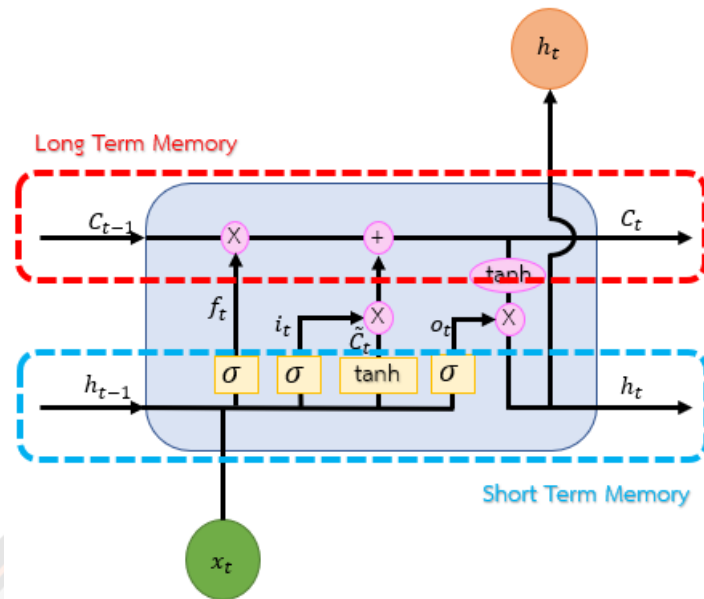
Long Short-Term Memory Model (LSTM)

Long Short-Term Memory (LSTM) เป็นประเภทของโครงข่ายประสาทเทียมที่ถูกพัฒนาจากโครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent neural network : RNN) เนื่องจากข้อดีของโครงข่ายประสาทเทียมแบบรีเคอร์เร็น คือ สามารถนำข้อมูลก่อนหน้ามาใช้ในการพยากรณ์สิ่งที่อาจจะเกิดขึ้นในอนาคตได้ แต่จะมีข้อเสียคือจะสามารถดูข้อมูลย้อนหลังได้แค่เพียงระยะสั้น ๆ เท่านั้น ซึ่งทำให้เกิดปัญหาในการทำการคำนวณหาค่าความผิดพลาดย้อนหลัง (Backpropagation) ของแต่ละเซลล์เมื่อสิ้นสุดการทำงาน (27, 28) เพราะการหาค่าความผิดพลาดย้อนหลังนั้นจะต้องทำย้อนกลับไปหลายขั้นตอนและหลายเซลล์ จึงทำให้เกิดปัญหาที่ Gradient จะค่อย ๆ มีค่าลดลงจนใกล้ศูนย์ซึ่งส่งผลให้ไม่มีการเปลี่ยนแปลงค่าถ่วงน้ำหนักอีกต่อไป (Vanishing Gradient Problem) (29) ดังนั้นเพื่อแก้ปัญหาดังกล่าวจึงทำให้เกิดเทคนิค Long Short-Term Memory ขึ้น โดยเทคนิคนี้เริ่มเป็นที่รู้จักในปี ค.ศ.1997 โดยงานวิจัยของ Hochreiter และ Schmidhuber (30)




ภาพที่ 16 โครงสร้างการทำงานของ Long Short-Term Memory
(ที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>)

Long Short-Term Memory มีการเพิ่มส่วนประกอบต่าง ๆ ภายในเซลล์เข้ามาจากระบบโครงข่ายประสาทเทียมแบบรีเคอร์เร็นต์หลายส่วน โดย โครงสร้างหลักของ Long Short-Term Memory จะแบ่งเป็น “Long Term Memory” ซึ่งเป็นส่วนที่อยู่ด้านบน และ “Short Term Memory” เป็นส่วนที่อยู่ด้านล่าง ดังในภาพที่ 17 โดยมีส่วนประกอบอื่น ๆ เพื่อกำหนดความสำคัญของการใช้ข้อมูลทั้ง Long Term และ Short Term ส่วนในเรื่องของฟังก์ชันกระตุ้นมีการเพิ่มฟังก์ชันกระตุ้นซิกมอยด์เข้ามา และจุดเด่นสำคัญของ Long Short-Term Memory คือส่วนประกอบดังกล่าวถูกนำมาใช้เป็นฟังก์ชันพิเศษที่เป็นเสมือนประตู (Gate) โดยทั้ง 3 ประตูจะถูกเรียกคือ ประตูแรก Forget Gate ประตูที่สอง Input Gate และ ประตูสุดท้าย Output Gate ดังภาพที่ 18



ภาพที่ 17 ภาพแสดงส่วนของ Long Term Memory และ Short Term Memory
(ที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>)



ภาพที่ 18 ภาพแสดง Forget Gate Input Gate และ Output Gate
(ที่มา: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>)

ในส่วนแรกของแบบจำลอง มีข้อมูลเข้ามาในเซลล์ 2 ส่วน คือข้อมูลทั้งแบบ Long Term และ Short Term ในส่วนนี้จะเป็นการใช้ข้อมูลเข้าทั้งจากอดีตและข้อมูลเข้าปัจจุบันผ่านฟังก์ชันกระตุ้นซิกมอยด์ เพื่อทำการกำหนดความสำคัญของข้อมูล Long Term ว่ามีความสำคัญหรือไม่ หากมีค่ามากตัวคูณที่เป็นผลลัพธ์จากการผ่านฟังก์ชันดังกล่าว จะมีค่ามากทำให้ผลลัพธ์จากการคูณกับข้อมูล Long Term มีค่ามากตามไปด้วย ในทางตรงข้าม หากความสำคัญน้อยก็จะได้ผลลัพธ์ที่มีค่าน้อย จากหลักการทำงานดังกล่าวทำให้ส่วนนี้ถูกเรียกว่า “Forget Gate” ดังสมการที่ (2.18)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.18)$$

โดยที่ f คือผลลัพธ์จากฟังก์ชัน σ คือฟังก์ชันกระตุ้นซิกมอยด์ W คือค่าถ่วงน้ำหนัก h คือข้อมูลเข้าในอดีต x คือข้อมูลเข้า และ b คือไบแอส

ในส่วนที่สองจะเป็นส่วนส่วนที่ทำหน้าที่กำหนดข้อมูลเข้าในส่วนของข้อมูล Short Term ที่จะถูกนำไปรวมกับข้อมูล Long Term โดยจะใช้ข้อมูลเข้าในอดีตและข้อมูลเข้าปัจจุบันมาผ่านฟังก์ชันกระตุ้นซิกมอยด์ และฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนก์เจนท์ เมื่อนำผลลัพธ์ของทั้งสองมาคูณกัน จากนั้นนำผลลัพธ์ที่ได้ไปรวมส่วน Long Term ดังนั้นการจัดการข้อมูลเข้านี้จึงถูกเรียกว่า “Input Gate” ดังสมการที่ (2.19)

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.19)$$

โดยที่ i คือผลลัพธ์จากฟังก์ชันแรก \tilde{C} คือผลลัพธ์จากฟังก์ชันที่สอง และ C คือข้อมูลออก

ในส่วนสุดท้ายจะกำหนดข้อมูลที่จะออกจากเซลล์เพื่อเข้าไปยังเซลล์ถัดไป รวมถึงเป็นการกำหนดความสำคัญของข้อมูล Short Term ที่จะใช้ต่อไป ในส่วนนี้จึงทำการนำทั้งข้อมูล Long Term และ Short Term มาผ่านฟังก์ชันกระตุ้นซิกมอยด์ และฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนก์เจนท์ จากนั้นนำมาคูณกันเพื่อให้ได้ผลลัพธ์เพื่อใช้เป็นข้อมูลเข้าให้เซลล์ถัดไป เนื่องจากส่วนนี้เป็นการจัดการกับข้อมูลออกจึงทำให้ถูกเรียกว่า “Output Gate” โดยมีสมการทางคณิตศาสตร์ดังสมการที่ (2.20, 2.21)

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.20)$$

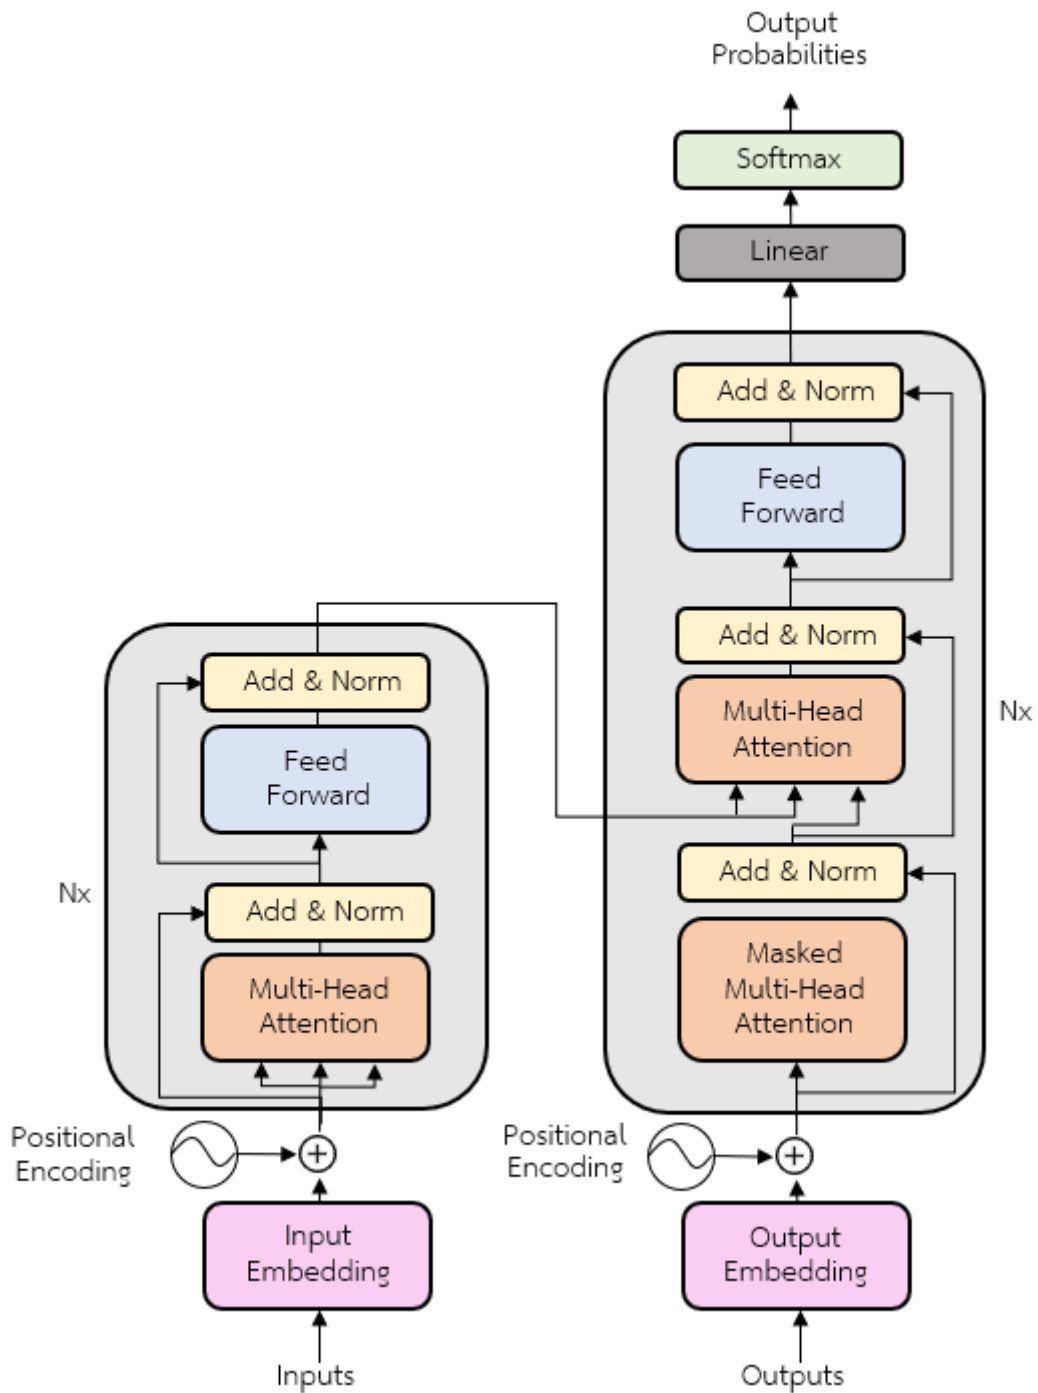
$$h_t = o_t * \tanh(C_t) \quad (2.21)$$

โดยที่ o คือข้อมูลที่ออกจากฟังก์ชันกระตุ้นซิกมอยด์ σ คือฟังก์ชันกระตุ้นซิกมอยด์ \tanh คือฟังก์ชันกระตุ้นไฮเพอร์โบลิกแทนกเจนท์ W คือค่าถ่วงน้ำหนัก h คือข้อมูลเข้าในอดีต x คือข้อมูลเข้า และ b คือไบแอส

แบบจำลองทรานส์ฟอร์มเมอร์ (Transformer Model)

แบบจำลองทรานส์ฟอร์มเมอร์ (Transformers Model) เป็นโครงข่ายประสาทเทียมที่ถูกเผยแพร่ออกมาในปี 2017 จากบทความที่มีชื่อว่า “Attention is all you need” (31) โดยงานวิจัยนี้ถูกนำไปใช้อ้างอิง และพัฒนาเป็นระบบโครงข่ายประสาทเทียมต่อยอดอีกเป็นจำนวนมาก เนื่องจากแบบจำลองทรานส์ฟอร์มเมอร์นี้สามารถแก้ไขปัญหาด้านการแปลภาษาด้วยเครื่อง (Machine Translation) ได้เป็นอย่างดี โดยระบบโครงข่ายประสาทเทียมชนิดนี้สามารถแก้ไขจุดอ่อนของระบบโครงข่ายประสาทเทียมที่นิยมใช้กันในช่วงก่อนหน้าคือ โครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent Neural Network) (32, 33) และระบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) ได้ (34) โดยมีหลักการสำคัญในการทำงานคือการใช้กระบวนการ “Self-Attention”

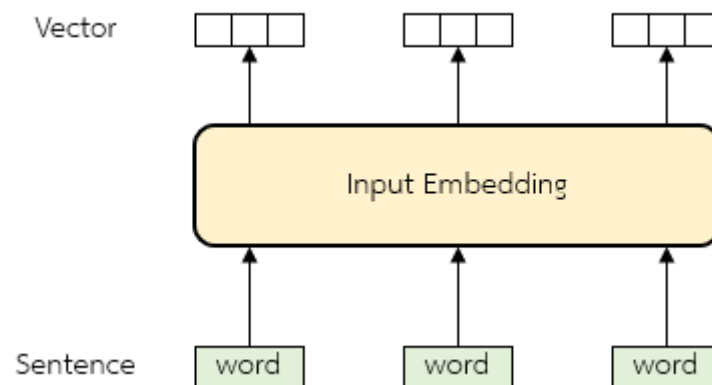
สถาปัตยกรรมของแบบจำลองทรานส์ฟอร์มเมอร์ (Transformer Architecture) จะแบ่งส่วนประกอบออกเป็น 2 ส่วน คือ การเข้ารหัส (Encoder) และการถอดรหัส (Decoder) โดยจะมีข้อมูลเข้า (Input Data) ที่แยกออกจากกัน โดยฝั่งของการเข้ารหัสส่วนของข้อมูลเข้าคือภาษาที่ต้องการแปล ส่วนฝั่งการถอดรหัสเป็นการใช้ข้อมูลออกก่อนหน้ามาเป็นข้อมูลเข้าเพื่อพยากรณ์หาคำถัดไป ซึ่งในส่วนของการเข้ารหัสและการถอดรหัสนั้นมีส่วนประกอบย่อยหรือชั้นต่าง ๆ ที่ทำให้ทั้ง 2 ส่วนมีการทำงานที่แตกต่างกัน โดยสถาปัตยกรรม (Architecture) โดยรวมของโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์เป็นดังที่แสดงไว้ในภาพที่ 19



ภาพที่ 19 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์
(ที่มา: Attention is all you need. Figure 1)

Input Embedding คือ ส่วนประกอบที่จะทำหน้าที่ในการแปลงข้อมูลที่เป็นคำศัพท์หรือข้อความให้เป็นปริมาณในเชิงคณิตศาสตร์ในรูปแบบเวกเตอร์ (Vector) เพื่อที่จะใช้เป็นข้อมูลเข้า

ให้กับแบบจำลอง (Model) โดยคำศัพท์ที่ได้รับการแปลงเป็นข้อมูลแบบเวกเตอร์นั้นจะมีค่าที่ใกล้เคียงกันหรือแตกต่างกันตามความหมายของคำศัพท์ที่ผ่านเข้าไป โดยเทคนิคที่ใช้ในส่วนนี้คือ Byte-pair Embedding (BPE) ในการเตรียมข้อมูลคำก่อนที่จะทำการเทียบกับข้อมูลคำศัพท์ที่บันทึกไว้ (Lookup Table) เพื่อเปรียบเทียบหาค่าเวกเตอร์ที่เหมาะสมกับคำศัพท์



ภาพที่ 20 ภาพแสดงการหลักการทำงานในขั้นตอน Input Embedding

Positional Encoding คือ การระบุตำแหน่งของข้อมูลให้กับเวกเตอร์ที่ผ่านการแปลงค่าจากคำศัพท์ในขั้นตอนของ Input Embedding เนื่องจากในแบบจำลองโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์นั้นไม่ได้มีการช่วยระบุตำแหน่งของข้อมูล เช่นเดียวกับ รีเคอร์เร็น (Recurrent) ในโครงข่ายประสาทเทียมแบบรีเคอร์เร็น (Recurrent Neural Network) และการทำคอนโวลูท (Convolute) ในโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) หลักจากผ่านกระบวนการ Positional Encoding เวกเตอร์ของคำศัพท์จะเข้าสู่ส่วนถัดไปของแบบจำลอง โดยในกระบวนการ Positional Encoding ของระบบโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์นี้จะใช้ฟังก์ชันไซน์ (Sine) และโคไซน์ (Cosine) เข้ามาช่วยในการระบุตำแหน่งของเวกเตอร์นั้น ๆ โดยฟังก์ชันดังกล่าวมีดังสมการที่ (2.22, 2.23)

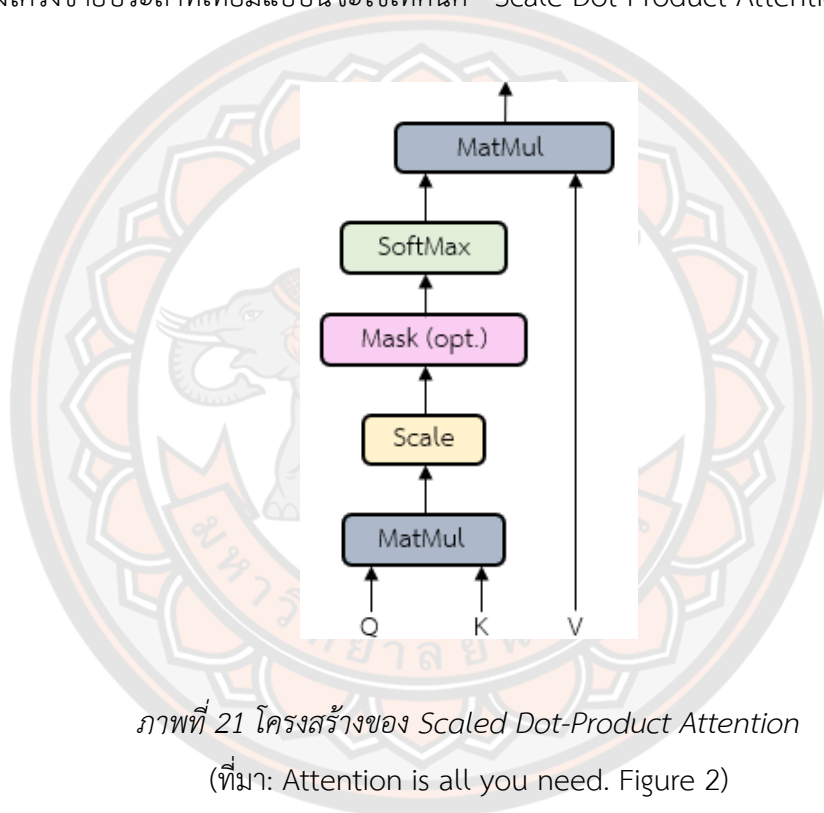
$$PE_{(pos,2i)} = \sin(pos/10000^{2i/d_{model}}) \quad (2.22)$$

$$PE_{(pos,2i+1)} = \cos(pos/10000^{2i/d_{model}}) \quad (2.23)$$

โดยที่ pos คือ ตำแหน่งของเวกเตอร์ i คือ ลำดับ และ d_{model} คือ มิติของเวกเตอร์

จากภาพที่ 19 กระบวนการของฝั่งการเข้ารหัส (ซ้าย) โดยในส่วนของฝั่งการถอดรหัส (ขวา) นั้น จะใช้ข้อมูลก่อนหน้าเป็นข้อมูลเข้า แต่ในส่วนของกระบวนการอื่น ๆ ทั้ง Input Embedding และ Positional Encoder จะเหมือนกับในส่วนของฝั่งการเข้ารหัส

หลังจากที่ได้ทำการแปลงข้อมูลเข้าจากที่เป็นคำศัพท์เป็นเวกเตอร์พร้อมกับใส่ตำแหน่งให้กับเวกเตอร์ผ่านกระบวนการ Input Embedding และ Positioning Encoder แล้วข้อมูลที่เป็นเวกเตอร์ก็จะเข้าสู่กระบวนการถัดไป โดยกระบวนการต่อจากนี้จะใช้เทคนิคเป็นส่วนสำคัญของโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์ คือ Attention ที่แปลตรงตัวว่า “ความสนใจ” ในส่วนของโครงข่ายประสาทเทียมแบบนี้จะใช้เทคนิค “Scale Dot-Product Attention”



