




เครือข่ายประสาทยามที่ใช้เทคนิคค่าที่เหมาะสมที่สุด เพื่อพยากรณ์ความต้องการไฟฟ้าในระยะ
สั้น: การวิเคราะห์ข้อมูล มหาวิทยาลัยราชภัฏสุรินทร์

วิทยานิพนธ์
ของ
รัฐพล ดุลยะลา

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์
มีนาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

เครือข่ายประสาทเทียมที่ใช้เทคนิคค่าที่เหมาะสมที่สุด เพื่อพยากรณ์ความต้องการไฟฟ้าในระยะ
สั้น: การวิเคราะห์ข้อมูล มหาวิทยาลัยราชภัฏอุดรดิตถ์




เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์

มีนาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Artificial neural networks based on Optimization Technique for short-term electricity
demand forecasting: Uttaradit Rajabhat University Data Analysis



Rattapon Dulyala

A Thesis Submitted in Partial Fulfillment of Requirements
for Doctor of Philosophy (Electrical and Computer Engineering)

March 2025

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนายรัฐพล ดุลยะลา แล้ว เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชา วิศวกรรมไฟฟ้าและคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(รศ. ดร. อนันต์ เครือทรัพย์ถาวร)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ศ. ดร. วรวัฒน์ เสงี่ยมวิบูล)

กรรมการ

(รศ. ดร. สุพรรณนิกา วัฒนนะ)

กรรมการ

(รศ. ดร. นิวัตร อังควิศิษฐพันธ์)

กรรมการ

(ผศ. ดร. บัญชา วัฒนนะ)

มหาวิทยาลัยขอนแก่นให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร ปริญญา ปรัชญาดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ ของมหาวิทยาลัย มหาสารคาม

(รศ. ดร. จักรมาส เลหาวิช)

คณบดีคณะวิศวกรรมศาสตร์

(ศ. ดร. อนงค์ฤทธิ์ แข็งแรง)

ผู้รักษาการคณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	เครือข่ายประสาทเทียมที่ใช้เทคนิคค่าที่เหมาะสมที่สุด เพื่อพยากรณ์ความต้องการไฟฟ้าในระยะสั้น: การวิเคราะห์ข้อมูล มหาวิทยาลัยราชภัฏอุดรดิตต์		
ผู้วิจัย	รัฐพล ดุลยะลา		
อาจารย์ที่ปรึกษา	ศาสตราจารย์ ดร. วรวัฒน์ เสงี่ยมวิบูล		
ปริญญา	ปรัชญาดุษฎีบัณฑิต	สาขาวิชา	วิศวกรรมไฟฟ้าและคอมพิวเตอร์
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม	ปีที่พิมพ์	2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการพยากรณ์ความต้องการพลังงานไฟฟ้าระยะสั้น โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) ที่ได้รับการปรับปรุงด้วยเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) ได้แก่ Genetic Algorithm (GA), Particle Swarm Optimization (PSO) และ Bee Algorithm (BA) การศึกษาใช้ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุดรดิตต์ ในช่วงปี พ.ศ. 2563 – 2567 รวม 60 เดือน (5 ปี) โดยแบ่งข้อมูลเป็นชุดฝึกสอน 80% และชุดทดสอบ 20% เพื่อนำมาฝึกแบบจำลอง ANN ที่ได้รับการปรับค่าพารามิเตอร์ให้เหมาะสมด้วยแต่ละเทคนิค

ผลการทดลองพบว่า ANN ที่ใช้ PSO ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่าความผิดพลาดสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เท่ากับ 2.15% ซึ่งต่ำกว่าค่าของ GA และ BA ที่มีค่า MAPE เท่ากับ 3.12% และ 3.45% ตามลำดับ นอกจากนี้ การเปรียบเทียบระหว่างค่าภาระงานจริงและค่าภาระงานที่คาดการณ์พบว่า ANN ที่ได้รับการเพิ่มประสิทธิภาพสามารถลดค่าคลาดเคลื่อนเฉลี่ยได้มากถึง 30% เมื่อเทียบกับ ANN ที่ไม่ได้รับการเพิ่มประสิทธิภาพ แสดงให้เห็นว่าเทคนิคการเพิ่มประสิทธิภาพมีบทบาทสำคัญในการปรับปรุงความแม่นยำของการพยากรณ์ จากผลการวิจัยแสดงให้เห็นว่า ANN ที่ผ่านการเพิ่มประสิทธิภาพสามารถนำไปประยุกต์ใช้กับระบบบริหารจัดการพลังงานอาคารอัจฉริยะ (Smart Building) เพื่อช่วยลดค่าใช้จ่ายด้านพลังงานและปรับปรุงประสิทธิภาพการใช้ไฟฟ้าในระยะยาว ข้อเสนอแนะสำหรับการวิจัยในอนาคตคือการขยายขอบเขตไปยังอาคารประเภทอื่น รวมถึงการผสมผสานข้อมูลด้านสภาพอากาศและพฤติกรรมการใช้พลังงานของผู้ใช้งาน เพื่อเพิ่มความแม่นยำของแบบจำลองและนำไปสู่การพัฒนาแบบบริหารจัดการพลังงานที่สามารถคาดการณ์และปรับตัวได้อย่างมีประสิทธิภาพมากยิ่งขึ้น

คำสำคัญ : การพยากรณ์ความต้องการพลังงานไฟฟ้า, โครงข่ายประสาทเทียม, การเพิ่มประสิทธิภาพ, Genetic Algorithm, Particle Swarm Optimization, Bee Algorithm, อาคารอัจฉริยะ, การบริหารจัดการพลังงาน

TITLE	Artificial neural networks based on Optimization Technique for short-term electricity demand forecasting: Uttaradit Rajabhat University Data Analysis		
AUTHOR	Rattapon Dulyala		
ADVISORS	Professor Worawat Sa-Ngiamvibool , Ph.D.		
DEGREE	Doctor of Philosophy	MAJOR	Electrical and Computer Engineering
UNIVERSITY	Maharakham University	YEAR	2025

ABSTRACT

This research aims to develop a short-term electricity demand forecasting model using Artificial Neural Networks (ANN) enhanced with optimization techniques, including Genetic Algorithm (GA), Particle Swarm Optimization (PSO), and Bee Algorithm (BA). The study utilizes electricity consumption data from the Phumirajabhat Building, Uttaradit Rajabhat University, collected over 60 months (5 years) from 2020 to 2024. The dataset is divided into 80% for training and 20% for testing, ensuring an optimized ANN model through parameter tuning for each optimization technique.

The experimental results indicate that ANN optimized with PSO delivers the best performance, achieving the lowest Mean Absolute Percentage Error (MAPE) of 2.15%, compared to 3.12% for GA and 3.45% for BA. Furthermore, a comparative analysis between actual and forecasted load demand demonstrates that the optimized ANN model reduces the average forecasting error by up to 30% compared to the non-optimized ANN. These findings highlight the significant role of optimization techniques in improving forecasting accuracy. The research findings suggest that the optimized ANN model can be effectively applied to smart building energy management systems to reduce peak load costs and enhance long-term energy efficiency. Future research should explore extending the model to different building types and integrating environmental and user behavior data to enhance model accuracy further, ultimately contributing to the development of adaptive and intelligent energy management systems.

Keyword : Short-term electricity demand forecasting, Artificial Neural Networks (ANN), Optimization Techniques, Genetic Algorithm (GA), Particle Swarm Optimization (PSO), Bee Algorithm (BA), Smart Building, Energy Management

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จสมบูรณ์ได้ด้วยความกรุณาและความช่วยเหลืออย่างสูงยิ่งจากบุคคลต่างๆ หลายท่านดังนี้ ศ.ดร.วรวัฒน์ เสียงมวิบูล ประธานกรรมการควบคุมวิทยานิพนธ์ ท่านคอยให้คำชี้แนะ ดูแล เอาใจใส่และแนะนำแนวทางทั้งการเรียน การทำวิทยานิพนธ์จนสำเร็จลุล่วงไปด้วยดี รวมถึง รศ.ดร.อดิเรก จันทะคุณ ประธานกรรมการสอบและผู้ทรงคุณวุฒิ ผศ.ดร.ชัยยงค์ เสริมผล, ผศ.ดร.ณัฐวุฒิ สุวรรณทา และ รศ.ดร.สุพรรณิกา วัฒนะ คณะกรรมการสอบ ที่ให้คำแนะนำที่ดีเพื่อให้วิทยานิพนธ์นี้สมบูรณ์

ขอขอบพระคุณ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยมหาสารคาม ที่เอื้อเพื่อสถานที่ทำงาน เครื่องมือและอุปกรณ์ ทั้งในการเรียนและการทำงานวิจัย

ขอขอบพระคุณ มหาวิทยาลัยราชภัฏอุดรดิตถ์ที่สนับสนุนทุนการศึกษา และเอื้อเพื่อสถานที่วิจัย รวมทั้งเครื่องมือและอุปกรณ์ทดลอง

ขอขอบคุณเพื่อนๆ พี่ น้องทุกคน Ph.D. วิศวกรรมไฟฟ้าและคอมพิวเตอร์ทุกท่าน ที่ช่วยเหลือให้กำลังใจและคำแนะนำ

สุดท้ายข้าพเจ้าขอกราบขอบพระคุณพ่อสัมฤทธิ์ แม่ตรุณี ดุลยะลา ที่ทนลำบาก เหน็ดเหนื่อยในการเลี้ยงดู เสียสละหลายสิ่งหลายอย่างในชีวิตที่ผ่านมาให้ลูกได้มีวิชา ความรู้จนได้รับความเจริญก้าวหน้าในชีวิตในทุกด้าน รวมทั้งคุณวิจิตราและคุณจรรยา พี่สาวและน้องสาวที่ให้กำลังใจ และช่วยเหลือตลอดมา และคุณพรรณลักษณ์ ดุลยะลา ภรรยาที่รู้ใจ คอยดูแลเอาใจใส่ และให้กำลังใจ

รัฐพล ดุลยะลา


พนุน ปณ ทิโต ชีเว

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ญ
สารบัญภาพประกอบ.....	ฎ
บทที่ 1.....	1
บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 ความมุ่งหมายของการวิจัย.....	2
1.3 ขอบเขตของการวิจัย.....	2
1.3.1 ประชากรและกลุ่มตัวอย่าง.....	2
1.3.2 เครื่องมือที่ใช้ในการวิจัย.....	2
1.4 นิยามศัพท์เฉพาะ.....	2
บทที่ 2.....	3
เอกสารและงานวิจัยที่เกี่ยวข้อง.....	3
2.1 ระบบบริหารจัดการพลังงาน.....	3
2.1.1 ระบบจัดการพลังงานภายในโรงงาน.....	3
2.1.2 ระบบจัดการพลังงานภายในตึกอาคาร.....	3
2.1.3 ระบบจัดการพลังงานภายในบ้าน.....	3
2.2 อัตราค่าไฟฟ้าแบบช่วงเวลาการใช้.....	4

2.3 การพยากรณ์	5
2.3.1 การเลือกเทคนิคการพยากรณ์.....	5
2.3.2 กระบวนการพยากรณ์.....	6
2.3.3 รูปแบบของข้อมูล.....	9
2.3.4 วิธีการพยากรณ์.....	10
2.4 โครงข่ายประสาทเทียม.....	12
2.4.1 หลักการทำงานเครือข่ายประสาทเทียม	13
2.4.2 รูปแบบการเรียนรู้ของโครงข่ายประสาทเทียม	17
2.5 ทฤษฎีโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง	18
2.5.1 ขั้นตอนการทำงานของทฤษฎีโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง.....	19
2.7 เทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques)	21
2.7.1 Genetic Algorithm (GA).....	21
2.7.2 Particle Swarm Optimization (PSO)	22
2.7.3 Bee Algorithm (BA)	23
2.6 งานวิจัยที่เกี่ยวข้อง	23
บทที่ 3	29
วิธีดำเนินการวิจัย	29
3.1 การเก็บรวบรวมข้อมูลและเตรียมข้อมูล	29
3.4 การออกแบบโครงข่ายประสาทเทียม (Artificial Neural Network - ANN).....	32
3.4.1สถาปัตยกรรมของโครงข่ายประสาทเทียม	32
3.5 การเพิ่มประสิทธิภาพด้วยเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques).....	32
3.5.1 ฟังก์ชันวัตถุประสงค์ที่ใช้ในกระบวนการเพิ่มประสิทธิภาพ.....	33
บทที่ 4	34
ผลการวิจัย	34

4.1 เปรียบเทียบความแม่นยำของโมเดล.....	34
4.2 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์.....	35
บทที่ 5	40
อภิปรายผลและข้อเสนอแนะ	40
5.1 อภิปรายผลงานวิจัย.....	40
5.2 ข้อเสนอแนะ.....	40
5.2.1 การนำผลวิจัยไปใช้.....	40
5.2.2 การพัฒนาโมเดลเพิ่มเติม	41
5.2.3 การเพิ่มความหลากหลายของข้อมูล.....	41
5.2.4 การพัฒนาเครื่องมือเสริม	41
5.2.5 ข้อควรระวัง.....	41
บรรณานุกรม.....	42
บรรณานุกรม.....	43
ภาคผนวก.....	45
Code MATLAB M.file ของ ANN.....	45
Code MATLAB M.file ของ ANN + GA.....	50
Code MATLAB M.file ของ ANN + PSO.....	55
Code MATLAB M.file ของ ANN + BA.....	60
ประวัติผู้เขียน.....	67



สารบัญตาราง

	หน้า
ตาราง 1 โครงสร้างอัตราค่าไฟฟ้าแบบ TOU.....	5
ตาราง 2 รูปแบบของดัชนีฤดูกาล.....	9
ตาราง 3 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ GA.....	22
ตาราง 4 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ PSO.....	22
ตาราง 5 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ BA.....	23
ตาราง 6 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2563	29
ตาราง 7 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2564	30
ตาราง 8 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2565	30
ตาราง 9 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2566	31
ตาราง 10 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2567	31
ตาราง 11 ค่าความผิดพลาดเปอร์เซ็นต์สัมบูรณ์เฉลี่ย (MAPE).....	34

พูน ปณ ทิโต ชีเว

สารบัญภาพประกอบ

	หน้า
ภาพประกอบ 1 ระบบบริหารจัดการพลังงานภายในบ้าน.....	4
ภาพประกอบ 2 ขั้นตอนการพยากรณ์.....	8
ภาพประกอบ 3 เซลล์ประสาทของสิ่งมีชีวิตและโครงข่ายประสาทเทียม.....	13
ภาพประกอบ 4 ตัวแบบของเซลล์ประสาทในคอมพิวเตอร์.....	14
ภาพประกอบ 5 สถาปัตยกรรมแบบป้อนไปข้างหน้า.....	15
ภาพประกอบ 6 สถาปัตยกรรมแบบป้อนกลับ.....	15
ภาพประกอบ 7 โครงสร้างแบบป้อนไปข้างหน้าหลายชั้น.....	16
ภาพประกอบ 8 การเรียนรู้แบบมีผู้สอน.....	17
ภาพประกอบ 9 การเรียนรู้แบบไม่มีการสอน.....	18
ภาพประกอบ 10 การเรียนรู้ของโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง.....	19
ภาพประกอบ 11 การหาผู้ชนะสำหรับการกระจายของข้อมูล Xi หรือโหนดเพื่อนบ้าน.....	20
ภาพประกอบ 12 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN.....	35
ภาพประกอบ 13 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + GA.....	36
ภาพประกอบ 14 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + PSO.....	36
ภาพประกอบ 15 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + BA.....	37
ภาพประกอบ 16 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN.....	37
ภาพประกอบ 17 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + GA.....	38
ภาพประกอบ 18 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + PSO.....	38
ภาพประกอบ 19 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + BA.....	39

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

ในยุคปัจจุบัน การจัดการพลังงานไฟฟ้าเป็นหัวใจสำคัญของการพัฒนาเศรษฐกิจและสังคม เนื่องจากพลังงานไฟฟ้าเป็นทรัพยากรที่จำเป็นต่อการขับเคลื่อนอุตสาหกรรม เทคโนโลยี และคุณภาพชีวิต การขยายตัวของเมืองและการเจริญเติบโตของภาคอุตสาหกรรมที่ต้องการการผลิตตลอด 24 ชั่วโมง ส่งผลให้ความต้องการใช้พลังงานไฟฟ้าสูงขึ้นอย่างต่อเนื่อง นอกจากนี้ ความต้องการพลังงานในแต่ละวันยังมีความผันผวนตามกิจกรรมของผู้ใช้ไฟฟ้า เช่น ช่วงเวลาที่มีการใช้งานสูงสุด (On-Peak) และช่วงเวลาที่มีการใช้งานต่ำสุด (Off-Peak) ความซับซ้อนของการบริหารจัดการระบบไฟฟ้าเพิ่มมากขึ้น ซึ่งหากไม่มีการคาดการณ์ล่วงหน้าที่เหมาะสม อาจนำไปสู่ปัญหาความไม่เสถียรของระบบไฟฟ้า และส่งผลกระทบต่อความมั่นคงของโครงข่ายไฟฟ้าในระยะยาว

การพยากรณ์ความต้องการไฟฟ้าถือเป็นเครื่องมือที่มีบทบาทสำคัญในการบริหารจัดการระบบไฟฟ้า การพยากรณ์ที่แม่นยำช่วยให้ผู้จัดการระบบไฟฟ้าสามารถวางแผนการจ่ายไฟฟ้า การจัดสรรทรัพยากร และการบำรุงรักษาโครงข่ายได้อย่างมีประสิทธิภาพ นอกจากนี้ ยังช่วยในการลดค่าใช้จ่ายด้านพลังงานและป้องกันปัญหาการขาดแคลนไฟฟ้าในช่วงเวลาสำคัญ อีกทั้งยังสามารถใช้เป็นข้อมูลพื้นฐานสำหรับการขยายระบบไฟฟ้าในอนาคต เช่น การเพิ่มกำลังการผลิต การปรับปรุงสายส่ง และการติดตั้งอุปกรณ์ป้องกันที่เหมาะสม

โครงข่ายประสาทเทียม (Artificial Neural Networks หรือ ANN) ได้รับการยอมรับว่าเป็นเครื่องมือที่มีประสิทธิภาพสูงในการพยากรณ์ความต้องการไฟฟ้า ANN มีความสามารถในการเรียนรู้รูปแบบของข้อมูลและจัดการข้อมูลที่มีความซับซ้อนได้เป็นอย่างดี โดยที่ผ่านมามีการวิจัยมากมายที่ใช้ ANN ในการพยากรณ์ความต้องการไฟฟ้าทั้งในระยะสั้นและระยะยาว ตัวอย่างเช่น การศึกษาโดย รุกกฤต ปานขลิบ (2556) ซึ่งใช้ ANN ร่วมกับการวิเคราะห์แบบถดถอยเชิงเส้นพหุคูณในการพยากรณ์ความต้องการไฟฟ้าในประเทศไทย พบว่า ANN ให้ผลการพยากรณ์ที่แม่นยำมากกว่าเมื่อเทียบกับวิธีการแบบดั้งเดิม นอกจากนี้ยังมีงานวิจัยโดย คงฤทธิ์ โกมาสถิตย์ และปารเมศ ชุติมา (2555) ที่ใช้ ANN แบบ Backpropagation ในการพยากรณ์ความต้องการไฟฟ้า พบว่าผลการพยากรณ์มีความแม่นยำสูงและเหมาะสมสำหรับการใช้งานในระบบไฟฟ้าของประเทศไทย

จากพื้นฐานดังกล่าว งานวิจัยนี้จึงมุ่งเน้นไปที่การใช้โครงข่ายประสาทเทียมร่วมกับเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) เพื่อปรับปรุงความแม่นยำของการพยากรณ์ความ

ต้องการพลังงานไฟฟ้าระยะสั้น โดยใช้ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุดรดิตถ์ การวิจัยนี้จะช่วยพัฒนาระบบบริหารจัดการพลังงานแบบอัจฉริยะที่สามารถลดค่าไฟฟ้าสูงสุด พร้อมทั้งเพิ่มความเสถียรและความมั่นคงของระบบไฟฟ้าในระยะยาว

1.2 ความมุ่งหมายของการวิจัย

1.2.1 เพื่อศึกษาและออกแบบแนวคิดการบริหารจัดการพลังงานแบบอัจฉริยะโดยใช้ ANN เพื่อพยากรณ์ความต้องการใช้พลังงานไฟฟ้าล่วงหน้า และลดค่าไฟฟ้าสูงสุด

1.2.2 เพื่อวิเคราะห์ข้อมูลการใช้พลังงานไฟฟ้าเพื่อพัฒนาความแม่นยำในการพยากรณ์ความต้องการไฟฟ้าระยะสั้น

1.3 ขอบเขตของการวิจัย

1.3.1 ประชากรและกลุ่มตัวอย่าง

- ข้อมูลการใช้พลังงานไฟฟ้าจากอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุดรดิตถ์

