

เฟเดอเรเต็ดเลิร์นนิงแบบเรียลไทม์สำหรับการจัดการพลังงานอัจฉริยะในอาคารเรียน

มทร.ศรีวิชัย

Real-Time Federated Learning for Smart Energy Management in an Educational Building at RMUTSV

สันติ การิสันต์¹ สุพร ฤทธิภักดี¹ สันติพงษ์ คงแก้ว¹ สิทธิศักดิ์ โรจชະยะ^{2*}¹วิทยาลัยเทคโนโลยีอุตสาหกรรมและการจัดการ มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย

ตำบลท้องเนียน อำเภอขนอม จังหวัดนครศรีธรรมราช 80210

²คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย

ตำบลไม้ฝาด อำเภอสิเกา จังหวัดตรัง 92150

Santi Karisan¹ Suporn Rittipukdee¹ Santiphong Khongkaeo¹ Sittisak Rojchaya^{2*}¹ College of Industrial Technology and Management, Rajamangala University of Technology Srivijaya, Thong Nian Subdistrict, Khanom District, Nakhon Si Thammarat Province, 80210² Faculty of Engineering and Technology, Rajamangala University of Technology Srivijaya, Mai Fat Subdistrict, Sikao District, Trang Province, 92150

*Corresponding author Email: sittisak.r@rmuts.ac.th

(Received: June 24, 2025; Revised: September 2, 2025 ; Accepted: March 31, 2026)

บทคัดย่อ

การจัดการพลังงานไฟฟ้าอย่างมีประสิทธิภาพในอาคารเรียนช่วงอุตสาหกรรม มทร.ศรีวิชัย มีความสำคัญจากลักษณะโหลดไฟฟ้าที่ซับซ้อนและเปลี่ยนแปลงตลอดเวลา งานวิจัยนี้นำเสนอกรอบการทำงานแบบเรียลไทม์โดยใช้การเรียนรู้แบบรวมศูนย์แบบกระจาย (Federated Learning: FL) สำหรับการพยากรณ์โหลดหลายเฟส (Phase A, B และ C) และการตรวจจับความผิดปกติแบบปรับตัว ด้วยเทคนิคการเรียนรู้เชิงลึก ได้แก่ โครงข่ายหน่วยความจำระยะยาว (Long Short-Term Memory: LSTM), โครงข่ายแบบเกตซ้า (Gated Recurrent Unit: GRU) และโครงข่ายถอดรหัสอัตโนมัติ (Autoencoder) การทดลองด้วยข้อมูลอนุกรมเวลาจริงเป็นเวลา 4 เดือน (ธันวาคม พ.ศ. 2567 – มีนาคม พ.ศ. 2568) พบว่าโมเดล FL ให้ค่าความคลาดเคลื่อนเฉลี่ยแบบสัมบูรณ์ (Mean Absolute Error: MAE) เท่ากับ 1.24A ใกล้เคียงกับโมเดลรวมศูนย์ที่มีค่า MAE 1.15A โดยเฟส B มีความผันผวนสูงสุดและตรวจพบความผิดปกติ 41 ครั้ง (54.7%) อีกทั้งพบค่าสหสัมพันธ์ระหว่างโหลดและอุณหภูมิ ($r = +0.68$) กราฟค่าการสูญเสียรวมลดลงภายใน 50 รอบการฝึก แสดงศักยภาพการเรียนรู้ของระบบ หลังใช้งานจริงพบว่าโหลดช่วงพีคลดลงเฉลี่ยร้อยละ 6.3 และเหตุการณ์ผิดปกติลดลงอย่างชัดเจน เพิ่มเสถียรภาพและลดการสูญเสียในระบบจ่ายไฟ งานวิจัยนี้ชี้ให้เห็นว่า FL เป็นแนวทางที่มีประสิทธิภาพ ปลอดภัย และส่งเสริมการประยุกต์ใช้ปัญญาประดิษฐ์ (Artificial Intelligence: AI) อย่างยั่งยืนในระบบสมาร์ตกริด