ภาพที่ 21 โครงสร้างของ Scaled Dot-Product Attention

(ที่มา: Attention is all you need. Figure 2)

จากภาพที่ 21 Scaled Dot-Product Attention มีการแบ่งเวกเตอร์ออกเป็น 3 ส่วน คือ Query (q) ต่อมาคือ Key (k) และสุดท้ายคือ Value (v) โดย Query และ Key จะต้องนำมาทำการคูณแบบเวกเตอร์ (Dot Product) เพื่อเปรียบเทียบหาความเหมือนของข้อมูล จากนั้นจึงนำค่า Value ที่เหมาะสมมาใช้ โดยจะได้สมการแสดงความสัมพันธ์กันในรูปแบบเมทริกซ์ (Matrix) ได้ดังสมการที่ (2.24)

$$relevance = QK^T \quad (2.24)$$

โดยที่ Q คือ เมทริกซ์ของ query และ K^T คือ เมทริกซ์สลับเปลี่ยน (Transpose Matrix) ของ Key

หลังจากที่ได้สมการความสัมพันธ์ระหว่าง Query และ Key จะทำการแปลงค่าความสัมพันธ์ (Relevance) เป็นค่าความน่าจะเป็นก่อนที่จะเข้าสู่กระบวนการถัดไป โดยในระบบโครงข่ายประสาทเทียมแบบทรานส์ฟอร์มเมอร์นี้จะใช้ฟังก์ชันซอร์ฟแม็กซ์ (Softmax Function) ดังสมการที่ (2.25)

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (2.25)$$

โดยที่ x คือ ข้อมูลเข้า และ e คือ ค่าลอการิทึมธรรมชาติ (Natural Logarithm)

นอกจากเปลี่ยนค่าให้เป็นค่าความน่าจะเป็นด้วยฟังก์ชันซอร์ฟแม็กซ์แล้วในกระบวนการ Self-Attention นี้ยังต้องกำหนด Scale ของข้อมูล เนื่องจากขนาดของ Query และ Key จะมีผลต่อขนาดของผลลัพธ์ที่ได้จากการคูณเชิงเวกเตอร์ โดยจะนำรากของขนาดมิติของ Key มาหาร Scale กับค่าความสัมพันธ์ (Relevance) ก่อนจะนำเข้าไปในฟังก์ชันซอร์ฟแม็กซ์ เพื่อที่จะช่วยลดความแปรปรวนของข้อมูล (Variance) ลงดังสมการที่ (2.26)

$$\text{Attention}(K, Q, V) = \text{softmax}\left(\frac{KQ^T}{\sqrt{d_k}}\right) \quad (2.26)$$


โดยที่ d_k คือ ขนาดมิติของ Key

เมื่อทำการ Scaled Dot-Product Attention แล้ว ต้องมีการทำ Attention อีกรูปแบบหนึ่งเพื่อทำการลดข้อดีของการทำ Attention วิธีแรก คือการที่นำค่า Query Key และ Value มาคำนวณเพียงอย่างเดียวอาจจะไม่เพียงพอ จำเป็นต้องมีการเพิ่มในส่วน of ค่าถ่วงน้ำหนัก (Weight) และเพิ่มจำนวนการทำ Attention ให้มีค่า Query Key และ Value หลาย ๆ ชุด พร้อมกับค่าถ่วงน้ำหนักที่ต่างกัน เพื่อจะทำให้แบบจำลองสามารถเรียนรู้จากความสัมพันธ์ที่แตกต่างกันของข้อมูลแต่ละชุด จากนั้นจึงทำการรวมทุกชุด Attention เข้าด้วยกัน (Concatenation) ดังภาพที่ 22 ทำให้วิธีการนี้ถูกเรียกว่า “Multi-Head Attention” ดังสมการที่ (2.27, 2.28)

$$\text{head}_i = A(QW_i^Q, KW_i^K, VW_i^V) \quad (2.27)$$

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^O \quad (2.28)$$

โดยที่ W คือ เมทริกซ์ของค่าถ่วงน้ำหนัก



ภาพที่ 22 โครงสร้างของ Multi-Head Attention
(ที่มา: Attention is all you need. Figure 2)

การทำ Attention ในแบบจำลองทรานส์ฟอร์มเมอร์ มีการทำ Attention Layer อยู่ทั้งหมด 3 ตำแหน่ง ดังในภาพที่ 19 ตำแหน่งแรกคือในบริเวณของส่วนการเข้ารหัสโดยการทำ Attention ที่บริเวณนี้จะมีขั้นตอนเหมือนดังที่กล่าวมาข้างต้น คือการรับค่า Query Key และ Value เข้ามาหลักจากที่ผ่านมาจากกระบวนการ Embedding และ Positional Encoder โดยทุก ๆ ข้อมูลเข้าจะถูกนำมาคำนวณหาความสัมพันธ์กันทั้งหมด ตำแหน่งที่สองคือบริเวณต้นทางของส่วนของการถอดรหัส (Decoder) โดยการทำ Attention ที่บริเวณนี้จะไม่ได้อาศัยทุกค่าข้อมูลเข้ามาคำนวณหาความสัมพันธ์กันทั้งหมดเหมือนกับบริเวณส่วนการเข้ารหัส แต่จะใช้เฉพาะข้อมูลก่อนหน้าเท่านั้น เนื่องจากบริเวณนี้จะถือเป็นส่วนที่ใช้สำหรับการพยากรณ์หาข้อมูลตัวถัดไป การที่ให้แบบจำลองสามารถรู้ถึงข้อมูลตัวที่อยู่ถัดไปได้ อาจจะทำให้การฝึกสอนมีประสิทธิภาพที่ลดลง จึงต้องทำการปรับค่าให้ค่าความสัมพันธ์ของข้อมูลที่อยู่ถัดไปมีค่าเป็นอนันต์ (Masked) เพื่อให้แบบจำลองไม่สามารถรู้คำตอบได้ และตำแหน่งสุดท้ายคือบริเวณที่อยู่ในจุดเชื่อมต่อระหว่างส่วนเข้ารหัสกับถอดรหัสโดยจะใช้ข้อมูลเข้าจากทั้งสองส่วนคือใช้ Key และ Value จากส่วนของการเข้ารหัส และใช้ค่า Query จากส่วนของการถอดรหัส

ชั้นที่อยู่ถัดจากการทำ Attention คือ Layer Normalization ทำหน้าที่ปรับค่าต่าง ๆ ให้มีค่าที่เหมือนกันในแต่ละชุดข้อมูลเข้า โดยทำการปรับค่าเฉลี่ย (Mean) ค่าความแปรปรวน (Variance) ค่ามาตรฐาน (Normalize) สุดท้ายคือการปรับสเกลและชิฟ (Scale and Shift)

ส่วนถัดมาคือการทำให้ Feed-Forward Networks แบบเชื่อมต่อกันทั้งหมด (Fully-Connected) โดยในแบบจำลองทรานส์ฟอร์มเมอร์นี้จะใช้กระบวนการที่เรียกว่า “Positional-Wise Feed-Forward Neural Network” คือเป็นการใช้โครงข่ายเดียวกันในทุก ๆ ข้อมูลเข้าโดยแต่ละข้อมูลจะถูกคูณด้วยเมทริกซ์ถ่วงน้ำหนักค่าเดียวกันทั้งหมด ด้วยเหตุนี้จึงเป็นการช่วยลดจำนวนตัวแปรที่แบบจำลองจะต้องเรียนรู้ลง และในโครงข่ายประสาทเทียมนี้จะใช้จำนวนชั้นซ่อน (Hidden Layer) 1 ชั้น โดยภายในมีจำนวนโหนดของเซลล์ประสาทอยู่ 2,048 เซลล์ และจำนวนชั้นข้อมูลออกอยู่ที่ 512 เซลล์ ซึ่งในแบบจำลองนี้ได้ใช้ฟังก์ชันกระตุ้นเป็นแบบเรกติไฟต์ลิเนียยูนิต (ReLU) (31)

แบบจำลองทรานส์ฟอร์มเมอร์เป็นแบบจำลองที่ได้รับความนิยมอย่างมากเนื่องจากความสามารถในการประมวลผลและความแม่นยำของแบบจำลอง (35, 36) โดยแบบจำลองทรานส์ฟอร์มเมอร์นั้นได้ถูกนำไปพัฒนาใช้กับปัญหาในด้านต่าง ๆ อย่างแพร่หลาย ไม่ว่าจะเป็นด้าน การก่อกำเนิดข้อความ (Text Generation) โดยแบบจำลอง GPT (Generative Pre-trained Transformer) (37) ด้านการทำความเข้าใจบริบทของข้อความโดยแบบจำลอง BERT (Bidirectional Encoder Representations from Transformers) (38) ด้านการจำแนกประเภทภาพ (Image Classification) โดยแบบจำลอง ViT (Vision Transformer) (39) และด้านการวางกรอบของงานด้าน NLP โดยแบบจำลอง T5 (Text-to-Text Transfer Transformer) (40)

แบบจำลอง N-BEATS (Neural Basis Expansion Analysis for interpretable Time Series forecasting Model)

แบบจำลอง N-BEATS เป็นแบบจำลองการเรียนรู้เชิงลึกที่ถูกพัฒนาขึ้นเพื่อการพยากรณ์อนุกรมเวลา โดยมุ่งหวังที่จะให้การพยากรณ์ที่แม่นยำพร้อมกับการทำให้เป็นอิสระและยืดหยุ่น (41) แนวคิดสำคัญของแบบจำลอง N-BEATS คือการแยกส่วนข้อมูลอนุกรมเวลา ออกเป็นแบบรูป (Pattern) และแนวโน้มที่เป็นตัวแปรได้โดยใช้โครงข่ายประสาทเทียมจำนวนมากเชื่อมต่อกัน

แบบจำลอง N-BEATS ประกอบด้วยกลุ่มของโครงข่ายประสาทเทียมแต่ละกลุ่มทำการตรวจจับความเชื่อมโยงของข้อมูลอนุกรมเวลาในด้านต่าง ๆ โดยส่วนประกอบดังกล่าวมีโครงสร้างชั้นย่อยซ้อนกัน และแต่ละตัวเน้นการตรวจจับแนวโน้มที่มีช่วงเวลาต่าง ๆ เช่นแนวโน้มระยะสั้น ถึงความสัมพันธ์ระยะยาว ทำให้แบบจำลอง N-BEATS สามารถจับความซับซ้อนในข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพ

คุณสมบัติที่สำคัญของแบบจำลอง N-BEATS คือความสามารถในการอธิบายผลลัพธ์ (Interpretability) ด้วยการแยกวิเคราะห์ข้อมูลอนุกรมเวลาเป็นรูปแบบที่สามารถอธิบายได้ โดยแบบจำลอง N-BEATS จะให้ข้อมูลเชิงลึกเกี่ยวกับรูปแบบและแนวโน้มซึ่งถือเป็นปัจจัยในการฝึกสอน

แบบจำลอง ความสามารถในการอธิบายผลลัพธ์นี้เป็นประโยชน์ในการเข้าใจปัจจัยที่มีผลต่อการพยากรณ์และการรับรู้ถึงข้อมูลที่สามารถนำไปใช้ในการตัดสินใจได้

แบบจำลอง N-BEATS นั้นเป็นแบบจำลองการเรียนรู้เชิงลึกที่ออกแบบมาสำหรับงานพยากรณ์อนุกรมเวลา โดยใช้การเชื่อมต่อแบบ Fully-Connected ของโครงข่ายประสาทเทียม เพื่อตรวจจับความซับซ้อนและแยกแยะรูปแบบและแนวโน้มต่าง ๆ ในข้อมูล แบบจำลองสามารถพยากรณ์อย่างแม่นยำโดยที่เน้นไปที่ช่วงเวลาต่าง ๆ ด้วยการสื่อสาร ด้วยความสามารถในการอธิบายและความยืดหยุ่นของมัน N-BEATS เป็นเครื่องมือที่มีประสิทธิภาพสำหรับการเข้าใจและพยากรณ์ข้อมูลลำดับเวลาในด้านต่าง ๆ ไม่ว่าจะเป็น ด้านการเงิน ด้านพลังงาน หรือแม้กระทั่งด้านสุขภาพ

แบบจำลอง N-HiTS (Neural Hierarchical Interpolation for Time Series Forecasting Model)

แบบจำลอง N-HiTS (42) เป็นแบบจำลองที่มีการพัฒนามาจากแบบจำลอง N-BEATS ให้มีความแม่นยำของการพยากรณ์และลดปริมาณทรัพยากรที่ใช้ในการฝึกสอนแบบจำลอง โดยเทคนิคนี้เป็นเทคนิคที่ออกแบบมาเพื่อแก้ไขความสามารถในการพยากรณ์ข้อมูลอนุกรมเวลาซึ่งมีลักษณะประกอบด้วยชุดข้อมูลอนุกรมเวลาที่มีความสัมพันธ์กันหลายชุดที่มีลำดับชั้น (Hierarchical) แบบจำลอง N-HiTS นั้นการใช้โครงข่ายประสาทในการจำลองความสัมพันธ์ที่เป็นลำดับชั้นและความสัมพันธ์ต่อกันในชุดข้อมูลอนุกรมเวลา โดยนำสถาปัตยกรรมของแบบจำลองการเรียนรู้เชิงลึก เช่น โครงข่ายประสาทเทียมแบบรีเคอร์เร็น หรือ LSTM นำมาใช้งานเนื่องจาก แบบจำลองโครงข่ายประสาทเหล่านี้สามารถจับรูปแบบและความสัมพันธ์ที่ซับซ้อนภายในข้อมูลได้

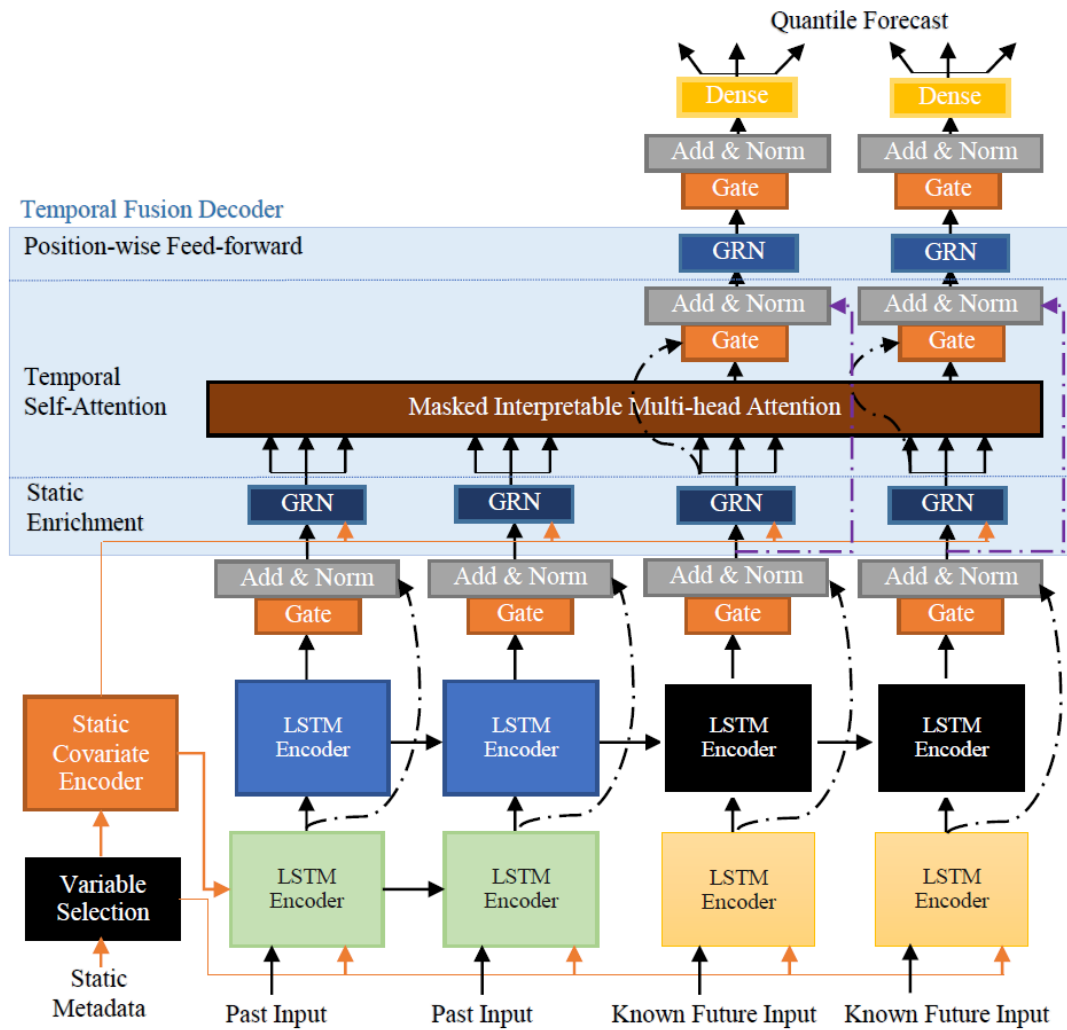
หลักการการทำงานของแบบจำลอง N-HiTS นั้นประกอบด้วยขั้นตอนหลายขั้นตอน การจัดการชุดข้อมูลอนุกรมเวลาแบบลำดับชั้น จะถูกจัดการให้เรียบร้อยโดยให้แต่ละชุดข้อมูลอนุกรมเวลาเชื่อมโยงกับระดับการรวมที่เกี่ยวข้อง (Respective Aggregation Level) โดยโครงสร้างนี้ช่วยให้สามารถจัดการและพยากรณ์ข้อมูลในระดับข้อมูลที่แตกต่างกันได้ นอกจากนี้แบบจำลอง N-HiTS ยังสามารถจัดการกับข้อมูลที่สูญหายหรือมีการเว้นว่างในชุดข้อมูลอนุกรมเวลา ด้วยเทคนิคการประมาณค่าในช่วง (Interpolation) เพื่อเติมเต็มข้อมูลที่ขาดหายด้วยการประมาณค่า ซึ่งขั้นตอนนี้ให้ข้อมูลที่ให้การพยากรณ์มีความน่าเชื่อถือและครบถ้วนมากยิ่งขึ้น

จากลักษณะการทำงานที่ได้อธิบายไปข้างต้นจะเห็นว่าแบบจำลอง N-HiTS นั้นใช้โครงข่ายประสาทและเทคนิคการจัดการความต่างระดับชั้นเพื่อจัดการกับความซับซ้อนในการพยากรณ์ข้อมูลอนุกรมเวลา และจัดการกับความไม่ต่อเนื่องของข้อมูล โดยการจับรูปแบบและความสัมพันธ์ระดับชั้นของข้อมูล แบบจำลอง N-HiTS นั้นสามารถนำไปประยุกต์ใช้ได้หลายด้าน ไม่ว่าจะเป็นการจัดการกับการค้า การจัดการสินค้าคงคลัง หรือด้านการใช้พลังงานได้

แบบจำลอง TFT (Temporal Fusion Transformer Model)

แบบจำลอง TFT คือแบบจำลองการเรียนรู้เชิงลึกที่ได้พัฒนามาจากหลาย ๆ เทคนิคในอดีต ให้มีความทันสมัยและมีประสิทธิภาพที่ดีสำหรับงานการพยากรณ์ข้อมูลอนุกรมเวลา โดยแบบจำลองนี้ได้รับการแนะนำในงานวิจัยที่ชื่อ "Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting" (43) โดยการใช้แบบจำลอง TFT ถือเป็นการพัฒนาการนำข้อมูลอนุกรมเวลามาใช้อย่างมีประสิทธิภาพ เนื่องจากความสามารถในการสร้างคาดการณ์ที่แม่นยำสำหรับหลายระยะเวลาพร้อมกัน ทำให้มีประสิทธิภาพและความหลากหลายในการจัดการกับการพยากรณ์ข้อมูลอนุกรมเวลา

ในสถาปัตยกรรมของแบบจำลอง TFT นั้นได้ใช้หลักการของแบบจำลองทรานส์ฟอร์มเมอร์ที่ได้ถูกพัฒนาและนำมาใช้งานอย่างแพร่หลายทางด้านการประมวลภาษาธรรมชาติ (Natural Language Processing) ซึ่งใช้เทคนิคอย่าง Self-Attention (44) ที่ช่วยให้แบบจำลองสามารถจับการขึ้นต่อการตั้งค่าง่ายยาวในข้อมูลที่มีความเป็นลำดับได้อย่างมีประสิทธิภาพ ดังภาพที่ 23 ในบริบทของการพยากรณ์ข้อมูลอนุกรมเวลา แบบจำลอง TFT ใช้สถาปัตยกรรมของทรานส์ฟอร์มเมอร์เพื่อให้สามารถคำนวณและตรวจจับลำดับเวลาที่ซับซ้อน ซึ่งทำให้มีความสามารถในการจัดการความซับซ้อนระหว่างจุดเวลาต่าง ๆ ในชุดข้อมูล



ภาพที่ 23 สถาปัตยกรรมของแบบจำลอง TFT (Temporal Fusion Transformer Model)