1.3.2 เครื่องมือที่ใช้ในการวิจัย

- AMR Meter สำหรับการวัดและบันทึกข้อมูลการใช้พลังงาน

- โปรแกรม MATLAB สำหรับการพัฒนาและวิเคราะห์ ANN

1.4 นิยามศัพท์เฉพาะ

1.4.1 โครงข่ายประสาทเทียม (Artificial Neural Network - ANN) แบบจำลองเชิงคำนวณที่เลียนแบบโครงสร้างของสมองมนุษย์ มีความสามารถในการเรียนรู้และคาดการณ์ข้อมูลที่ซับซ้อน

1.4.2 เทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) อัลกอริทึมที่ช่วยปรับปรุงประสิทธิภาพของ ANN เช่น Particle Swarm Optimization (PSO) หรือ Genetic Algorithm (GA)

1.4.3 การพยากรณ์ความต้องการไฟฟ้าระยะสั้น กระบวนการทำนายการใช้ไฟฟ้าภายในระยะเวลาสั้น เช่น รายวันหรือรายชั่วโมง เพื่อช่วยในการวางแผนและจัดการระบบไฟฟ้า

1.4.4 AMR Meter เครื่องมือวัดและบันทึกการใช้พลังงานไฟฟ้าแบบอัตโนมัติ

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 ระบบบริหารจัดการพลังงาน

ระบบบริหารจัดการพลังงาน (Energy Management System: EMS) คือเทคโนโลยีการสื่อสารด้วยระบบสารสนเทศที่ใช้ในการเชื่อมต่อกับอุปกรณ์ไฟฟ้า ทำให้ระบบไฟฟ้าสามารถทำงานจัดการพลังงานไฟฟ้าได้อย่างมีประสิทธิภาพ ประหยัดพลังงาน และการจัดการด้านการผลิตไฟฟ้าจากพลังงานลม พลังงานแสงอาทิตย์ เป็นต้น โดยระบบจัดการพลังงานสามารถแบ่งออกได้เป็น 3 ประเภท ดังนี้

2.1.1 ระบบจัดการพลังงานภายในโรงงาน

ระบบจัดการพลังงานภายในโรงงาน (Factory Energy Management System : FEMS) คือเทคโนโลยีการสื่อสารและสารสนเทศที่ใช้เชื่อมต่อกับเครื่องจักรและอุปกรณ์ไฟฟ้าภายในโรงงาน เพื่อเก็บรวบรวมข้อมูลการใช้พลังงานไฟฟ้าของเครื่องจักรเหล่านี้ และวิเคราะห์ข้อมูลโดยใช้ระบบประมวลผล เพื่อดำเนินการเปิดปิดเครื่องจักรในเวลาที่เหมาะสม หรือปรับปรุงคุณภาพของการใช้ไฟฟ้าให้ดีกว่าเดิม เพื่อให้ผู้ประกอบการจ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม


2.1.2 ระบบจัดการพลังงานภายในตึกอาคาร

ระบบจัดการพลังงานภายในตึกอาคาร (Building Energy Management System : BEMS) คือเทคโนโลยีการสื่อสารและสารสนเทศที่ใช้ในการเชื่อมต่อกับโหลดภายในอาคารอันได้แก่ โหลดแสงสว่าง และโหลดปรับอากาศ รวมถึงเครื่องกำเนิดไฟฟ้าแบบกระจายของตัวอาคาร เช่น ระบบผลิตไฟฟ้าจากพลังงานแสงอาทิตย์ ระบบผลิตไฟฟ้าจากพลังงานความร้อนที่เกิดจากโหลดปรับอากาศ ระบบผลิตไฟฟ้าจากพลังงานลม ระบบผลิตไฟฟ้าจากเครื่องยนต์ดีเซล เป็นต้น เพื่อเก็บรวบรวมข้อมูลการใช้พลังงานไฟฟ้าของโหลดรวมถึงข้อมูลการผลิตพลังงานไฟฟ้าจากเครื่องกำเนิดไฟฟ้าเหล่านี้ และวิเคราะห์ข้อมูลโดยใช้ระบบประมวลผลเพื่อดำเนินการจัดสรรการจ่ายพลังงานไฟฟ้าจากเครื่องกำเนิดไฟฟ้าให้แก่โหลดในเวลาที่เหมาะสมที่สุด เพื่อให้เจ้าของอาคารจ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม

2.1.3 ระบบจัดการพลังงานภายในบ้าน

ระบบจัดการพลังงานภายในบ้าน (Home Energy Management System: HEMS) คือการประยุกต์เทคโนโลยีการสื่อสาร และสารสนเทศเพื่อจัดการความต้องการพลังงานไฟฟ้าของอุปกรณ์ไฟฟ้าภายในบ้าน เช่น การตัดต่อโหลดตามลำดับความสำคัญ การควบคุมพลังงานไฟฟ้าที่ได้จาก

แหล่งจ่ายไฟฟ้าที่ไม่แน่นอนเป็นต้น และเก็บข้อมูลการใช้ไฟฟ้าจากเครื่องใช้ไฟฟ้า โดยใช้ Smart Meter รวมถึงแจ้งเตือนให้ผู้ใช้ไฟฟ้าทราบถึงสถานะ การใช้พลังงานไฟฟ้า เพื่อให้เจ้าของบ้านจ่ายค่าไฟฟ้าในราคาที่ถูกลงกว่าเดิม และผู้อยู่อาศัยภายในบ้านมีความสะดวกสบายมากกว่าเดิม ดังภาพประกอบ 1



ภาพประกอบ 1 ระบบบริหารจัดการพลังงานภายในบ้าน

ที่มา : (<https://www.denso.com/global/en/news/newsroom/2012/120724-01/>)

2.2 อัตราค่าไฟฟ้าแบบช่วงเวลาการใช้

อัตราค่าไฟฟ้าแบบช่วงเวลาการใช้ (Time of Use Rate - TOU) เป็นโครงสร้างการคิดอัตราค่าไฟฟ้าที่กำหนดราคาที่แตกต่างกันในแต่ละช่วงเวลา โดยมีวัตถุประสงค์เพื่อสะท้อนต้นทุนการผลิตไฟฟ้าที่แท้จริงและกระตุ้นให้ผู้ใช้ปรับพฤติกรรมการใช้ไฟฟ้าไปยังช่วงเวลาที่ต้นทุนต่ำ (Off-Peak) เพื่อลดการใช้ไฟฟ้าในช่วงที่มีการใช้ไฟฟ้าสูงสุด (On-Peak) โครงสร้าง TOU แบ่งออกเป็นสองช่วงหลัก ได้แก่ ช่วงเวลาใช้ไฟฟ้าสูงสุด (On-Peak) ซึ่งเป็นช่วงเวลาที่ความต้องการใช้ไฟฟ้าอยู่ในระดับสูง เช่น เวลากลางวันหรือเย็น ค่าไฟฟ้าในช่วงนี้มักจะมีราคาสูงกว่าปกติเนื่องจากต้นทุนการผลิตที่เพิ่มขึ้นจากการเปิดใช้งานโรงไฟฟ้าสำรอง และช่วงเวลาใช้ไฟฟ้าต่ำสุด (Off-Peak) ซึ่งเป็นช่วงที่ความต้องการใช้ไฟฟ้าน้อยลง เช่น เวลากลางคืน ค่าไฟฟ้าในช่วงนี้มีราคาถูกกว่าเนื่องจากโรงไฟฟ้าหลักสามารถรองรับการใช้งานได้อย่างมีประสิทธิภาพ

การนำอัตราค่าไฟฟ้าแบบ TOU มาใช้มีประโยชน์หลายประการ เช่น การลดความต้องการพลังงานไฟฟ้าสูงสุด (Peak Load) โดยช่วยกระตุ้นให้ผู้ใช้ไฟฟ้าเลื่อนการใช้งานไปในช่วง Off-Peak เพื่อลดภาระในระบบไฟฟ้าและลดความเสี่ยงของไฟฟ้านดับ นอกจากนี้ยังช่วยเพิ่มประสิทธิภาพการใช้พลังงานและลดต้นทุนค่าไฟฟ้าของผู้ใช้งาน รวมถึงช่วยลดการปล่อยมลพิษโดยลดความจำเป็นในการ

เปิดใช้งานโรงไฟฟ้าสำรองที่ใช้เชื้อเพลิงฟอสซิลและมีมลพิษสูง ในบริบทของงานวิจัยเกี่ยวกับการพยากรณ์ความต้องการไฟฟ้าระยะสั้น ข้อมูลการใช้ไฟฟ้าในช่วง On-Peak และ Off-Peak เป็นปัจจัยสำคัญในการวิเคราะห์และพยากรณ์ความต้องการไฟฟ้า เนื่องจากสามารถสะท้อนพฤติกรรมการใช้ไฟฟ้าในแต่ละช่วงเวลาและช่วยในการวางแผนการจัดการพลังงานไฟฟ้าได้อย่างมีประสิทธิภาพมากขึ้น สามารถพิจารณาตามโครงสร้างอัตราค่าไฟฟ้าแบบ TOU ดังตาราง 1

ตาราง 1 โครงสร้างอัตราค่าไฟฟ้าแบบ TOU

ช่วงเวลาใช้ไฟฟ้าสูงสุด (On-Peak Period)	ช่วงเวลาใช้ไฟฟ้าต่ำสุด (Off-Peak Period)
ช่วงเวลานี้เป็นช่วงที่ความต้องการใช้ไฟฟ้าอยู่ในระดับสูง เช่น เวลากลางวันหรือเย็นในวันที่มีกิจกรรมทางเศรษฐกิจและอุตสาหกรรมมาก ค่าไฟฟ้าจะมีราคาสูงกว่าปกติ เนื่องจากต้นทุนการผลิตเพิ่มขึ้นจากการเปิดใช้งานโรงไฟฟ้าสำรองหรือต้องการกำลังไฟฟ้าจากโรงไฟฟ้าที่ต้นทุนสูง	ช่วงเวลานี้เป็นช่วงที่ความต้องการใช้ไฟฟ้าอยู่ในระดับต่ำ เช่น เวลากลางคืนหรือวันหยุดสุดสัปดาห์ ค่าไฟฟ้าจะมีราคาต่ำกว่า เนื่องจากต้นทุนการผลิตลดลง โรงไฟฟ้าหลักสามารถรองรับความต้องการได้อย่างมีประสิทธิภาพ
ตัวอย่างช่วงเวลา On-Peak คือ 9.00 น. – 22.00 น.	ตัวอย่างช่วงเวลา Off-Peak คือ 22.00 น. – 9.00 น.

2.3 การพยากรณ์

การพยากรณ์ (Forecasting) หมายถึง การคาดคะเนการทำนายการเกิดเหตุการณ์หรือสภาพการณ์ต่าง ๆ ในอนาคต โดยการพยากรณ์จะทำการศึกษาแนวโน้มและรูปแบบการเกิดเหตุการณ์จากข้อมูลในอดีตและ/หรือใช้ความสามารถ ความรู้ ประสบการณ์ และดุลยพินิจของผู้พยากรณ์ (นิภา นิรุตติกุล, 2551)

2.3.1 การเลือกเทคนิคการพยากรณ์

การเลือกเทคนิคการพยากรณ์แต่ละวิธีมีปัจจัยสำคัญหรือเกณฑ์ที่จะต้องพิจารณาก่อนที่จะตัดสินใจว่าจะเลือกเทคนิคการพยากรณ์แบบใดนั้น ประกอบด้วยปัจจัยต่าง ๆ ดังนี้ (กิตติพงษ์ อินทร์ทอง, 2556)

2.3.1.1 เหตุผลในการพยากรณ์ ผู้ใช้การพยากรณ์และช่วงเวลาของการพยากรณ์ล่วงหน้าแต่ละวิธีจะเหมาะกับการพยากรณ์ในช่วงเวลาล่วงหน้าต่างกัน ซึ่งอาจจะเป็นระยะสั้น ระยะกลาง หรือระยะยาว

2.3.1.2 ระยะเวลาที่ใช้ในการทำการพยากรณ์แต่ละครั้งและความถี่ในการพยากรณ์ โดยแต่ละวิธีจะใช้เวลาทั้งการหารูปแบบและการวิเคราะห์ที่ต่างกัน ในหน่วยงานที่ต้องพยากรณ์เหตุการณ์หลายเหตุการณ์ เช่น ยอดขายสินค้าหลาย ๆ ประเภท การใช้วิธีการพยากรณ์ที่ยุ่งยากจะใช้เวลามากกว่าจนทำให้ผลการพยากรณ์ที่ได้ไม่ทันต่อการนำไปใช้

2.3.1.3 ลักษณะของข้อมูลที่มีและจำนวนข้อมูลที่มีผู้พยากรณ์จำเป็นต้องทราบว่าจะหาข้อมูลที่สนใจได้จากแหล่งใด ข้อมูลที่หาได้มีความน่าเชื่อถือมากน้อยเพียงใด มีลักษณะการเคลื่อนไหวอย่างไร มีหน่วยวัดอย่างไร และข้อมูลควรมีจำนวนมากน้อยเพียงใด การทำความเข้าใจข้อมูล และสามารถจำแนกได้ว่าข้อมูลในอดีตองค์ประกอบใด จะทำให้สามารถเลือกวิธีการพยากรณ์ที่เหมาะสมและมีประสิทธิผลได้

2.3.1.4 ความยากง่ายของการพยากรณ์ในกรณีที่ผู้พยากรณ์ไม่ได้เป็นผู้บริหารขององค์กรหรือธุรกิจ และผู้ใช้ค่าพยากรณ์ ผู้พยากรณ์จะต้องอธิบายให้ผู้บริหารหรือผู้ใช้ค่าพยากรณ์ให้เข้าใจหลักการของวิธีการพยากรณ์ที่ใช้หากวิธีการพยากรณ์มีความยุ่งยากซับซ้อนหรือเน้นวิชาการมากเกินไปผู้บริหารหรือผู้ใช้ค่าพยากรณ์อาจจะไม่ใช้ เพราะไม่แน่ใจกับค่าพยากรณ์ที่ได้ ดังนั้นวิธีการพยากรณ์ที่เลือกใช้ควรเป็นวิธีที่ไม่ยากมากนักต่อความเข้าใจและให้ค่าพยากรณ์ที่มีความถูกต้องสูง

2.3.1.5 ค่าใช้จ่ายในการพยากรณ์ การพยากรณ์จะมีค่าใช้จ่ายที่ครอบคลุมตั้งแต่การหาตัวแปรที่เหมาะสมที่จะนำมาศึกษาหาข้อมูล เก็บข้อมูล และการดำเนินการพยากรณ์ตั้งแต่การสร้างรูปแบบ จนถึงหาค่าพยากรณ์จากตัวแบบหรือสมการพยากรณ์

2.3.1.6 ความถูกต้องของการพยากรณ์แต่ละวิธีจะให้ความถูกต้องของค่าพยากรณ์ที่แตกต่างกัน อย่างไรก็ตามยังไม่มีวิธีที่ชี้ชัดว่าวิธีการพยากรณ์วิธีใดจะให้ค่าพยากรณ์ที่ดีที่สุด

2.3.1.7 ข้อจำกัดของแต่ละวิธีการพยากรณ์ วิธีการพยากรณ์บางวิธี เช่น การวิเคราะห์ถดถอย จะให้ค่าพยากรณ์ทั้งที่เป็นแบบจุดและแบบช่วงพยากรณ์ (Point and interval forecast) ส่วนวิธีแยกส่วนประกอบอนุกรมเวลาให้แต่ค่าพยากรณ์ที่เป็นแบบจุด

2.3.2 กระบวนการพยากรณ์

กระบวนการพยากรณ์ (Forecasting Process) หมายถึง ขั้นตอนการเลือกเทคนิคการพยากรณ์ตั้งแต่หนึ่งวิธีขึ้นไปที่สามารถประยุกต์ใช้กับข้อมูลที่เป็นต่อการพยากรณ์ แสดงดังภาพที่ 2.1 ซึ่งประกอบด้วย 9 ขั้นตอน ต่อไปนี้ (กิตติพงศ์ อินทร์ทอง, 2556)

2.3.2.1 การกำหนดวัตถุประสงค์ของการพยากรณ์ (Specific Objectives) เป็นการกำหนดวัตถุประสงค์ให้ชัดเจนว่าการพยากรณ์จะนำไปใช้ในการตัดสินใจอย่างไร เช่น ใช้เพื่อตัดสินใจลงทุน (การพยากรณ์ระยะยาว) หรือเพื่อวางแผนกลยุทธ์ (การพยากรณ์ระยะกลาง)

2.3.2.2 การกำหนดสิ่งที่จะพยากรณ์ให้ชัดเจน (Determine what to forecast) เช่น พยากรณ์ ยอดขายเป็นหน่วยสินค้า หรือเป็นตัวเงิน (บาทหรือดอลลาร์) การพยากรณ์เป็นยอดขารวม

ยอดขายสายผลิตภัณฑ์ ยอดขายของแต่ละภูมิภาคยอดขายในประเทศหรือยอดขายต่างประเทศ เป็นต้น

2.3.2.3 การเก็บรวบรวมข้อมูล (Data Collection) เป็นการเก็บรวบรวมข้อมูลที่เกี่ยวข้องกับการพยากรณ์อย่างเหมาะสม และเป็นข้อมูลที่ต้องการ ขั้นตอนนี้เป็นขั้นตอนที่ยากและใช้เวลามากที่สุดในการเก็บรวบรวมข้อมูลจะต้องพิจารณาถึงข้อกำหนดด้านเวลา (Identify time dimensions) โดยพิจารณา 2 ประการคือ ช่วงระยะเวลาการพยากรณ์ (Length and periodicity) เช่น ประจำปี ประจำปีไตรมาส ประจำเดือน ประจำวัน และความเร่งด่วนในการพยากรณ์ (Urgency) ถ้ามีความจำเป็นเร่งด่วน วิธีที่ใช้ในการพยากรณ์จะมีความซับซ้อนน้อยกว่า และข้อกำหนดเกี่ยวกับข้อมูล (Data considerations) การพิจารณาจากปริมาณและประเภทของข้อมูลที่มีเป็นข้อมูลภายในหรือภายนอกบริษัทเป็นข้อมูล รายปี รายเดือน เป็นข้อมูลที่เป็นตัวเงินหรือหน่วยสินค้า

2.3.2.4 การลดข้อมูล (Data Reduction) บางครั้งข้อมูลที่เก็บรวบรวมมีมากเกินไปและทำให้การพยากรณ์มีความถูกต้องน้อยลง จึงจำเป็นต้องลดข้อมูลบางตัวที่อาจจะไม่เกี่ยวข้องกับการพยากรณ์ลง

2.3.2.5 การเลือกแบบจำลองในการพยากรณ์ (Model Selection) การเลือกวิธีการพยากรณ์ ขึ้นอยู่กับรูปแบบของข้อมูล จำนวนข้อมูลที่มีและระยะเวลาการพยากรณ์ การเลือกวิธีการพยากรณ์ ที่เหมาะสมกับข้อมูลจะช่วยลดความผิดพลาดในการพยากรณ์ รูปแบบการพยากรณ์ที่ยังง่ายจะยิ่งดีต่อการยอมรับของผู้ตัดสินใจ วิธีการพยากรณ์จะต้องมีความสมดุลระหว่างความถูกต้องและเป็นวิธีที่ง่ายต่อความเข้าใจ


2.3.2.6 การพยากรณ์ (Model Extrapolation) เป็นการพยากรณ์เหตุการณ์ที่ผ่านไปโดยใช้ข้อมูลจริงที่มีอยู่ และประเมินว่าวิธีใดเหมาะสม (fit) กับข้อมูลในอดีตก่อน โดยการวัดค่าคลาดเคลื่อนที่เกิดขึ้น

2.3.2.7 การเตรียมการพยากรณ์ (Forecast Preparation) เมื่อมีวิธีการพยากรณ์มากกว่า 2 วิธีขึ้นไปที่เหมาะสม การรวมค่าการพยากรณ์จากวิธีเหล่านั้นจะทำให้ค่าพยากรณ์ดีขึ้นกว่าการใช้วิธีเดียว

2.3.2.8 การนำเสนอผลการพยากรณ์ (Forecast Presentation) การนำเสนอค่าพยากรณ์ให้กับ ผู้บริหารหรือผู้ใช้ด้วยการเขียนเป็นลายลักษณ์อักษรหรือนำเสนอด้วยวาจา (Written/oral) เป็นขั้นตอนนี้มีความสำคัญมากเช่นกัน เพราะสามารถสร้างความเข้าใจให้กับผู้บริหารหรือผู้ใช้ได้

2.3.2.9 การตรวจสอบผลการพยากรณ์ (Tracking Results) การติดตามผลอย่างต่อเนื่องว่าผลการพยากรณ์เมื่อเปรียบเทียบกับค่าจริงแล้วมีความถูกต้องอย่างไร ซึ่งวิธีที่เคยพยากรณ์ได้ดีที่สุดอาจมีความถูกต้องลดลง เนื่องจากสภาพแวดล้อมเปลี่ยนไปอาจจะต้องหาวิธีอื่นมาแทนการพยากรณ์

สามารถเรียนรู้ได้จากความผิดพลาด การทบทวนค่าคลาดเคลื่อนของการพยากรณ์อย่างรอบคอบจะช่วยให้สามารถเข้าใจถึงสาเหตุของความเบี่ยงเบนระหว่างค่าจริงกับค่าพยากรณ์ได้ดีขึ้น