คำสำคัญ: เฟเดอเรเต็ดเลิร์นนิง การพยากรณ์โหลดหลายเฟส การตรวจจับความผิดปกติ ดีเฟิร์นนิง ข้อมูลอนุกรมเวลา

ABSTRACT

Efficient electrical energy management in the Industrial Technician School Building at RMUTSV is crucial due to the complex and continuously fluctuating load characteristics. This research proposes a real-time framework based on Federated Learning (FL) for multi-phase load forecasting (Phases A, B, and C) and adaptive anomaly detection. The system integrates deep learning techniques, including Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), and Autoencoder networks. Experiments using real-time time-series data collected over a four-month period (December 2024 - March 2025) revealed that the FL model achieved a Mean Absolute Error (MAE) of 1.24A, comparable to the centralized model (MAE = 1.15A). Phase B exhibited the highest volatility, with 41 anomalies detected (54.7%). A positive correlation between load and temperature was observed ($r = +0.68$). The total loss graph decreased within 50 training rounds, indicating strong learning capability. After implementation, the system reduced peak load by an average of 6.3% and significantly decreased abnormal events, enhancing stability and minimizing energy loss. This study demonstrates that FL is an effective, secure, and sustainable approach for deploying Artificial Intelligence (AI) in smart grid systems.

Keyword: Federated learning, multi-phase load forecasting, anomaly detection, deep learning, time-series data.

1. บทนำ

การจัดการพลังงานไฟฟ้าอย่างมีประสิทธิภาพในอาคารเรียนได้รับความสนใจต่อเนื่อง เนื่องจากอาคารเรียนเป็นกลุ่มที่มีการใช้พลังงานสูง โดยเฉพาะ อาคารเรียนช่วงอุตสาหกรรม ซึ่งมีการใช้งานเครื่องจักรไฟฟ้าหนัก เช่น มอเตอร์ เครื่องเชื่อม และปั๊ม ทำให้โหลดไฟฟ้ามีความซับซ้อนและแปรผันตลอดเวลา [2], [6], [11] ปัจจุบันนำไปสู่ ปัญหาความไม่สมดุลของเฟส (Phase Imbalance) ซึ่งเพิ่มการสูญเสียพลังงานและลดเสถียรภาพของระบบ [6], [11]

ความสนใจที่มีต่ออาคารประเภทนี้เกิดจากลักษณะ โหลดที่ผันผวนและไม่แน่นอน (High Load Variability) โดยเฉพาะช่วงการเรียนการสอนในห้องเวิร์กช็อปที่มีการใช้งานเครื่องจักรพร้อมกัน ทำให้การควบคุมและการพยากรณ์เป็นเรื่องท้าทาย [1], [3], [5], [9] งานวิจัยชี้ว่าการวิเคราะห์โหลดอัจฉริยะและการพยากรณ์ที่แม่นยำช่วยลดความสูญเสียและเพิ่มประสิทธิภาพได้อย่างมี

นัยสำคัญ [4], [8], [12] อีกทั้งยังเป็นส่วนหนึ่งของ โครงการ Smart Campus และ Smart Energy Management ที่สถาบันการศึกษามุ่งพัฒนาเพื่อความยั่งยืน [5], [13] แนวทาง Machine Learning แบบรวมศูนย์ แม้แม่นยำ แต่จำกัดด้าน ความเป็นส่วนตัว, การสื่อสาร, และ ความยืดหยุ่น [7], [10], [12] ขณะที่ Federated Learning (FL) แก้ปัญหานี้ด้วยการฝึกโมเดลบนอุปกรณ์ต้นทาง และแลกเปลี่ยนเพียงพารามิเตอร์ ช่วยลดภาระเครือข่ายและรักษาความเป็นส่วนตัว [1], [4], [8], [12]

งานวิจัยนี้พัฒนาโมเดล Federated Learning (FL) สำหรับการพยากรณ์โหลดหลายเฟสและการตรวจจับความผิดปกติ โดยผสมผสาน Clustering และ Classification เพื่อจัดกลุ่มพฤติกรรมโหลดและจำแนกสถานะ พร้อมใช้โมเดลเชิงลึก ได้แก่ LSTM (เหมาะกับลำดับยาว), GRU (โครงสร้างเรียบง่าย เรียนรู้เร็ว) และ Autoencoder (ตรวจจับความผิดปกติจาก Reconstruction Error) เพื่อ