จุดเด่นสำคัญของแบบจำลอง TFT คือการนำเทคนิคการรวมข้อมูลเวลา (Temporal Fusion Techniques) เข้ามาใช้ร่วมกัน ทำให้แบบจำลอง TFT สามารถรวมข้อมูลจากหลายช่วงเวลาได้อย่างมีประสิทธิภาพ และสามารถสร้างการคาดการณ์ที่แม่นยำ นอกจากนี้แบบจำลอง TFT ทำการรวมข้อมูลตามช่วงเวลาเพื่อสร้างความเข้าใจที่ครอบคลุมในเชิงเวลาของชุดข้อมูล ทำให้มีประสิทธิภาพในการจัดการกับพยากรณ์ในชุดข้อมูลอนุกรมเวลาแต่ละลำดับขั้น โดยไม่ต้องใช้แบบจำลองอื่น ๆ เข้ามาช่วยในการจัดการ

จากที่ได้กล่าวมาข้างต้นทำให้แบบจำลอง TFT นั้นมีความเหมาะสมสำหรับการนำมาใช้เป็นเครื่องมือในการพยากรณ์หาค่าความต้องการใช้พลังงาน ซึ่งเป็นชุดข้อมูลที่มีลักษณะเป็นอนุกรมเวลา พร้อมทั้งยังสามารถนำปัจจัยอื่น ๆ ที่มีความเกี่ยวข้องกับการใช้พลังงานเข้ามาเป็นส่วนหนึ่งสำหรับ

การพยากรณ์เพื่อเพิ่มความแม่นยำให้กับแบบจำลองได้ รวมถึงได้มีการทดลองใช้งานแบบจำลอง TFT ในการหาค่าความผิดพลาดของการพยากรณ์หาค่าความต้องการใช้ไฟฟ้าโดยใช้ข้อมูลการใช้ไฟฟ้าในประเทศปานามา (45) โดยผลลัพธ์ค่าความผิดพลาดของการพยากรณ์หาค่าความต้องการใช้ไฟฟ้าที่ได้ น้อยกว่าการใช้แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ดังนั้นจึงทำให้แบบจำลอง TFT เหมาะสมสำหรับนำมาใช้ในวิทยานิพนธ์นี้



บทที่ 3

วิธีดำเนินการวิจัย

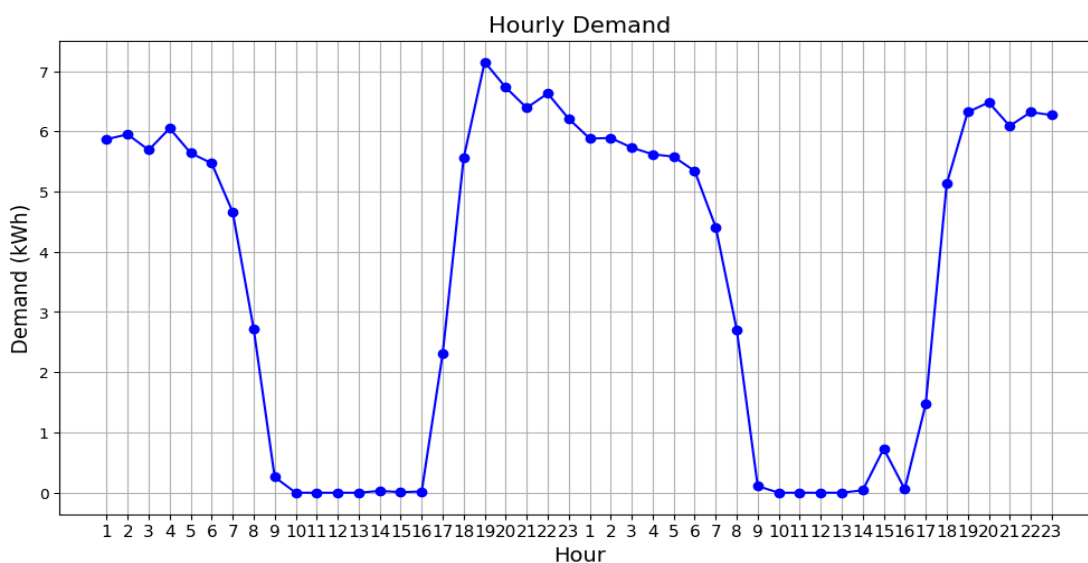
ในบทนี้เป็นการอธิบายขั้นตอนการดำเนินการวิจัยการพยากรณ์หาค่าความต้องการไฟฟ้าภายในอาคารของวิทยาลัยพลังงานทดแทนและสมาร์ตกริดเทคโนโลยี (SGtech) ตั้งแต่ขั้นตอนการจัดเตรียมข้อมูลความต้องการใช้ไฟฟ้าในอดีต การพิจารณาปัจจัยที่เกี่ยวข้อง และการจัดกลุ่มข้อมูลสำหรับใช้ฝึกสอนแบบจำลอง รวมถึงวิธีวัดประสิทธิภาพของแบบจำลอง

การเตรียมข้อมูลสำหรับการฝึกสอนแบบจำลอง

ขั้นตอนแรกสำหรับการเตรียมข้อมูลสำหรับฝึกสอนแบบจำลองคือการนำข้อมูลความต้องการไฟฟ้าในอดีตของอาคารในวิทยาลัย ฯ ที่ต้องการพยากรณ์มาจัดเตรียมนำส่วนของข้อมูลที่มีความสำคัญต่อการพยากรณ์ โดยมีข้อมูล ดังนี้ วันที่ เวลารายชั่วโมง และปริมาณความต้องการใช้ไฟฟ้า ดังตารางที่ 1

ตารางที่ 1 ตัวอย่างข้อมูลการใช้พลังงานภายในอาคารในวิทยาลัยพลังงาน ฯ

Date	Hour	Demand (kWh)
2022-01-01	1	5.87
2022-01-01	2	5.95
2022-01-01	3	5.69
2022-01-01	4	6.05
2022-01-01	5	5.64
2022-01-01	6	5.47
2022-01-01	7	4.66
2022-01-01	8	2.72
2022-01-01	9	0.26
2022-01-01	10	0
2022-01-01	11	0
2022-01-01	12	0
2022-01-01	13	0
2022-01-01	14	0.03



ภาพที่ 24 ข้อมูลความต้องการใช้ไฟฟ้าเป็นรายชั่วโมงของอาคาร NDIR ที่มีลักษณะการใช้ไฟฟ้าแบบโพรซูเมอร์

ข้อมูลจากตารางที่ 1 เมื่อนำมาแสดงในรูปแบบกราฟเส้นดังภาพที่ 24 แสดงถึงปริมาณการใช้พลังงานไฟฟ้าของอาคาร NDIR ซึ่งมีลักษณะเป็นโพรซูเมอร์ (Prosumer) ที่มีการผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ใช้งานภายในอาคาร เป็นเวลา 2 วัน ซึ่งข้อมูลแสดงเป็นรายชั่วโมงตั้งแต่ 1 ถึง 23 ชั่วโมง โดยจะเห็นว่าในช่วงชั่วโมงที่ 1 ถึง 6 มีปริมาณความต้องการใช้ไฟฟ้าอยู่ที่ประมาณ 5 กิโลวัตต์-ชั่วโมง จากนั้นจึงลดลงจนถึงชั่วโมงที่ 10 ที่ความต้องการไฟฟ้ามีค่าประมาณ 0 กิโลวัตต์-ชั่วโมง เป็นเวลา 6 ชั่วโมง จนถึงชั่วโมงที่ 16 ความต้องการไฟฟ้ากลับมีเพิ่มขึ้นอย่างรวดเร็วจนมีค่าประมาณ 7 กิโลวัตต์-ชั่วโมง ที่ชั่วโมง 19 และอยู่ที่ช่วง 6 กิโลวัตต์-ชั่วโมง จนถึงชั่วโมงที่ 23 ซึ่งถือว่าครบเวลา 1 วัน ถัดมาพฤติกรรมโดยรวมนั้นยังมีความคล้ายคลึงกับวันที่ 1 โดยสังเกตได้ว่าในช่วงเวลากลางวันจะมีความต้องการใช้พลังงานไฟฟ้าที่ต่ำกว่าช่วงกลางคืนถึงช่วงเช้า

หลังจากที่มีข้อมูลความต้องการใช้ไฟฟ้าเป็นรายชั่วโมงในอดีตแล้ว ขั้นตอนถัดไปจะเป็นการนำข้อมูลปัจจัยต่าง ๆ ที่คาดว่าจะมีผลต่อความต้องการใช้ไฟฟ้ามารวมเข้ากับข้อมูลความต้องการใช้ไฟฟ้าเพื่อนำไปฝึกสอนแบบจำลองต่อไป

การพิจารณาเลือกปัจจัยที่ส่งผลต่อความต้องการใช้ไฟฟ้า

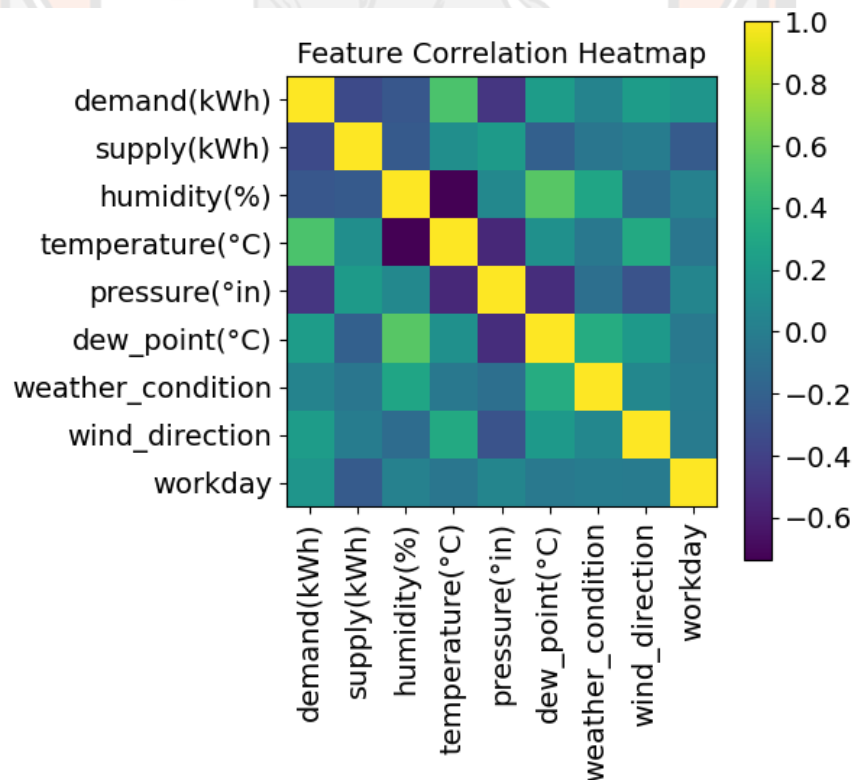
นอกจากการใช้ข้อมูลปริมาณความต้องการใช้ไฟฟ้าในอดีตมาเป็นข้อมูลสำหรับการฝึกสอนแบบจำลอง การเพิ่มปัจจัยอื่น ๆ ที่อาจมีความสัมพันธ์กับปริมาณการใช้ไฟฟ้าถือเป็นอีกปัจจัยที่จะส่งผลต่อความแม่นยำของแบบจำลองในการพยากรณ์หาค่าความต้องการใช้ไฟฟ้าในอนาคต โดยใน

การทดลองได้รวบรวมปัจจัยอื่น ๆ ที่คาดว่าจะมีผลต่อการพยากรณ์มาใช้เพิ่มเติม โดยหลังจากรวบรวมมาได้จะทำการวิเคราะห์หาสหสัมพันธ์ (Correlation) ของปัจจัยอื่น ๆ แต่ละชนิดต่อค่าความต้องการใช้ไฟฟ้า

การคำนวณหาค่าสหสัมพันธ์ของแต่ละปัจจัย ด้วยการคำนวณค่าสหสัมพันธ์ของทุกข้อมูลเปรียบเทียบกับโดยใช้สหสัมพันธ์แบบเพียร์สัน (Pearson Correlation) มาทำการคำนวณ โดยค่าที่ได้จากการคำนวณจะมีค่าอยู่ระหว่าง -1 ถึง 1 โดยที่ค่าที่เข้าใกล้ 1 แสดงถึงค่าความเกี่ยวข้องกันของข้อมูล ค่าเข้าใกล้ 0 แสดงให้เห็นว่าข้อมูลไม่มีความเกี่ยวข้องกัน และค่าเข้าใกล้ -1 แสดงถึงความผกผันกันของข้อมูล ดังรูปภาพที่ 25 โดยสมการทางคณิตศาสตร์ของการหาสหสัมพันธ์แบบเพียร์สันมีดังสมการ (3.1)

$$\rho(x, y) = \frac{cov(x, y)}{\sigma_x \sigma_y} \quad (3.1)$$

โดยที่ $\rho(x, y)$ คือค่าสัมประสิทธิ์สหสัมพันธ์ $cov(x, y)$ คือค่าความแปรปรวน และ σ คือส่วนเบี่ยงเบนมาตรฐาน



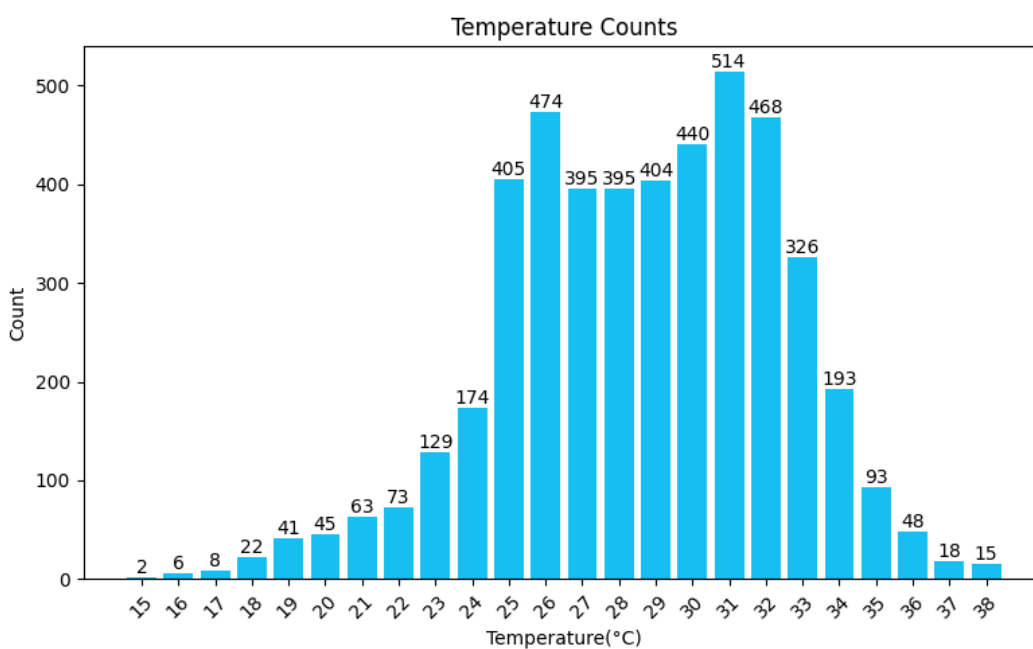
ภาพที่ 25 แผนที่ความร้อน (Heatmap) ของค่าสหสัมพันธ์ของปัจจัยที่คาดว่าจะมีผลต่อการพยากรณ์

จากภาพที่ 25 เป็นการนำปัจจัยที่คิดว่าเกี่ยวข้องกับความต้องการใช้ไฟฟ้า ประกอบด้วย ปริมาณการจ่ายพลังงานไฟฟ้า (Supply) ความชื้น (Humidity) อุณหภูมิ (Temperature) ความดันอากาศ (Pressure) อุณหภูมิจุดน้ำค้าง (Dew Point) สภาพอากาศ (Weather Condition) ทิศทางลม (Wind Direction) วันทำการของวิทยาลัย ฯ (Workday) และช่วงเวลาของวัน (Hour Group) มาทำการหาค่าสหสัมพันธ์ เพื่อหาปัจจัยที่มีผลลัพธ์ค่าสหสัมพันธ์เป็นบวก ซึ่งแสดงถึงความเกี่ยวข้องกันของระหว่างสองปัจจัย โดยปัจจัยที่มีค่าสหสัมพันธ์มากที่สุดจะถูกนำไปรวมกับความต้องการใช้ไฟฟ้าในการฝึกสอนแบบจำลอง โดยปัจจัยที่มีค่าสหสัมพันธ์มากที่สุดได้แก่ อุณหภูมิ อุณหภูมิจุดน้ำค้าง ทิศทางลม วันทำการของวิทยาลัย ฯ ช่วงเวลาของวัน และสภาพอากาศ เมื่อนำมารวมกับความต้องการใช้ไฟฟ้าจะได้ดังตารางที่ 2

ตารางที่ 2 ข้อมูลปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงาน

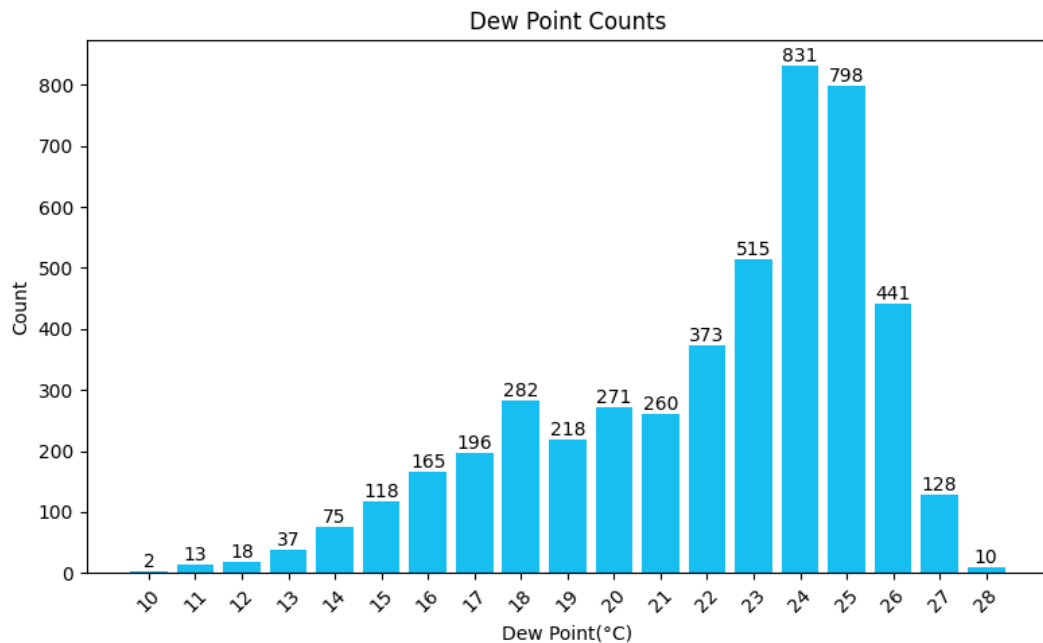
Date	Hour	Demand (kWh)	Temperature (°C)	Dew Point (°C)	Wind Direction	Weather Condition	Hour Group	Work day
15/2/22	7	6.28	25	22.22	0	8	0	1
15/2/22	8	6.95	25	22.22	0	8	0	1
15/2/22	9	9.92	25	22.22	10	0	0	1
15/2/22	10	42.1	26.11	22.22	10	0	0	1
15/2/22	11	41.05	26.11	22.22	8	5	0	1
15/2/22	12	34.64	27.22	22.22	11	0	0	1
15/2/22	13	38.05	27.78	20	11	0	1	1
15/2/22	14	39.91	27.22	21.11	5	4	1	1
15/2/22	15	32.76	25	21.11	11	7	1	1
15/2/22	16	32.8	25	22.22	7	6	1	1
15/2/22	17	30.62	23.89	22.78	8	6	1	1
15/2/22	18	19.07	23.89	22.22	8	5	1	1
15/2/22	19	11.27	22.78	22.22	0	0	1	1
15/2/22	20	8.6	22.78	22.22	0	0	1	1
16/2/22	6	6.17	22.78	22.22	8	6	0	1
16/2/22	7	5.92	22.78	22.22	0	6	0	1
16/2/22	8	5.1	22.78	22.78	0	7	0	1

จากภาพที่ 26 แสดงให้เห็นถึงปริมาณอุณหภูมิแต่ละช่วงอุณหภูมิของข้อมูลอุณหภูมิทั้งหมด โดยจะเห็นว่ามียุณหภูมิตั้งแต่ 15 องศาเซลเซียส จนถึง 38 องศาเซลเซียส ส่วนของช่วงอุณหภูมิที่มีปริมาณชั่วโมงมากที่สุดเป็นช่วงตั้งแต่ 25 องศาเซลเซียส จนถึง 33 องศาเซลเซียส ซึ่งมีปริมาณชั่วโมงเกิน 300 ชั่วโมงในแต่ละช่วงอุณหภูมิ




ภาพที่ 26 ปริมาณอุณหภูมิแต่ละช่วงของปัจจัยที่เกี่ยวข้องอุณหภูมิ

จากภาพที่ 27 แสดงให้เห็นถึงปริมาณอุณหภูมิแต่ละช่วงอุณหภูมิจุดน้ำค้างของข้อมูลอุณหภูมิจุดน้ำค้างทั้งหมด โดยจะเห็นว่ามียุณหภูมิตั้งแต่ 10 องศาเซลเซียส จนถึง 28 องศาเซลเซียส ส่วนของช่วงอุณหภูมิที่มีปริมาณชั่วโมงมากที่สุดเป็นช่วงตั้งแต่ 16 องศาเซลเซียส จนถึง 26 องศาเซลเซียส ซึ่งมีปริมาณชั่วโมงเกิน 150 ชั่วโมงในแต่ละช่วงอุณหภูมิจุดน้ำค้าง