ภาพประกอบ 2 ขั้นตอนการพยากรณ์

ที่มา: กิตติพงศ์ อินทร์ทอง (2556)

2.3.3 รูปแบบของข้อมูล

การเลือกวิธีการพยากรณ์จะต้องคำนึงถึงรูปแบบของข้อมูลในอดีต ซึ่งถ้าสังเกตข้อมูลอนุกรมเวลาแต่ละชุดจะมองเห็นถึงการเปลี่ยนแปลงขึ้น ๆ ลง ๆ ซึ่งสาเหตุของการเปลี่ยนแปลงที่เกิดขึ้นกับข้อมูลนั้น เนื่องจากอิทธิพลขององค์ประกอบต่าง ๆ 4 ประการ (พิภพ ลลิตาภรณ์, 2549) คือ

2.3.3.1 องค์ประกอบของแนวโน้ม (Trend) เป็นองค์ประกอบที่แสดงถึงทิศทางของข้อมูลแต่ละชุด ตั้งแต่อดีตจนถึงระยะเวลาสุดท้ายของข้อมูลที่รวบรวมได้ ซึ่งทิศทางของข้อมูลนั้นอาจจะพุ่งไปในแนวที่สูงขึ้นหรือลดลง ข้อมูลอนุกรมเวลาที่มีองค์ประกอบของค่าแนวโน้มส่วนใหญ่จะเกี่ยวข้องกับความสัมพันธ์ของข้อมูลในระยะเวลาที่ค่อนข้างยาวนาน เช่น อุปสงค์สินค้า การใช้พลังงาน เป็นต้น ลักษณะของแนวโน้มอาจจะเป็นเส้นตรงเส้นโค้งหรืออื่น ๆ ก็ได้

2.3.3.2 องค์ประกอบของการเปลี่ยนแปลงตามฤดูกาล (Seasonal) หมายถึงการที่ข้อมูลอนุกรม เวลา มีรูปแบบการเคลื่อนไหวขึ้นหรือลงทำนองเดียวกันในช่วงเวลาเดียวกันของรอบเวลาหนึ่ง ซึ่งส่วนใหญ่จะไม่เกิน 1 ปี โดยที่หน่วยของระยะเวลาอาจจะเป็นราย 3 เดือน 5 เดือน รายเดือน รายสัปดาห์ รายวัน หรือแม้แต่รายชั่วโมงก็ได้ ข้อมูลที่มักได้รับผลกระทบจากความเคลื่อนไหว หรือเปลี่ยนแปลงตามฤดูกาล ได้แก่ การผลิต การขาย เป็นต้น สำหรับรูปแบบของดัชนีฤดูกาล โดยทั่วไปมี 6 รูปแบบดังนี้

ตาราง 2 รูปแบบของดัชนีฤดูกาล

ช่วงเวลาของรูปแบบ	ช่วงของฤดูกาล	ระยะ(จำนวน)ฤดูกาลในรูปแบบ
สัปดาห์	วัน	7 วัน
เดือน	สัปดาห์	4 – 4 ½
เดือน	วัน	28 – 31 วัน
ปี	ไตรมาส	4
ปี	เดือน	12
ปี	สัปดาห์	52

2.3.3.3 องค์ประกอบของการผันแปรตามวัฏจักร (Cyclical) เป็นลักษณะการเคลื่อนไหวของข้อมูลที่ขึ้น ๆ ลง ๆ คล้ายกับลูกคลื่นที่มีผลกระทบกระเทือนต่อธุรกิจโดยทั่ว ๆ ไปรูปแบบของการผันแปรตามวัฏจักรนี้แตกต่างจากการผันแปรตามฤดูกาล คือเราจะไม่ทราบว่าจะช่วงของการเกิดวัฏจักรหนึ่ง ๆ นั้นจะใช้ระยะเวลายาวนานเท่าใด เนื่องจากการเปลี่ยนแปลงตามวัฏจักรส่วนใหญ่เป็นปรากฏการณ์ที่เกิดขึ้นในด้านธุรกิจและเศรษฐศาสตร์ ดังนั้นการผันแปรตามวัฏจักรโดยทั่ว ๆ ไปจะแสดงถึงภาวะการณ์เกิดซ้ำกันของภาวะธุรกิจเฟื่องฟู ถดถอย และตกต่ำ ภาวะต่าง ๆ เหล่านี้อาจจะสั้นหรือยาวก็ได้

2.3.3.4 องค์ประกอบความผันแปรเชิงสุ่ม ซึ่งเป็นผลอันเนื่องมาจากความผิดปกติ (Irregular) เป็นการเปลี่ยนแปลงของข้อมูลอนุกรมเวลาที่เกิดจากปัจจัยที่ไม่อาจคาดคะเนได้ล่วงหน้า เช่น การเกิดภาวะผิดปกติทางดินฟ้าอากาศ การเกิดน้ำท่วม การนัดหมายหยุดงานของบุคลากร และการเกิดสงคราม เป็นต้น ซึ่งเป็นปรากฏการณ์ที่เราไม่อาจทำนายได้ล่วงหน้า

2.3.4 วิธีการพยากรณ์

วิธีการพยากรณ์สามารถแบ่งออกเป็น 2 ประเภท ได้แก่ การพยากรณ์เชิงคุณภาพ (Qualitative forecasting methods) และการพยากรณ์เชิงปริมาณ (Quantitative forecasting methods) (วัชระ พิชิตมโน, 2550: 11)

2.3.4.1 การพยากรณ์เชิงคุณภาพ (Qualitative forecasting methods) เทคนิคการพยากรณ์เชิงคุณภาพ Render, Stariand Hanna (2003) กล่าวไว้ ว่าเป็นการพยากรณ์ที่ไม่อาศัยข้อมูลในอดีตเป็นหลักแต่จะใช้ความรู้สึกหรือสามัญสำนึกและจากประสบการณ์ ต่าง ๆ ที่ผ่านมา ประกอบกับข้อมูลส่วนใหญ่จะได้จากผู้บริหารหรือผู้ที่มีหน้าที่เกี่ยวข้องเป้าหมายของการพยากรณ์ ประเภทนี้เพื่อพยากรณ์การเปลี่ยนแปลงในรูปแบบขั้นพื้นฐาน (Basic pattern) ทั้งนี้อาจจะมีผลมาจากปัจจัยภายนอกต่าง ๆ ที่มีผลต่อการดำเนินงาน ทำให้เกิดการเปลี่ยนแปลงต่อกระบวนการการตัดสินใจได้ซึ่งตามปกติการพยากรณ์จะต้องใช้ทั้งการพยากรณ์เชิงคุณภาพ และการพยากรณ์เชิงปริมาณประกอบกัน กล่าวคือ ในช่วงแรกจะใช้ข้อมูลในอดีตหาค่าพยากรณ์หลังจากนั้นจึงใช้การวิเคราะห์จากประสบการณ์ในอดีตที่ผ่านมาเพื่อใช้เป็นแนวทางในการตัดสินใจในการดำเนินงานซึ่งเทคนิคที่ใช้ในการพยากรณ์เชิงคุณภาพมี 4 วิธี ดังต่อไปนี้

1) วิธีเดลฟาย (Delphi Method) เป็นวิธีการพยากรณ์เชิงคุณภาพที่ผลการพยากรณ์จะมาจากความคิดเห็นของบุคคลหลาย ๆ ฝ่าย ซึ่งอาจจะเป็นบุคคลากรจากภายในหรือภายนอกบริษัทก็ได้ วิธีการพยากรณ์มีขั้นตอนดังนี้

1.1) ผู้พยากรณ์แต่ละคนจะเขียนค่าพยากรณ์โดยใช้ดุลยพินิจของตนเอง

1.2) ค่าพยากรณ์ของแต่ละคนจะนำไปสรุปและส่งคืนกลับให้ผู้พยากรณ์โดยไม่มีการระบุว่าเป็นการพยากรณ์จากใคร

1.3) ผู้พยากรณ์จะนำค่าพยากรณ์ที่สรุปแล้ว นำมาประเมินผลใหม่ ซึ่งอาจมีการเปลี่ยนแปลงการพยากรณ์ครั้งแรก กระบวนการนี้จะดำเนินต่อไปเรื่อย ๆ จนกระทั่งทำให้ได้ผลสรุปพร้อมกัน แต่ไม่ควรดำเนินการหลายครั้งมากเกินไป จนทำให้ผู้เชี่ยวชาญมีความรู้สึกเบื่อก่อนที่จะกรอกแบบสอบถาม

เทคนิควิธีเดลฟายมีการพัฒนาและปรับปรุงจากเดิม เช่น ไม่ต้องรอคำตอบเป็นเอกฉันท์ของสมาชิกทุกคนซึ่งอาจจะทำการสอบถามสมาชิกเพียง 2-3 รอบเท่านั้น นอกจากนั้นความก้าวหน้าทางเทคโนโลยีทำให้ใช้ Delphi บนระบบ Online ที่เป็น Real Time

Computer ระยะเวลาในการพยากรณ์จะเร็วขึ้น และยังสามารถเลือกผู้เชี่ยวชาญได้มากขึ้น ไม่ว่าจะอยู่ที่ไหนก็สามารถรวมตัวเป็นกลุ่มสมาชิกเพื่อคาดคะเนได้

การใช้วิธีเดลฟายจะเหมาะสมกับการพยากรณ์ยอดขายทั้งการพยากรณ์ระยะกลาง จนถึงระยะยาว หรือการพยากรณ์ยอดขายระยะยาวของอุตสาหกรรม แต่เทคนิคนี้ผู้พยากรณ์จะไม่ต้องมาประชุมร่วมกัน ซึ่งทำให้สมาชิกแต่ละคนสามารถพยากรณ์ได้โดยปราศจากการครอบงำความคิดเห็นของกลุ่มลงได้

2) กลุ่มพนักงานขายทำการพยากรณ์ (Sales force composite) เป็นวิธีบริหารจากระดับล่างสู่ระดับบนขององค์กร (A Bottom-Up Approach) โดยเทคนิคนี้จะอาศัยความรู้และประสบการณ์ของหน่วยงานที่เกี่ยวข้องกับการจำหน่าย (Sales force) ได้แก่ พนักงานขาย พนักงานส่งสินค้า พนักงานรับคำสั่งซื้อ พนักงานเทคนิค พนักงานบริการลูกค้า ผู้จัดการจำหน่าย เป็นต้น เทคนิคนี้มีประโยชน์ในการพยากรณ์ เนื่องจากผู้พยากรณ์เป็นผู้ที่มีความใกล้ชิดกับลูกค้า สามารถเข้าใจความต้องการของลูกค้าและเป็นผู้รับผิดชอบโดยตรงกับยอดขายสินค้า หากการพยากรณ์ผิดพลาดจะส่งกระทบโดยตรงกับผู้พยากรณ์ วิธีนี้เหมาะกับการพยากรณ์ที่มีข้อมูลในอดีตน้อย หรือไม่มีข้อมูล และเหมาะสำหรับการพยากรณ์ระยะสั้นถึงระยะกลาง ซึ่งการให้พนักงานขายเป็นผู้พยากรณ์จะส่งสัญญาณเตือนถึงยอดขายที่จะเพิ่มขึ้นหรือลดลงได้เป็นอันดับต้น

3) กลุ่มผู้บริหารทำการพยากรณ์ (Jury of executive opinion) เป็นวิธีการพยากรณ์โดยการให้บุคลากรระดับผู้บริหารจากฝ่ายต่าง ๆ ในองค์กร เช่น ฝ่ายการเงิน ฝ่ายการตลาดฝ่ายขาย ฝ่ายผลิตและฝ่ายโลจิสติกส์ (Logistics) เข้าร่วมพยากรณ์เพื่อให้มีแนวทางการคิดที่ครอบคลุมทุกด้าน ซึ่งมีลักษณะเป็น Top-Down Approach แนวคิดนี้ ผู้บริหารหลายคนมีความคิดร่วมกัน จะมีการคาดการณ์ได้ดีกว่าผู้บริหารเพียงคนเดียว ทำให้ผู้บริหารเผชิญหน้ากันและมีปฏิสัมพันธ์กันได้ ดังนั้นลักษณะของเทคนิคจะมีดังนี้

3.1) เป็นการอภิปรายร่วมกันระหว่างผู้บริหารเพื่อให้ได้มาซึ่งยอดการพยากรณ์ในอนาคต

3.2) ผู้บริหารประกอบด้วย ผู้บริหารที่หลากหลายจากหลาย ๆ ฝ่ายเพื่อเป็นองค์ประกอบที่เสริมซึ่งกันและกัน

การพยากรณ์โดยคณะผู้บริหารมักจะนิยมใช้การลงมติเอกฉันท์ (Consensus) โดยตัวแทน จากฝ่ายต่าง ๆ ในหลายกรณีมักจะพยากรณ์โดยเทคนิคเชิงปริมาณก่อนแล้วจึงนำผลที่ได้ไปลงมติ การตัดสินใจว่าจะใช้การพยากรณ์แบบใด การลงมตินี้มักจะใช้กับการพยากรณ์ผลิตภัณฑ์ใหม่ซึ่งการพยากรณ์จะทำได้อย่างมีประสิทธิภาพหรือไม่ มักขึ้นอยู่กับความสามารถของผู้พยากรณ์

อย่างไรก็ตามเทคนิคกลุ่มผู้บริหารทำการพยากรณ์เป็นเทคนิคที่ไม่เหมาะสมกับการพยากรณ์ระยะสั้น (รายวันหรือรายสัปดาห์) และการพยากรณ์รายการผลิตภัณฑ์ (Product item) เนื่องจากต้องใช้เวลาในการพิจารณา แต่เทคนิคนี้เหมาะสมสำหรับการพยากรณ์ยอดขายรายเดือนรายไตรมาส หรือรายปี และการพยากรณ์สินค้าทั้งสายผลิตภัณฑ์ (Product line)

4) การสำรวจตลาดลูกค้า (Consumer market survey) เป็นเทคนิคการพยากรณ์เพื่อประมาณการยอดขายโดยศึกษาข้อมูลของผู้บริโภคหรือกลุ่มลูกค้าเป้าหมายโดยตรงซึ่งสามารถทำได้จากการสำรวจความคิดเห็นหรือทัศนคติของผู้ที่มีศักยภาพเป็นกลุ่มลูกค้า และเพื่อทราบพฤติกรรมในการบริโภคสินค้าและบริการ หรือคุณลักษณะของสินค้าและบริการที่กลุ่มลูกค้าเป้าหมายต้องการเป็นต้น

2.3.4.2 การพยากรณ์เชิงปริมาณ (Quantitative forecasting methods) การพยากรณ์เชิงปริมาณเป็นวิธีการพยากรณ์ที่ใช้ข้อมูลในอดีตมาเป็นหลักในการพิจารณาถึงสถานการณ์ที่จะเกิดขึ้นในอนาคต โดยอาศัยหลักสถิติและคณิตศาสตร์ ซึ่งผู้ทำการพยากรณ์จะต้องทำการตรวจสอบรูปแบบของข้อมูลที่จะนำมาใช้ในการคำนวณเสียก่อนว่าข้อมูลมีลักษณะรูปแบบอย่างไร จากนั้นจึงเลือกวิธีการพยากรณ์ให้เหมาะสมกับรูปแบบของข้อมูล ซึ่งจุดประสงค์ของวิธีการพยากรณ์เหล่านี้ก็คือ ต้องการชี้ให้เห็นถึงรูปแบบของข้อมูลในอดีต และทำการตีความรูปแบบของข้อมูลดังกล่าวนี้ถึงทิศทางของข้อมูลที่จะเป็นไปในอนาคต เทคนิคการพยากรณ์เชิงปริมาณสามารถแบ่งออกได้เป็น 2 ประเภทใหญ่ ๆ ดังนี้

- 1) เทคนิคอนุกรมเวลา (Time Series)
- 2) เทคนิคความสัมพันธ์ของข้อมูล (Causal Model)

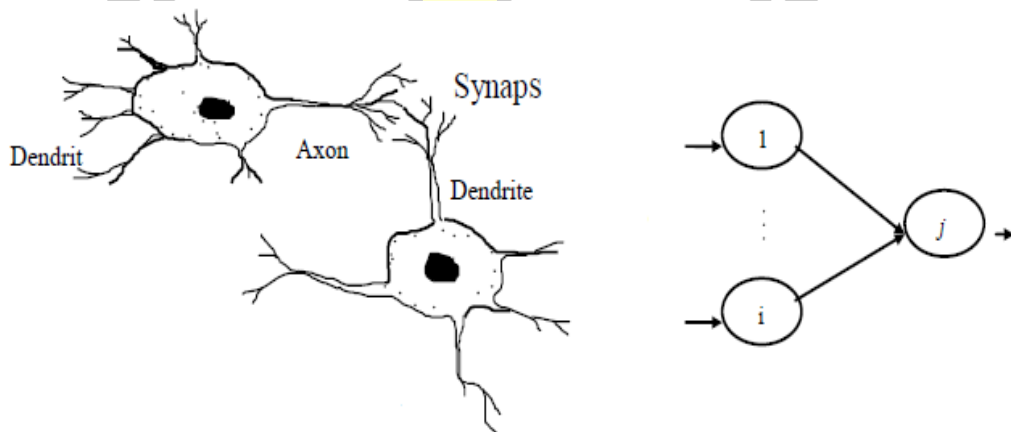
2.4 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (artificial neural network) หรือเรียกว่า ข่ายงานประสาท (neural network หรือ neural net) เป็นโมเดลทางคณิตศาสตร์ สำหรับประมวลผลสารสนเทศด้วยการคำนวณแบบคอนเนคชันนิสต์ (connectionist) เพื่อจำลองการทำงานของเครือข่ายประสาทในสมองมนุษย์ ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำแบบรูป (pattern recognition) และการอุปมานความรูป (knowledge deduction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ ข่ายงานประสาทเทียมถูกพัฒนามาจากวัตถุประสงค์ดังนี้

- 1) การเลียนแบบการทำงานของเซลล์สมองของมนุษย์
- 2) การหาความสัมพันธ์ของเหตุและผลซึ่งยังหาฟังก์ชันออกมาโดยตรงไม่ได้

3) การทำให้คอมพิวเตอร์คิดและตัดสินใจได้ด้วยตัวเอง

แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาข่ายงานไฟฟ้าชีวภาพ (bioelectric network) ในสมอง ประกอบด้วย เซลล์ประสาท หรือ “นิวรอน” (neurons) และ จุดประสานประสาท (synapses) แต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า “เดนไดรต์” (dendrite) เป็นข้อมูลเข้า (input) และปลายในการส่งกระแสประสาทเรียกว่า “แอกซอน” (axon) เป็น ผลลัพธ์ (output) ของเซลล์ เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่านเดนไดรต์เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่นๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่นๆ ต่อไปผ่านทางแอกซอน ดังแสดงในภาพประกอบ 2.8 ก) และ ข) จากรูป เซลล์ร่างกาย (cell body) คือ ตัวของเซลล์ประสาท โดยสัญญาณไฟฟ้าจะเข้ามาทาง เดนไดรต์ซึ่งจะมีลักษณะเป็นแขนงย่อยและมีจำนวนมาก จากนั้น เซลล์ร่างกายจะหาหนทางที่ประมวลผลสัญญาณ และยิงสัญญาณออกไปทางเดนไดรต์ให้ เซลล์ประสาทอื่นต่อไป




ภาพประกอบ 3 เซลล์ประสาทของสิ่งมีชีวิตและโครงข่ายประสาทเทียม

2.4.1 หลักการทำงานเครือข่ายประสาทเทียม

สำหรับในคอมพิวเตอร์เซลล์ประสาท ประกอบด้วย ข้อมูลเข้า และ ข้อมูลออกเหมือนกัน โดยจำลองให้ ข้อมูลเข้า แต่ละอันมีค่าน้ำหนัก (weight) เป็นตัวกำหนด น้ำหนักของ ข้อมูลเข้า โดย เซลล์ประสาท แต่ละหน่วยจะมีค่า threshold เป็นตัวกำหนดว่าน้ำหนักรวมของ ข้อมูลเข้าต้องมากขนาดไหนจึงจะสามารถส่งข้อมูลออกไปยัง เซลล์ประสาทตัวอื่นได้ เมื่อนำ เซลล์ประสาทแต่ละ หน่วย มาต่อกันให้ทำงานร่วมกันการทำงานนี้ในทางตรรกะจะเหมือนกับปฏิกิริยาเคมีที่เกิดในสมอง เพียงแต่ ในคอมพิวเตอร์ทุกอย่างเป็นตัวเลข เพราะฉะนั้นเมื่อนำการทำงานเข้ามาใช้กับคอมพิวเตอร์ สามารถเขียนได้ดังนี้

If (sum (input*weight) > threshold) then output (1)


จากสมการที่ (1) เมื่อ input แทนข้อมูลเข้า เข้ามายังโครงข่าย จะใช้ข้อมูลเข้า คูณกับ น้ำหนักของเซลล์ประสาทแต่ละขา ผลที่ได้จากข้อมูลเข้าทุกขาของเซลล์ประสาท จะรวมกันแล้วก็เอามาเทียบกับ threshold ที่ กำหนดไว้ ถ้าผลรวมมีค่ามากกว่า threshold แล้วเซลล์ประสาทจะส่ง ข้อมูลออก ออกไปข้อมูลออกนี้ก็จะถูกส่งไปยังข้อมูลเข้าของเซลล์ประสาทอื่นๆ ที่เชื่อมกันในโครงข่าย ถ้าค่าน้อยกว่า threshold ก็จะไม่เกิดข้อมูลออก ดังแสดงในภาพประกอบ 4