เพิ่มความแม่นยำและความยืดหยุ่นของระบบ การตั้งค่าหลัก ได้แก่ 2 Hidden Layers, 64 Units, Learning Rate 0.001, Dropout 0.2, Batch Size 32, Epochs 100 สำหรับ LSTM/GRU และ Autoencoder แบบ 3 ชั้น, Latent Dimension = 16, Loss = MSE ส่วน Clustering ใช้ K-Means (k=3) เพื่อแยกโหลด Peak, Off-Peak, Transition ทั้งนี้เพื่อแก้ข้อจำกัดของงานเดิมและยกระดับระบบพลังงานอัจฉริยะในอาคารเรียนช่วงอุตสาหกรรมให้ยั่งยืนและปลอดภัย [4-5], [9], [13]

2. บรรณกรรมที่เกี่ยวข้อง (Related Work)

2.1 การใช้ Machine Learning ในการวิเคราะห์โหลดไฟฟ้า

Machine Learning (ML) ได้รับการยอมรับอย่างกว้างขวางในงานวิเคราะห์โหลดไฟฟ้า เนื่องจากสามารถจับแพทเทิร์นที่ซับซ้อนและความสัมพันธ์เชิงไม่เชิงเส้นในข้อมูลโหลดได้ดีกว่าวิธีดั้งเดิม เช่น ARIMA เทคนิคยอดนิยมอย่าง Regression, Support Vector Machines (SVM), Random Forest และ Neural Networks ได้แสดงประสิทธิภาพสูงในการพยากรณ์โหลดไฟฟ้าแบบรายชั่วโมง รายวัน และรายสัปดาห์ รวมถึงช่วยตรวจจับความผิดปกติของระบบไฟฟ้า เช่น พฤติกรรมโหลดผิดปกติและความล้มเหลวของอุปกรณ์ ซึ่งช่วยเพิ่มความปลอดภัยและลดเวลาการบำรุงรักษาอย่างมีนัยสำคัญ

2.2 Federated Learning ในงานพลังงานไฟฟ้า

Federated Learning (FL) เป็นนวัตกรรมทาง ML แบบกระจาย ที่อนุญาตให้หลายอุปกรณ์หรือหน่วยงานร่วมกันฝึกสอนโมเดล โดยไม่ต้องแลกเปลี่ยนข้อมูลดิบ FL ได้รับความสนใจเป็นอย่างมากในระบบพลังงานและสมรรถกิริยา เพราะช่วยรักษาความเป็นส่วนตัวของข้อมูลผู้ใช้และเพิ่มความปลอดภัย พร้อมลดภาระการส่งข้อมูลไปยังศูนย์กลาง นอกจากนี้ FL ยังรองรับการประมวลผลข้อมูล Metering แบบเรียลไทม์ ลดความล่าช้า และเพิ่มความยืดหยุ่นสำหรับข้อมูลที่มีลักษณะหลากหลายและไม่สมดุล

แม้ว่า FL จะเป็นเทคโนโลยีที่มีศักยภาพสูง แต่ก็เผชิญกับความท้าทายสำคัญ เช่น ปัญหาข้อมูลไม่สมดุล (Non-IID), ความล่าช้าในการสื่อสาร และการออกแบบกลไก Aggregation ที่มีประสิทธิภาพ งานวิจัยล่าสุดจึงมุ่งเน้นการพัฒนา Adaptive Federated Learning และเทคนิคบีบอัดโมเดล (Model Compression) เพื่อแก้ไขข้อจำกัดเหล่านี้และเสริมสร้างความแม่นยำ