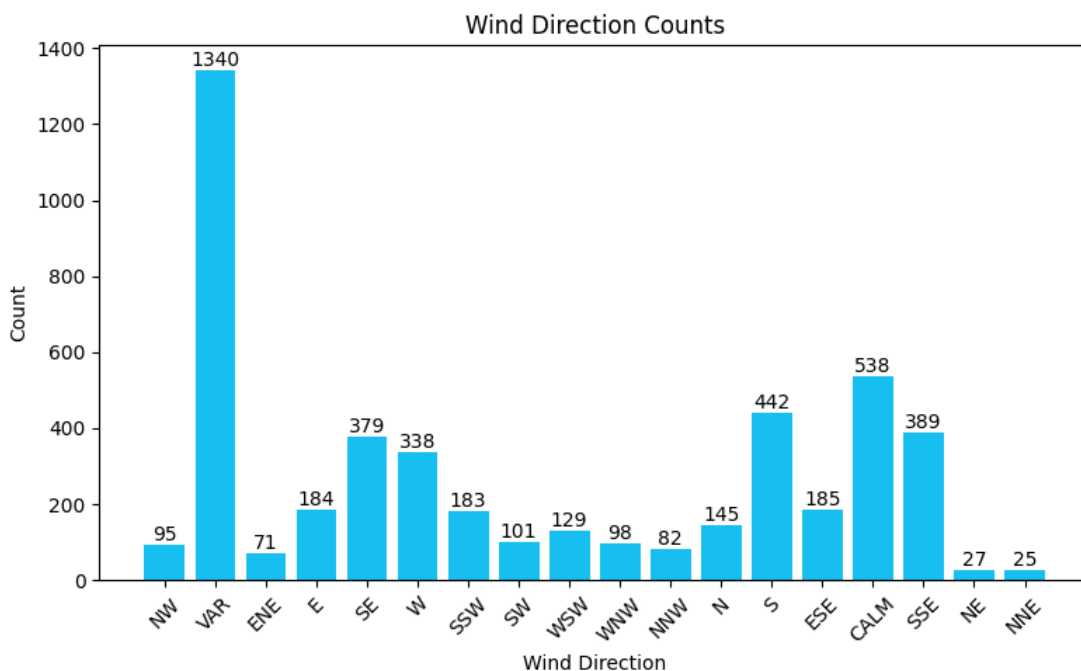
ภาพที่ 27 ปริมาณอุณหภูมิจุดน้ำค้างแต่ละช่วงของปัจจัยที่เกี่ยวข้องของอุณหภูมิจุดน้ำค้าง

จากภาพที่ 28 แสดงให้เห็นถึงปริมาณสภาพอากาศแต่ละชนิดของข้อมูลสภาพอากาศทั้งหมด โดยชนิดสภาพอากาศที่มีมากที่สุดคืออากาศดี (Fair) ที่มีจำนวน 3600 ชั่วโมง ส่วนสภาพอากาศที่มีปริมาณน้อยลงมากคือมีเมฆบางส่วน (Partly Cloudy) จำนวน 409 ชั่วโมง และมีเมฆเป็นส่วนมาก (Mostly Cloudy) จำนวน 409 ชั่วโมง ส่วนสภาพอากาศอื่น ๆ ที่เหลือมีปริมาณชั่วโมงที่น้อย อยู่ที่น้อยกว่า 100 ชั่วโมง



ภาพที่ 28 ปริมาณสภาพอากาศแต่ละชนิดของปัจจัยที่เกี่ยวข้องสภาพอากาศ

จากภาพที่ 29 แสดงให้เห็นถึงปริมาณทิศทางลมแต่ละทิศของข้อมูลทิศทางลมทั้งหมด โดยชนิดทิศทางลมที่มีมากที่สุดคือทิศทางแปรปรวน (VAR) ที่มีจำนวน 1340 ชั่วโมง ส่วนทิศทางลมที่มีปริมาณน้อยลงมากคือลมสงบ (CALM) จำนวน 538 ชั่วโมง ทิศใต้ (S) จำนวน 442 ชั่วโมง ทิศใต้-ทิศตะวันออกเฉียงใต้ (SSE) จำนวน 389 ชั่วโมง ทิศตะวันออกเฉียงใต้ (SE) จำนวน 379 ชั่วโมง และทิศตะวันตก (W) จำนวน 338 ชั่วโมง ส่วนทิศที่เหลือมีปริมาณน้อยกว่า 200 ชั่วโมง



ภาพที่ 29 ปริมาณทิศทางลมแต่ละทิศของปัจจัยที่เกี่ยวข้องทิศทางลม

การจัดการข้อมูลด้วยวิธีการเข้ารหัสป้าย

ในส่วนของการจัดการข้อมูลด้วยการเข้ารหัสป้าย (Label Encoding) เป็นวิธีการจัดการข้อมูลด้วยการแปลงค่าของข้อมูลจากตัวอักษรเป็นตัวเลขเพื่อให้สะดวกต่อการนำไปใช้ในการฝึกสอนแบบจำลอง ในวิทยานิพนธ์นี้มีการวิธีการเข้ารหัสป้ายในส่วนข้อมูลทิศทางลมและสภาพอากาศดังภาพที่ 30 และ 31 ที่มีลักษณะเป็นตัวอักษรให้กลายเป็นตัวเลขก่อนนำไปเข้าสู่กระบวนการฝึกสอน นอกจากนี้ยังมีการเพิ่มการจำแนกข้อมูลของวันทำงานและวันหยุดรวมถึงช่วงเวลาในวันนั้น ๆ ซึ่งส่งผลโดยตรงต่อปริมาณการใช้ไฟฟ้าภายในอาคารเพื่อเพิ่มปริมาณของข้อมูลให้กับแบบจำลอง

Before		After
VAR	LABEL ENCODING	0
ESE		1
ENE		2
NE		3
SE		4
WNW		5
WSE		6
W		7
NNW		8
CALM		9
N		10
MW		11
E		12
SSE		13
SW		14
NNE		15
SSW		16
S	17	

ภาพที่ 30 การจัดการข้อมูลด้วยวิธีการเข้ารหัสป้ายของข้อมูลทิศทางลม

Before		After
Fair	LABEL ENCODING	0
Shallow Fog		1
Partial Fog		2
Mist		3
Mostly Cloudy		4
Partly Cloudy		5
Light Rain		6
Light Drizzle		7
Cloudy		8
Rain		9
Fog		10
T-Storm		11
Haze		12
Showers in the Vicinity		13
Thunder	14	

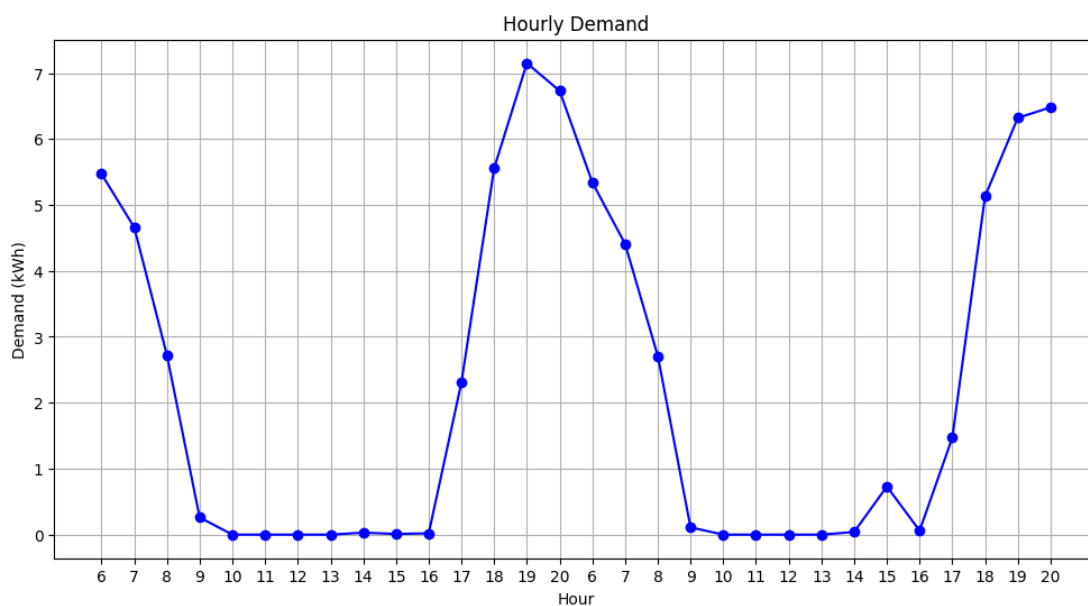
ภาพที่ 31 การจัดการข้อมูลด้วยวิธีการเข้ารหัสป้ายของข้อมูลสภาพอากาศ

ตารางที่ 3 ข้อมูลสำหรับการฝึกสอนแบบจำลอง

Date	Hour	Demand (kWh)	Temperature (°C)	Dew Point (°C)	Wind Direction	Weather Condition	Hour Group	Work day
15/2/22	7	6.28	25	22.22	0	8	0	1
15/2/22	8	6.95	25	22.22	0	8	0	1
15/2/22	9	9.92	25	22.22	10	0	0	1
15/2/22	10	42.1	26.11	22.22	10	0	0	1
15/2/22	11	41.05	26.11	22.22	8	5	0	1
15/2/22	12	34.64	27.22	22.22	11	0	0	1
15/2/22	13	38.05	27.78	20	11	0	1	1
15/2/22	14	39.91	27.22	21.11	5	4	1	1
15/2/22	15	32.76	25	21.11	11	7	1	1
15/2/22	16	32.8	25	22.22	7	6	1	1
15/2/22	17	30.62	23.89	22.78	8	6	1	1
15/2/22	18	19.07	23.89	22.22	8	5	1	1
15/2/22	19	11.27	22.78	22.22	0	0	1	1
15/2/22	20	8.6	22.78	22.22	0	0	1	1
16/2/22	6	6.17	22.78	22.22	8	6	0	1
16/2/22	7	5.92	22.78	22.22	0	6	0	1
16/2/22	8	5.1	22.78	22.78	0	7	0	1
16/2/22	9	4.46	22.78	22.78	0	6	0	1
16/2/22	10	6.99	22.78	22.78	0	9	0	1
16/2/22	11	7.09	22.78	22.78	11	7	0	1
16/2/22	12	4.43	22.78	22.78	0	6	0	1
16/2/22	13	2.26	23.89	23.89	0	6	1	1
16/2/22	14	1.35	25	23.89	0	4	1	1
16/2/22	15	1.96	25	22.78	0	0	1	1
16/2/22	16	2.42	25	23.89	0	0	1	1
16/2/22	17	2.22	25	23.89	0	0	1	1
16/2/22	18	6.62	23.89	23.89	0	0	1	1
16/2/22	19	8.71	23.89	23.89	9	6	1	1
16/2/22	20	8.1	23.89	23.89	2	0	1	1

ตารางที่ 4 สรุปข้อมูลสำหรับฝึกสอนแบบจำลอง

ตัวแปร	ชนิดข้อมูล	คำอธิบาย / ตัวอย่าง	ช่วงข้อมูล
Date	String	ข้อมูลวัน/เดือน/ปี	-
Hour	Integer	ข้อมูลเวลารายชั่วโมง	[0,23]
Demand	Float	ข้อมูลปริมาณความต้องการใช้ไฟฟ้า ณ ชั่วโมงนั้น ๆ มีหน่วยเป็น กิโลวัตต์ชั่วโมง (kWh)	[0,∞]
Supply	Float	ข้อมูลปริมาณการจ่ายไฟฟ้าไปยังภายนอก ณ ชั่วโมงนั้น ๆ มีหน่วยเป็น กิโลวัตต์ชั่วโมง (kWh)	[0,∞]
Wind	String	ข้อมูลทิศทางลม ณ ชั่วโมงนั้น ๆ	-
Condition	String	ข้อมูลสภาพอากาศ ณ ชั่วโมงนั้น ๆ	-
Humidity	Float	ข้อมูลค่าความชื้นในอากาศ ณ ชั่วโมงนั้น ๆ มีหน่วยเป็นเปอร์เซ็นต์ (%)	[0-100]
Temperature	Float	ข้อมูลค่าอุณหภูมิ ณ ชั่วโมงนั้น ๆ มีหน่วยเป็นองศาเซลเซียส (°C)	[0-100]
Pressure	Float	ข้อมูลค่าความกดอากาศ ณ ชั่วโมงนั้น ๆ มีหน่วยเป็นนิ้วปรอท (inHg)	[28.5-31.0]
Dew Point	Float	ข้อมูลค่าอุณหภูมิจุดน้ำค้าง ณ ชั่วโมงนั้น ๆ มีหน่วยเป็นองศาเซลเซียส (°C)	[0-100]
Work Day	Boolean	ข้อมูลแสดงวันทำการของวิทยาลัย ๆ โดย 0 คือวันที่ไม่เปิดทำการ และ 1 คือวันที่เปิดทำการ	[0-1]
Hour Group	Boolean	ข้อมูลแสดงช่วงเวลาของวันโดยแบ่งระหว่างช่วงก่อนและหลังเวลา 12.00 น. โดยช่วงเวลาก่อน 12.00 น. มีค่าเป็น 0 และช่วงเวลาหลัง 12.00 น. มีค่าเป็น 1	[0-1]
Wind Direction	Integer	ข้อมูลทิศทางลม ณ ชั่วโมงนั้น ๆ ที่ผ่านการจำแนกด้วยวิธีการ One Hot Encoding	[0-17]
Weather Condition	Integer	ข้อมูลสภาพอากาศ ณ ชั่วโมงนั้น ๆ ที่ผ่านการจำแนกด้วยวิธีการ One Hot Encoding	[0-14]



ภาพที่ 32 ข้อมูลความต้องการไฟฟ้ารายชั่วโมงหลังจากรวมกับปัจจัยที่เกี่ยวข้อง

จากภาพที่ 32 เมื่อนำข้อมูลความต้องการใช้ไฟฟ้ารวมกับปัจจัยที่เกี่ยวข้องแล้วจะเห็นว่า ช่วงเวลาชั่วโมงที่ 1 ถึง 5 และชั่วโมงที่ 21 ถึง 23 หายไปเป็นผลมาจากการที่ข้อมูลทั้งอุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลมที่ได้มานั้นไม่ได้เก็บผลของช่วงเวลาดังกล่าว จึงทำให้ ต้องนำข้อมูลความต้องการไฟฟ้าในช่วงเวลาที่ไม่มีข้อมูลปัจจัยที่เกี่ยวข้องออกจากการนำไปฝึกสอน เพื่อให้ข้อมูลมีช่วงเวลาที่เทียบเท่ากัน

การวัดประสิทธิภาพของแบบจำลอง

เพื่อที่จะประเมินความสามารถของแบบจำลองการเรียนรู้เชิงลึกที่ได้ผ่านการฝึกสอนแล้ว การวัดประสิทธิภาพของระบบถือเป็นสิ่งสำคัญ โดยประสิทธิภาพของแบบจำลองนั้นจะตัดสินด้วยความแม่นยำของผลลัพธ์ที่ได้จากแบบจำลอง ยังมีความผิดพลาดจากค่าจริงน้อยถือว่าแบบจำลองมีประสิทธิภาพที่สูง โดยตัววัดที่นิยมใช้ในการหาค่าความผิดพลาดของแบบจำลองการเรียนรู้เชิงลึกมี ดังนี้

Mean Absolute Error (MAE) หรือ L1 Loss เป็นการนำการค่าสัมบูรณ์ (Absolute) มาใช้ หาค่าความผิดพลาดของแบบจำลอง ด้วยวิธีการหาค่าสัมบูรณ์ของผลต่างระหว่างค่าจริงและค่าที่ พยากรณ์ได้ จากนั้นนำไปหาค่าเฉลี่ย ส่วนสมการการหาค่า Mean Absolute Error มีดังสมการที่ (3.2)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \bar{y}_i| \quad (3.2)$$

Mean Square Error (MSE) หรือ L2 Loss เป็นการหาค่าความผิดพลาดของแบบจำลอง ด้วยวิธีการยกกำลังสองระหว่างค่าจริงและค่าที่พยากรณ์ได้มายกกำลังสอง จากนั้นทำการหาค่าเฉลี่ยของผลลัพธ์ ส่วนสมการของ Mean Square Error มีดังสมการที่ (3.3)

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2 \quad (3.3)$$

Root Mean Square Error (RMSE) เป็นการนำค่าความผิดพลาดมายกกำลังสองจากนั้นจึงทำการถอดรากที่สอง หรือเป็นการนำค่า Mean Square Error มาทำการถอดรากที่สอง เพื่อที่จะได้ผลลัพธ์ค่าความผิดพลาดที่เป็นบวกแต่จะแตกต่างกันตรงที่ค่าทำได้จะค่าน้อยกว่า Mean Square Error ทำให้ง่ายต่อการอ่านค่ามากขึ้น โดยการหาค่า Root Mean Square Error มีดังสมการที่ (3.4)

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (3.4)$$

จากวิธีการหาค่าความผิดพลาดแต่ละชนิดที่ได้กล่าวมาข้างต้น เพื่อให้ง่ายต่อการทำความเข้าใจ จะทำการสมมติค่าจริงและค่าพยากรณ์จำนวน 2 ชุด เพื่อแสดงผลลัพธ์การหาค่าความผิดพลาดแต่ละชนิดดังภาพที่ 33

ค่าจริง	[10.2, 15.4, 17.7]
ค่าพยากรณ์ 1	[11.5, 18.6, 19.5]
ค่าพยากรณ์ 2	[11.1, 17.1, 38.3]

	MAE	MSE	RMSE
ค่าพยากรณ์ 1	2.10	13.23	3.64
ค่าพยากรณ์ 2	7.73	179.41	13.39

ภาพที่ 33 ผลการคำนวณหาค่าความผิดพลาด MAE MSE และ RMSE ด้วยค่าสมมติ

จากภาพที่ 33 ค่าพยากรณ์ 1 แสดงถึงชุดข้อมูลที่มีผลลัพธ์การพยากรณ์ที่ใกล้เคียงกับค่าจริง และค่าพยากรณ์ 2 แสดงถึงชุดข้อมูลที่มีผลลัพธ์การพยากรณ์บางค่าต่างจากค่าจริงมากเพื่อเปรียบเทียบผลการหาค่าความผิดพลาด โดยค่าพยากรณ์ 1 มีวิธีการคำนวณหาค่าความผิดพลาดดังนี้ MAE คือ $(|10.2-11.5|+|15.4-18.6|+|17.7-19.5|)/3 = 2.10$ ส่วน MSE คือ $((10.2-11.5)^2+(15.4-18.6)^2+(17.7-19.5)^2)/3 = 13.23$ และสุดท้าย RMSE คือ $\sqrt{((10.2-11.5)^2+(15.4-18.6)^2+(17.7-19.5)^2)/3} = 3.64$ โดยเมื่อเทียบกับค่าพยากรณ์ 2 ซึ่งในชุดข้อมูลมีผลลัพธ์บางจำนวนที่ต่างจากค่าจริงมาก ได้ผลการคำนวณคือ MAE คือ 7.73 MSE คือ 179.41 และ RMSE 13.39 แสดงให้เห็นถึงความแตกต่างระหว่างค่าความผิดพลาดแต่ละชนิดเมื่อชุดข้อมูลมีลักษณะต่างกัน โดย MSE และ RMSE มีความต่างของผลลัพธ์การหาความผิดพลาดต่างกันมากในชุดข้อมูลการพยากรณ์ 2 ชุด แต่ MAE มีแตกต่างของผลการพยากรณ์ที่น้อยกว่าอย่างเห็นได้ชัด

จากลักษณะการคำนวณที่ได้แสดงไปข้างต้น แสดงให้เห็นว่า MAE ได้รับผลจากข้อมูลที่มีความแตกต่างมาก ๆ ได้ดีเนื่องจากการคำนวณที่มีลักษณะเป็นเชิงเส้น ส่วน MSE และ RMSE ที่มีการใช้เลขยกกำลังในการคำนวณค่าความแตกต่างที่มากขึ้นจะส่งผลต่อผลลัพธ์มากขึ้น ดังนั้นการใช้งาน MAE จึงเหมาะสมกับชุดข้อมูลที่อาจมีความแตกต่างที่มากในชุดข้อมูลเป็นปกติ และได้ผลลัพธ์ที่มีหน่วยเดียวกับข้อมูลเริ่มต้น ส่วน MSE จะเหมาะสมกับระบบที่มีความละเอียดอ่อนของข้อมูลมากกว่า เนื่องจากการคำนวณแบบยกกำลังสองนั้นส่งผลให้ความผิดพลาดที่มีขนาดใหญ่แสดงผลออกมาได้ชัดเจนกว่า ส่วน RMSE เนื่องจากมีการถอดรากที่สองของผลลัพธ์กลับมาอยู่ในหน่วยเดียวกับข้อมูล เพื่อให้ง่ายต่อการวัดผล แต่ยังคงความสามารถในการตรวจจับความผิดพลาดที่มีขนาดใหญ่ในชุดข้อมูลอยู่ ดังนั้นการเลือกใช้งานวิธีการหาค่าความผิดพลาดแต่ละชนิดนั้น จะขึ้นอยู่กับลักษณะของข้อมูลที่นำมาใช้ฝึกสอนแบบจำลอง และลักษณะของผลลัพธ์ที่ต้องการ