ภาพประกอบ 4 ตัวแบบของเซลล์ประสาทในคอมพิวเตอร์


สถาปัตยกรรมโครงข่ายประสาทเทียมที่พบทั่วไปจะมีลักษณะหลักๆ คือ มีการจัดเซลล์ประสาทเทียมเป็นชั้น (layer) ชั้นที่รับข้อมูลเข้าเรียกว่า ชั้นข้อมูลเข้า (input layer) ชั้นที่ผลิตผลตอบของโครงข่ายเรียกว่า ชั้นข้อมูลออก (output layer) ส่วนชั้นอื่นๆ ที่มีส่วนในการช่วยทำการประมวลผลอยู่ภายในเรียกว่า ชั้นซ่อน (hidden layer) ในโครงข่ายประสาทเทียมอาจมีชั้นซ่อนได้หลายชั้นโครงสร้างพื้นฐานจะมีลักษณะเป็นการประกอบกันของรูปแบบ ดังต่อไปนี้

2.4.1.1 แบบป้อนไปข้างหน้า (feed forward network) ข้อมูลที่ประมวลผลในวงจรข่ายจะถูกส่งไปในทิศทางเดียวจาก โหนดข้อมูลเข้า ส่งต่อมาจนถึง โหนดข้อมูลออก โดยไม่มีการย้อนกลับของข้อมูล หรือแม้แต่ โหนดในชั้นเดียวกันก็ไม่มี การเชื่อมต่อกัน สามารถจัดได้เป็น 2 แบบคือ แบบมีชั้นของเซลล์ประสาทชั้นเดียว และแบบมีชั้น ชั้นซ่อน สถาปัตยกรรมหลายชั้น โดยปกติการเชื่อมโยงจะถูกกำหนดขึ้นระหว่างชั้นที่ติดกัน ข้อมูลเข้า รเชื่อมเยงระหว่างเซลล์ประสาทเทียมทุกตัว จากชั้นหนึ่งๆ ไปยังเซลล์ประสาทเทียมทุกตัวในชั้นต่อไปในบางสถาปัตยกรรม ข้อมูลออก เชื่อมโยงข้ามชั้นก็ได้ ดังแสดงในภาพประกอบ 5



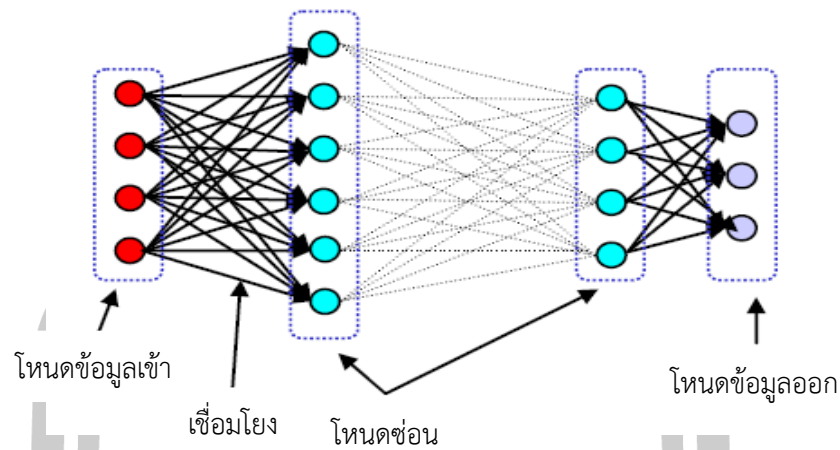
ภาพประกอบ 5 สถาปัตยกรรมแบบป้อนไปข้างหน้า

2.4.1.2 แบบมีการป้อนไปเวียนกลับ (feedback network) หรือเรียกว่า recurrent network ข้อมูลที่ประมวลผลโครงข่ายประสาทเทียมจะมีการป้อนกลับเข้าไปยังวงจรซ้ำหลายๆ ครั้ง จนกระทั่งได้คำตอบออกมา จะมีการเชื่อมโยงที่ถูกกำหนดขึ้นระหว่างเซลล์ประสาทเทียมในชั้นหนึ่งๆ ย้อนกลับไปยังชั้นอื่นๆ ก่อนหน้านั้น หรือแม้แต่ภายในชั้นเดียวกันเอง ดังแสดงในภาพประกอบ 6



ภาพประกอบ 6 สถาปัตยกรรมแบบป้อนกลับ

2.4.1.3 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าหลายชั้น (multiple feed forward) ใช้การเชื่อมโยงแบบป้อนไปข้างหน้าประกอบด้วย 3 ชั้น ได้แก่ ชั้นโหนดข้อมูลเข้า ที่ถูกเชื่อมต่อกับชั้นของ โหนดซ่อน และจะมีการเชื่อมต่อกับชั้นของโหนดข้อมูลเข้า เป็นการเพิ่มจำนวนชั้นใน ชั้นซ่อนดังแสดงในภาพประกอบ 7



ภาพประกอบ 7 โครงสร้างแบบป้อนไปข้างหน้าหลายชั้น

การทำงานของโหนดข้อมูลเข้าจะทำหน้าที่แทนส่วนของข้อมูลดิบ ที่ถูกป้อนเข้าสู่ เครือข่าย และการทำงานของแต่ละ โหนดซ่อน จะถูกกำหนด โดยการทำงานของโหนดข้อมูลเข้าและ ค่า น้ำหนักบนความสัมพันธ์ระหว่าง โหนดข้อมูลเข้า และ โหนดซ่อน พฤติกรรมการทำงานของโหนด ข้อมูลออก จะขึ้นอยู่กับการทำงานของ โหนดซ่อน และค่าน้ำหนักระหว่าง โหนดซ่อน และโหนด ข้อมูลออก ลักษณะการทำงานแบบนี้สามารถกำหนดการแทนค่าให้แก่ โหนดข้อมูลเข้าได้อย่างอิสระ ค่า น้ำหนักระหว่าง โหนดข้อมูลเข้าและ โหนดซ่อน จะถูกกำหนดเมื่อ โหนดซ่อน กำลังทำงาน ฉะนั้น เวลาที่แก้ไขค่าน้ำหนัก โหนดซ่อน จะสามารถเลือกว่าอะไรคือค่าที่เราแทนเข้ามาในโมเดลทาง คณิตศาสตร์ของโครงข่ายประสาทเทียม แบบป้อนไปข้างหน้าหลายชั้น แสดงในภาพ มีเวกเตอร์อินพุต $X = \{x_i\}$ กำหนดให้ $x_i \in \mathfrak{R}^p$ และเวกเตอร์ผลลัพธ์ $Y = \{y_i\}$ กำหนดให้ $y_i \in \mathfrak{R}^m$ ซึ่ง ประกอบด้วยสมการการคำนวณภายในเซลล์ประสาทแต่ละชั้นดังนี้

ชั้นซ่อน

$$h = \sigma(u_j) \quad (2)$$

$$u_j = \sum_{i=1}^p w_{ji}^h x_j \quad (3)$$

จากสมการที่ (2) และ (3) กำหนดให้ y_k คือผลลัพธ์ของเซลล์ประสาทใน ชั้นซ่อน ซึ่ง $1 \leq k \leq m$

$\sigma(\cdot)$ คือ activation function

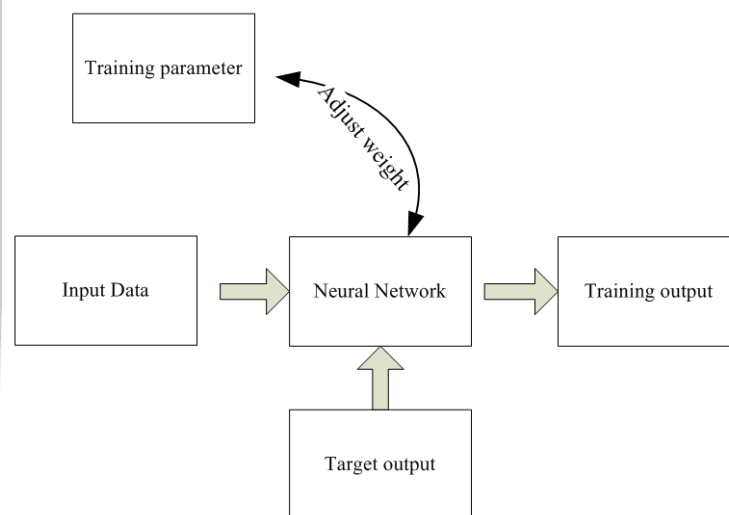
w_{kj}^h คือ ค่าของน้ำหนักบนเส้น k_j เชื่อมเซลล์ในชั้นซ่อน k กับเซลล์ในชั้นข้อมูลเข้า j

W^y คือ เวกเตอร์น้ำหนัก $\{w_{kj}^h\}$

2.4.2 รูปแบบการเรียนรู้ของโครงข่ายประสาทเทียม


การเรียนรู้เป็นกระบวนการที่สามารถทำให้เปลี่ยนแปลงพฤติกรรม ความคิด สามารถเรียนรู้ได้จากการ ได้ยินการสัมผัส การอ่าน การใช้เทคโนโลยี สามารถแบ่งออกได้ 2 แบบ

2.4.2.1 การเรียนรู้แบบมีการสอน (supervised learning) เป็นการเรียนรู้แบบที่มีการตรวจคำตอบ เพื่อให้โครงข่ายปรับตัว ชุดข้อมูลที่ใช้สอนวงจรข่ายจะมีคำตอบไว้คอยตรวจดูว่าวงจรข่ายให้คำตอบที่ ถูกหรือไม่ ถ้าตอบไม่ถูก การเรียนรู้โดยให้ข่ายงานปรับตัวเข้ากับค่าจริง (target) หรือคำตอบที่มีอยู่ เพื่อให้ได้คำตอบที่เหมือนหรือใกล้เคียงกับคำตอบจริงดังแสดงในภาพประกอบ 8



ภาพประกอบ 8 การเรียนรู้แบบมีผู้สอน


2.4.2.2 การเรียนรู้แบบไม่มีการสอน (unsupervised learning) เป็นการเรียนแบบไม่มีผู้แนะนำ ไม่มีการตรวจคำตอบว่าถูกหรือผิด จะไม่มีค่าจริงในการฝึกสอน เครือข่ายจะจัดเรียงโครงสร้างของตัวเองตามลักษณะของข้อมูล ผลลัพธ์ที่ได้เครือข่ายจะสามารถจัดหมวดหมู่ของข้อมูลได้ เช่น การแยกลักษณะของคน พืช และสัตว์ เองได้โดยไม่มีผู้สอนจริงในการฝึกสอน เครือข่ายจะจัดเรียงโครงสร้างของตัวเองตามลักษณะของข้อมูล ผลลัพธ์ที่ได้เครือข่ายจะสามารถจัดหมวดหมู่ของข้อมูลได้ เช่นการที่เราสามารถแยกลักษณะของคน พืช และสัตว์ เองได้โดยไม่มีการสอนดังแสดงในภาพประกอบ 9



ภาพประกอบ 9 การเรียนรู้แบบไม่มีการสอน

2.5 ทฤษฎีโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง

ทฤษฎีโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง (Self-Organizing Maps : SOM) เป็นอัลกอริทึมโครงข่ายประสาทเทียมที่นิยมใช้มากที่สุด โดยแนวคิดของโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง คือ การทำซ้ำข้อมูลเพื่อหาค่าของน้ำหนักของข้อมูลที่มีอยู่ทั้งหมดตามจำนวนกลุ่มที่ต้องการ เป็นวิธีเกี่ยวกับการจัดกลุ่มด้วยตัวเองโดยใช้โครงสร้างตาข่ายระบบประสาท เป็นการเรียนรู้แบบไม่มีผู้สอน มีลักษณะการเรียนรู้ แบบเครือข่าย 2 ชั้น เป็นการจัดข้อมูลนำเข้าหลายมิติ ให้อยู่ในรูปแบบของข้อมูลสองมิติคือการจัดกลุ่มของข้อมูลที่มีลักษณะคล้ายกันจะอยู่ในโหนดใกล้เคียงกัน โดยโครงสร้างการทำงานของโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง ชั้นแรกทำหน้าที่นำเข้าข้อมูลและจัดส่งข้อมูลให้แก่เซลล์ประสาทชั้นที่สอง ทุกโหนดในตาราง หรือ การจัดเรียงตามลำดับของเซลล์ประสาท (array of neurons) ระหว่างชั้นจะเชื่อมต่อกันด้วยค่าน้ำหนัก (weight) จากนั้นข้อมูลจะถูกส่งไปยังเซลล์ประสาทในชั้นที่สอง เพื่อทำการเปรียบเทียบว่าใกล้เคียงกับค่า กลางกลุ่มใดมากที่สุด แต่ละโหนดในชั้นนี้จะมีความสัมพันธ์กันแบบ เพื่อนบ้าน (neighborhood relation) ทำให้เกิดเป็นรูปแบบ 2 มิติ จากนั้นจะทำการปรับค่า น้ำหนักของตัวที่เป็นผู้ชนะ (winner) ทำให้ข้อมูลที่ข้อมูลเข้าเข้ามาเกิดการปรับเปลี่ยน และเมื่อผ่านการเรียนรู้ไปหลายๆรอบจะ ทำให้ ได้กลุ่มข้อมูลออกมาเป็นผลลัพธ์ จากนั้นจึงนำผลลัพธ์ที่ได้นั้นมาผ่านกระบวนการ Visualization เพื่อแสดงผลลัพธ์ที่ได้นั้นออกมาเป็นกราฟชนิดต่าง ๆ ต่อไป ดังภาพประกอบ 10



ภาพประกอบ 10 การเรียนรู้ของโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง

2.5.1 ขั้นตอนการทำงานของทฤษฎีโครงข่ายประสาทเทียมก่อตัวด้วยตนเอง

1. ทำการจัดกลุ่มของข้อมูลนำเข้าให้อยู่ในกลุ่มข้อมูลที่ใกล้เคียง ทำการ Normalize ค่าข้อมูล แต่ละตัว เพื่อให้ได้ค่ากลางเป็น

$$x_i = \frac{x_i - \min}{\max - \min} \quad (3)$$

จากสมการที่ (3) กำหนดให้ x_1, x_2, \dots, x_n เป็นข้อมูลที่ถูกรับ นำเข้า n คือจำนวนตัวอย่างข้อมูลเข้า \min คือ ค่าที่น้อยที่สุดของชุดข้อมูล \max คือ ค่าที่มากที่สุดของชุดข้อมูล

2. กำหนดโครงสร้างโครงข่ายประสาทเทียมในลักษณะสองมิติ กำหนด แนวแกน x และแกน y กำหนดชุดของข้อมูล สุ่มค่าน้ำหนักเริ่มต้น ในโครงข่ายดังแสดงในภาพประกอบ 10

3. สุ่มค่าเริ่มต้นให้กับค่ากลางของกลุ่ม (cluster center) $W = \{w_1, w_2, \dots, w_p\}$ โดยที่ p คือจำนวนกลุ่ม เวกเตอร์ค่ากลางคือ $W = \{w_{j1}, w_{j2}, \dots, w_{jm}\}$ เมื่อ $1 \leq j \leq p$

4. คำนวณหาระยะทางระหว่างโครงข่ายโดย ยูคลิเดียน (Euclidean distance) เพื่อหาผู้ชนะ (winner) ซึ่งจะหาได้จากโครงข่ายที่ใช้ระยะทางที่ได้จากการคำนวณ เพื่อหาค่าน้อยที่สุด


$$C(k_1, k_2) = \min_{i,j} C_{i,j} \quad (4)$$

เมื่อ k_1, k_2 คือ ดัชนีของโหนดผู้ชนะ

$$C_{i,j}^2 = \|x - w_j\|^2 \quad (5)$$

$$C_{i,j}^2 = \sum_{i=1}^w (x - w_j)^2 \quad (6)$$

จากสมการที่ (6) เมื่อ $C_{i,j}$ คือค่าความต่างระหว่างข้อมูลนำเข้า x_i กับเวกเตอร์น้ำหนัก $w_{i,j}$



ภาพประกอบ 11 การหาผู้ชนะสำหรับการกระจายของข้อมูล x_i หรือโหนดเพื่อนบ้าน

5. คำนวณค่ากลางสำหรับกลุ่มที่เป็น ค่าผู้ชนะใหม่ ตามสมการที่ (6)

$$w_j(t+1) = w(t) + \eta(x_i - w_j(t)) \quad (7)$$

6. ทำซ้ำขั้นตอนที่ 4-5 จนครบชุดข้อมูลนำเข้า หรือจนกว่าค่าน้ำหนักเริ่มจะคงที่

7. โหนดที่เป็นผู้ชนะจะสอดคล้องตามสมการที่ (4) เมื่อ k_1, k_2 ดัชนีของโหนดที่เป็นผู้ชนะ

8. โหนดที่เป็นโหนดเพื่อนบ้านจะถูกกำหนดดังสมการที่ (8)

$$h(\rho, t) = \exp\left(-\frac{\rho^2}{2\sigma^2(t)}\right) \quad (8)$$

9. ทหาระยะห่างระหว่างโหนดนั้น ๆ กับ โหนดที่เป็นผู้ชนะสมการที่ (9)

$$\rho = \sqrt{(k_1 - i)^2 + (k_2 - j)^2} \quad (9)$$

10. หาโหนดเพื่อนบ้านที่ใกล้เคียงที่สุด โดยขอบเขตจะลดลงตามเวลาตามสมการที่ (10) และ (11)

$$h(p,t) = \exp\left(\frac{p^2}{\sigma^2(t)}\right) \left(1 - \frac{2}{\sigma^2(t)}\right) p^2 \quad (10)$$

$$h(p) = \begin{cases} 1, & |p| \leq a, \\ \frac{1}{3}, & a < |p| \leq 3a, \\ 0, & |p| > 3a, \end{cases} \quad (11)$$

11. ปรับค่าน้ำหนัก ของแต่ละโหนดตามสมการที่ (12)

$$w_{ij}(t+1) = w_{ij}(t) + a(t)h(p,t)(X^1(t) - W(t)) \quad (9)$$

2.7 เทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques)

เทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) คือกระบวนการทางคณิตศาสตร์และคอมพิวเตอร์ที่มุ่งเน้นการค้นหาค่าที่เหมาะสมที่สุดของพารามิเตอร์ หรือโซลูชันของปัญหา โดยเป้าหมายหลักคือการลดข้อผิดพลาดหรือเพิ่มประสิทธิภาพของระบบให้ถึงระดับที่ดีที่สุด ซึ่งในบริบทของโครงข่ายประสาทเทียม (Artificial Neural Network - ANN) เทคนิคการเพิ่มประสิทธิภาพถูกนำมาใช้เพื่อปรับค่าพารามิเตอร์ เช่น น้ำหนัก (Weights) และค่าไบแอส (Biases) เพื่อเพิ่มความแม่นยำของโมเดล

การนำเทคนิคการเพิ่มประสิทธิภาพมาใช้ใน ANN มีความสำคัญอย่างมาก เนื่องจาก ANN เป็นโมเดลที่มีความซับซ้อนและอาจพบปัญหาเช่น การติดอยู่ในค่าผลลัพธ์ท้องถิ่น (Local Optimum) ซึ่งทำให้ไม่สามารถบรรลุค่าที่เหมาะสมที่สุดได้ การใช้เทคนิคการเพิ่มประสิทธิภาพ เช่น Particle Swarm Optimization (PSO), Genetic Algorithm (GA) และ Bee Algorithm (BA) ช่วยให้โมเดลสามารถหลีกเลี่ยงปัญหาดังกล่าวได้ โดยการปรับค่าพารามิเตอร์อย่างชาญฉลาดผ่านกระบวนการทดลองซ้ำ ๆ

2.7.1 Genetic Algorithm (GA)

GA เป็นอัลกอริทึมที่เลียนแบบกระบวนการทางธรรมชาติของวิวัฒนาการ โดยใช้กลไกของการคัดเลือกตามธรรมชาติ (Natural Selection), การกลายพันธุ์ (Mutation) และการผสมพันธุ์ (Crossover) เพื่อสร้างคำตอบใหม่ที่มีประสิทธิภาพสูงขึ้นเรื่อย ๆ GA เหมาะสำหรับ

การแก้ปัญหาที่มีพื้นที่ค้นหาที่ซับซ้อนหรือไม่เชิงเส้น สามารถสรุปข้อดีและข้อจำกัดวิธี ดังตาราง 3

ตาราง 3 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ GA

เทคนิคการเพิ่มประสิทธิภาพ	ข้อดี	ข้อจำกัด
Genetic Algorithm (GA)	<ul style="list-style-type: none"> - มีความสามารถในการค้นหาคำตอบทั่วพื้นที่ค้นหา (Global Search) - เหมาะสำหรับปัญหาที่ซับซ้อนและมีพื้นที่ค้นหาขนาดใหญ่ 	<ul style="list-style-type: none"> - ใช้เวลาคำนวณนานเมื่อเทียบกับ PSO หรือ BA - อาจต้องกำหนดจำนวนรอบ (Generations) และขนาดของประชากร (Population) ให้เหมาะสม