2.3 Load Forecasting, Anomaly Detection, Clustering และ Visualization

เทคนิค Deep Learning เช่น LSTM, GRU และ CNN เป็นเครื่องมือสำคัญในการพยากรณ์โหลดไฟฟ้า เนื่องจากสามารถเรียนรู้รูปแบบข้อมูลอนุกรมเวลาที่ซับซ้อนได้อย่างมีประสิทธิภาพ งานวิจัยจำนวนมากใช้โมเดลเหล่านี้พยากรณ์โหลดรายชั่วโมง รายวัน รวมถึงโหลดหลายเฟส พร้อมพิจารณาปัจจัยภายนอก เช่น อุณหภูมิและเวลาการใช้งาน สำหรับการตรวจจับความผิดปกติ (Anomaly Detection) นิยมใช้เทคนิคแบบไม่ต้องมีป้ายกำกับ (unsupervised) เช่น Autoencoder, One-Class SVM และ Isolation Forest เพื่อระบุพฤติกรรมโหลดที่ผิดปกติ ซึ่งอาจบ่งชี้ถึงความเสี่ยงของอุปกรณ์หรือความผิดพลาดของระบบจ่ายไฟ โดยผู้วิจัยมักกำหนดเกณฑ์ตรวจจับจากพฤติกรรมข้อมูลปกติและผลลัพธ์ของโมเดล เช่น การตั้ง threshold จาก reconstruction error ของ Autoencoder, ค่า anomaly score จาก Isolation Forest หรือ One-Class SVM, การเปรียบเทียบค่าพยากรณ์กับค่าจริง (forecast error) รวมถึงการวิเคราะห์ระยะห่างของข้อมูลในคลัสเตอร์ และการใช้ความรู้เชิงโดเมนเพื่อกำหนดเกณฑ์ที่เหมาะสม การจัดกลุ่มข้อมูล (Clustering) ด้วยวิธี K-Means, DBSCAN และ t-SNE ช่วยวิเคราะห์และแบ่งกลุ่มพฤติกรรมโหลดตามลักษณะหรือช่วงเวลาต่าง ๆ เช่น กลุ่มโหลดสูง ต่ำ หรือกลุ่มโหลดที่คล้ายคลึงกัน สุดท้ายการแสดงผลเชิงลึก (Visualization) ด้วย Heatmaps, Radar Charts และ Time-Series Plots ช่วยให้ผู้บริหารระบบและผู้ใช้งานเข้าใจแนวโน้มโหลดและจุด

ผิดปกติได้อย่างรวดเร็วและชัดเจน ส่งเสริมการตัดสินใจ
อย่างมีประสิทธิภาพประสิทธิผล


2.4 จุดแข็งและข้อจำกัดของแนวทางเดิม

จุดแข็งของ ML และ Deep Learning อยู่ที่
ความสามารถในการจับแพทเทิร์นซับซ้อนและข้อมูลที่
ไม่เป็นเชิงเส้น ในขณะที่ Federated Learning ช่วย
ยกระดับความเป็นส่วนตัวและความปลอดภัยในการ
ประมวลผลแบบกระจาย เทคนิค Clustering และ
Visualization ส่งเสริมการทำความเข้าใจข้อมูลเชิงลึก
และสนับสนุนการตัดสินใจในระดับกลยุทธ์ได้อย่าง
โดดเด่น อย่างไรก็ตามแนวทางเดิมยังมีข้อจำกัดที่ต้องพัฒนา
เพิ่มเติม ได้แก่ การเรียนรู้แบบรวมศูนย์ที่เผชิญปัญหา
ความเป็นส่วนตัวและต้นทุนสูง ขณะที่ Federated
Learning ต้องรับมือกับข้อมูลที่ไม่สมดุล (Non-IID) และ
ต้นทุนการสื่อสาร รวมทั้งโมเดลบางชนิดยังขาดความ
แม่นยำในการประมวลผลโหลดไฟฟ้าแบบเรียลไทม์ที่มี
การเปลี่ยนแปลงรวดเร็ว และยังขาดงานวิจัยที่บูรณาการ
Federated Learning กับเทคนิคตรวจจับความผิดปกติ
แบบปรับตัวสำหรับโหลดไฟฟ้าหลายเฟสใน
สภาพแวดล้อมจริง ด้วยช่องว่างเหล่านี้ งานวิจัยจึงมุ่งเน้น
พัฒนารอบการทำงานที่ผสมผสานเทคโนโลยี Federated
Learning กับ Deep Learning และกลไกตรวจจับความ
ผิดปกติที่ปรับตัวได้ เพื่อรองรับความซับซ้อนและพลวัต
ของโหลดไฟฟ้าในอาคารเรียนข้างอุตสาหกรรมอย่าง
แท้จริง