บทที่ 4

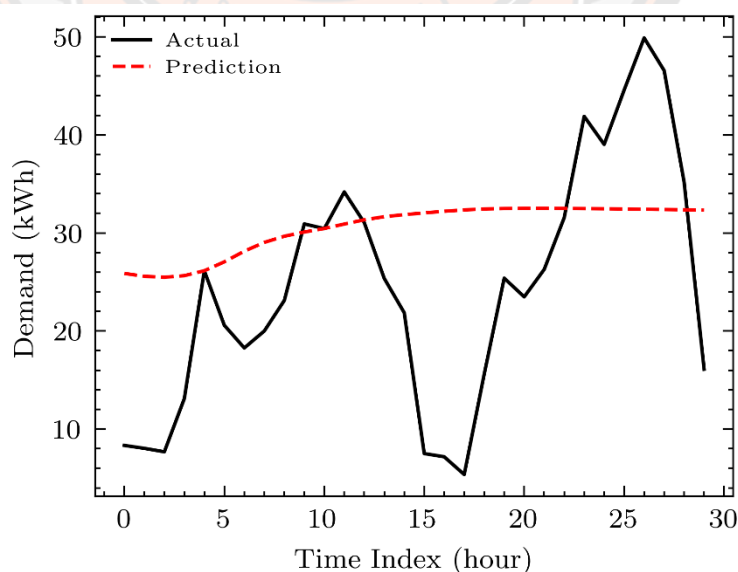
ผลการดำเนินการวิจัย

ในบทนี้ จะกล่าวถึงผลการทดลองของปรับค่าไฮเปอร์พารามิเตอร์ (Hyperparameter) และปัจจัยต่าง ๆ ที่เกี่ยวข้องกับความต้องการใช้ไฟฟ้า เพื่อค้นหาการตั้งค่าที่มีความเหมาะสมกับแบบจำลองและมีค่าความผิดพลาดน้อยที่สุดสำหรับการพยากรณ์หาค่าความต้องการใช้พลังงานไฟฟ้าภายในวิทยาลัย ฯ

ผลการทดลองค้นหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม

การทดลองเพื่อหาค่าไฮเปอร์พารามิเตอร์ของแบบจำลอง TFT โดยไฮเปอร์พารามิเตอร์ที่ทำการทดลองปรับมีทั้งหมด 3 ค่า คือ จำนวนชั้นซ่อน อัตราการเรียนรู้ (Learning Rate) และจำนวนส่วนความตั้งใจ (Attention Head) โดยจะทำการทดลองจนกระทั่งได้ชุดไฮเปอร์พารามิเตอร์ที่ให้ค่าความผิดพลาดน้อยที่สุด และได้ทำการทดลองทั้งหมด 5 รอบ ของแต่ละชุดไฮเปอร์พารามิเตอร์ เพื่อหาค่าเฉลี่ยเลขคณิตและค่าส่วนเบี่ยงเบนมาตรฐาน พร้อมทั้งภาพแสดงผลการพยากรณ์ที่มีค่าความผิดพลาดน้อยที่สุดในแต่ละชุดการทดลอง โดยมีผลการทดลองดังนี้

การทดลองรูปแบบที่ 1 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 8 อัตราการเรียนรู้เท่ากับ 0.01 และจำนวนส่วนความตั้งใจเท่ากับ 1




ภาพที่ 34 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 1

ตารางที่ 5 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 1 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	13.2412	281.1709	16.7682
2	12.9120	268.8027	16.3952
3	13.1045	298.2198	17.0249
4	13.8747	275.5664	16.5012
5	14.1021	279.5479	16.9737
ค่าเฉลี่ยเลขคณิต	13.4469	280.6615	16.7326
ส่วนเบี่ยงเบนมาตรฐาน	0.5143	10.9131	0.2794

จากภาพที่ 34 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ได้มีลักษณะค่อนข้างคงที่ของผลการพยากรณ์ โดยมีค่าเริ่มต้นตั้งแต่ 26 กิโลวัตต์-ชั่วโมง จากนั้นจึงเพิ่มขึ้นและมีค่าค่อนข้างที่ตั้งแต่ในช่วงดัชนีเวลา (Time Index) ที่ 8 โดยมีค่าความต้องการใช้ไฟฟ้าที่พยากรณ์ออกมาอยู่ในช่วง 30-32 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง มีดังนี้ MAE มีค่าเท่ากับ 13.4469 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 280.6615 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 16.7326 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 5

การทดลองรูปแบบที่ 2 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 16 อัตราการเรียนรู้เท่ากับ 0.01 และจำนวนส่วนความตั้งใจเท่ากับ 1



ภาพที่ 35 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 2


ตารางที่ 6 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 2 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	7.8541	105.0041	9.5216
2	8.0249	121.2040	10.1879
3	7.6588	101.5227	9.5207
4	7.8952	105.5932	9.5781
5	7.4061	94.2478	9.4788
ค่าเฉลี่ยเลขคณิต	7.7678	105.5144	9.6574
ส่วนเบี่ยงเบนมาตรฐาน	0.2411	9.8653	0.2986

จากภาพที่ 35 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงให้เห็นว่าค่าที่พยากรณ์ได้มีลักษณะที่เริ่มมีการเปลี่ยนแปลงใกล้เคียงกับค่าจริงมากขึ้น ในช่วงดัชนีเวลาที่ 0 ถึง 17 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้พลังงานไฟฟ้าจริง โดยมีค่าความ

ต่างที่มากที่สุดประมาณ 10 กิโลวัตต์-ชั่วโมง แต่ในช่วงหลังจากดัชนีเวลาที่ 17 เป็นต้นไป ค่าที่พยากรณ์ได้มีผลลัพธ์ที่ต่างจากค่าจริงมาก โดยมีค่าความต่างที่มากถึงประมาณ 20 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง ลดลงจากการทดลองรูปแบบที่ 1 ในทุก ๆ ชนิดของค่าความผิดพลาดที่วัดได้ ดังนี้ MAE มีค่าเท่ากับ 7.7678 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 105.5144 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 9.6574 กิโลวัตต์-ชั่วโมง ดังตารางที่ 6

การทดลองรูปแบบที่ 3 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 32 อัตราการเรียนรู้เท่ากับ 0.01 และจำนวนส่วนความตั้งใจเท่ากับ 1




ภาพที่ 36 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 3

ตารางที่ 7 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 3 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	7.7481	104.0341	9.6540
2	7.1896	86.4658	9.2489
3	7.4101	101.5227	9.5207
4	7.8367	107.2143	9.3687
5	7.3072	93.5134	9.5004
ค่าเฉลี่ยเลขคณิต	7.4983	98.5501	9.4585
ส่วนเบี่ยงเบนมาตรฐาน	0.2813	8.4466	0.1548

จากภาพที่ 36 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าให้เห็นว่าค่าที่พยากรณ์ในการทดลองนี้เริ่มมีพฤติกรรมปรับตัวเข้ากับค่าความต้องการใช้พลังงานไฟฟ้าจริงมากขึ้นจากการทดลองรูปแบบที่ 1 และ 2 แต่ในหลายช่วงเวลายังคงมีผลลัพธ์ความต่างระหว่างค่าจริงกับค่าที่พยากรณ์ได้มาก ส่วนค่าความผิดพลาดของชุดการทดลองนี้ โดยมีค่าความต่างที่มากที่สุดประมาณ 17 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดเฉลี่ยทั้ง 3 ชนิด มีค่าน้อยกว่าการทดลองรูปแบบที่ 1 และ 2 โดยมีผลลัพธ์ค่าความผิดพลาดที่ได้ คือ MAE มีค่าเท่ากับ 7.4983 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 98.5501 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 9.4585 กิโลวัตต์-ชั่วโมง ดังตารางที่ 7

การทดลองรูปแบบที่ 4 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 32 อัตราการเรียนรู้เท่ากับ 0.005 และจำนวนส่วนความตั้งใจเท่ากับ 1




ภาพที่ 37 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 4

ตารางที่ 8 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 4 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	8.0211	134.1142	9.9057
2	8.3104	154.3200	10.1412
3	8.2987	141.8554	10.0891
4	8.0148	120.4712	9.8544
5	8.1482	138.5547	10.0570
ค่าเฉลี่ยเลขคณิต	8.1586	137.8631	10.0095
ส่วนเบี่ยงเบนมาตรฐาน	0.1435	12.2860	0.1233

จากภาพที่ 37 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ได้ในช่วงดัชนีเวลาที่ 5 ถึง 13 ค่าที่พยากรณ์ได้จะมีค่าสูงกว่าค่าความต้องการใช้ไฟฟ้าจริงอยู่ในช่วง 10 ถึง 20 กิโลวัตต์-ชั่วโมง เช่นเดียวกับในช่วงดัชนีเวลาที่ 20 ถึง 30 ที่มีค่าความต่างที่มากที่สุดประมาณ 15 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดของการทดลองนี้พบว่ามีค่ามากกว่าการทดลองรูปแบบที่ 2 และ 3 คือ MAE มีค่าเท่ากับ 8.1586 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 137.8631 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 10.0095 กิโลวัตต์-ชั่วโมง ดังตารางที่ 8

การทดลองรูปแบบที่ 5 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 32 อัตราการเรียนรู้เท่ากับ 0.05 และจำนวนส่วนความตั้งใจเท่ากับ 1




ภาพที่ 38 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 5

ตารางที่ 9 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 5 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	6.3303	75.5638	8.7714
2	6.7410	77.9824	8.8953
3	6.3809	76.0144	8.8179
4	6.5044	77.4740	8.8411
5	6.8799	80.5473	9.1048
ค่าเฉลี่ยเลขคณิต	6.5673	77.5164	8.8861
ส่วนเบี่ยงเบนมาตรฐาน	0.2359	1.9668	0.1301

จากภาพที่ 38 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าในช่วงดัชนีเวลาที่ 0 ถึง 20 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้พลังงานจริง มากกว่าการทดลองรูปแบบที่ 1 ถึง 4 โดยมีค่าความแตกต่างระหว่างผลลัพธ์มากที่สุดประมาณ 6 กิโลวัตต์-ชั่วโมง แต่หลังจากช่วงดัชนีเวลาดังกล่าวค่าที่พยากรณ์ได้เริ่มมีความต่างจากค่าจริงมากขึ้น โดยมีค่าความต่างสูงสุดประมาณ 15 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดเฉลี่ยของการทดลอง รูปแบบนี้มีค่าน้อยกว่าการทดลองรูปแบบที่ 1 ถึง 4 คือ MAE มีค่าเท่ากับ 6.5673 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 77.5164 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 8.8861 กิโลวัตต์-ชั่วโมง ดังตารางที่ 9

การทดลองรูปแบบที่ 6 กำหนดให้จำนวนชั้นซ่อนเท่ากับ 32 อัตราการเรียนรู้เท่ากับ 0.05 และจำนวนส่วนความตั้งใจเท่ากับ 2



ภาพที่ 39 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 6

ตารางที่ 10 ผลการทดลองหาค่าไฮเปอร์พารามิเตอร์รูปแบบที่ 6 ทั้ง 5 ครั้ง

การทดลองครั้งที่	MAE	MSE	RMSE
1	7.7050	99.6229	9.6333
2	7.1801	86.4658	9.2489
3	7.3670	97.1115	9.5000
4	7.7936	102.8031	9.3480
5	7.2641	89.1022	9.4797
ค่าเฉลี่ยเลขคณิต	7.4620	95.0211	9.4420
ส่วนเบี่ยงเบนมาตรฐาน	0.2723	6.9702	0.1479

จากภาพที่ 39 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงให้เห็นว่าค่าที่พยากรณ์ได้ในช่วงดัชนีเวลาที่ 5 ถึง 13 ค่าที่พยากรณ์ได้จะมีค่าสูงกว่าค่าจริงอยู่ในช่วงประมาณ 10 ถึง 15 กิโลวัตต์-ชั่วโมง เช่นเดียวกับในช่วงดัชนีเวลาที่ 20 ถึง 30 ที่มีค่าความต่าง

ที่มากที่สุดประมาณ 18 กิโลวัตต์-ชั่วโมง ส่วนค่าความผิดพลาดเฉลี่ยของการทดลองทดลองรูปแบบนี้มีค่าใกล้เคียงกับการทดลองรูปแบบที่ 2 และ 3 คือ MAE มีค่าเท่ากับ 7.4620 กิโลวัตต์-ชั่วโมง MSE มีค่าเท่ากับ 95.0211 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่าเท่ากับ 9.4420 กิโลวัตต์-ชั่วโมง แต่ยังคงมีค่าความผิดพลาดทั้ง 3 ชนิด มากกว่าการทดลองรูปแบบที่ 5 ดังตารางที่ 10

จากผลการทดลองปรับเปลี่ยนไฮเปอร์พารามิเตอร์ทั้ง 6 รูปแบบ แสดงให้เห็นว่าจำนวนชั้นซ่อน 32 ชั้น อัตราการเรียนรู้เท่ากับ 0.05 และจำนวนส่วนความตั้งใจเท่ากับ 2 คือชุดไฮเปอร์พารามิเตอร์ที่ทำให้ค่าที่พยากรณ์ออกมา มีความผิดพลาดน้อยที่สุดตามตารางที่ 11

ตารางที่ 11 ค่าความผิดพลาดของการทดลองปรับไฮเปอร์พารามิเตอร์ทั้ง 6 ชุด

Hyperparameter			Result		
Hidden Layer	Learning Rate	Attention Head	MAE	MSE	RMSE
8	0.01	1	13.45±0.51	280.66±10.91	16.73±0.28
16	0.01	1	7.76±0.24	105.51±9.87	9.66±0.30
32	0.01	1	7.50±0.28	98.55±8.45	9.46±0.15
32	0.005	1	8.16±0.14	137.86±12.29	10.01±0.12
32	0.05	1	6.57±0.24	77.52±6.67	8.89±0.13
32	0.05	2	7.46±0.27	95.02±6.97	9.44±0.15

ผลการทดลองการใช้อัจฉริยะอื่น ๆ ที่คาดว่าจะส่งผลต่อการพยากรณ์ความต้องการใช้พลังงานไฟฟ้า


การทดลองนี้ทำการนำปัจจัยอื่น ๆ ที่เกี่ยวข้องกับความต้องการใช้พลังงานไฟฟ้าด้วยการคัดเลือกจากการใช้การวิเคราะห์หาสหสัมพันธ์ โดยปัจจัยที่ส่งผลที่ใช้ในการทดลองคือ อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ ทิศทางลม วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน และได้ทำการทดลองทั้งหมด 5 รอบ ของแต่ละชุดปัจจัยที่เกี่ยวข้อง เพื่อหาค่าเฉลี่ยเลขคณิตและส่วนเบี่ยงเบนมาตรฐานของค่าความผิดพลาด พร้อมทั้งภาพแสดงผลการพยากรณ์ที่มีค่าความผิดพลาดน้อยที่สุดในแต่ละชุดการทดลอง โดยมีผลการทดลองดังนี้

การทดลองใช้ปัจจัยที่เกี่ยวข้อง 1 ปัจจัยร่วมกับความต้องการใช้ไฟฟ้า ทำการทดลองโดยการนำความต้องการใช้พลังงานไฟฟ้าไปจับคู่กับปัจจัยอื่น ๆ อีก 1 ปัจจัย เพื่อให้ครบทุกคู่ปัจจัย ได้แก่ อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ ทิศทางลม วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน ดังที่แสดงในตารางที่ 12

ตารางที่ 12 รูปแบบการทดลองปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงานร่วมกับปัจจัยที่เกี่ยวข้อง 1 ปัจจัย

จำนวน	ค่าความต้องการใช้ไฟฟ้า	ปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงาน					
		อุณหภูมิ	อุณหภูมิจุดน้ำค้าง	สภาพอากาศ	ทิศทางลม	วันทำการวิทยาลัย ฯ	ช่วงเวลาของวัน
1	✓ ✓ ✓ ✓ ✓ ✓	✓	✓	✓	✓	✓	✓

คู่มือปัจจัยความต้องการใช้ไฟฟ้า และอุณหภูมิ



ภาพที่ 40 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและอุณหภูมิ


ตารางที่ 13 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและอุณหภูมิ

การทดลองครั้งที่	MAE	MSE	RMSE
1	11.0227	274.1428	16.8982
2	11.7515	287.3201	16.9508
3	10.8316	266.0665	16.3116
4	11.6501	280.1153	16.9002
5	11.1743	278.5456	16.9107
ค่าเฉลี่ยเลขคณิต	11.2860	277.2381	16.7943
ส่วนเบี่ยงเบนมาตรฐาน	0.3992	7.8425	0.2707

จากภาพที่ 40 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 100 และ 130 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 110 ถึง 130 ค่าที่พยากรณ์ได้

ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง โดยผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.2860 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 277.2381 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 16.7943 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 13

คู่มือปัจจัยความต้องการใช้ไฟฟ้า และอุณหภูมิจุดน้ำค้าง




ภาพที่ 41 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและอุณหภูมิจุดน้ำค้าง

ตารางที่ 14 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและอุณหภูมิจุดน้ำค้าง

การทดลองครั้งที่	MAE	MSE	RMSE
1	11.7516	287.3214	16.9506
2	12.7257	301.2247	17.0503
3	12.8216	305.2567	17.3642
4	11.9647	206.0245	16.9882
5	12.9374	308.5419	17.6874
ค่าเฉลี่ยเลขคณิต	12.4402	281.6738	17.2081
ส่วนเบี่ยงเบนมาตรฐาน	0.5419	43.0552	0.3137

จากภาพที่ 41 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงให้เห็นว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 100 และ 130 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 110 ถึง 130 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง โดยค่าที่พยากรณ์ได้ในคู่ปัจจัยนี้มีความใกล้เคียงกับคู่ปัจจัยความต้องการใช้ไฟฟ้าและอุณหภูมิ ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 12.4402 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 281.6738 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 17.2081 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 14

คู่ปัจจัยความต้องการใช้ไฟฟ้า และสภาพอากาศ




ภาพที่ 42 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและสภาพอากาศ

ตารางที่ 15 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและสภาพอากาศ

การทดลองครั้งที่	MAE	MSE	RMSE
1	19.2454	498.5421	21.9227
2	18.1139	449.5473	21.0014
3	18.8413	465.2835	21.2348
4	18.1047	447.5477	20.9812
5	17.6214	436.0158	20.8809
ค่าเฉลี่ยเลขคณิต	18.3853	459.3873	21.2042
ส่วนเบี่ยงเบนมาตรฐาน	0.6488	24.2440	0.4221

จากภาพที่ 42 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงถึงค่าที่พยากรณ์ว่ามีลักษณะเป็นคลื่นลักษณะคล้ายกันในทุก ๆ ช่วงดัชนีเวลาของการทดลอง และมีค่าสูงสุดอยู่ในช่วง 43 ถึง 45 กิโลวัตต์-ชั่วโมง โดยผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 18.3853 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 459.3873 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 21.2042 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 15

คู่ปัจจัยความต้องการใช้ไฟฟ้า และทิศทางลม




ภาพที่ 43 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและทิศทางลม

ตารางที่ 16 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและทิศทางลม

การทดลองครั้งที่	MAE	MSE	RMSE
1	16.5739	412.2193	22.4173
2	15.7298	377.7466	19.4357
3	15.7411	381.6974	19.6348
4	15.8812	384.3429	20.0093
5	16.4224	400.2249	21.5437
ค่าเฉลี่ยเลขคณิต	16.0697	391.2462	20.6082
ส่วนเบี่ยงเบนมาตรฐาน	0.399267	14.50485	1.306613

จากภาพที่ 43 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าในช่วงดัชนีเวลาที่ 10 ถึง 30 และ 75 ถึง 130 ค่าที่พยากรณ์ได้มีค่าต่างจากค่าความต้องการใช้ไฟฟ้าจริงและโดยส่วนมากมีค่ามากกว่า โดยเฉพาะในช่วงดัชนีเวลาที่ 100 ถึง 130 จะมีความผันผวนของค่าสูงสุดในช่วง 30 ถึง 40 กิโลวัตต์-ชั่วโมง โดยผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 16.0697 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 391.2462 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 20.6052 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 16

คู่มือจ่ายความต้องการใช้ไฟฟ้า และวันทำการของวิทยาลัย ฯ



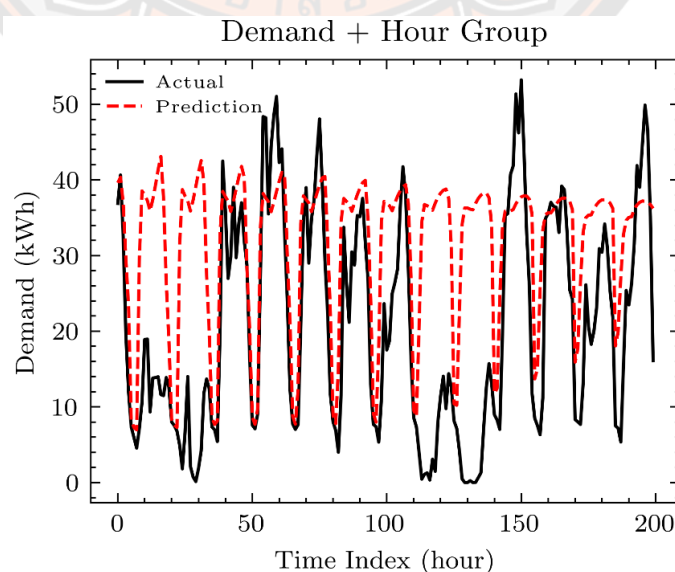
ภาพที่ 44 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและวันทำการของวิทยาลัย ฯ

ตารางที่ 17 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและวันทำการของวิทยาลัย ฯ

การทดลองครั้งที่	MAE	MSE	RMSE
1	11.9547	205.7939	14.3455
2	12.8512	251.5978	15.3642
3	12.1013	209.2189	14.3981
4	13.2044	287.1131	15.6317
5	12.2856	230.2298	14.6596
ค่าเฉลี่ยเลขคณิต	12.4794	236.7907	14.8798
ส่วนเบี่ยงเบนมาตรฐาน	0.529077	33.59928	0.584379

จากภาพที่ 44 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าในช่วงดัชนีเวลาที่ 30 ถึง 110 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาอื่น ค่าพยากรณ์ที่ได้มีค่าต่างกับค่าจริงความต้องการใช้ไฟฟ้ามาก โดยผลลัพธ์ ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 12.4794 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 236.7907 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 14.8798 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 17