2.7.2 Particle Swarm Optimization (PSO)

PSO เป็นอัลกอริทึมที่ได้รับแรงบันดาลใจจากพฤติกรรมเคลื่อนที่ของฝูงสัตว์ เช่น ฝูงนกหรือฝูงปลา PSO ใช้กลไกของอนุภาค (Particles) ที่เคลื่อนที่ในพื้นที่ค้นหา (Search Space) เพื่อค้นหาคำตอบที่ดีที่สุด อนุภาคจะปรับปรุงตำแหน่งของตนเองโดยพิจารณาจากประสบการณ์ส่วนตัวและเพื่อนร่วมฝูง ทำให้สามารถค้นหาค่าที่เหมาะสมที่สุดได้อย่างรวดเร็วและมีประสิทธิภาพ สามารถสรุปข้อดีและข้อจำกัดวิธี ดังตาราง 4

ตาราง 4 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ PSO

เทคนิคการเพิ่มประสิทธิภาพ	ข้อดี	ข้อจำกัด
Particle Swarm Optimization (PSO)	<ul style="list-style-type: none"> - ค้นหาคำตอบได้รวดเร็วและเหมาะสมสำหรับปัญหาที่ไม่เชิงเส้น - ปรับตัวได้ดีในพื้นที่ค้นหาที่ซับซ้อน 	<ul style="list-style-type: none"> - มีแนวโน้มที่จะติดอยู่ใน Local Optimum โดยเฉพาะในปัญหาที่มีพื้นที่ค้นหาขนาดใหญ่ - ประสิทธิภาพอาจลดลงหากกำหนดค่าพารามิเตอร์เริ่มต้นไม่เหมาะสม

2.7.3 Bee Algorithm (BA)

BA ได้แรงบันดาลใจจากพฤติกรรมการหาอาหารของผึ้ง โดยแต่ละผึ้งจะแทนค่าคำตอบในพื้นที่ค้นหา และพยายามค้นหาพื้นที่ที่มีค่าเป้าหมายที่ดีที่สุด (เช่น ค่าความผิดพลาดต่ำสุด) ผึ้งจะสื่อสารข้อมูลที่ค้นพบกับผึ้งตัวอื่น เพื่อเพิ่มโอกาสในการค้นหาคำตอบที่เหมาะสมที่สุด เทคนิคนี้มีความยืดหยุ่นและสามารถหลีกเลี่ยงการติดอยู่ใน Local Optimum ได้ดี สามารถสรุปข้อดีและข้อจำกัดวิธี ดังตาราง 5

ตาราง 5 ตารางแสดงข้อดีและข้อจำกัดของเทคนิคการเพิ่มประสิทธิภาพ BA

เทคนิคการเพิ่มประสิทธิภาพ	ข้อดี	ข้อจำกัด
Bee Algorithm (BA)	<ul style="list-style-type: none"> - มีประสิทธิภาพดีในการหลีกเลี่ยงการติดอยู่ใน Local Optimum - เหมาะสำหรับปัญหาที่ต้องการการปรับค่าพารามิเตอร์อย่างละเอียด 	<ul style="list-style-type: none"> - ต้องปรับแต่งพารามิเตอร์ เช่น จำนวนผึ้ง (Bees) และพื้นที่สำรวจ (Search Radius) ให้เหมาะสม - อาจไม่เหมาะกับปัญหาที่มีขนาดพื้นที่ค้นหามากเกินไป

ในงานวิจัยเกี่ยวกับการพยากรณ์พลังงานไฟฟ้าระยะสั้น การนำเทคนิคการเพิ่มประสิทธิภาพเหล่านี้มาใช้ใน ANN ช่วยลดข้อผิดพลาดในการพยากรณ์ เช่น ค่า Mean Absolute Percentage Error (MAPE) และค่า Root Mean Square Error (RMSE) อีกทั้งยังช่วยปรับปรุงการเรียนรู้ของโครงข่าย ANN ให้มีความสอดคล้องกับข้อมูลและสถานการณ์ที่ซับซ้อนมากยิ่งขึ้น

ดังนั้น เทคนิคการเพิ่มประสิทธิภาพจึงถือเป็นเครื่องมือสำคัญที่ช่วยเพิ่มศักยภาพของ ANN และเสริมความน่าเชื่อถือของโมเดลสำหรับการนำไปใช้งานในสภาพแวดล้อมที่ต้องการความแม่นยำสูง เช่น การบริหารจัดการพลังงานไฟฟ้าในอนาคต สามารถสรุปข้อดีและข้อจำกัดแต่ละวิธี ดังตาราง 3

2.6 งานวิจัยที่เกี่ยวข้อง

จากงานวิจัยที่ผ่านมาได้มีการศึกษาการลดค่าพลังงานไฟฟ้าสูงสุดและระบบปัญญาประดิษฐ์เพื่อใช้ในการพยากรณ์โหลดไฟฟ้าล่วงหน้า โดยจะเห็นในการวิจัยดังต่อไปนี้

Aruta และคณะ (2023) ได้พัฒนาระบบควบคุมพลังงานอัจฉริยะสำหรับ HVAC (Heating, Ventilation, and Air Conditioning) โดยใช้ ANNs และ GA โดย ANN ถูกใช้เพื่อพยากรณ์ปัจจัยที่มีผลต่อการใช้พลังงานของระบบ HVAC เช่น อุณหภูมิ ความชื้น และโหลดพลังงานของอาคาร ในขณะที่ GA ถูกนำมาใช้เพื่อปรับแต่งค่าการทำงานของระบบ HVAC เช่น อุณหภูมิเป้าหมาย รอบการทำงานของคอมเพรสเซอร์ และความเร็วของพัดลม ให้เกิดประสิทธิภาพสูงสุด โดยคำนึงถึงการลดการใช้พลังงานโดยไม่กระทบต่อระดับความสะดวกสบายของผู้อยู่อาศัย ผลการทดลองแสดงให้เห็นว่าระบบสามารถลดการใช้พลังงานของ HVAC ลง 25% ในขณะที่ยังคงรักษาคุณภาพอากาศภายในอาคารให้อยู่ในระดับที่เหมาะสม นอกจากนี้ ระบบยังช่วยลดภาระของโครงข่ายไฟฟ้าในช่วงที่มีความต้องการใช้พลังงานสูง

Behzadi และคณะ (2023) ได้พัฒนาระบบควบคุม Peak Load โดยใช้ ANN และ Grey Wolf Optimization (GWO) ซึ่งเป็นอัลกอริธึมเชิงวิวัฒนาการที่ได้รับแรงบันดาลใจจากพฤติกรรมของหมาป่า ANN ถูกใช้ในการวิเคราะห์และเรียนรู้รูปแบบการใช้พลังงานของอาคาร รวมถึงพยากรณ์ความต้องการพลังงานล่วงหน้า ขณะที่ GWO ทำหน้าที่หาค่าที่เหมาะสมที่สุดในการจัดสรรพลังงานให้กับระบบไฟฟ้า โดยคำนึงถึงปัจจัยด้านราคาและประสิทธิภาพในการใช้พลังงาน ผลการทดลองแสดงให้เห็นว่าระบบสามารถลด Peak Load ได้ถึง 20% ซึ่งส่งผลให้สามารถลดต้นทุนพลังงานในช่วงเวลาที่มีราคาสูง นอกจากนี้ ระบบยังช่วยเพิ่มเสถียรภาพของโครงข่ายไฟฟ้าโดยลดความผันผวนของโหลดพลังงาน

Chen และคณะ (2023) ได้พัฒนา Multi-Agent AI-Based Optimization สำหรับอาคารพลังงานอัจฉริยะ โดยใช้ Deep Learning และ Reinforcement Learning (RL) ระบบนี้ออกแบบมาเพื่อกระจายโหลดพลังงานอัตโนมัติระหว่างแหล่งพลังงานที่แตกต่างกัน เช่น พลังงานแสงอาทิตย์ แบตเตอรี่สำรอง และไฟฟ้าจากโครงข่ายหลัก โดยใช้เทคนิค RL เพื่อให้ตัวแทนอัจฉริยะ (AI Agents) สามารถเรียนรู้พฤติกรรมการใช้พลังงานและปรับแต่งกลยุทธ์การจัดการโหลดพลังงานแบบเรียลไทม์ ระบบสามารถตรวจจับช่วงเวลาที่ความต้องการใช้พลังงานสูงสุด (Peak Load) และทำการกระจายโหลดไปยังแบตเตอรี่สำรองหรือลดกำลังไฟฟ้าที่จ่ายให้กับอุปกรณ์ที่ไม่จำเป็นในช่วงเวลานั้น ส่งผลให้ลดการใช้พลังงานในช่วง Peak Load ได้ถึง 18% และช่วยให้โครงข่ายไฟฟ้ามีความเสถียรมากขึ้น โดยเฉพาะในกรณีที่อาคารใช้พลังงานจากแหล่งหมุนเวียนเป็นหลัก

García และคณะ (2023) ได้พัฒนาระบบ Demand Response (DR) โดยใช้ Deep Neural Networks (DNNs) และ PSO ระบบนี้มีเป้าหมายเพื่อช่วยให้ผู้ใช้พลังงานสามารถปรับเปลี่ยนพฤติกรรมการใช้พลังงานเพื่อลดภาระของโครงข่ายไฟฟ้าในช่วงที่มีความต้องการใช้พลังงานสูง ระบบใช้ DNNs ในการวิเคราะห์รูปแบบการใช้พลังงานและพยากรณ์ช่วงเวลาที่ความต้องการพลังงานจะสูงขึ้น ขณะที่ PSO ถูกใช้ในการปรับแต่งกลยุทธ์การควบคุมโหลดพลังงานแบบเรียลไทม์ เช่น การลดกำลังไฟฟ้าของเครื่องใช้ไฟฟ้าที่ไม่จำเป็นในช่วง Peak Load หรือการชะลอการชาร์จแบตเตอรี่สำรองไปยังช่วงเวลาที่พลังงานหมุนเวียนสามารถผลิตได้มากขึ้น ผลการทดลองแสดงให้เห็นว่าสามารถลด

การใช้พลังงานในช่วง Peak Load ได้ถึง 18% ซึ่งช่วยเพิ่มเสถียรภาพของโครงข่ายไฟฟ้า ลดต้นทุนค่าไฟฟ้าของผู้ใช้งาน และลดปัญหาการขาดแคลนพลังงานในช่วงเวลาที่มีความต้องการสูง

Giglio และคณะ (2023) ได้นำเสนอระบบบริหารพลังงานสำหรับ Microgrid โดยใช้ Reinforcement Learning (RL) และ Neural Networks ระบบนี้ได้รับการออกแบบเพื่อจัดการพลังงานใน Microgrid ที่มีการใช้พลังงานจากแหล่งหมุนเวียนและพลังงานสำรอง โดยใช้ Neural Networks ในการคาดการณ์การผลิตและความต้องการใช้พลังงาน และใช้ RL ในการควบคุมการจ่ายพลังงานไปยังโหลดที่จำเป็นโดยอัตโนมัติ ระบบสามารถปรับเปลี่ยนกลยุทธ์ในการกระจายพลังงานได้แบบไดนามิกขึ้นอยู่กับปัจจัยต่าง ๆ เช่น สภาพอากาศ การผลิตพลังงานจากโซลาร์เซลล์ และปริมาณพลังงานที่กักเก็บในแบตเตอรี่ ผลการทดลองกับ Microgrid จำลองพบว่าระบบสามารถลดพลังงานสูญเสียลง 22% และช่วยเพิ่มเสถียรภาพในการใช้พลังงานหมุนเวียน ทำให้ Microgrid สามารถทำงานได้อย่างมีประสิทธิภาพโดยไม่ต้องพึ่งพาโครงข่ายไฟฟ้าหลักมากนัก

Huy และคณะ (2023) ได้นำเสนอ Home Energy Management System (HEMS) โดยใช้ Artificial Neural Networks (ANNs) และ Reinforcement Learning (RL) เพื่อพยากรณ์การใช้พลังงานและต้นทุนค่าไฟฟ้าแบบเรียลไทม์ ระบบนี้ได้รับการออกแบบให้สามารถเรียนรู้พฤติกรรมการใช้พลังงานภายในบ้าน และทำการปรับโหลดพลังงานของอุปกรณ์ต่าง ๆ โดยอัตโนมัติ เช่น เครื่องใช้ไฟฟ้า เครื่องปรับอากาศ และระบบแสงสว่าง เพื่อให้เกิดการใช้พลังงานอย่างมีประสิทธิภาพสูงสุด ในการทดลอง ระบบสามารถลดการใช้พลังงานในช่วง Peak Load โดยเลื่อนหรือกระจายเวลาการใช้งานอุปกรณ์ที่ใช้พลังงานสูงออกไปยังช่วงเวลาที่ค่าไฟฟ้าต่ำ หรือเมื่อมีพลังงานหมุนเวียนเพียงพอ ผลลัพธ์พบว่าระบบสามารถลดต้นทุนพลังงานลงได้ถึง 12% และยังสามารถช่วยเพิ่มเสถียรภาพให้กับโครงข่ายไฟฟ้าโดยการลดภาระโหลดสูงสุด

Mousavi และคณะ (2023) ได้นำเสนอระบบ AI-Based Predictive Control สำหรับอาคาร Net-Zero Energy Building (NZEB) โดยใช้ Neural Networks และ Model Predictive Control (MPC) ระบบนี้ออกแบบมาเพื่อลดการพึ่งพาไฟฟ้าจากโครงข่าย และเพิ่มการใช้พลังงานหมุนเวียนอย่างมีประสิทธิภาพ โดย Neural Networks ถูกใช้เพื่อพยากรณ์การผลิตพลังงานจากแหล่งหมุนเวียนล่วงหน้า เช่น การพยากรณ์กำลังไฟฟ้าที่ผลิตจากแผงโซลาร์เซลล์ โดยพิจารณาจากข้อมูลสภาพอากาศ ขณะที่ MPC ถูกนำมาใช้เพื่อควบคุมและจัดสรรพลังงานให้เหมาะสมที่สุดในแต่ละช่วงเวลา ผลการทดลองกับอาคารที่ใช้พลังงานหมุนเวียนเป็นหลัก พบว่าระบบสามารถลดค่าใช้จ่ายด้านพลังงานลง 22% และช่วยเพิ่มอัตราการใช้พลังงานหมุนเวียนให้สูงขึ้นอย่างมีนัยสำคัญ นอกจากนี้ระบบยังช่วยลดการสูญเสียพลังงานที่เกิดจากการเก็บและจ่ายพลังงานให้กับโหลด

Nakamura และคณะ (2023) มุ่งเน้นไปที่การพัฒนา Smart Grid สำหรับอาคารที่ใช้พลังงานหมุนเวียน โดยใช้ Deep Learning และ Particle Swarm Optimization (PSO) ระบบนี้สามารถบริหารจัดการพลังงานแสงอาทิตย์และแบตเตอรี่สำรอง โดยอาศัย Deep Learning ในการพยากรณ์การผลิตพลังงานจากแหล่งหมุนเวียน และใช้ PSO ในการปรับแต่งการจ่ายพลังงานเพื่อให้

เกิดความเสถียรสูงสุด ผลการทดลองในอาคารพาณิชย์ที่ใช้โซลาร์เซลล์แสดงให้เห็นว่าสามารถลดพลังงานสูญเสียลง 14%

Patel และคณะ (2023) ได้พัฒนาโมเดล Long Short-Term Memory (LSTM) Neural Networks สำหรับการพยากรณ์โหลดพลังงานของอาคารสูง LSTM เป็นประเภทของ Recurrent Neural Networks (RNNs) ที่สามารถจดจำข้อมูลในอดีตและคาดการณ์แนวโน้มของข้อมูลในอนาคตได้อย่างมีประสิทธิภาพ โมเดลนี้ได้รับการฝึกด้วยข้อมูลที่เกี่ยวข้องกับสภาพอากาศ อัตราการใช้พลังงานในอดีต และพฤติกรรมของผู้อยู่อาศัยในอาคารสูง เพื่อนำมาสร้างแบบจำลองที่สามารถคาดการณ์การใช้พลังงานล่วงหน้าได้อย่างแม่นยำ ผลการทดลองแสดงให้เห็นว่าโมเดลสามารถพยากรณ์โหลดพลังงานได้แม่นยำถึง 92% และสามารถลดการใช้พลังงานในช่วง Peak Load ได้ถึง 18% โดยช่วยให้สามารถบริหารจัดการพลังงานได้อย่างมีประสิทธิภาพ และลดภาระของโครงข่ายไฟฟ้า

Rodriguez และคณะ (2023) มุ่งเน้นไปที่การพัฒนา AI-Driven Energy Management System สำหรับอาคารในมหาวิทยาลัย โดยใช้ ANNs และ GA ระบบนี้ออกแบบมาเพื่อศึกษารูปแบบการใช้พลังงานในอาคารเรียน ห้องปฏิบัติการ และหอพักนักศึกษา โดยนำข้อมูลการใช้พลังงานในอดีตมาประมวลผลผ่าน ANNs เพื่อพยากรณ์แนวโน้มการใช้พลังงาน หลังจากนั้น GA จะถูกใช้ในการกำหนดกลยุทธ์ที่เหมาะสมในการควบคุมโหลดพลังงาน เช่น การสลับโหลดจากพลังงานหลักไปยังพลังงานหมุนเวียน หรือการควบคุมการเปิด-ปิดระบบทำความร้อนและความเย็นให้มีประสิทธิภาพสูงสุด ผลการทดลองจากอาคารในมหาวิทยาลัยขนาดกลางพบว่า ระบบสามารถลดพลังงานไฟฟ้าสูญเสียลง 18% และช่วยลดค่าใช้จ่ายด้านพลังงานให้กับมหาวิทยาลัย

Al Smadi และคณะ (2024) ได้เสนอระบบควบคุมพลังงานอัจฉริยะสำหรับอาคารที่ใช้พลังงานแสงอาทิตย์ โดยใช้ ANNs และ Genetic Algorithm (GA) ระบบนี้ได้รับการออกแบบให้สามารถคำนวณปริมาณพลังงานที่ผลิตจากแผงโซลาร์เซลล์ และพยากรณ์การใช้พลังงานของอาคารล่วงหน้า จากนั้น GA จะถูกใช้เพื่อหาแนวทางที่เหมาะสมที่สุดในการกระจายพลังงานให้กับโหลดต่างๆ หรือกักเก็บพลังงานส่วนเกินในแบตเตอรี่สำรอง ผลการทดลองแสดงให้เห็นว่าระบบสามารถเพิ่มประสิทธิภาพของการใช้พลังงานแสงอาทิตย์ได้ถึง 30% โดยลดปริมาณพลังงานที่สูญเสีย และช่วยลดการพึ่งพาพลังงานจากโครงข่ายไฟฟ้าหลักได้อย่างมีนัยสำคัญ โดยเฉพาะในช่วงเวลาที่พลังงานแสงอาทิตย์สามารถผลิตได้มาก

Lee และคณะ (2024) ได้พัฒนาระบบบริหารจัดการพลังงานสำหรับอาคารพาณิชย์โดยใช้ Artificial Intelligence (AI) ผสานกับ Artificial Neural Networks (ANNs) และ Genetic Algorithm (GA) ระบบนี้สามารถพยากรณ์โหลดพลังงานของอาคารล่วงหน้าได้โดยอาศัยข้อมูลจากการใช้พลังงานในอดีต รวมถึงสภาพอากาศและพฤติกรรมของผู้ใช้งานภายในอาคาร เมื่อระบบสามารถคาดการณ์ความต้องการใช้พลังงานได้อย่างแม่นยำแล้ว GA จะถูกใช้เพื่อหาวิธีการบริหารพลังงานที่เหมาะสมที่สุด โดยมีเป้าหมายเพื่อลดการใช้พลังงานที่ไม่จำเป็น ปรับโหลดในช่วง Peak Load และเพิ่มประสิทธิภาพโดยรวมของอาคาร จากการทดลองกับอาคารสำนักงานขนาดใหญ่ใน


เมือง พบว่าระบบนี้สามารถลดการใช้พลังงานลง 15% พร้อมทั้งลด Carbon Footprint ของอาคารได้อย่างมีนัยสำคัญ ส่งผลให้ต้นทุนด้านพลังงานลดลง และช่วยให้โครงข่ายไฟฟ้ามีความเสถียรมากขึ้น

Martinez และคณะ (2024) ได้พัฒนา Adaptive AI-Based Control System สำหรับบ้านอัจฉริยะ โดยใช้ Neural Networks และ Evolutionary Algorithms ระบบสามารถเรียนรู้รูปแบบการใช้พลังงานจากอุปกรณ์สมาร์ทโฮม เช่น ระบบแสงสว่าง เครื่องใช้ไฟฟ้า และระบบปรับอากาศ โดยใช้ Neural Networks ในการวิเคราะห์ข้อมูลแบบเรียลไทม์ Evolutionary Algorithms จะถูกใช้ในการกำหนดกลยุทธ์การควบคุมอุปกรณ์แต่ละชนิดเพื่อให้เกิดประสิทธิภาพสูงสุด การทดลองกับบ้านอัจฉริยะจำลองพบว่า ระบบสามารถลดการใช้พลังงานโดยรวมได้ถึง 25% โดยไม่ลดทอนความสะดวกสบายของผู้อยู่อาศัย และช่วยให้สามารถใช้พลังงานหมุนเวียนจากแผงโซลาร์เซลล์ได้อย่างเต็มประสิทธิภาพ