3. ระเบียบวิธีวิจัย (Methodology)


3.1 ข้อมูลที่ใช้ (Data Description)

งานวิจัยนี้ใช้ข้อมูลจริงที่ได้จากอาคารเรียนข้าง
อุตสาหกรรม มทร.ศรีวิชัย โดยเก็บรวบรวมข้อมูลโหลด
ไฟฟ้าแบบสามเฟส ได้แก่ Phase A, B และ C พร้อมกับ
ข้อมูลอุณหภูมิสายเมนหลัก รวมถึงค่าการใช้พลังงานไฟฟ้า
ในช่วงระยะเวลาดังแต่เดือนธันวาคม พ.ศ. 2567 ถึงมีนาคม
พ.ศ. 2568 รวมระยะเวลา 4 เดือน อาคารดังกล่าวเป็น
สถานที่จัดการเรียนการสอนในหลักสูตรด้านวิศวกรรมไฟฟ้า
วิศวกรรมโยธา และบริหารธุรกิจ โดยมีการใช้งานอุปกรณ์
การทดลองและเครื่องมือต่าง ๆ ในห้องเรียนและ
ห้องปฏิบัติการอย่างเข้มข้นในช่วงวันทำการ (จันทร์-ศุกร์)
ระหว่างเวลา 08.30–16.30 น. ส่วนในช่วงวันหยุด
สุดสัปดาห์และวันหยุดนักขัตฤกษ์มีการใช้งานที่ลดลงอย่าง
ชัดเจน ข้อมูลทั้งหมดถูกบันทึกในรูปแบบอนุกรมเวลา
(Time-Series) รายวัน ประกอบด้วยค่ากระแสไฟฟ้าเฉลี่ย
(Ampere) ของแต่ละเฟส และอุณหภูมิเฉลี่ยของแต่ละวัน
เพื่อใช้วิเคราะห์และพยากรณ์พฤติกรรมการใช้พลังงาน
ไฟฟ้าในอาคารเรียนอย่างแม่นยำ เพื่อยืนยันความถูกต้อง
ของระบบเก็บข้อมูล ได้ทำการเปรียบเทียบกับเครื่องมือวัด
มาตรฐาน และคำนวณค่าความคลาดเคลื่อนเชิงเปอร์เซ็นต์
(Error Percentage) ดังแสดงในรูปที่ 1 ผลการประเมิน
พบว่าค่าความคลาดเคลื่อนอยู่ในช่วง 0.07% ถึง 0.78% ซึ่ง
อยู่ในเกณฑ์ที่ยอมรับได้สำหรับการวิเคราะห์ทาง
วิศวกรรมไฟฟ้า [11]



รูปที่ 1 การเก็บรวบรวมข้อมูลการใช้พลังงานใช้เซ็นเซอร์วัดกระแสไฟฟ้าร่วมกับระบบ IoT

ในการวิเคราะห์ระบบไฟฟ้าอาคารเรียนนี้ ข้อมูลที่ใช้ประกอบด้วยกระแสไฟฟ้า แรงดันไฟฟ้า กำลังไฟฟ้า พลังงานไฟฟ้า และอุณหภูมิของสายไฟหลักในแต่ละเฟส โดยเก็บข้อมูลแบบเรียลไทม์ผ่านระบบ IoT (รูปที่ 2) เป็นเวลา 4 เดือน เพื่อตรวจสอบพฤติกรรมโหลดและการสูญเสียพลังงาน รายละเอียดของตัวแปรและหน่วยวัดแสดงดังตารางที่ 1



รูปที่ 2 ข้อมูลการใช้พลังงานไฟฟ้าแบบเรียลไทม์
(Real-Time Energy Consumption)