คู่มือปัจจัยความต้องการใช้ไฟฟ้า และช่วงเวลาของวัน



ภาพที่ 45 ผลการทดลองใช้ความต้องการใช้ไฟฟ้าและช่วงเวลาของวัน

ตารางที่ 18 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้าและช่วงเวลาของวัน

การทดลองครั้งที่	MAE	MSE	RMSE
1	12.5657	282.7571	16.8154
2	13.5217	297.5412	16.9811
3	13.9307	342.1160	17.9942
4	13.2804	311.9833	17.4249
5	12.7044	289.1211	17.1336
ค่าเฉลี่ยเลขคณิต	13.2006	304.7037	17.2698
ส่วนเบี่ยงเบนมาตรฐาน	0.568294	23.6032	0.462922


จากภาพที่ 45 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงถึงผลลัพธ์ของค่าที่มีลักษณะเป็นคลื่นที่มีค่าสม่ำเสมอตลอดช่วงการทดลอง ช่วงดัชนีเวลาที่ 30 ถึง 100 และ 130 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 110 ถึง 130 ค่าที่พยากรณ์ได้มีสูงกว่าค่าจริง โดยผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 13.2006 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 304.7037 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 17.2698 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 18

การทดลองใช้ปัจจัยที่เกี่ยวข้อง 2 ปัจจัยร่วมกับความต้องการใช้ไฟฟ้า ทำการทดลองโดยการนำความต้องการใช้พลังงานไฟฟ้าไปจับคู่กับปัจจัยอื่น ๆ อีก 2 ปัจจัย ได้แก่ อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ ทิศทางลม วันทำการของวิทยาลัย ฯ ดังที่แสดงในตารางที่ 19

ตารางที่ 19 รูปแบบการทดลองปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงานร่วมกับปัจจัยที่เกี่ยวข้อง 2 ปัจจัย

จำนวน	ค่าความต้องการใช้ไฟฟ้า	ปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงาน					
		อุณหภูมิ	อุณหภูมิจุดน้ำค้าง	สภาพอากาศ	ทิศทางลม	วันทำการวิทยาลัย ฯ	ช่วงเวลาของวัน
2 ปัจจัย	✓	✓	✓				
	✓	✓		✓			
	✓	✓			✓		
	✓	✓				✓	
	✓	✓					✓
	✓	✓	✓	✓			
	✓	✓	✓		✓		
	✓	✓	✓			✓	
	✓	✓	✓				✓
	✓	✓		✓	✓		
	✓	✓		✓		✓	
	✓	✓			✓	✓	
	✓	✓				✓	✓
	✓	✓				✓	✓

คู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และอุณหภูมิจุดน้ำค้าง



ภาพที่ 46 ผลการทดลองคู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และอุณหภูมิจุดน้ำค้าง


ตารางที่ 20 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และอุณหภูมิจุดน้ำค้าง

การทดลองครั้งที่	MAE	MSE	RMSE
1	9.9083	214.4027	14.6425
2	10.2511	244.1473	15.6252
3	10.3936	249.2119	15.7864
4	10.1002	235.0144	15.3302
5	10.1541	238.5293	15.4444
ค่าเฉลี่ยเลขคณิต	10.1615	236.2611	15.3657
ส่วนเบี่ยงเบนมาตรฐาน	0.1802	13.3642	0.4401

จากภาพที่ 46 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 100 และ 110 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 100 ถึง 110 ค่าที่พยากรณ์ได้

ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 10.1615 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 236.2611 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.3657 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 20

คู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และสภาพอากาศ




ภาพที่ 47 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และสภาพอากาศ

ตารางที่ 21 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และสภาพอากาศ

การทดลองครั้งที่	MAE	MSE	RMSE
1	10.5921	222.1433	14.9045
2	10.8216	228.6537	15.1213
3	10.1554	214.7141	14.6531
4	11.0852	232.2217	15.2388
5	11.2475	237.6426	15.4157
ค่าเฉลี่ยเลขคณิต	10.7804	227.0751	15.0667
ส่วนเบี่ยงเบนมาตรฐาน	0.4298	8.9130	0.2965

จากภาพที่ 47 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองพบว่า ค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 100 และ 110 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 100 ถึง 110 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 10.7804 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 227.0751 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.0667 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 21

คู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และทิศทางลม



ภาพที่ 48 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และทิศทางลม

ตารางที่ 22 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และทิศทางลม


การทดลองครั้งที่	MAE	MSE	RMSE
1	10.8510	236.4298	15.3763
2	10.8401	233.0197	15.2650
3	11.7411	251.4523	15.8572
4	11.0048	240.5874	15.5109
5	11.5419	246.5449	15.7017
ค่าเฉลี่ยเลขคณิต	11.19578	241.6068	15.5422
ส่วนเบี่ยงเบนมาตรฐาน	0.4180	7.4649	0.2398

จากภาพที่ 48 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 125 ถึง 140 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.1958 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 241.6068 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.5422 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 22

สรุปปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และวันทำการของวิทยาลัย ฯ

ตารางที่ 23 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และวันทำการของวิทยาลัย ฯ


การทดลองครั้งที่	MAE	MSE	RMSE
1	6.2711	77.5639	8.8070
2	7.1157	98.1271	9.9059
3	6.6824	82.1687	9.0647
4	7.5082	105.6523	10.2787
5	6.2949	80.0047	8.9445
ค่าเฉลี่ยเลขคณิต	6.7745	88.7033	9.4002
ส่วนเบี่ยงเบนมาตรฐาน	0.5354	12.4351	0.6518



ภาพที่ 49 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และวันทำการของวิทยาลัย

จากภาพที่ 49 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงถึงค่าพยากรณ์ช่วงดัชนีเวลาที่ 10 ถึง 20 ที่มีความแตกต่างจากค่าความต้องการใช้ไฟฟ้าจริง อย่างเป็นได้ชัด แต่ในช่วงดัชนีเวลาอื่น ๆ ค่อนข้างมีพฤติกรรมตรงกับค่าความต้องการใช้ไฟฟ้าจริง มาก ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 6.7745 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 88.7033 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 9.4002 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 23

คู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และช่วงเวลาของวัน



ภาพที่ 50 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิ และช่วงเวลาของวัน


ตารางที่ 24 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิ และช่วงเวลาของวัน

การทดลองครั้งที่	MAE	MSE	RMSE
1	11.7157	221.5498	14.8845
2	12.2974	234.2687	15.3058
3	12.3549	247.5973	15.7352
4	11.8400	224.5607	14.9853
5	11.6536	218.3203	14.7757
ค่าเฉลี่ยเลขคณิต	11.9723	229.2594	15.1373
ส่วนเบี่ยงเบนมาตรฐาน	0.3305	11.8591	0.3885

จากภาพที่ 50 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 125 ถึง 140 ค่าที่พยากรณ์ได้

ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.1958 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 241.6068 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.5422 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และสภาพอากาศ




ภาพที่ 51 ผลการทดลองคู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และสภาพอากาศ

ตารางที่ 25 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง สภาพอากาศ

การทดลองครั้งที่	MAE	MSE	RMSE
1	9.2992	187.1532	13.6804
2	10.5429	211.2463	14.5343
3	9.5582	203.3204	14.2590
4	9.2955	185.0432	13.6031
5	10.3910	208.4191	14.4367
ค่าเฉลี่ยเลขคณิต	9.8174	199.0364	14.1027
ส่วนเบี่ยงเบนมาตรฐาน	0.6049	12.1706	0.4331

จากภาพที่ 51 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 125 ถึง 140 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 9.8174 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 199.0364 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 14.1027 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และทิศทางลม




ภาพที่ 52 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และทิศทางลม

ตารางที่ 26 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และทิศทางลม

การทดลองครั้งที่	MAE	MSE	RMSE
1	10.7836	234.4196	15.3108
2	10.7477	232.5694	15.2502
3	11.0836	248.4163	15.7612
4	11.7914	257.9004	16.0593
5	10.2319	227.6393	15.0877
ค่าเฉลี่ยเลขคณิต	10.9276	240.1890	15.4938
ส่วนเบี่ยงเบนมาตรฐาน	0.5717	12.5521	0.4028

จากภาพที่ 52 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ เห็นได้ว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 125 ถึง 140 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.1958 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 241.6068 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.5422 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และวันทำการของวิทยาลัย ฯ




ภาพที่ 53 ผลการทดลองคู่มือปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และวันทำการของวิทยาลัย ฯ

ตารางที่ 27 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และวันทำการของวิทยาลัย ฯ

การทดลองครั้งที่	MAE	MSE	RMSE
1	7.9104	112.8424	10.6227
2	7.7989	101.0540	10.0526
3	8.5208	131.0682	11.4485
4	8.0241	120.5174	10.9780
5	8.2302	125.9347	11.2221
ค่าเฉลี่ยเลขคณิต	8.0969	118.2833	10.8648
ส่วนเบี่ยงเบนมาตรฐาน	0.2856	11.7627	0.5476

จากภาพที่ 53 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลอง แสดงให้เห็นว่าค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริงในทุก ๆ ช่วงดัชนีเวลา มีเพียงช่วงดัชนีเวลาที่ 110 ถึง 125 ที่ค่าที่พยากรณ์ได้ยังคงต่างจากค่าความต้องการใช้ไฟฟ้าจริงมาก ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 8.0969 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 118.2833 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 10.8648 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 27

คู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และช่วงเวลาของวัน



ภาพที่ 54 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า อุณหภูมิน้ำค้าง และช่วงเวลาของวัน


ตารางที่ 28 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการไฟฟ้า อุณหภูมิจุดน้ำค้าง และช่วงเวลาของวัน

การทดลองครั้งที่	MAE	MSE	RMSE
1	10.2459	163.0726	12.7700
2	10.4531	172.6244	13.1387
3	10.8011	186.4179	13.6535
4	10.5730	175.4599	13.2461
5	11.2009	196.4497	14.0161
ค่าเฉลี่ยเลขคณิต	10.6548	178.8049	13.3649
ส่วนเบี่ยงเบนมาตรฐาน	0.3654	12.9053	0.4813

จากภาพที่ 54 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 0 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่า

ความต้องการใช้ไฟฟ้าจริง มีเพียงช่วงดัชนีเวลาที่ 125 ถึง 140 ที่ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 10.6548 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 178.8049 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 13.3649 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 28

คู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และทิศทางลม



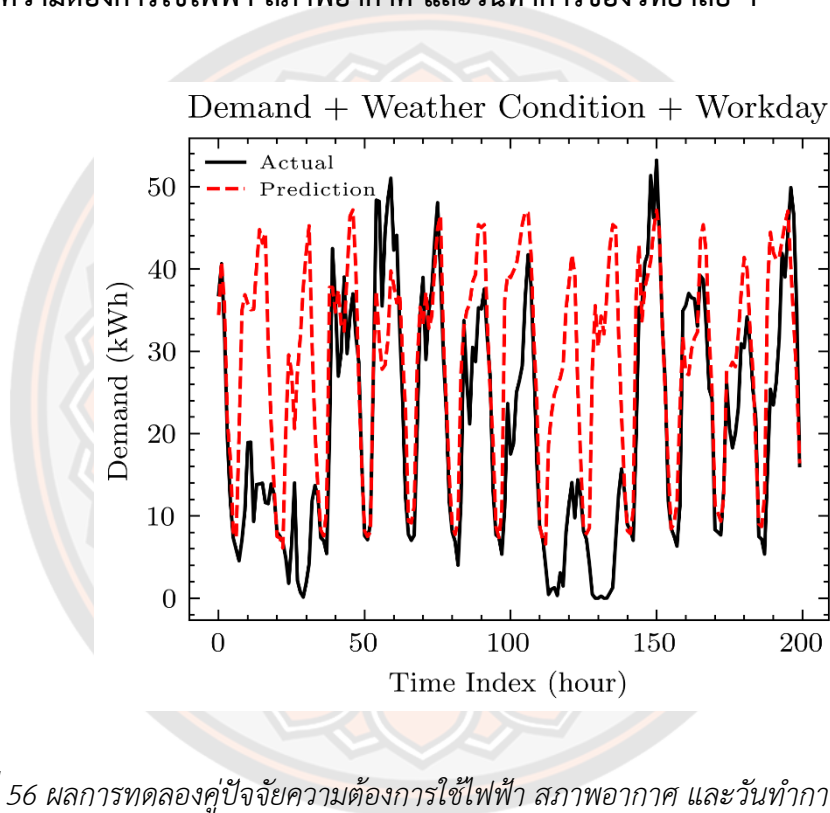
ภาพที่ 55 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และทิศทางลม

ตารางที่ 29 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และทิศทางลม

การทดลองครั้งที่	MAE	MSE	RMSE
1	9.8238	197.4615	14.0521
2	10.3346	206.4179	14.3673
3	9.8017	195.0446	13.9658
4	9.3922	173.4595	13.1704
5	10.2639	201.6593	14.2007
ค่าเฉลี่ยเลขคณิต	9.9232	194.8086	13.9513
ส่วนเบี่ยงเบนมาตรฐาน	0.3847	12.6943	0.4624

จากภาพที่ 55 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ เห็นได้ว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 30 ถึง 125 และ 140 ถึง 170 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 30 และ 125 ถึง 140 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าจริง ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.1958 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 241.6068 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.5422 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และวันทำการของวิทยาลัย ฯ




ภาพที่ 56 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และวันทำการของวิทยาลัย ฯ

ตารางที่ 30 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และวันทำการของวิทยาลัย ฯ

การทดลองครั้งที่	MAE	MSE	RMSE
1	11.1093	251.4146	15.8561
2	10.5347	234.1667	15.3025
3	10.4115	230.7944	15.1919
4	11.2028	256.4160	16.0130
5	10.3630	219.8009	14.8257
ค่าเฉลี่ยเลขคณิต	10.7243	238.5185	15.4378
ส่วนเบี่ยงเบนมาตรฐาน	0.4005	15.1293	0.4897

จากภาพที่ 56 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 40 ถึง 90 และ 140 ถึง 200 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาที่ 10 ถึง 40 และ 90 ถึง 140 ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริงมาก ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.1958 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 241.6068 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.5422 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และช่วงเวลาของวัน



ภาพที่ 57 ผลการทดลองคู่ปัจจัยความต้องการใช้ไฟฟ้า สภาพอากาศ และช่วงเวลาของวัน


ตารางที่ 31 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า สภาพอากาศ และช่วงเวลาของวัน

การทดลองครั้งที่	MAE	MSE	RMSE
1	10.7364	220.9780	14.8653
2	10.8108	225.1187	15.0040
3	11.7146	255.3241	15.9789
4	11.2744	231.4135	15.2123
5	10.8793	227.5903	15.0861
ค่าเฉลี่ยเลขคณิต	11.0831	232.0849	15.2293
ส่วนเบี่ยงเบนมาตรฐาน	0.4097	13.5333	0.4376

จากภาพที่ 57 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้พบว่าค่าที่พยากรณ์ช่วงดัชนีเวลาที่ 20 ถึง 130 และ 140 ถึง 160 ค่าที่พยากรณ์ได้มีค่าใกล้เคียงกับ

ค่าความต้องการใช้ไฟฟ้าจริง แต่ในส่วนช่วงดัชนีเวลาอื่น ๆ ค่าที่พยากรณ์ได้ยังมีสูงกว่าค่าความต้องการใช้ไฟฟ้าจริง โดยเฉพาะช่วงดัชนีเวลาที่ 10 ถึง 20 และ 130 ถึง 140 ที่ค่าที่พยากรณ์ได้สูงกว่าค่าความต้องการใช้ไฟฟ้าจริงมาก ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 11.0831 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 232.0849 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 15.2293 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 24

คู่มือปัจจัยความต้องการใช้ไฟฟ้า วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน



ภาพที่ 58 ผลการทดลองคู่มือปัจจัยความต้องการใช้ไฟฟ้า วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน

ตารางที่ 32 ผลการทดลองหาค่าความผิดพลาดโดยใช้ความต้องการใช้ไฟฟ้า วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน

การทดลองครั้งที่	MAE	MSE	RMSE
1	5.5135	63.5413	7.9713
2	5.4948	59.4456	7.7101
3	6.1608	80.6540	8.9808
4	5.7012	67.2609	8.2013
5	5.9381	70.5693	8.4006
ค่าเฉลี่ยเลขคณิต	5.7617	68.2942	8.2528
ส่วนเบี่ยงเบนมาตรฐาน	0.2859	8.0606	0.4817

จากภาพที่ 58 ซึ่งเป็นผลการพยากรณ์มีค่าความผิดพลาดน้อยที่สุดของชุดการทดลองนี้ แสดงให้เห็นว่าค่าที่พยากรณ์ได้ในทุกช่วงดัชนีเวลามีค่าใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริง ยกเว้นบางช่วงดัชนีเวลาที่ยังคงมีค่าต่างจากค่าความต้องการใช้ไฟฟ้าจริงเล็กน้อย มีเพียงช่วงดัชนีเวลาสั้น ๆ บางช่วงดัชนีเวลา คือ ช่วงดัชนีเวลาที่ 10 ถึง 15 ช่วงดัชนีเวลาที่ 45 ถึง 50 ช่วงดัชนีเวลาที่ 90 ถึง 100 และช่วงดัชนีเวลาที่ 170 ถึง 175 ที่มีค่ามากกว่าค่าจริงชัดเจน โดยมีผลลัพธ์ต่างจากค่าจริงประมาณ 10 ถึง 20 กิโลวัตต์-ชั่วโมง ซึ่งเป็นจำนวนดัชนีเวลาที่น้อยกว่าการทดลองด้วยคู่แข่งอื่น ๆ ก่อนหน้า ส่วนผลลัพธ์ค่าความผิดพลาดเฉลี่ยของการทดลองทั้ง 5 ครั้ง คือ MAE เท่ากับ 5.7617 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 68.2942 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 8.2528 กิโลวัตต์-ชั่วโมง ดังที่แสดงในตารางที่ 32

จากผลการทดลองทุกการทดลองทั้งการใช้ปัจจัยร่วม 1 ปัจจัย และ 2 ปัจจัย แสดงให้เห็นว่าการใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ร่วมกับความต้องการใช้ไฟฟ้านั้น ทำให้แบบจำลองสามารถพยากรณ์ค่าได้ใกล้เคียงกับค่าความต้องการใช้ไฟฟ้าจริงมากที่สุดของทุกการทดลองที่ผ่านมา เช่นเดียวกับค่าความผิดพลาดเฉลี่ยทั้ง 3 ชนิด ที่มีค่าน้อยกว่าการทดลองก่อนหน้าทุก ๆ การทดลอง โดยมีผลลัพธ์คือ MAE เท่ากับ 5.7617 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 68.2942 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 8.2528 กิโลวัตต์-ชั่วโมง

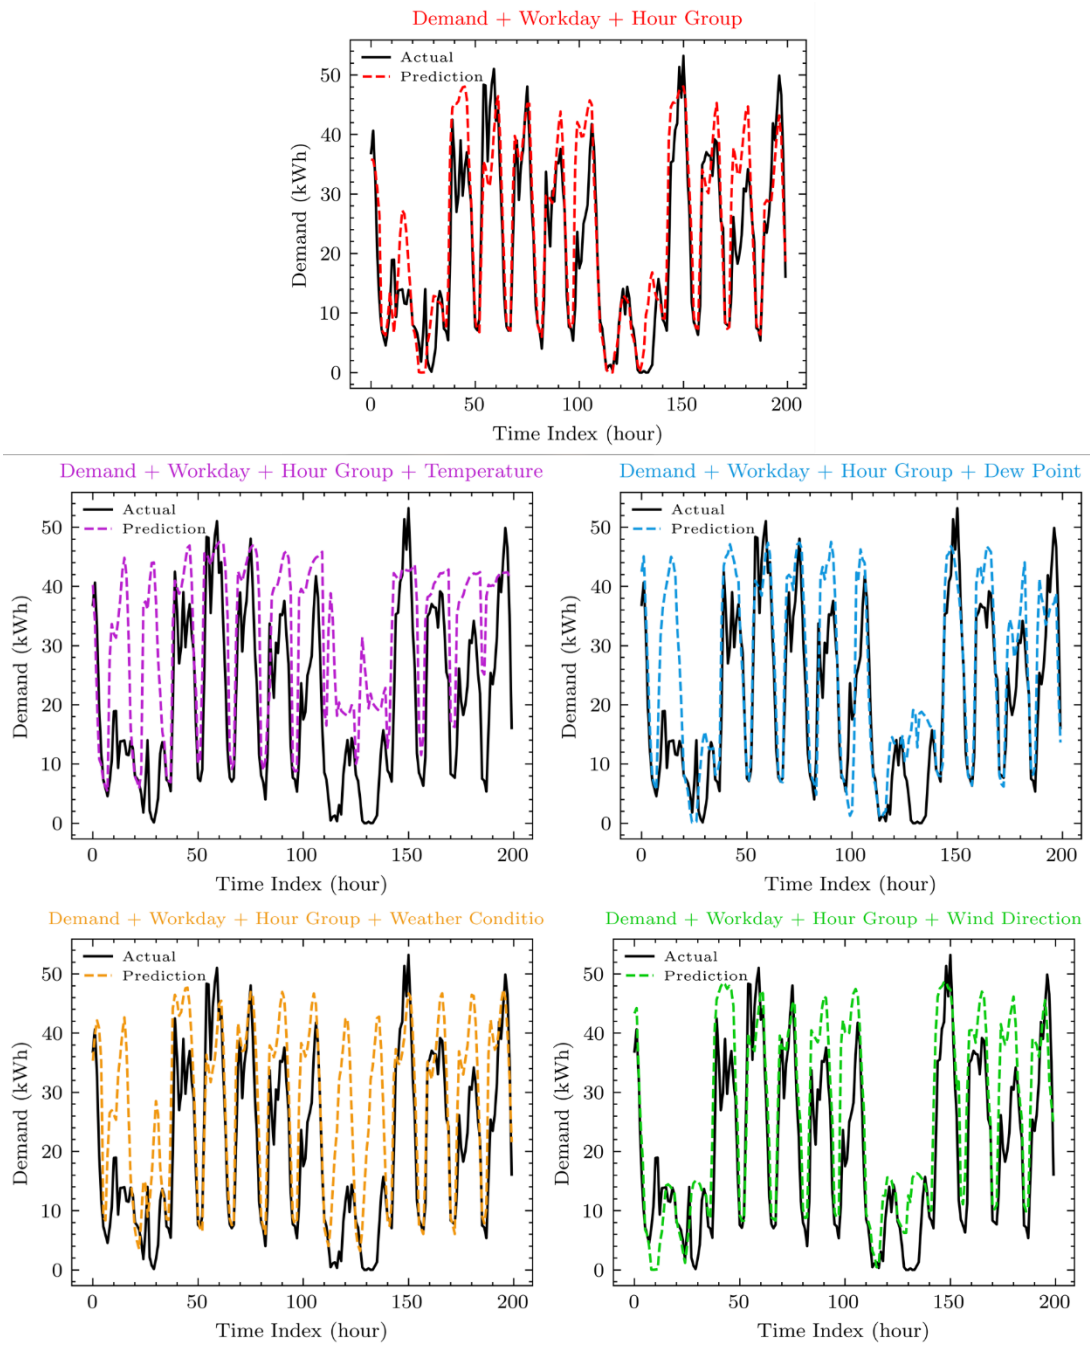
เปรียบเทียบผลการทดลองของชุดปัจจัย วันทำการของวิทยาลัย ฯ และ ช่วงเวลาของวัน ร่วมกับ ปัจจัยอุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลม

การทดลองนี้เป็นการนำปัจจัยที่เกี่ยวข้องทั้ง อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และ ทิศทางลม เข้ามาใช้ฝึกสอนแบบจำลองร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวันซึ่งเป็นชุดปัจจัยที่ได้ผลลัพธ์ค่าความผิดพลาดของการพยากรณ์ต่ำที่สุดจากการทดลองใช้ปัจจัยที่เกี่ยวข้อง 1 และ 2 ปัจจัยร่วมกับความต้องการใช้ไฟฟ้า เพื่อหาค่าความผิดพลาดของแต่ละชุดปัจจัยที่เพิ่มเข้ามา

จากภาพที่ 59 แสดงให้เห็นว่าการนำปัจจัยที่เกี่ยวข้องทั้ง อุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลม เข้ามาใช้ร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวันทำให้ค่าที่พยากรณ์ได้ในช่วงดัชนีเวลาที่ 10 ถึง 40 และช่วงดัชนีเวลาที่ 110 ถึง 140 มีค่าสูงกว่าค่าความต้องการใช้ไฟฟ้าจริงมากขึ้นกว่าการใช้เพียงแค่ปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวันอย่างมีนัยสำคัญ โดยค่าพยากรณ์ที่เพิ่มขึ้นมีค่าต่างจากค่าจริงมากที่สุดประมาณ 40 กิโลวัตต์-ชั่วโมง

ส่วนค่าความผิดพลาดของการใช้ปัจจัยที่เกี่ยวข้องอื่นๆ เพิ่มเติม ผลลัพธ์ของทุกชุดการทดลองมีค่ามากกว่าการใช้เพียงแค่ปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน การนำปัจจัยอุณหภูมิเข้ามาใช้เพิ่มเติมนั้นให้ผลลัพธ์ค่าความผิดพลาดมากที่สุด โดยมีค่าความผิดพลาดสูงดังนี้ MAE มีค่ามากกว่า 6.98 กิโลวัตต์-ชั่วโมง MSE มีค่ามากกว่า 174.99 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่ามากกว่า 7.63 กิโลวัตต์-ชั่วโมง ส่วนการนำปัจจัยทิศทางลมมาใช้เพิ่มเติมได้ผลลัพธ์ใกล้เคียงที่สุด คือ MAE มีค่ามากกว่า 1.48 กิโลวัตต์-ชั่วโมง MSE มีค่ามากกว่า 21.20 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE มีค่ามากกว่า 1.21 กิโลวัตต์-ชั่วโมง ดังตารางที่ 33

จากผลการทดลองในตารางที่ 33 พบว่าการเพิ่มปัจจัยอุณหภูมิให้ผลลัพธ์ค่าความผิดพลาดมากกว่าการใช้เพียงปัจจัยวันทำการของวิทยาลัย ฯ อาจเป็นผลจากการเพิ่มขึ้นของแสงอาทิตย์ทำให้อาคาร NDIR ที่มีลักษณะการใช้พลังงานแบบโพรซูเมอร์ สามารถผลิตพลังงานไฟฟ้าได้มากขึ้น แต่ในเวลาเดียวกันทำให้อุณหภูมิเพิ่มขึ้น ส่งผลให้ปริมาณการใช้ไฟฟ้าเพิ่มขึ้นตาม ดังนั้นผลการทดลองที่ได้ อาจไม่สอดคล้องกับผลลัพธ์ที่คาดการณ์




ภาพที่ 59 ภาพเปรียบเทียบการใช้ปัจจัยอื่น ๆ ที่เกี่ยวข้อง กับคู่ปัจจัยวันทำการของวิทยาลัย ฯ และ
ช่วงเวลาของวัน

ตารางที่ 33 ค่าความผิดพลาดของการทดลองการใช้ปัจจัยอื่น ๆ ที่เกี่ยวข้อง กับคู่ปัจจัยวันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน

ปัจจัยที่ใช้ร่วมกับความต้องการใช้ไฟฟ้า	MAE	MSE	RMSE
วันทำการของวิทยาลัย ฯ + ช่วงเวลาของวัน	5.76±0.29	68.29±8.06	8.25±0.48
วันทำการของวิทยาลัย ฯ + ช่วงเวลาของวัน + อุณหภูมิ	12.74±0.49	243.28±20.98	15.88±0.57
วันทำการของวิทยาลัย ฯ + ช่วงเวลาของวัน + อุณหภูมิจุดน้ำค้าง	7.36±0.42	97.08±9.51	9.97±0.36
วันทำการของวิทยาลัย ฯ + ช่วงเวลาของวัน + สภาพอากาศ	10.36±0.37	219.80±15.73	14.83±0.60
วันทำการของวิทยาลัย ฯ + ช่วงเวลาของวัน + ทิศทางลม	7.24±21	89.49±10.22	9.46±0.34


แบ่งช่วงดัชนีเวลาของการใช้ปัจจัยความต้องการใช้ไฟฟ้าร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน

เพื่อให้สามารถสังเกตผลการทดลองได้สะดวกขึ้น จึงแบ่งการทดลองการใช้ปัจจัยความต้องการใช้ไฟฟ้าร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ซึ่งเป็นชุดปัจจัยที่มีผลลัพธ์ค่าความผิดพลาดของการพยากรณ์น้อยที่สุดในการทดลองการใช้ปัจจัยอื่น ๆ โดยแบ่งการทดลองออกเป็น 4 ช่วงเวลา ช่วงเวลาระยะ 50 ดัชนีเวลา จากนั้นแทนที่ดัชนีเวลาด้วยวันที่และเวลาจริง เพื่อให้สะดวกต่อการวิเคราะห์ผลการทดลอง




ภาพที่ 60 ผลการทดลองครั้งที่ 1 ช่วงเวลา 16.00 น. วันที่ 18 มีนาคม 2565 ถึงช่วงเวลา 20.00 น. วันที่ 21 มีนาคม 2565

จากภาพที่ 60 พบว่าในช่วงการทดลองแรกนี้แบบจำลองมีผลการพยากรณ์ที่แม่นยำเพียงช่วงเวลา 16.00 น. วันที่ 18 มีนาคม 2565 จนถึงเวลา 11.00 น. วันที่ 19 มีนาคม 2565 และช่วงเวลา 7.00 น. วันที่ 21 มีนาคม 2565 จนถึงเวลา 11.00 น. วันที่ 21 มีนาคม 2565 โดยในช่วงเวลานี้มีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงประมาณ 0 ถึง 4 กิโลวัตต์-ชั่วโมง ส่วนช่วงเวลาอื่น ๆ มีความแม่นยำในการพยากรณ์ต่ำ โดยมีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงมากที่สุดประมาณ 15 กิโลวัตต์-ชั่วโมง ส่วนผลลัพธ์ค่าความผิดพลาดของช่วงเวลาแรกคือ MAE เท่ากับ 6.4524 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 72.6457 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 8.5232 กิโลวัตต์-ชั่วโมง



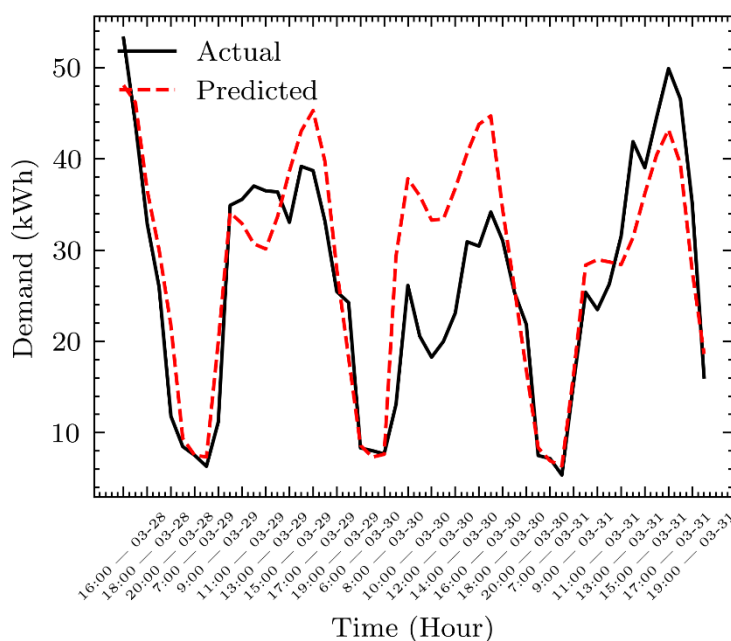
ภาพที่ 61 ผลการทดลองครั้งที่ 2 ช่วงเวลา 6.00 น. วันที่ 22 มีนาคม 2565 ถึงช่วงเวลา 10.00 น. วันที่ 25 มีนาคม 2565

จากภาพที่ 61 พบว่าในช่วงการทดลองที่ 2 นี้แบบจำลองมีผลการพยากรณ์ที่แม่นยำตั้งแต่เวลา 18.00 น. วันที่ 22 มีนาคม 2565 จนถึงเวลา 7.00 น. วันที่ 25 มีนาคม 2565 โดยในช่วงเวลานี้มีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงประมาณ 0 ถึง 5 กิโลวัตต์-ชั่วโมง ส่วนช่วงเวลาที่การพยากรณ์มีความแม่นยำต่ำคือช่วงเวลา 6.00 น. วันที่ 22 มีนาคม 2565 ถึงช่วงเวลา 16.00 น. วันที่ 22 มีนาคม 2565 โดยในช่วงเวลานี้มีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงมากที่สุดประมาณ 5 ถึง 20 กิโลวัตต์-ชั่วโมง และผลลัพธ์ค่าความผิดพลาดของช่วงเวลาที่สองคือ MAE เท่ากับ 4.7292 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 47.1235 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 6.8647 กิโลวัตต์-ชั่วโมง



ภาพที่ 62 ผลการทดลองครั้งที่ 3 ช่วงเวลา 11.00 น. วันที่ 25 มีนาคม 2565 ถึงช่วงเวลา 15.00 น. วันที่ 28 มีนาคม 2565

จากภาพที่ 62 พบว่าในช่วงการทดลองที่ 3 นี้แบบจำลองมีผลการพยากรณ์ที่แม่นยำตั้งแต่เวลา 17.00 น. วันที่ 25 มีนาคม 2565 จนถึงเวลา 10.00 น. วันที่ 27 มีนาคม 2565 โดยในช่วงเวลานี้มีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงประมาณ 0 ถึง 5 กิโลวัตต์-ชั่วโมง ส่วนช่วงเวลาอื่น ๆ มีความแม่นยำในการพยากรณ์ต่ำ โดยมีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงมากที่สุดประมาณ 22 กิโลวัตต์-ชั่วโมง และผลลัพธ์ค่าความผิดพลาดของช่วงเวลาที่สามคือ MAE เท่ากับ 5.3365 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 67.7780 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 8.2327 กิโลวัตต์-ชั่วโมง




ภาพที่ 63 ผลการทดลองช่วงที่ 4 ช่วงเวลา 16.00 น. วันที่ 28 มีนาคม 2565 ถึงช่วงเวลา 20.00 น. วันที่ 31 มีนาคม 2565

จากภาพที่ 63 พบว่าในช่วงการทดลองแรกนี้แบบจำลองมีผลการพยากรณ์ที่แม่นยำเพียงช่วงเวลา 16.00 น. วันที่ 28 มีนาคม 2565 จนถึงเวลา 11.00 น. วันที่ 29 มีนาคม 2565 และช่วงเวลา 18.00 น. วันที่ 30 มีนาคม 2565 จนถึงเวลา 11.00 น. วันที่ 31 มีนาคม 2565 โดยในช่วงเวลานี้มีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงประมาณ 0 ถึง 3 กิโลวัตต์-ชั่วโมง ส่วนช่วงเวลาอื่น ๆ มีความแม่นยำในการพยากรณ์ต่ำ โดยมีผลต่างของค่าที่พยากรณ์ได้กับค่าความต้องการใช้ไฟฟ้าจริงมากที่สุดประมาณ 20 กิโลวัตต์-ชั่วโมง ส่วนผลลัพธ์ค่าความผิดพลาดของช่วงเวลาแรกคือ MAE เท่ากับ 5.4613 กิโลวัตต์-ชั่วโมง MSE เท่ากับ 50.2364 กิโลวัตต์-ชั่วโมงยกกำลังสอง และ RMSE เท่ากับ 7.0878 กิโลวัตต์-ชั่วโมง


เปรียบเทียบผลการพยากรณ์กับแบบจำลอง N-BEATS และแบบจำลอง N-HiTs

เปรียบเทียบผลการพยากรณ์ความต้องการใช้พลังงานด้วยแบบจำลอง TFT ด้วยปัจจัยที่เกี่ยวข้อง 2 ปัจจัยที่มีผลการทดลองที่ได้ผลลัพธ์ที่ดีที่สุด คือ ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน เปรียบเทียบกับแบบจำลอง N-BEATS และแบบจำลอง N-HiTs เพื่อให้เห็นความแตกต่างของผลการพยากรณ์เมื่อใช้แบบจำลองที่ต่างกันมาทำการพยากรณ์ข้อมูลชุดเดียวกัน โดยแบ่งการทดลองออกเป็น 4 ช่วง ช่วงละ 50 ดัชนีเวลา




ภาพที่ 64 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS
ช่วงที่ 1

จากภาพที่ 64 ผลการพยากรณ์ช่วงที่ 1 แบบจำลอง TFT มีผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงในช่วงเวลา 16.00 น. วันที่ 18 มีนาคม 2565 ถึงช่วงเวลา 11.00 น. วันที่ 19 มีนาคม 2565 และช่วงเวลา 19.00 น. วันที่ 19 มีนาคม 2565 ถึง ช่วงเวลา 9.00 น. วันที่ 21 มีนาคม 2565 ในขณะที่ผลการพยากรณ์ของแบบจำลอง N-BEATS และ N-HITS มีค่าต่างจากค่าจริงในทุก ๆ ช่วงเวลา ในช่วงการพยากรณ์ที่ 1 นี้ ในส่วนแบบจำลอง N-BEATS มีผลการพยากรณ์ความต้องการไฟฟ้าอยู่ระหว่าง 10 กิโลวัตต์-ชั่วโมง ถึง 35 กิโลวัตต์-ชั่วโมง โดยช่วงเวลา 16.00 น. วันที่ 20 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดคือประมาณ 35 กิโลวัตต์-ชั่วโมง และแบบจำลอง N-HITS มีผลการพยากรณ์ความต้องการไฟฟ้าอยู่ระหว่าง 20 กิโลวัตต์-ชั่วโมง ถึง 36 กิโลวัตต์-ชั่วโมง โดยช่วงเวลา 16.00 น. วันที่ 20 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดเช่นเดียวกับแบบจำลอง N-BEATS มีค่าประมาณ 25 กิโลวัตต์-ชั่วโมง




ภาพที่ 65 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HITS ช่วงที่ 2

จากภาพที่ 65 ผลการพยากรณ์ช่วงที่ 2 แบบจำลอง TFT มีผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงเกือบทุกช่วงเวลา โดยช่วงเวลาที่พยากรณ์ได้ต่างจากค่าจริงคือช่วงเวลา 10.00 น. วันที่ 22 มีนาคม 2565 ถึงช่วงเวลา 18.00 น. วันที่ 22 มีนาคม 2565 และช่วงเวลา 12.00 น. วันที่ 24 มีนาคม 2565 ถึง ช่วงเวลา 18.00 น. วันที่ 24 มีนาคม 2565 ส่วนแบบจำลอง N-BEATS มีเพียงช่วงเวลาตั้งแต่ 20.00 น. วันที่ 22 มีนาคม 2565 ถึงช่วงเวลา 13.00 น. วันที่ 23 มีนาคม 2565 ที่มีความใกล้เคียงค่าจริง และแบบจำลอง N-HITS ในช่วงการพยากรณ์ช่วงที่ 2 นี้ มีผลลัพธ์ที่ต่างจากค่าจริงชัดเจนในทุก ๆ ช่วงเวลา โดยช่วงเวลา 8.00 น. วันที่ 24 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดคือประมาณ 32 กิโลวัตต์-ชั่วโมง



ภาพที่ 66 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HiTs ช่วงที่ 3

จากภาพที่ 66 ผลการพยากรณ์ช่วงที่ 3 แบบจำลอง TFT มีผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงเกือบทุกช่วงเวลา โดยช่วงเวลาที่พยากรณ์ได้ต่างจากค่าจริงคือช่วงเวลา 11.00 น. วันที่ 27 มีนาคม 2565 ถึงช่วงเวลา 17.00 น. วันที่ 27 มีนาคม 2565 โดยช่วงในช่วงนี้มีผลต่างระหว่างค่าที่พยากรณ์ได้กับค่าจริงมากที่สุดประมาณ 15 กิโลวัตต์-ชั่วโมง ในขณะที่ผลการพยากรณ์ของแบบจำลอง N-BEATS และ N-HITS มีค่าต่างจากค่าจริงในทุก ๆ ช่วงเวลา ในส่วนของแบบจำลอง N-BEATS มีผลการพยากรณ์ความต้องการไฟฟ้าปรับเปลี่ยนเพิ่มสลับกับลดอยู่ระหว่าง 20 กิโลวัตต์-ชั่วโมง ถึง 42 กิโลวัตต์-ชั่วโมง โดยช่วงเวลา 15.00 น. วันที่ 27 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดคือประมาณ 37 กิโลวัตต์-ชั่วโมง และแบบจำลอง N-HITS มีผลการพยากรณ์ความต้องการไฟฟ้าที่มีลักษณะเป็นค่าที่ไม่คงที่อยู่ระหว่าง 20 กิโลวัตต์-ชั่วโมง ถึง 42 กิโลวัตต์-ชั่วโมง และมีพฤติกรรมไม่สอดคล้องกับลักษณะของค่าจริง



ภาพที่ 67 ผลการพยากรณ์ระหว่างแบบจำลอง TFT แบบจำลอง N-BEATS และ แบบจำลอง N-HiTs
ช่วงที่ 4

จากภาพที่ 67 ผลการพยากรณ์ช่วงที่ 3 แบบจำลอง TFT มีผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงเกือบทุกช่วงเวลา โดยช่วงเวลาที่พยากรณ์ได้ต่างจากค่าจริงคือช่วงเวลา 10.00 น. วันที่ 30 มีนาคม 2565 ถึงช่วงเวลา 18.00 น. วันที่ 30 มีนาคม 2565 โดยช่วงในช่วงนี้มีผลต่างระหว่างค่าที่พยากรณ์ได้กับค่าจริงมากที่สุดประมาณ 17 กิโลวัตต์-ชั่วโมง ในขณะที่แบบจำลอง N-BEATS และ N-HiTs ผลการพยากรณ์ที่ได้ค่อนข้างมีพฤติกรรมต่างจากค่าจริง ในส่วนแบบจำลอง N-BEATS มีผลการพยากรณ์ความต้องการไฟฟ้าปรับตัวเพิ่มขึ้นตั้งแต่ 10 กิโลวัตต์-ชั่วโมง จนถึง 45 กิโลวัตต์-ชั่วโมง โดยช่วงเวลา 7.00 น. วันที่ 31 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดคือประมาณ 42 กิโลวัตต์-ชั่วโมง และแบบจำลอง N-HiTs มีผลการพยากรณ์ความต้องการไฟฟ้าเปลี่ยนแปลงเพิ่มขึ้นและลดลงอยู่ระหว่าง 25 กิโลวัตต์-ชั่วโมง ถึง 42 กิโลวัตต์-ชั่วโมง โดยช่วงเวลา 7.00 น. วันที่ 31 มีนาคม 2565 เป็นช่วงที่ค่าที่พยากรณ์ได้ต่างจากค่าจริงมากที่สุดเช่นเดียวกับแบบจำลอง N-BEATS มีค่าประมาณ 32 กิโลวัตต์-ชั่วโมง