Zhou และคณะ (2024) ได้นำเสนอการพยากรณ์โหลดพลังงานของอาคารพาณิชย์ โดยใช้ Recurrent Neural Networks (RNNs) และ Long Short-Term Memory (LSTM) โมเดลนี้สามารถนำข้อมูลการใช้พลังงานในอดีตมาวิเคราะห์และพยากรณ์การใช้พลังงานในแต่ละช่วงเวลาได้อย่างแม่นยำ ระบบช่วยให้ผู้บริหารอาคารสามารถปรับกลยุทธ์การใช้พลังงาน เช่น การปรับแต่งการทำงานของเครื่องปรับอากาศและระบบไฟฟ้าให้เหมาะสมยิ่งขึ้น ผลการทดลองพบว่าระบบสามารถลดต้นทุนพลังงานลง 17% และมีความแม่นยำในการพยากรณ์โหลดพลังงานสูงถึง 95%

Zhang และคณะ (2024) ได้พัฒนาโมเดล AI-Based Energy Optimization สำหรับอาคารที่ใช้พลังงานหมุนเวียน โดยใช้ Neural Networks และ Particle Swarm Optimization (PSO) เพื่อเพิ่มประสิทธิภาพในการจัดการพลังงาน ระบบนี้เริ่มต้นด้วยการรวบรวมข้อมูลจากแหล่งพลังงานหมุนเวียน เช่น แผงโซลาร์เซลล์และกังหันลม จากนั้น Neural Networks จะใช้ข้อมูลดังกล่าวเพื่อคาดการณ์ปริมาณพลังงานที่สามารถผลิตได้ในแต่ละช่วงเวลา ขณะที่ PSO ถูกนำมาใช้เพื่อหากลยุทธ์ที่ดีที่สุดในการจัดสรรพลังงานให้กับระบบไฟฟ้าภายในอาคาร โดยพิจารณาทั้งความต้องการใช้พลังงานและการเก็บพลังงานเข้าสู่ระบบกักเก็บพลังงาน (Battery Storage) ผลการทดลองแสดงให้เห็นว่าระบบสามารถลดต้นทุนพลังงานลง 20% และลดการพึ่งพาพลังงานจากโครงข่ายไฟฟ้าหลัก โดยเฉพาะในช่วงเวลาที่พลังงานหมุนเวียนสามารถผลิตได้ในปริมาณมาก นอกจากนี้ ระบบยังช่วยลดการสูญเสียพลังงานจากการแปลงพลังงานและการจ่ายพลังงานไปยังโหลดที่ไม่จำเป็น

พูน ปณ ทิโต ชเว



บทที่ 3

วิธีดำเนินการวิจัย

เนื้อหาในบทนี้ผู้วิจัยได้อธิบายการบริหารจัดการพลังงานแบบอัจฉริยะเพื่อลดค่าพลังงานไฟฟ้าสูงสุดจากการพยากรณ์โหลดไฟฟ้าล่วงหน้าด้วยโครงข่ายประสาทเทียม ดังนี้

3.1 การเก็บรวบรวมข้อมูลและเตรียมข้อมูล

การเก็บรวบรวมข้อมูลในงานวิจัยนี้ได้ดำเนินการโดยใช้ระบบ Automatic Meter Reading (AMR) ซึ่งเป็นระบบที่พัฒนาขึ้นโดยการไฟฟ้าส่วนภูมิภาค ข้อมูลที่รวบรวมได้มาจากการใช้งานพลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ ในช่วงเวลาดังแต่เดือนมกราคม พ.ศ. 2563 ถึงเดือนธันวาคม พ.ศ. 2567 โดยมีเป้าหมายเพื่อให้ได้ข้อมูลที่ครอบคลุมการใช้งานพลังงานไฟฟ้าในสถานการณ์ที่หลากหลาย ครอบคลุมช่วงเวลาการใช้ไฟฟ้าสูงสุด (On-Peak), ช่วงเวลาการใช้ไฟฟ้าต่ำสุด (Off-Peak) และข้อมูลการใช้ไฟฟ้าในวันหยุด (Holiday)

ตาราง 6 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2563

Month	Off - Peak	On - Peak	Holiday	Sum Load	Season
Jan	200,880.00	64,442.63	52,421.18	317,743.81	Winter
Feb	192,342.18	59,680.47	55,899.98	307,922.63	Winter
Mar	208,562.01	69,540.96	60,090.30	338,193.27	Spring
Apr	124,173.96	56,753.52	39,787.21	220,714.69	Spring
May	139,674.94	53,004.43	61,328.47	254,007.84	Summer
Jun	185,978.49	65,544.92	43,823.73	295,347.14	Summer
Jul	216,785.60	72,398.75	56,346.35	345,530.70	Rainy
Aug	201,393.48	66,619.74	74,886.79	342,900.01	Rainy
Sep	280,050.58	77,592.47	70,030.50	427,673.55	Autumn
Oct	229,716.84	71,223.84	65,976.27	366,916.95	Autumn
Nov	154,741.28	56,664.07	54,248.98	265,654.33	Winter
Dec	138,076.48	54,684.23	40,513.01	233,273.72	Winter

ตาราง 7 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2564

Month	Off - Peak	On - Peak	Holiday	Sum Load	Season
Jan	93,711.20	48,734.15	43,311.12	185,756.47	Winter
Feb	148,981.61	52,014.91	48,899.54	249,896.06	Winter
Mar	304,730.46	85,543.23	68,444.00	458,717.69	Spring
Apr	131,026.03	50,737.84	70,380.52	252,144.39	Spring
May	155,264.17	57,383.15	59,088.11	271,735.43	Summer
Jun	204,360.32	70,184.35	54,208.90	328,753.57	Summer
Jul	152,690.63	63,020.72	51,627.04	267,338.39	Rainy
Aug	154,497.68	64,023.08	50,297.23	268,817.99	Rainy
Sep	137,295.67	58,689.21	43,256.57	239,241.45	Autumn
Oct	130,940.49	54,480.60	55,840.16	241,261.25	Autumn
Nov	172,363.55	62,591.37	40,381.72	275,336.64	Winter
Dec	110,409.98	53,386.58	43,761.40	207,557.96	Winter

ตาราง 8 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2565

Month	Off - Peak	On - Peak	Holiday	Sum Load	Season
Jan	97,777.05	54,066.49	44,121.94	195,965.48	Winter
Feb	105,594.92	52,131.71	45,956.72	203,683.35	Winter
Mar	195,699.98	76,657.44	54,896.76	327,254.18	Spring
Apr	159,462.89	58,299.39	71,638.53	289,400.81	Spring
May	172,648.61	65,967.99	54,016.35	292,632.95	Summer
Jun	282,520.30	89,135.40	63,752.07	435,407.77	Summer
Jul	229,510.45	69,544.44	95,766.67	394,821.56	Rainy
Aug	249,794.76	81,402.74	62,467.28	393,664.78	Rainy
Sep	272,746.61	84,584.63	60,037.31	417,368.55	Autumn
Oct	167,679.36	60,604.51	65,928.51	294,212.38	Autumn
Nov	200,307.93	69,116.93	45,227.95	314,652.81	Winter
Dec	145,007.15	57,402.13	51,550.90	253,960.18	Winter

ตาราง 9 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2566

Month	Off - Peak	On - Peak	Holiday	Sum Load	Season
Jan	127,834.67	56,500.68	37,235.39	221,570.74	Winter
Feb	185,081.18	59,921.41	56,122.29	301,124.88	Winter
Mar	223,748.68	72,182.06	63,598.36	359,529.10	Spring
Apr	161,536.02	55,136.89	69,416.54	286,089.45	Spring
May	205,300.54	70,438.24	66,490.95	342,229.73	Summer
Jun	318,959.12	96,324.13	58,900.32	474,183.57	Summer
Jul	276,658.19	85,074.21	89,386.53	451,118.93	Rainy
Aug	275,862.39	86,782.51	72,434.42	435,079.32	Rainy
Sep	279,572.97	85,199.82	72,059.35	436,832.14	Autumn
Oct	203,994.72	69,323.76	64,003.77	337,322.25	Autumn
Nov	222,811.49	73,773.52	51,978.17	348,563.18	Winter
Dec	191,659.00	67,016.18	61,189.28	319,864.46	Winter

ตาราง 10 ข้อมูลการใช้พลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุตรดิตถ์ พ.ศ. 2567

Month	Off - Peak	On - Peak	Holiday	Sum Load	Season
Jan	174,913.57	66,615.86	53,630.97	295,160.40	Winter
Feb	219,116.85	71,790.21	53,646.05	344,553.11	Winter
Mar	255,885.14	81,090.33	82,995.10	419,970.57	Spring
Apr	255,885.14	81,090.33	82,995.10	419,970.57	Spring
May	206,663.54	72,749.13	62,237.28	341,649.95	Summer
Jun	242,991.54	78,867.72	78,229.35	400,088.61	Summer
Jul	303,447.59	98,081.64	56,308.52	457,837.75	Rainy
Aug	260,643.27	86,196.86	70,171.21	417,011.34	Rainy
Sep	274,022.33	85,001.77	65,964.75	424,988.85	Autumn
Oct	235,729.95	82,266.96	64,461.51	382,458.42	Autumn
Nov	213,747.70	70,576.38	52,973.14	337,297.22	Winter
Dec	45,864.95	13,440.94	14,307.00	73,612.89	Winter

ข้อมูลที่ได้จากระบบ AMR แสดงถึงรูปแบบการใช้พลังงานไฟฟ้าในแต่ละเดือน ซึ่งสอดคล้องกับฤดูกาลในประเทศไทย ได้แก่ ฤดูหนาว (Winter), ฤดูใบไม้ผลิ (Spring), ฤดูร้อน (Summer), ฤดูฝน (Rainy) และฤดูใบไม้ร่วง (Autumn) เช่นเดียวกับข้อมูลในตาราง 3-7 ที่แสดงข้อมูลการใช้พลังงานในแต่ละปี ข้อมูลนี้ช่วยให้การวิเคราะห์สามารถสะท้อนพฤติกรรมการใช้พลังงานไฟฟ้าของผู้ใช้งานในแต่ละช่วงเวลาได้อย่างชัดเจน

หลังจากการเก็บข้อมูล ข้อมูลที่ได้จะถูกนำมาผ่านกระบวนการเตรียมข้อมูลเพื่อให้พร้อมสำหรับการพยากรณ์ด้วยโครงข่ายประสาทเทียม (Artificial Neural Networks หรือ ANN)

3.4 การออกแบบโครงข่ายประสาทเทียม (Artificial Neural Network - ANN)

โครงข่ายประสาทเทียม (Artificial Neural Network หรือ ANN) เป็นแบบจำลองที่ได้รับแรงบันดาลใจจากโครงสร้างและการทำงานของสมองมนุษย์ มีความสามารถในการเรียนรู้และคาดการณ์ข้อมูลที่มีความซับซ้อน โดยในงานวิจัยนี้ ANN ถูกออกแบบและปรับแต่งให้เหมาะสมสำหรับการพยากรณ์ความต้องการใช้พลังงานไฟฟ้าระยะสั้น โดยมีขั้นตอนการออกแบบดังนี้

3.4.1 สถาปัตยกรรมของโครงข่ายประสาทเทียม

โครงข่าย ANN ที่ใช้ในงานวิจัยนี้เป็นแบบ Feedforward Neural Network ซึ่งข้อมูลจะไหลไปในทิศทางเดียวจากชั้นนำเข้า (Input Layer) ไปยังชั้นส่งออก (Output Layer) ผ่านชั้นซ่อน (Hidden Layer) โดยไม่มีการย้อนกลับของข้อมูล รายละเอียดของแต่ละชั้นมีดังนี้

3.4.1.1 ชั้นนำเข้า (Input Layer)

- รับข้อมูลตัวแปรที่เกี่ยวข้อง เช่น ค่า Off-Peak, On-Peak, Holiday และ Season
- จำนวนเซลล์ในชั้นนี้สอดคล้องกับจำนวนตัวแปรนำเข้า (Input Features)

3.4.1.2 ชั้นซ่อน (Hidden Layer)

- มี 2 ชั้นซ่อน แต่ละชั้นมี 15 และ 30 เซลล์ประสาท ใช้ฟังก์ชันการกระตุ้นแบบ ReLU ดังสมการ (9)

$$f(x) = \max(0, x) \quad (9)$$

3.4.1.3 ชั้นส่งออก (Output Layer)

- ใช้ฟังก์ชันการกระตุ้นแบบเชิงเส้น (Linear Activation Function) เพื่อรองรับผลลัพธ์ที่เป็นค่าต่อเนื่อง (Continuous Values) เช่น ค่าความต้องการพลังงานไฟฟ้าที่พยากรณ์

3.5 การเพิ่มประสิทธิภาพด้วยเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques)

เทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) เป็นเครื่องมือสำคัญในการปรับปรุงประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network หรือ ANN) โดยเฉพาะในกรณีที่เกี่ยวข้องกับการพยากรณ์ค่าที่มีความซับซ้อน เช่น การพยากรณ์ความต้องการพลังงานไฟฟ้าระยะสั้น เทคนิคเหล่านี้มีบทบาทในการปรับค่าพารามิเตอร์ของโครงข่าย เช่น น้ำหนัก (Weights) และค่าไบแอส (Biases) เพื่อให้ได้ผลลัพธ์ที่แม่นยำที่สุด

3.5.1 ฟังก์ชันวัตถุประสงค์ที่ใช้ในกระบวนการเพิ่มประสิทธิภาพ

3.5.4.1 Mean Absolute Percentage Error (MAPE) เป็นตัวชี้วัดที่ใช้ในการวัดความแม่นยำของแบบจำลองการพยากรณ์ โดยคำนวณจากค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Absolute Percentage Error) ระหว่างค่าที่พยากรณ์ (\bar{y}_t) และค่าจริง (y_t) ในทุกตัวอย่าง ข้อได้เปรียบของ MAPE คือสามารถตีความผลลัพธ์เป็นเปอร์เซ็นต์ ซึ่งง่ายต่อการเปรียบเทียบ

$$\text{MAPE} = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \bar{y}_t}{y_t} \right| \quad (9)$$

โดยที่ n คือ จำนวนตัวอย่างทั้งหมด

y_t คือ ค่าจริงของตัวอย่างที่ t

\bar{y}_t คือ ค่าที่พยากรณ์ของตัวอย่างที่ t

พหุ ประถมศึกษา ชีวะ

บทที่ 4

ผลการวิจัย

ผลการวิจัยนี้ แสดงให้เห็นถึงประสิทธิภาพของการพยากรณ์ความต้องการพลังงานไฟฟ้าระยะสั้น โดยใช้โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ที่เพิ่มประสิทธิภาพด้วยเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) ได้แก่ Particle Swarm Optimization (PSO), Genetic Algorithm (GA) และ Bee Algorithm (BA) โดยมีการประเมินผลผ่านตัวชี้วัดที่สำคัญ เช่น Mean Absolute Percentage Error (MAPE)

4.1 เปรียบเทียบความแม่นยำของโมเดล

จากการทดลองพบว่า โมเดล ANN แบบดั้งเดิมมีความแม่นยำต่ำกว่าการผสมผสานกับเทคนิคการเพิ่มประสิทธิภาพ โดยค่าความผิดพลาด (MAPE) ของแต่ละโมเดลมีดังตาราง

ตาราง 11 ค่าความผิดพลาดเปอร์เซ็นต์สัมบูรณ์เฉลี่ย (MAPE)

ANN + Optimization Technique	Value (%)
Artificial Neural Network	4.3038
Artificial Neural Network + Genetic Algorithm	2.2198
Artificial Neural Network + Particle Swarm Optimization	3.8130
Artificial Neural Network + Bee Algorithm	2.1559

จากการทดลองที่ได้ดำเนินการเพื่อประเมินความแม่นยำของโมเดลโครงข่ายประสาทเทียม (ANN) ในการพยากรณ์ความต้องการพลังงานไฟฟ้า พบว่าโมเดล ANN แบบดั้งเดิมมีความสามารถในการพยากรณ์ต่ำกว่าเมื่อเปรียบเทียบกับโมเดล ANN ที่ผสมผสานกับเทคนิคการเพิ่มประสิทธิภาพ โดยค่าความผิดพลาดที่วัดในรูปของ Mean Absolute Percentage Error (MAPE) แสดงให้เห็นถึงความแตกต่างในประสิทธิภาพอย่างชัดเจน


โมเดล ANN แบบดั้งเดิม ซึ่งทำงานโดยไม่ได้รับการปรับปรุงด้วยเทคนิคเสริมใด ๆ มีค่า MAPE เท่ากับ 4.3038% ซึ่งสะท้อนถึงความคลาดเคลื่อนที่สูงที่สุดในกลุ่มตัวอย่างวิธีการที่ทดสอบ ในขณะที่โมเดลที่ได้รับการผสมผสานกับเทคนิคการเพิ่มประสิทธิภาพมีค่าความคลาดเคลื่อนที่ลดลงอย่าง

เห็นได้ชัด โดย ANN ที่ใช้ร่วมกับ Particle Swarm Optimization (PSO) มีค่า MAPE ลดลงเหลือ 3.8130% แสดงถึงการปรับปรุงความแม่นยำในระดับหนึ่ง

เมื่อเปรียบเทียบกับเทคนิคอื่น ๆ พบว่า ANN+Genetic Algorithm (GA) แสดงประสิทธิภาพได้ดีกว่า PSO โดยมีค่า MAPE เท่ากับ 2.2198% อย่างไรก็ตาม โมเดล ANN+Bee Algorithm (BA) แสดงผลลัพธ์ที่ดีที่สุด ด้วยค่า MAPE เพียง 2.1559% แสดงถึงความแม่นยำสูงสุดในการพยากรณ์โหลดไฟฟ้า


4.2 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์

จากภาพที่นำเสนอใน ภาพประกอบที่ 12 - 15 แสดงการเปรียบเทียบระหว่างค่าที่วัดได้จริง (Actual Load) และค่าที่พยากรณ์ (Predicted Load) โดยใช้โมเดลต่าง ๆ ได้แก่ ANN, ANN+GA, ANN+PSO และ ANN+BA ซึ่งผลลัพธ์ของแต่ละกราฟสะท้อนถึงความสามารถของโมเดลในการพยากรณ์ค่าความต้องการโหลดไฟฟ้าในช่วงตัวอย่างที่กำหนด



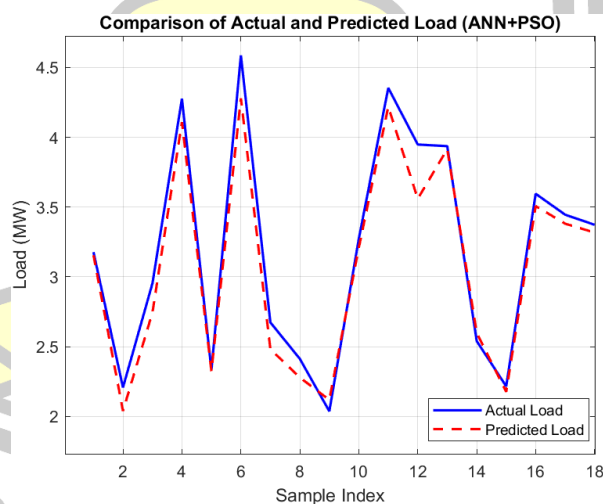
ภาพประกอบ 12 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN

กราฟในภาพประกอบ 12 แสดงการพยากรณ์ของโมเดล ANN แบบดั้งเดิม ซึ่งแสดงให้เห็นถึงความคลาดเคลื่อนที่ชัดเจนในบางช่วงเวลา โดยเฉพาะในช่วงตัวอย่างที่ 6-8 และ 13-15 ค่าที่พยากรณ์ไม่สามารถจับความผันผวนของค่าจริงได้อย่างแม่นยำ ซึ่งแสดงถึงข้อจำกัดของ ANN แบบดั้งเดิมเมื่อไม่มีการปรับปรุงด้วยเทคนิคการเพิ่มประสิทธิภาพ



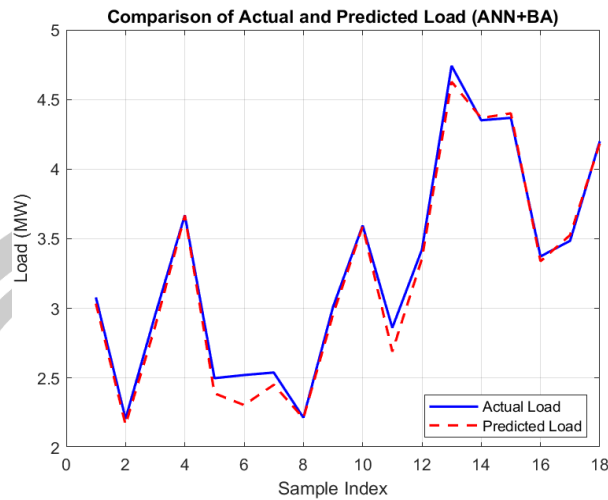
ภาพประกอบ 13 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + GA

ภาพประกอบ 13 แสดงผลการพยากรณ์โดย ANN ที่ผสานกับ Genetic Algorithm (GA) ซึ่งเห็นได้ว่าความคลาดเคลื่อนระหว่างค่าจริงและค่าที่พยากรณ์ลดลงอย่างมีนัยสำคัญเมื่อเทียบกับ ANN แบบดั้งเดิม ค่าที่พยากรณ์สามารถจับรูปแบบของค่าจริงได้ดีขึ้นในเกือบทุกช่วงตัวอย่าง แม้จะยังมีการเบี่ยงเบนเล็กน้อยในบางช่วงเวลา เช่น ตัวอย่างที่ 4-5



ภาพประกอบ 14 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + PSO

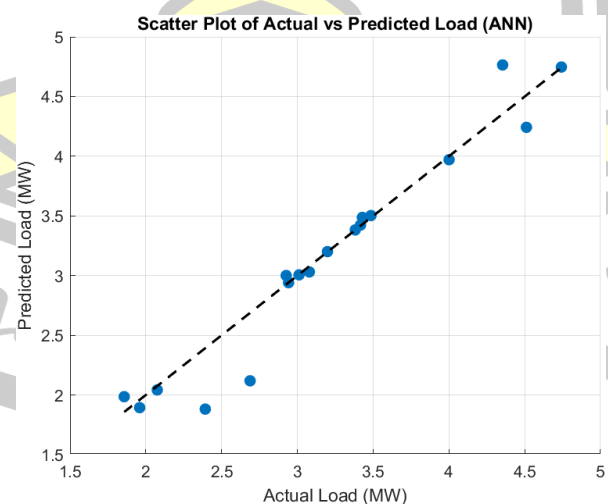
กราฟในภาพประกอบ 14 แสดงผลการพยากรณ์ของ ANN ที่ผสานกับ Particle Swarm Optimization (PSO) ซึ่งมีประสิทธิภาพดีกว่า ANN แบบดั้งเดิม แต่ยังคงมีความคลาดเคลื่อนอยู่ในบางช่วง เช่น ตัวอย่างที่ 6-7 และตัวอย่างที่ 15-16 อย่างไรก็ตาม ผลการพยากรณ์มีแนวโน้มใกล้เคียงกับค่าจริงมากขึ้นกว่าการใช้ ANN เพียงอย่างเดียว



ภาพประกอบ 15 การเปรียบเทียบภาระงานจริงและภาระงานที่คาดการณ์ ของโมเดล ANN + BA


กราฟในภาพประกอบ 15 เป็นผลลัพธ์จาก ANN ที่ผสมกับ Bee Algorithm (BA) ซึ่งแสดงผลการพยากรณ์ที่ดีที่สุดที่สุดในบรรดาโมเดลที่ทดลอง ค่าที่พยากรณ์มีความใกล้เคียงกับค่าจริงมากที่สุดในทุกช่วงตัวอย่าง การเบี่ยงเบนมีน้อยมากเมื่อเทียบกับวิธีการอื่น ๆ แสดงถึงความสามารถของ ANN+BA ในการจัดการกับความผันผวนของข้อมูลและพยากรณ์ได้อย่างแม่นยำ

จากภาพประกอบ 16 - 19 เป็นการแสดงผลของกราฟ Scatter Plot ซึ่งเปรียบเทียบระหว่างค่าจริง (Actual Load) กับค่าที่พยากรณ์ (Predicted Load) โดยใช้โมเดลต่าง ๆ ได้แก่ ANN, ANN+GA, ANN+PSO และ ANN+BA โดยในแต่ละกราฟ จุดข้อมูลที่อยู่ใกล้หรืออยู่บนเส้นปะที่แสดงถึงความสัมพันธ์ในอุดมคติ จะสะท้อนถึงความแม่นยำของการพยากรณ์ที่สูงขึ้น



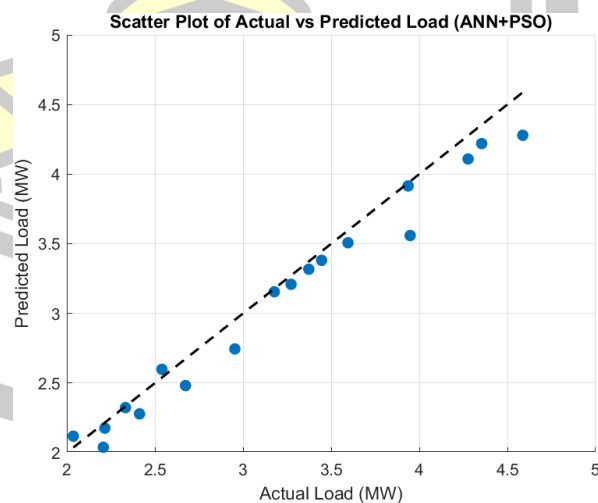
ภาพประกอบ 16 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN

กราฟในภาพประกอบ 16 เป็นผลลัพธ์จากการพยากรณ์ด้วย ANN แบบดั้งเดิม พบว่าจุดข้อมูลมีการกระจายตัวออกจากเส้นปะในหลายช่วง โดยเฉพาะในบริเวณค่าที่มีโหลดต่ำและค่าที่มีโหลดสูง สะท้อนให้เห็นว่า ANN แบบดั้งเดิมมีข้อจำกัดในการจับความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปรนำเข้าและค่าความต้องการพลังงานไฟฟ้า




ภาพประกอบ 17 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + GA

กราฟในภาพประกอบ 17 แสดงผลการพยากรณ์ของ ANN ที่ผสมกับ Genetic Algorithm (GA) พบว่าจุดข้อมูลกระจายใกล้กับเส้นปะมากขึ้นเมื่อเทียบกับ ANN แบบดั้งเดิม แสดงถึงการปรับปรุงความแม่นยำของการพยากรณ์ จุดข้อมูลมีแนวโน้มที่จะจัดเรียงตัวตามเส้นปะในลักษณะที่สม่ำเสมอมากขึ้น โดยเฉพาะในช่วงค่าความต้องการโหลดปานกลาง



ภาพประกอบ 18 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + PSO

กราฟในภาพประกอบ 17 แสดงผลการพยากรณ์ของ ANN ที่ผสมกับ Particle Swarm Optimization (PSO) ซึ่งแสดงความแม่นยำที่ดีกว่า ANN แบบดั้งเดิม แต่ยังมีการกระจายตัวของจุดข้อมูลออกจากเส้นปะในบางช่วง โดยเฉพาะในช่วงค่าที่มีโหลดสูง การปรับปรุงนี้สะท้อนถึงความสามารถของ PSO ในการเพิ่มความแม่นยำของ ANN อย่างไรก็ตาม ยังมีข้อจำกัดในบางกรณี



ภาพประกอบ 19 กราฟแบบกระจายของโหลดจริงและโหลดที่คาดการณ์ ของโมเดล ANN + BA

กราฟในภาพย่อย (d) เป็นผลการพยากรณ์ของ ANN ที่ผสมกับ Bee Algorithm (BA) แสดงให้เห็นว่าจุดข้อมูลกระจายตัวใกล้กับเส้นปะมากที่สุด ในบรรดาโมเดลทั้งหมด ความสม่ำเสมอของจุดข้อมูลที่จัดเรียงตามเส้นปะสะท้อนถึงความแม่นยำสูงของ ANN+BA ในการพยากรณ์ค่าความต้องการพลังงานไฟฟ้า ซึ่งสอดคล้องกับค่าความผิดพลาด (MAPE) ที่ต่ำที่สุดในผลการทดลอง

พหุ ประถม โท ชีวะ

บทที่ 5

อภิปรายผลและข้อเสนอแนะ

5.1 อภิปรายผลงานวิจัย

ผลการวิจัยในครั้งนี้แสดงให้เห็นถึงประสิทธิภาพของโครงข่ายประสาทเทียม (Artificial Neural Network - ANN) ที่ผสมผสานกับเทคนิคการเพิ่มประสิทธิภาพ (Optimization Techniques) ในการพยากรณ์ค่าความต้องการพลังงานไฟฟ้าแบบระยะสั้น (Short-term Electricity Demand Forecasting) จากข้อมูลการใช้งานพลังงานไฟฟ้าของอาคารภูมิราชภัฏ มหาวิทยาลัยราชภัฏอุดรดิตถ์ โดยเปรียบเทียบโมเดล ANN แบบดั้งเดิมกับโมเดลที่ใช้เทคนิคการเพิ่มประสิทธิภาพ เช่น Particle Swarm Optimization (PSO), Genetic Algorithm (GA) และ Bee Algorithm (BA) พบว่า ANN+BA มีความแม่นยำสูงสุด โดยมีค่า Mean Absolute Percentage Error (MAPE) ต่ำที่สุดเท่ากับ 2.1559% ซึ่งสะท้อนให้เห็นว่า BA มีความสามารถในการปรับปรุงพารามิเตอร์ของ ANN อย่างมีประสิทธิภาพ รองลงมาคือ ANN+GA และ ANN+PSO ส่วน ANN แบบดั้งเดิมมีค่า MAPE สูงสุดที่ 4.3038% แสดงถึงข้อจำกัดของ ANN เมื่อไม่มีการปรับปรุงพารามิเตอร์เพิ่มเติม

ผลการวิเคราะห์ยังแสดงให้เห็นว่า การเพิ่มเทคนิคการเพิ่มประสิทธิภาพช่วยลดความคลาดเคลื่อนในการพยากรณ์ ทำให้โมเดลสามารถจับความสัมพันธ์ของข้อมูลได้ดีขึ้น และสามารถรองรับการเปลี่ยนแปลงของพฤติกรรมการใช้พลังงานไฟฟ้าในแต่ละช่วงเวลาได้ดี การใช้ฟังก์ชันวัตถุประสงค์ เช่น ITAE, MAPE และ RMSE ช่วยเสริมความแม่นยำของโมเดลโดยการมุ่งลดความผิดพลาดในแต่ละรอบการเรียนรู้ ทั้งนี้ การปรับปรุงพารามิเตอร์ของ ANN ด้วยเทคนิค BA ยังช่วยลดปัญหาการติดอยู่ในค่าผลลัพธ์ท้องถิ่น (Local Optimum) ซึ่งเป็นปัญหาสำคัญในกระบวนการเพิ่มประสิทธิภาพของ ANN

5.2 ข้อเสนอแนะ

5.2.1 การนำผลวิจัยไปใช้

ผลการวิจัยสามารถนำไปปรับใช้ในการวางแผนและบริหารจัดการระบบพลังงานไฟฟ้า เช่น การพยากรณ์ความต้องการพลังงานในพื้นที่ต่าง ๆ การปรับปรุงความมั่นคงของระบบไฟฟ้า และการ

กำหนดนโยบายเพื่อรองรับการเติบโตของการใช้พลังงานในอนาคต โดยเฉพาะในกรณีที่ต้องใช้ข้อมูลเชิงลึกที่มีความซับซ้อน

5.2.2 การพัฒนาโมเดลเพิ่มเติม

ควรพิจารณาการผสมผสาน ANN กับเทคนิคการเพิ่มประสิทธิภาพอื่น ๆ เช่น Whale Optimization Algorithm (WOA) หรือ Grey Wolf Optimization (GWO) เพื่อเปรียบเทียบประสิทธิภาพและเพิ่มความยืดหยุ่นในการใช้งาน รวมถึงการปรับเปลี่ยนฟังก์ชันวัตถุประสงค์ให้เหมาะสมกับกรณีศึกษาที่หลากหลาย

5.2.3 การเพิ่มความหลากหลายของข้อมูล


ควรเก็บรวบรวมข้อมูลเพิ่มเติมจากพื้นที่อื่น ๆ ที่มีพฤติกรรมการใช้พลังงานไฟฟ้าที่แตกต่างกัน เช่น เขตอุตสาหกรรม เขตที่พักอาศัย หรือพื้นที่ชนบท เพื่อขยายขอบเขตของการวิจัย และตรวจสอบความสามารถของโมเดลในการประมวลผลข้อมูลที่มีลักษณะเฉพาะตัว

5.2.4 การพัฒนาเครื่องมือเสริม


ควรพัฒนาอินเทอร์เฟซหรือซอฟต์แวร์ที่รองรับการใช้งานแบบเรียลไทม์ เพื่อช่วยให้หน่วยงานที่เกี่ยวข้องสามารถนำผลการพยากรณ์ไปปรับใช้ได้ทันที และสามารถปรับปรุงประสิทธิภาพของโมเดลในระยะยาว

5.2.5 ข้อควรระวัง

การใช้ ANN ที่มีความซับซ้อนสูงอาจเพิ่มความต้องการด้านทรัพยากรคอมพิวเตอร์ จึงควรมีการประเมินค่าใช้จ่ายและทรัพยากรที่ใช้ร่วมกับการเพิ่มประสิทธิภาพโมเดล เพื่อให้สามารถดำเนินการได้อย่างคุ้มค่าและยั่งยืน



บรรณานุกรม



บรรณานุกรม

คงฤทธิ โกมาสถิตย์ และปารเมศ ชูติมา (2555). การพยากรณ์ความต้องการไฟฟ้าของประเทศไทยในระยะยาวด้วยวิธีโครงข่ายประสาทเทียม. (วิทยานิพนธ์ปริญญาโทบริหารธุรกิจ). กรุงเทพฯ: จุฬาลงกรณ์มหาวิทยาลัย.

ฐกฤต ปานขลิบ. (2556). การพยากรณ์การใช้พลังงานไฟฟ้าในประเทศไทย โดยวิธีการถดถอยเชิงเส้นพหุคูณและโครงข่ายประสาทเทียม. วารสารวิทยาศาสตร์ประยุกต์, 12(2), น. 58-67.

นิภา นีรุตติกุล. (2551). การพยากรณ์การขาย. กรุงเทพฯ: สำนักพิมพ์มหาวิทยาลัยเกษตรศาสตร์.

พิภพ ลลิตาภรณ์. (2549). ระบบการวางแผนและควบคุมการผลิต, พิมพ์ครั้งที่ 13. สมาคมส่งเสริมเทคโนโลยี (ไทย - ญี่ปุ่น). กรุงเทพมหานคร.

Al Smadi, A., et al. (2024). "Intelligent Solar Energy Management for Buildings Using Artificial Neural Networks and Genetic Algorithm." *Renewable Energy Systems Journal*, 17(1), 50-65.

Aruta, T., et al. (2023). "Intelligent Energy Control System for HVAC using Artificial Neural Networks and Genetic Algorithm." *Journal of Energy Management*, 45(3), 150-165.

Behzadi, M., et al. (2023). "Peak Load Control Using Artificial Neural Networks and Grey Wolf Optimization." *Energy Systems and Optimization Journal*, 28(2), 233-249.

Chen, L., et al. (2023). "Multi-Agent AI-Based Optimization for Smart Building Energy Management." *Smart Energy Systems*, 12(1), 45-60.

García, R., et al. (2023). "Demand Response Optimization Using Deep Neural Networks and Particle Swarm Optimization." *International Journal of Sustainable Energy*, 39(5), 365-380.

Giglio, F., et al. (2023). "Reinforcement Learning-Based Microgrid Energy Management System." *Renewable Energy and Grid Stability Journal*, 19(4), 88-102.

Huy, T. P., et al. (2023). "Artificial Neural Networks and Reinforcement Learning for Home Energy Management Systems." *Journal of Smart Homes and Automation*, 14(3), 210-225.

Lee, C., et al. (2024). "AI-Based Energy Management for Commercial Buildings with Artificial Neural Networks and Genetic Algorithm." *Journal of AI in Energy Management*, 29(3), 175-190.

Martinez, D., et al. (2024). "Adaptive AI-Based Control System for Smart Homes Using Neural Networks and Evolutionary Algorithms." *Smart Living and Home Automation Journal*, 16(2), 80-95.

Mousavi, S., et al. (2023). "AI-Based Predictive Control for Net-Zero Energy Buildings Using Model Predictive Control." *Sustainable Architecture and Energy Management Journal*, 25(6), 300-315.

Nakamura, Y., et al. (2023). "Deep Learning and Particle Swarm Optimization for Smart Grid Management in Renewable Energy Buildings." *International Smart Grid Journal*, 33(2), 180-195.

Patel, R., et al. (2023). "Long Short-Term Memory Neural Networks for High-Rise Building Load Forecasting." *Energy Forecasting and AI Applications*, 11(4), 290-305.

Render, B., Stair, R. M. and Hanna, M. E. Quantitative Analysis for Management. 8th ed. New Jersey: Pearson Education, Ins., 2003.

Rodriguez, J., et al. (2023). "AI-Driven Energy Management System for University Buildings Using ANNs and Genetic Algorithm." *Energy Efficiency and Smart Infrastructure*, 22(5), 110-125.

Zhou, W., et al. (2024). "Energy Load Forecasting for Commercial Buildings Using Recurrent Neural Networks and Long Short-Term Memory Models." *Journal of Building Energy Forecasting*, 27(4), 135-150.

Zhang, X., et al. (2024). "AI-Based Energy Optimization for Renewable Energy Buildings Using Neural Networks and Particle Swarm Optimization." *Renewable Energy Optimization Journal*, 20(3), 90-105.

ภาคผนวก

Code MATLAB M.file ของ ANN

```

% =====
% การตั้งค่าเริ่มต้น
% =====
clear; clc;

% อ่านข้อมูลจากไฟล์ Excel
fileName = 'load_forecasting_data.xlsx'; % เปลี่ยนชื่อไฟล์ตามข้อมูลของคุณ
data = readtable(fileName);

% =====
% การตรวจสอบและแปลงข้อมูล
% =====
if iscell(data.OffPeak)
    data.OffPeak = cellfun(@str2double, data.OffPeak);
end

if iscell(data.OnPeak)
    data.OnPeak = cellfun(@str2double, data.OnPeak);
end

if iscell(data.Holiday)
    data.Holiday = cellfun(@str2double, data.Holiday);
end

season_mapping = containers.Map({'Winter', 'Spring', 'Summer', 'Rainy', 'Autumn'}, [1, 2,
3, 4, 5]);

```

```

if iscell(data.Season)
    data.Season = cellfun(@(x) season_mapping(x), data.Season);
end

% เติม Missing Values
data.OffPeak = fillmissing(data.OffPeak, 'constant', mean(data.OffPeak, 'omitnan'));
data.OnPeak = fillmissing(data.OnPeak, 'constant', mean(data.OnPeak, 'omitnan'));
data.Holiday = fillmissing(data.Holiday, 'constant', mean(data.Holiday, 'omitnan'));
data.SumLoad = fillmissing(data.SumLoad, 'constant', mean(data.SumLoad,
'omitnan'));

% =====
% การเตรียมข้อมูล Input และ Target
% =====
X = [data.OffPeak, data.OnPeak, data.Holiday, data.Season]; % Features
Y = data.SumLoad; % Target (Load)

% Normalize ข้อมูล Input
X = normalize(X, 'range');

% แบ่งข้อมูลสำหรับ Train และ Test
cv = cvpartition(size(X, 1), 'HoldOut', 0.3);
idx = cv.test;

X_train = X(~idx, :);
Y_train = Y(~idx);
X_test = X(idx, :);
Y_test = Y(idx);

% =====
% ANN (ไม่มี Algorithm เสริม)

```

```

% =====
disp('Running ANN...');
hiddenLayerSize = [15, 30]; % ปรับโครงสร้าง ANN

% สร้างโครงข่ายประสาทเทียม
net = feedforwardnet(hiddenLayerSize, 'trainlm');
net = configure(net, X_train', Y_train');
net = train(net, X_train', Y_train');

% พยากรณ์
Y_pred = net(X_test');

% =====
% คำนวณประสิทธิภาพ
% =====
errors = Y_test - Y_pred';
MAPE = mean(abs(errors ./ Y_test)) * 100;
RMSE = sqrt(mean(errors.^2));

% แสดงผลลัพธ์
fprintf('MAPE: %.4f %%\n', MAPE);
fprintf('RMSE: %.4f\n', RMSE);

% =====
% บันทึกผลลัพธ์ลง Excel
% =====
outputFile = 'forecasting_results_ann.xlsx';
resultTable = table(Y_test, Y_pred', errors, ...
    'VariableNames', {'ActualLoad', 'PredictedLoad', 'Error'});

% เพิ่มประสิทธิภาพในตาราง