การเปรียบเทียบเวลาที่ใช้ในการฝึกสอนแบบจำลองและพยากรณ์หาผลลัพธ์

การเปรียบเทียบประสิทธิภาพของแบบจำลองด้านเวลาในการประมวลผล โดยการหาเวลาแฝง (Latency) ของการฝึกสอนและพยากรณ์ของแบบจำลอง N-BEATS แบบจำลอง N-HITS และแบบจำลอง TFT ด้วยข้อมูลที่ใช้ฝึกสอน 4,750 ดัชนีเวลา และพยากรณ์ข้อมูล 100 ดัชนีเวลา ฝึกสอนจำนวนรอบ 30 รอบ ด้วยหน่วยประมวลผล NVIDIA Tesla T4 GPU ผลลัพธ์ที่ได้คือแบบจำลอง N-BEATS ใช้เวลาในการฝึกสอนเท่ากับ 63.37 วินาที และเวลาที่ใช้ในการพยากรณ์เท่ากับ 0.22 วินาที ถัดมาแบบจำลอง N-HITS ใช้เวลา 74.95 วินาที และ 0.22 วินาที สำหรับการฝึกสอนและการพยากรณ์ ตามลำดับ และสำหรับแบบจำลอง TFT ใช้เวลาในการฝึกสอนเท่ากับ 5,242.53 วินาที และเวลาในการพยากรณ์เท่ากับ 0.23 วินาที จากผลการทดลองที่แสดงในตารางที่ 34 พบว่าแบบจำลอง TFT ใช้เวลาในการพยากรณ์มากที่สุด ในขณะที่เวลาของการพยากรณ์ของแบบจำลองทั้ง 3 แบบจำลองใช้เวลาใกล้เคียงกัน

ตารางที่ 34 เวลาที่ใช้ในการฝึกสอนและพยากรณ์หาผลลัพธ์

Model	Training Time (s)	Forecasting Time (s)
N-BEATS	63.37±7.97	0.22±0.04
N-HITS	74.95±8.41	0.22±0.04
TFT	5242.53±107.57	0.23±0.06

บทที่ 5

สรุปและอภิปรายผลการทดลอง

สรุปผลการทดลอง

การทดลองการค้นหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมสำหรับแบบจำลอง TFT เพื่อเป็นไฮเปอร์พารามิเตอร์พื้นฐานสำหรับการทดลองชุดถัดไป พบว่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดคือการใช้จำนวนชั้นซ่อน 32 ชั้น ใช้อัตราการเรียนรู้เท่ากับ 0.05 และใช้จำนวนส่วนความตั้งใจเท่ากับ 1 ซึ่งให้ค่า MAE เท่ากับ 6.57 กิโลวัตต์ชั่วโมง MSE เท่ากับ 77.52 กิโลวัตต์ชั่วโมงยกกำลังสอง และค่า RMSE เท่ากับ 8.89 กิโลวัตต์ชั่วโมง

จากการทดลองการใช้ปัจจัยอื่น ๆ ที่คาดว่าจะส่งผลต่อการพยากรณ์ความต้องการใช้ไฟฟ้าด้วยปัจจัยที่เกี่ยวข้อง 2 ปัจจัย คู่ปัจจัยที่ส่งผลต่อผลการทดลองมากที่สุดคือการใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ซึ่งทำให้ค่าความผิดพลาดของการทดลองมีค่าน้อยกว่าการใช้คู่ปัจจัยอื่น ๆ โดยให้ค่า MAE เท่ากับ 5.76 กิโลวัตต์ชั่วโมง MSE เท่ากับ 68.29 กิโลวัตต์ชั่วโมงยกกำลังสอง และค่า RMSE เท่ากับ 8.25 กิโลวัตต์ชั่วโมง อย่างไรก็ตามการทดลองใช้ปัจจัยวันทำการของวิทยาลัย ฯ คู่กับปัจจัยอุณหภูมิ และการทดลองใช้ปัจจัยวันทำการของวิทยาลัย ฯ คู่กับปัจจัยอุณหภูมิจุดน้ำค้าง ให้ได้ผลลัพธ์ของการพยากรณ์ใกล้เคียงกับการใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ส่วนชุดปัจจัยอื่น ๆ นั้นให้ผลลัพธ์ของการพยากรณ์ที่ผิดพลาดมากกว่า 1.5 - 2 เท่าของผลลัพธ์ที่ดีที่สุด ส่วนการใช้ปัจจัยที่เกี่ยวข้อง 1 ปัจจัยนั้นได้ผลลัพธ์ค่าความผิดพลาดของการพยากรณ์มากกว่า 2 เท่าของการใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน

จากการทดลองการเปรียบเทียบผลการทดลองของชุดปัจจัย วันทำการของวิทยาลัย ฯ และช่วงเวลาของวัน ร่วมกับปัจจัยอุณหภูมิ อุณหภูมิน้ำค้าง สภาพอากาศ และทิศทางลม พบว่าการเพิ่มปัจจัยที่เกี่ยวข้องร่วมกับชุดปัจจัยที่ให้ผลลัพธ์ค่าความผิดพลาดของการพยากรณ์น้อยที่สุดนั้น มิได้ลดค่าความผิดพลาดของการพยากรณ์ลง แม้ว่าทุกปัจจัยที่นำมาใช้ทดลองนั้นล้วนผ่านการทดสอบว่าเป็นปัจจัยที่เกี่ยวข้องกับความต้องการใช้พลังงาน ทำให้สรุปได้ว่าการเพิ่มปัจจัยต่าง ๆ ให้มีจำนวนมากขึ้น มิได้ช่วยทำให้ค่าความผิดพลาดของการพยากรณ์ลดลง

การใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวันสำหรับการทดลองแบ่งช่วงดัชนีเวลาในการทดสอบแบบจำลองนั้น พบว่าผลลัพธ์ค่าความผิดพลาดต่ำกว่าการใช้ปัจจัยชุดอื่น หากพิจารณาความแม่นยำของการพยากรณ์รายชั่วโมง พบว่าการพยากรณ์นอกช่วงเวลาทำการของวิทยาลัย ฯ ได้ผลลัพธ์ที่แม่นยำมากกว่าการใช้ปัจจัยอื่น ๆ

อภิปรายผลการทดลอง

การทดลองปรับค่าไฮเปอร์พารามิเตอร์หลังจากได้ทดลองใช้ชุดพารามิเตอร์หลาย ๆ ชุดในการทดลองพบว่าการใช้จำนวนชั้นซ่อน 32 ชั้น เป็นจำนวนที่ทำให้ความซับซ้อนในขณะทำการฝึกสอนแบบจำลองไม่ต้องใช้ปริมาณทรัพยากรมากเกินไป ค่าอัตราการเรียนรู้ที่ได้นั้นเป็นค่าที่ทำให้แบบจำลองมีความสมดุล ขนาดขั้น (Step Size) ของการฝึกสอนมีขนาดที่เหมาะสม การใช้จำนวนส่วนความตั้งใจเพียง 1 ส่วน ได้ผลการทดลองที่ดีกว่าการใช้ส่วนความตั้งใจจำนวนมาก เนื่องจากการเพิ่มจำนวนส่วนความตั้งใจขึ้น ส่งผลให้เกิดการจดจำชุดข้อมูลฝึกสอนมากเกินไป ทำให้เกิดปัญหา Overfitting ของแบบจำลอง

การทดลองใช้ปัจจัยอื่น ๆ ที่คาดว่าจะเกี่ยวข้องกับความต้องการใช้ไฟฟ้านั้น ทำให้ทราบว่า การใช้ปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ซึ่งเป็นคู่ปัจจัยที่ได้ผลลัพธ์จากการทดลองที่ดีที่สุดนั้น ช่วยให้แบบจำลองสามารถแยกส่วนระหว่างช่วงเวลาที่มีบุคลากรปฏิบัติงานอยู่และไม่มีบุคลากรปฏิบัติงานอยู่ โดยส่งผลโดยตรงกับปริมาณความต้องการใช้ไฟฟ้า เนื่องจากการใช้อุปกรณ์เครื่องใช้ไฟฟ้า รวมถึงเครื่องปรับอากาศมากกว่าในช่วงนอกเวลาทำการอย่างมาก หากพิจารณาผลการทดลองที่ใช้ปัจจัยวันทำการของวิทยาลัย ฯ คู่กับปัจจัยอุณหภูมิ และใช้ปัจจัยวันทำการของวิทยาลัย ฯ คู่กับปัจจัยอุณหภูมิจุดน้ำค้าง พบว่าให้ค่าความใกล้เคียงกับผลการทดลองของปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ดังนั้นแสดงให้เห็นว่าปัจจัยวันทำการของวิทยาลัย ฯ ส่งผลต่อการพยากรณ์มากที่สุด ส่วนปัจจัยอื่น ๆ ทั้งอุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลมล้วนเป็นปัจจัยที่แปรผันตรงกับความต้องการใช้ไฟฟ้า จึงทำให้เมื่อนำมาใช้เป็นปัจจัยร่วมกันอาจทำให้แบบจำลองเกิดการคำนวณคลาดเคลื่อน

การทดลองเพิ่มปัจจัยที่เกี่ยวข้องทั้งอุณหภูมิ อุณหภูมิจุดน้ำค้าง สภาพอากาศ และทิศทางลม เข้าไปใช้ร่วมกับปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน ไม่ได้ทำให้ผลลัพธ์ของการทดลองดีขึ้น เนื่องจากการมีปัจจัยที่เกี่ยวข้องจำนวนมากเกินไป หากปัจจัยที่ใช้มีความคล้ายคลึงกันมากเกินไป อาจทำให้เกิดการสับสนในการฝึกสอนแบบจำลอง และไม่สามารถค้นหาปัจจัยสำคัญที่เกี่ยวข้องกับแบบจำลองได้

การแบ่งช่วงการทดลองของปัจจัยวันทำการของวิทยาลัย ฯ และปัจจัยช่วงเวลาของวัน นั้นพบว่าการใช้ปัจจัยดังกล่าว ส่งผลดีต่อความแม่นยำของการพยากรณ์ในช่วงวันหยุดทำการของวิทยาลัย ฯ ที่มีความต้องการใช้ไฟฟ้าต่ำ อย่างไรก็ตามเมื่อเปรียบเทียบกับปัจจัยอื่น ๆ นั้นมิได้สามารถจัดการกับการลดลงของการใช้ไฟฟ้าในช่วงวันหยุดทำการได้ ดังนั้นปัจจัยวันหยุดทำการ ทั้งวันเสาร์ วันอาทิตย์และวันหยุดเทศกาลต่าง ๆ นั้นช่วยให้ผลการพยากรณ์หาความต้องการใช้ไฟฟ้าแม่นยำขึ้น

ข้อจำกัดและแนวทางการแก้ไข

ข้อจำกัดที่มีความสำคัญของการทดลองนี้ คือปริมาณข้อมูลย้อนหลัง โดยมีผลต่อความสามารถในการพยากรณ์ของแบบจำลอง อีกทั้งความไม่ต่อเนื่องของข้อมูลในช่วงเวลาที่ขาดหายไปซึ่งมีผลต่อการพยากรณ์เช่นกัน ดังนั้นหากมีข้อมูลการใช้ไฟฟ้าในอดีตจำนวนมากและครบถ้วน ทุกช่วงเวลาจะส่งผลดีต่อการเรียนรู้ของแบบจำลอง

ส่วนของปัจจัยภายนอกที่เกี่ยวข้องนั้น มีความสำคัญต่อประสิทธิภาพของแบบจำลอง เนื่องจากปัจจัยภายนอกต่าง ๆ ที่ใช้ในวิทยานิพนธ์นี้ เช่น อุณหภูมิ อุณหภูมิน้ำค้าง สภาพอากาศ และทิศทางลม นั้น มิได้เป็นค่าที่เก็บได้เองภายในบริเวณวิทยาลัย ๆ แต่อ้างอิงจากบริเวณใกล้เคียงซึ่งเป็นปัจจัยที่อาจมีผลต่อความคลาดเคลื่อนจากความเป็นจริงในบริเวณวิทยาลัย ๆ หากในบริเวณวิทยาลัย ๆ มีการติดตั้งเครื่องมือวัดและเก็บข้อมูลดังกล่าวได้ จะส่งผลให้แบบจำลองสามารถพยากรณ์ได้แม่นยำมากขึ้น

ในส่วนของคุณภาพข้อมูลที่นำมาใช้ในวิทยานิพนธ์นี้ มีความละเอียดของตัวเลขหรือจุดทศนิยมที่ไม่มากพอ ซึ่งหากมีปัจจัยที่เกี่ยวข้องอื่น ๆ หลายปัจจัย จะทำให้เกิดความคลาดเคลื่อนของข้อมูลจริง ณ เวลานั้น ๆ ดังนั้น ควรเลือกเครื่องมือวัดที่มีคุณภาพที่จะเก็บค่าต่าง ๆ ได้อย่างละเอียดและครบถ้วน

ข้อเสนอแนะและการนำไปใช้งานในอนาคต

การทดลองเพื่อหาปัจจัยที่เกี่ยวข้องนั้น สามารถนำไปใช้ร่วมกับการพยากรณ์ด้านอื่น ๆ ได้ เช่น การพยากรณ์สภาพอากาศ หรือการนำไปใช้ในด้านเศรษฐศาสตร์ ซึ่งการพยากรณ์ในด้านที่กล่าวมานั้น ล้วนมีปัจจัยที่เกี่ยวข้องจำนวนมากโดยบางปัจจัยอาจส่งผลต่อการพยากรณ์หรืออาจจะมีได้ช่วยเพิ่มประสิทธิภาพความแม่นยำของแบบจำลองการพยากรณ์ ในทางกลับกันอาจส่งผลให้ความแม่นยำน้อยลงได้ เพื่อแก้ปัญหาดังกล่าวการใช้เทคนิค Neural Architecture Search (NAS) ที่สามารถช่วยค้นหาโครงข่ายประสาทเทียมที่เหมาะสมที่สุดในแต่ละชุดข้อมูลที่ต้องการพยากรณ์

ในส่วนของการพยากรณ์หาค่าความต้องการใช้ไฟฟ้านั้นจำเป็นต้องทำการทดสอบกับความถี่การใช้ไฟฟ้าในพื้นที่อื่น ๆ เพื่อหาข้อบกพร่องที่ไม่สามารถพบได้จากการใช้ชุดข้อมูลเพียงชุดเดียว และการพัฒนาหรือปรับเปลี่ยนสถาปัตยกรรมของการเรียนรู้เชิงลึกนั้นอาจทำให้การพยากรณ์มีประสิทธิภาพมากขึ้น โดยการใช้สถาปัตยกรรมที่มีความนิยมอื่น ๆ เข้ามาร่วมทดสอบ เช่น Generative Pre-trained Transformer (GPT) ที่เป็นปัญญาประดิษฐ์แบบการก่อกำเนิด (Generative) รูปแบบหนึ่งที่มีความนิยมมากในปัจจุบัน และการใช้ NAS จะช่วยในการค้นหาแบบจำลองที่เหมาะสมกับชุดข้อมูลมากที่สุด

บรรณานุกรม

1. แผนแม่บทการพัฒนาาระบบโครงข่ายสมาร์ตกริดของประเทศไทย พ.ศ. 2558-2579, (2015).
2. Albadi MH, El-Saadany EF, editors. Demand response in electricity markets: An overview. 2007 IEEE power engineering society general meeting; 2007: IEEE.
3. Albadi MH, El-Saadany EF. A summary of demand response in electricity markets. Electric power systems research. 2008;78(11):1989-96.
4. Conejo AJ, Morales JM, Baringo L. Real-time demand response model. IEEE Transactions on Smart Grid. 2010;1(3):236-42.
5. Deng R, Yang Z, Chow M-Y, Chen J. A survey on demand response in smart grids: Mathematical models and approaches. IEEE Transactions on Industrial Informatics. 2015;11(3):570-82.
6. Siano P. Demand response and smart grids—A survey. Renewable and sustainable energy reviews. 2014;30:461-78.
7. Aman S, Simmhan Y, Prasanna VK. Energy management systems: state of the art and emerging trends. IEEE Communications Magazine. 2013;51(1):114-9.
8. Chen C, Duan S, Cai T, Liu B, Hu G. Smart energy management system for optimal microgrid economic operation. IET renewable power generation. 2011;5(3):258-67.
9. Lee D, Cheng C-C. Energy savings by energy management systems: A review. Renewable and Sustainable Energy Reviews. 2016;56:760-77.
10. Zhao E, Sun S, Wang S. New developments in wind energy forecasting with artificial intelligence and big data: a scientometric insight. Data Science and Management. 2022;5(2):84-95.
11. Hamilton JD. Time series analysis: Princeton university press; 2020.
12. Shumway RH, Stoffer DS, Stoffer DS. Time series analysis and its applications: Springer; 2000.
13. Rick R, Berton L. Energy forecasting model based on CNN-LSTM-AE for many time series with unequal lengths. Engineering Applications of Artificial Intelligence. 2022;113.

14. Larrea M, Porto A, Irigoyen E, Barragán AJ, Andújar JM. Extreme learning machine ensemble model for time series forecasting boosted by PSO: Application to an electric consumption problem. *Neurocomputing*. 2021;452:465-72.
15. Holt CC. Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*. 2004;20(1):5-10.
16. Zhang GP. Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*. 2003;50:159-75.
17. Siami-Namini S, Tavakoli N, Namin AS, editors. A comparison of ARIMA and LSTM in forecasting time series. 2018 17th IEEE international conference on machine learning and applications (ICMLA); 2018: IEEE.
18. Chaturvedi S, Rajasekar E, Natarajan S, McCullen N. A comparative assessment of SARIMA, LSTM RNN and Fb Prophet models to forecast total and peak monthly energy demand for India. *Energy Policy*. 2022;168.
19. Murphy KP. *Machine learning: a probabilistic perspective*: MIT press; 2012.
20. Goodfellow I, Bengio Y, Courville A. *Deep learning*: MIT press; 2016.
21. Nielsen MA. *Neural networks and deep learning*: Determination press San Francisco, CA, USA; 2015.
22. Programmer L. *Deep Learning in Python Master Data Science and Machine Learning with Modern Neural Networks written in Python, Theano, and TensorFlow*2016.
23. StanfordUniversity. *Convolutional Neural Networks for Visual Recognition 2022* [Available from: <https://cs231n.github.io/neural-networks-1/>].
24. Nair V, Hinton GE, editors. Rectified linear units improve restricted boltzmann machines. *Icml*; 2010.
25. Miljanovic M. Comparative analysis of recurrent and finite impulse response neural networks in time series prediction. *Indian Journal of Computer Science and Engineering*. 2012;3(1):180-91.
26. Olah C. *Understanding LSTM Networks 2015* [Available from: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>].
27. Sagheer A, Kotb M. Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*. 2019;323:203-13.

28. Selvin S, Vinayakumar R, Gopalakrishnan E, Menon VK, Soman K, editors. Stock price prediction using LSTM, RNN and CNN-sliding window model. 2017 international conference on advances in computing, communications and informatics (icacci); 2017: IEEE.
29. Sundermeyer M, Schlüter R, Ney H, editors. LSTM neural networks for language modeling. Thirteenth annual conference of the international speech communication association; 2012.
30. Schmidhuber J, Hochreiter S. Long short-term memory. *Neural Comput.* 1997;9(8):1735-80.
31. Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez AN, et al. Attention is all you need. *Advances in neural information processing systems.* 2017;30.
32. L'Heureux A, Grolinger K, Capretz MAM. Transformer-Based Model for Electrical Load Forecasting. *Energies.* 2022;15(14).
33. Wang C, Wang Y, Ding Z, Zheng T, Hu J, Zhang K. A Transformer-Based Method of Multienergy Load Forecasting in Integrated Energy System. *IEEE Transactions on Smart Grid.* 2022;13(4):2703-14.
34. Chen M, Peng H, Fu J, Ling H, editors. Autoformer: Searching transformers for visual recognition. *Proceedings of the IEEE/CVF International Conference on Computer Vision;* 2021.
35. Zhou H, Zhang S, Peng J, Zhang S, Li J, Xiong H, et al., editors. Informer: Beyond efficient transformer for long sequence time-series forecasting. *Proceedings of the AAAI conference on artificial intelligence;* 2021.
36. Wu H, Xu J, Wang J, Long M. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting. *Advances in Neural Information Processing Systems.* 2021;34:22419-30.
37. Radford A, Narasimhan K, Salimans T, Sutskever I. Improving language understanding by generative pre-training. 2018.
38. Devlin J, Chang M-W, Lee K, Toutanova K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of naacL-HLT 2019.* p. 4171-86.
39. Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, et al.

An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. ICLR. 2021:1-21.

40. Raffel C, Shazeer N, Roberts A, Lee K, Narang S, Matena M, et al. Exploring the limits of transfer learning with a unified text-to-text transformer. *The Journal of Machine Learning Research*. 2020;21(1):5485-551.

41. Oreshkin BN, Carпов D, Chapados N, Bengio Y. N-BEATS: Neural basis expansion analysis for interpretable time series forecasting. *International Conference on Learning Representations* 2020.

42. Challu C, Olivares KG, Oreshkin BN, Garza F, Mergenthaler M, Dubrawski A. N-hits: Neural hierarchical interpolation for time series forecasting. *Thirty-Seventh AAAI Conference on Artificial Intelligence (AAAI-23)* 2023.

43. Lim B, Arik SÖ, Loeff N, Pfister T. Temporal fusion transformers for interpretable multi-horizon time series forecasting. *International Journal of Forecasting*. 2021;37(4):1748-64.

44. Niu Z, Zhong G, Yu H. A review on the attention mechanism of deep learning. *Neurocomputing*. 2021;452:48-62.

45. Jittanon S, Mensin Y, Termritthikun C, editors. Intelligent Forecasting of Energy Consumption using Temporal Fusion Transformer model. *2023 IEEE International Conference on Cybernetics and Innovations (ICCI); 2023: IEEE*.