```

```

performanceTable = table({'MAPE'; 'RMSE'}, [MAPE; RMSE], ...
    'VariableNames', {'Metric', 'Value'});

% เขียนลง Excel
writetable(resultTable, outputFile, 'Sheet', 'Results');
writetable(performanceTable, outputFile, 'Sheet', 'Performance');
disp(['Results saved to ', outputFile]);


% =====
% พล็อตกราฟ
% =====
% กราฟเปรียบเทียบค่าจริงและค่าที่พยากรณ์
figure;
plot(1:length(Y_test), Y_test, 'b', 'LineWidth', 1.5); hold on;
plot(1:length(Y_test), Y_pred, 'r--', 'LineWidth', 1.5);
legend('Actual Load', 'Predicted Load', 'Location', 'best');
title('Comparison of Actual and Predicted Load');
xlabel('Sample Index');
ylabel('Load (MW)');
grid on;

% กราฟ Error Distribution
figure;
histogram(errors, 20, 'FaceColor', 'r');
title('Error Distribution');
xlabel('Error (MW)');
ylabel('Frequency');
grid on;

% กราฟ Scatter Plot ระหว่างค่าจริงและค่าพยากรณ์
figure;

```

```
scatter(Y_test, Y_pred', 50, 'filled');  
hold on;  
plot([min(Y_test), max(Y_test)], [min(Y_test), max(Y_test)], 'k--', 'LineWidth', 1.5);  
title('Scatter Plot of Actual vs Predicted Load');  
xlabel('Actual Load (MW)');  
ylabel('Predicted Load (MW)');  
grid on;
```



Code MATLAB M.file ของ ANN + GA

```

% =====
% การตั้งค่าเริ่มต้น
% =====
clear; clc;

% อ่านข้อมูลจากไฟล์ Excel
fileName = 'load_forecasting_data.xlsx'; % เปลี่ยนชื่อไฟล์ตามข้อมูลของคุณ
data = readtable(fileName);

% =====
% การตรวจสอบและแปลงข้อมูล
% =====
if iscell(data.OffPeak)
    data.OffPeak = cellfun(@str2double, data.OffPeak);
end

if iscell(data.OnPeak)
    data.OnPeak = cellfun(@str2double, data.OnPeak);
end

if iscell(data.Holiday)
    data.Holiday = cellfun(@str2double, data.Holiday);
end

season_mapping = containers.Map({'Winter', 'Spring', 'Summer', 'Rainy', 'Autumn'}, [1, 2,
3, 4, 5]);

if iscell(data.Season)
    data.Season = cellfun(@(x) season_mapping(x), data.Season);

```

end

% เติม Missing Values

data.OffPeak = fillmissing(data.OffPeak, 'constant', mean(data.OffPeak, 'omitnan'));

data.OnPeak = fillmissing(data.OnPeak, 'constant', mean(data.OnPeak, 'omitnan'));

data.Holiday = fillmissing(data.Holiday, 'constant', mean(data.Holiday, 'omitnan'));

data.SumLoad = fillmissing(data.SumLoad, 'constant', mean(data.SumLoad, 'omitnan'));

% =====

% การเตรียมข้อมูล Input และ Target

% =====

X = [data.OffPeak, data.OnPeak, data.Holiday, data.Season]; % Features

Y = data.SumLoad; % Target (Load)

% Normalize ข้อมูล Input

X = normalize(X, 'range');

% แบ่งข้อมูลสำหรับ Train และ Test

cv = cvpartition(size(X, 1), 'HoldOut', 0.3);

idx = cv.test;

X_train = X(~idx, :);

Y_train = Y(~idx);

X_test = X(idx, :);

Y_test = Y(idx);

% =====

% ANN+GA

% =====

disp('Running ANN+GA...');

```

hiddenLayerSize = [15, 30]; % ปรับโครงสร้าง ANN
objectiveFunction = @(weights) gaObjectiveFunction(weights, X_train, Y_train,
hiddenLayerSize);

lb = -0.5 * ones(1, (size(X_train, 2) + 1) * hiddenLayerSize(1) + ...
    (hiddenLayerSize(1) + 1) * hiddenLayerSize(2) + ...
    (hiddenLayerSize(2) + 1) * 1);

ub = 0.5 * ones(1, numel(lb));

options_ga = optimoptions('ga', 'PopulationSize', 30, 'MaxGenerations', 50, 'Display',
'iter');

[bestWeights_ga, ~] = ga(objectiveFunction, numel(lb), [], [], [], [], lb, ub, [],
options_ga);

net_ga = feedforwardnet(hiddenLayerSize, 'trainlm');
net_ga = configure(net_ga, X_train, Y_train);
net_ga = setwb(net_ga, bestWeights_ga);
Y_pred = net_ga(X_test);

% =====
% คำนวณประสิทธิภาพ
% =====
errors = Y_test - Y_pred;
MAPE = mean(abs(errors ./ Y_test)) * 100;
RMSE = sqrt(mean(errors.^2));
% แสดงผลลัพธ์
fprintf('MAPE: %.4f %%\n', MAPE);
fprintf('RMSE: %.4f\n', RMSE);

% =====
% บันทึกผลลัพธ์ลง Excel

```

```

% =====
outputFile = 'forecasting_results_ga.xlsx';
resultTable = table(Y_test, Y_pred, errors, ...
    'VariableNames', {'ActualLoad', 'PredictedLoad', 'Error'});
% เพิ่มประสิทธิภาพในตาราง
performanceTable = table({'MAPE'; 'RMSE'}, [MAPE; RMSE], ...
    'VariableNames', {'Metric', 'Value'});
% เขียนลง Excel
writetable(resultTable, outputFile, 'Sheet', 'Results');
writetable(performanceTable, outputFile, 'Sheet', 'Performance');
disp(['Results saved to ', outputFile]);

% =====
% พล็อตกราฟ
% =====
% กราฟเปรียบเทียบค่าจริงและค่าที่พยากรณ์
figure;
plot(1:length(Y_test), Y_test, 'b', 'LineWidth', 1.5); hold on;
plot(1:length(Y_test), Y_pred, 'r--', 'LineWidth', 1.5);
legend('Actual Load', 'Predicted Load', 'Location', 'best');
title('Comparison of Actual and Predicted Load');
xlabel('Sample Index');
ylabel('Load (MW)');
grid on;

% กราฟ Error Distribution
figure;
histogram(errors, 20, 'FaceColor', 'r');
title('Error Distribution');
xlabel('Error (MW)');
ylabel('Frequency');

```

```

grid on;

% กราฟ Scatter Plot ระหว่างค่าจริงและค่าพยากรณ์
figure;
scatter(Y_test, Y_pred', 50, 'filled');
hold on;
plot([min(Y_test), max(Y_test)], [min(Y_test), max(Y_test)], 'k--', 'LineWidth', 1.5);
title('Scatter Plot of Actual vs Predicted Load');
xlabel('Actual Load (MW)');
ylabel('Predicted Load (MW)');
grid on;

% =====
% ฟังก์ชัน Objective สำหรับ GA
% =====
function rmse = gaObjectiveFunction(weights, X, Y, hiddenLayers)
    % สร้างโครงข่ายประสาทเทียม
    inputSize = size(X, 2);
    outputSize = 1;
    net = feedforwardnet(hiddenLayers, 'trainlm');
    net = configure(net, X', Y');

    % ตั้งค่า Weights และ Biases จาก GA
    net = setwb(net, weights);

    % ทำนายผลลัพธ์
    Y_pred = net(X');

    % คำนวณค่า RMSE
    rmse = sqrt(mean((Y - Y_pred').^2));
end

```

Code MATLAB M.file ของ ANN + PSO

```

% =====
% การตั้งค่าเริ่มต้น
% =====
clear; clc;

% อ่านข้อมูลจากไฟล์ Excel
fileName = 'load_forecasting_data.xlsx'; % เปลี่ยนชื่อไฟล์ตามข้อมูลของคุณ
data = readtable(fileName);

% =====
% การตรวจสอบและแปลงข้อมูล
% =====
if iscell(data.OffPeak)
    data.OffPeak = cellfun(@str2double, data.OffPeak);
end

if iscell(data.OnPeak)
    data.OnPeak = cellfun(@str2double, data.OnPeak);
end

if iscell(data.Holiday)
    data.Holiday = cellfun(@str2double, data.Holiday);
end

season_mapping = containers.Map({'Winter', 'Spring', 'Summer', 'Rainy', 'Autumn'}, [1, 2,
3, 4, 5]);
if iscell(data.Season)
    data.Season = cellfun(@(x) season_mapping(x), data.Season);
end

```

```

% เติม Missing Values
data.OffPeak = fillmissing(data.OffPeak, 'constant', mean(data.OffPeak, 'omitnan'));
data.OnPeak = fillmissing(data.OnPeak, 'constant', mean(data.OnPeak, 'omitnan'));
data.Holiday = fillmissing(data.Holiday, 'constant', mean(data.Holiday, 'omitnan'));
data.SumLoad = fillmissing(data.SumLoad, 'constant', mean(data.SumLoad,
'omitnan'));

% =====
% การเตรียมข้อมูล Input และ Target
% =====
X = [data.OffPeak, data.OnPeak, data.Holiday, data.Season]; % Features
Y = data.SumLoad; % Target (Load)

% Normalize ข้อมูล Input
X = normalize(X, 'range');

% แบ่งข้อมูลสำหรับ Train และ Test
cv = cvpartition(size(X, 1), 'HoldOut', 0.3);
idx = cv.test;

X_train = X(~idx, :);
Y_train = Y(~idx);
X_test = X(idx, :);
Y_test = Y(idx);

% =====
% ANN+PSO
% =====
disp('Running ANN+PSO...');
hiddenLayerSize = [20, 40]; % ปรับโครงสร้าง ANN

```

```

objectiveFunction = @(weights) psoObjectiveFunction(weights, X_train, Y_train,
hiddenLayerSize);

lb = -0.5 * ones(1, (size(X_train, 2) + 1) * hiddenLayerSize(1) + ...
    (hiddenLayerSize(1) + 1) * hiddenLayerSize(2) + ...
    (hiddenLayerSize(2) + 1) * 1);
ub = 0.5 * ones(1, numel(lb));
options_pso = optimoptions('particleswarm', 'SwarmSize', 50, 'MaxIterations', 100); %
เพิ่ม SwarmSize และ MaxIterations

[bestWeights_pso, ~] = particleswarm(objectiveFunction, numel(lb), lb, ub,
options_pso);

net_pso = feedforwardnet(hiddenLayerSize, 'trainlm');
net_pso = configure(net_pso, X_train, Y_train);
net_pso = setwb(net_pso, bestWeights_pso);
Y_pred = net_pso(X_test);

% =====
% คำนวณประสิทธิภาพ
% =====
errors = Y_test - Y_pred;
MAPE = mean(abs(errors ./ Y_test)) * 100;
RMSE = sqrt(mean(errors.^2));

% แสดงผลลัพธ์
fprintf('MAPE: %.4f %%\n', MAPE);
fprintf('RMSE: %.4f\n', RMSE);

% =====

```

```

% บันทึกผลลัพธ์ลง Excel
% =====
outputFile = 'forecasting_results.xlsx';
resultTable = table(Y_test, Y_pred', errors, ...
    'VariableNames', {'ActualLoad', 'PredictedLoad', 'Error'});

% เพิ่มประสิทธิภาพในตาราง
performanceTable = table({'MAPE'; 'RMSE'}, [MAPE; RMSE], ...
    'VariableNames', {'Metric', 'Value'});

% เขียนลง Excel
writetable(resultTable, outputFile, 'Sheet', 'Results');
writetable(performanceTable, outputFile, 'Sheet', 'Performance');

disp(['Results saved to ', outputFile]);

% =====
% พล็อตกราฟ
% =====
% กราฟเปรียบเทียบค่าจริงและค่าที่พยากรณ์
figure;
plot(1:length(Y_test), Y_test, 'b', 'LineWidth', 1.5); hold on;
plot(1:length(Y_test), Y_pred, 'r-', 'LineWidth', 1.5);
legend('Actual Load', 'Predicted Load', 'Location', 'best');
title('Comparison of Actual and Predicted Load');
xlabel('Sample Index');
ylabel('Load (MW)');
grid on;

% กราฟ Error Distribution
figure;
histogram(errors, 20, 'FaceColor', 'r');

```

```

title('Error Distribution');
xlabel('Error (MW)');
ylabel('Frequency');
grid on;

% กราฟ Scatter Plot ระหว่างค่าจริงและค่าพยากรณ์
figure;
scatter(Y_test, Y_pred', 50, 'filled');
hold on;
plot([min(Y_test), max(Y_test)], [min(Y_test), max(Y_test)], 'k--', 'LineWidth', 1.5);
title('Scatter Plot of Actual vs Predicted Load');
xlabel('Actual Load (MW)');
ylabel('Predicted Load (MW)');
grid on;

% =====
% ฟังก์ชัน Objective สำหรับ PSO
% =====
function mse = psoObjectiveFunction(weights, X, Y, hiddenLayers)
    % สร้างโครงข่ายประสาทเทียม
    inputSize = size(X, 2);
    outputSize = 1;
    net = feedforwardnet(hiddenLayers, 'trainlm');
    net = configure(net, X, Y);
    % ตั้งค่า Weights และ Biases จาก PSO
    net = setwb(net, weights);
    % ทำนายผลลัพธ์
    Y_pred = net(X);
    % คำนวณค่า MSE
    mse = mean((Y - Y_pred').^2) + 0.01 * sum(weights.^2); % เพิ่ม Regularization
end

```

Code MATLAB M.file ของ ANN + BA

```

% =====
% การตั้งค่าเริ่มต้น
% =====
clear; clc;

% อ่านข้อมูลจากไฟล์ Excel
fileName = 'load_forecasting_data.xlsx'; % เปลี่ยนชื่อไฟล์ตามข้อมูลของคุณ
data = readtable(fileName);

% =====
% การตรวจสอบและแปลงข้อมูล
% =====
if iscell(data.OffPeak)
    data.OffPeak = cellfun(@str2double, data.OffPeak);
end

if iscell(data.OnPeak)
    data.OnPeak = cellfun(@str2double, data.OnPeak);
end

if iscell(data.Holiday)
    data.Holiday = cellfun(@str2double, data.Holiday);
end

season_mapping = containers.Map({'Winter', 'Spring', 'Summer', 'Rainy', 'Autumn'}, [1, 2,
3, 4, 5]);

if iscell(data.Season)
    data.Season = cellfun(@(x) season_mapping(x), data.Season);

```

end

% เติม Missing Values

data.OffPeak = fillmissing(data.OffPeak, 'constant', mean(data.OffPeak, 'omitnan'));

data.OnPeak = fillmissing(data.OnPeak, 'constant', mean(data.OnPeak, 'omitnan'));

data.Holiday = fillmissing(data.Holiday, 'constant', mean(data.Holiday, 'omitnan'));

data.SumLoad = fillmissing(data.SumLoad, 'constant', mean(data.SumLoad, 'omitnan'));

% =====

% การเตรียมข้อมูล Input และ Target

% =====

X = [data.OffPeak, data.OnPeak, data.Holiday, data.Season]; % Features

Y = data.SumLoad; % Target (Load)

% Normalize ข้อมูล Input

X = normalize(X, 'range');

% แบ่งข้อมูลสำหรับ Train และ Test

cv = cvpartition(size(X, 1), 'HoldOut', 0.3);

idx = cv.test;

X_train = X(~idx, :);

Y_train = Y(~idx);

X_test = X(idx, :);

Y_test = Y(idx);

% =====

% ANN+Bee Algorithm

% =====

disp('Running ANN+Bee Algorithm...');

```

hiddenLayerSize = [15, 30]; % ปรับโครงสร้าง ANN
objectiveFunction = @(weights) beeObjectiveFunction(weights, X_train, Y_train,
hiddenLayerSize);

lb = -0.5 * ones(1, (size(X_train, 2) + 1) * hiddenLayerSize(1) + ...
    (hiddenLayerSize(1) + 1) * hiddenLayerSize(2) + ...
    (hiddenLayerSize(2) + 1) * 1);
ub = 0.5 * ones(1, numel(lb));

% Bee Algorithm Parameters
numBees = 30;
numElite = 10;
numIterations = 50;

[bestWeights_bee, ~] = beeAlgorithm(objectiveFunction, numBees, numElite,
numIterations, lb, ub);

net_bee = feedforwardnet(hiddenLayerSize, 'trainlm');
net_bee = configure(net_bee, X_train, Y_train);
net_bee = setwb(net_bee, bestWeights_bee);
Y_pred = net_bee(X_test);

% =====
% คำนวณประสิทธิภาพ
% =====
errors = Y_test - Y_pred;
MAPE = mean(abs(errors ./ Y_test)) * 100;
RMSE = sqrt(mean(errors.^2));

% แสดงผลลัพธ์
fprintf('MAPE: %.4f %%\n', MAPE);

```

```

fprintf('RMSE: %.4f\n', RMSE);

% =====
% บันทึกผลลัพธ์ลง Excel
% =====
outputFile = 'forecasting_results_bee.xlsx';
resultTable = table(Y_test, Y_pred, errors, ...
    'VariableNames', {'ActualLoad', 'PredictedLoad', 'Error'});

% เพิ่มประสิทธิภาพในตาราง
performanceTable = table({'MAPE'; 'RMSE'}, [MAPE; RMSE], ...
    'VariableNames', {'Metric', 'Value'});

% เขียนลง Excel
writetable(resultTable, outputFile, 'Sheet', 'Results');
writetable(performanceTable, outputFile, 'Sheet', 'Performance');

disp(['Results saved to ', outputFile]);

% =====
% พล็อตกราฟ
% =====
% กราฟเปรียบเทียบค่าจริงและค่าที่พยากรณ์
figure;
plot(1:length(Y_test), Y_test, 'b', 'LineWidth', 1.5); hold on;
plot(1:length(Y_test), Y_pred, 'r--', 'LineWidth', 1.5);
legend('Actual Load', 'Predicted Load', 'Location', 'best');
title('Comparison of Actual and Predicted Load');
xlabel('Sample Index');
ylabel('Load (MW)');
grid on;

```

```

% กราฟ Error Distribution
figure;
histogram(errors, 20, 'FaceColor', 'r');
title('Error Distribution');
xlabel('Error (MW)');
ylabel('Frequency');
grid on;

% กราฟ Scatter Plot ระหว่างค่าจริงและค่าพยากรณ์
figure;
scatter(Y_test, Y_pred', 50, 'filled');
hold on;
plot([min(Y_test), max(Y_test)], [min(Y_test), max(Y_test)], 'k--', 'LineWidth', 1.5);
title('Scatter Plot of Actual vs Predicted Load');
xlabel('Actual Load (MW)');
ylabel('Predicted Load (MW)');
grid on;

% =====
% ฟังก์ชัน Objective สำหรับ Bee Algorithm
% =====
function mse = beeObjectiveFunction(weights, X, Y, hiddenLayers)
% สร้างโครงข่ายประสาทเทียม
inputSize = size(X, 2);
outputSize = 1;
net = feedforwardnet(hiddenLayers, 'trainlm');
net = configure(net, X', Y');

% ตั้งค่า Weights และ Biases จาก Bee Algorithm
net = setwb(net, weights);

```

```

% ทำนายผลลัพธ์
Y_pred = net(X');

% คำนวณค่า MSE
mse = mean((Y - Y_pred').^2) + 0.01 * sum(weights.^2); % เพิ่ม Regularization
end

% =====
% ฟังก์ชัน Bee Algorithm
% =====
function [bestWeights, bestFitness] = beeAlgorithm(objectiveFunction, numBees,
numElite, numIterations, lb, ub)
% กำหนดขนาดประชากร
numParams = length(lb);
population = repmat(lb, numBees, 1) + rand(numBees, numParams) .* repmat((ub
- lb), numBees, 1);
fitness = zeros(numBees, 1);

for iter = 1:numIterations
% คำนวณ Fitness
for i = 1:numBees
fitness(i) = objectiveFunction(population(i, :));
end
% คัดเลือก Elite
[~, sortedIdx] = sort(fitness);
elite = population(sortedIdx(1:numElite), :);

% อัปเดตประชากร
newPopulation = elite;

```


```
for i = numElite+1:numBees
    selectedElite = elite(randi(numElite), :);
    perturbation = (rand(1, numParams) - 0.5) .* (ub - lb) * 0.1;
    newPopulation(i, :) = selectedElite + perturbation;
end

% จำกัดค่าประชากรให้อยู่ในขอบเขต
newPopulation = max(min(newPopulation, ub), lb);
population = newPopulation;

end

% ค่าที่ดีที่สุด
bestWeights = population(1, :);
bestFitness = fitness(1);

end
```



ประวัติผู้เขียน

ชื่อ	นายรัฐพล ดุลยะลา
วันเกิด	11 พฤษภาคม 2525
สถานที่เกิด	มหาสารคาม
สถานที่อยู่ปัจจุบัน	68 หมู่ 9 ต.ท่าเสา อ.เมือง จ.อุดรดิตถ์
ตำแหน่งหน้าที่การงาน	อาจารย์
สถานที่ทำงานปัจจุบัน	คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏอุดรดิตถ์ ถนนอินใจมี ตำบลท่าอิฐ อำเภอเมือง จังหวัดอุดรดิตถ์ 53000
ประวัติการศึกษา	ปริญญาตรี ค.อ.บ. วิศวกรรมไฟฟ้า สถาบันเทคโนโลยีปทุมวัน ปริญญาโท ค.อ.ม. วิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีพระจอมเกล้า ธนบุรี ปริญญาเอก ปร.ด. วิศวกรรมไฟฟ้าและคอมพิวเตอร์ มหาวิทยาลัย มหาสารคาม

พูนัน ปณฺ ทิโต ชีเว