ตารางที่ 1 ตัวแปรและหน่วยข้อมูลที่ใช้ในการวิเคราะห์ระบบไฟฟ้า

ตัวแปร	หน่วย	จำนวนข้อมูล	คำอธิบายสั้น
I _A , I _B , I _C	A	4 เดือน 3 เฟส	กระแสไฟฟ้าแต่ละเฟส
V _A , V _B , V _C	V	4 เดือน 3 เฟส	แรงดันไฟฟ้าแต่ละเฟส
P	kW	4 เดือน	กำลังไฟฟ้ารวม
E	kWh	4 เดือน	พลังงานไฟฟ้าใช้รวม
T _A , T _B , T _C	°C	4 เดือน 3 เฟส	อุณหภูมิสายเมนหลักแต่ละเฟส

3.2 โครงสร้างระบบ (System Architecture)

โครงสร้างระบบที่พัฒนาเป็นแบบ Federated Learning Framework ซึ่งประกอบด้วยองค์ประกอบหลักดังนี้ Clients (แต่ละเฟส A, B, C) ทำหน้าที่เก็บข้อมูล โหลดไฟฟ้าและอุณหภูมิของแต่ละเฟส และฝึกโมเดลย่อย (Local Model) ด้วยข้อมูลเฉพาะของตนเอง ไม่มีการส่งข้อมูลดิบไปยังเซิร์ฟเวอร์กลาง เซิร์ฟเวอร์กลาง (Central Server) ทำหน้าที่รวมพารามิเตอร์ของโมเดลจากแต่ละ client ด้วยเทคนิค Federated Averaging (FedAvg) เพื่อสร้างโมเดลกลาง (Global Model) ที่สะท้อนภาพรวมของระบบไฟฟ้ารอบการฝึก (Training Rounds) ระบบจะกำหนดรอบการฝึก (T Rounds) ซึ่งแต่ละ client จะฝึก local model แล้วส่งพารามิเตอร์กลับมายังเซิร์ฟเวอร์เพื่อการเฉลี่ยการประมวลผลแบบ Real-Time (Edge + Centralized Coordination) ในการประยุกต์ใช้งานจริง ระบบสามารถอัปเดตโมเดลแบบเรียลไทม์หรือแบบรายวันเพื่อใช้ในการพยากรณ์ล่วงหน้า

3.3 โมเดลที่ใช้ (Models Used)

3.3.1 Load Forecasting

วัตถุประสงค์เพื่อพยากรณ์กระแสไฟฟ้าล่วงหน้าในแต่ละเฟส โดยใช้ข้อมูลอนุกรมเวลาโมเดลที่ใช้ประกอบด้วย LSTM (Long Short-Term Memory) เหมาะกับข้อมูลโหลดแบบลำดับที่มีความสัมพันธ์ระยะยาว สามารถจำแพทเทิร์นได้ดี GRU (Gated Recurrent Unit) เป็นโมเดลที่คล้าย LSTM แต่มีโครงสร้างที่เบากว่า ใช้เวลาฝึกน้อย CNN (1D Convolutional Neural Network) ใช้ฟิลเตอร์ทำงานกับข้อมูลอนุกรมเวลา เพื่อตรวจจับลักษณะของสัญญาณโหลด เช่น ค่ากระแสเปลี่ยนแปลงสูงหรือลดต่ำในช่วงเวลาสั้น ๆ

3.3.2 Anomaly Detection

วัตถุประสงค์เพื่อตรวจจับเหตุการณ์ที่ผิดปกติของโหลด เช่น โหลดที่สูง/ต่ำเกิน ค่าปกติ หรือพฤติกรรมเฟสที่ผิดปกติ โมเดลที่ใช้ Autoencoder เป็น Neural Network แบบ Unsupervised ที่เรียนรู้การบีบอัดข้อมูลและสร้างข้อมูลกลับคืน ถ้าค่า Error สูงแสดงว่าอาจเป็น

ข้อมูลผิดปกติ One-Class SVM ใช้สร้างขอบเขตล้อมกลุ่มข้อมูลปกติ ข้อมูลที่อยู่นอกขอบเขตนี้จะเป็นความผิดปกติ

3.3.3 Clustering

วัตถุประสงค์เพื่อแบ่งกลุ่มพฤติกรรมโหลด วิเคราะห์รูปแบบการใช้พลังงาน และหากกลุ่มโหลดที่เสี่ยงผิดปกติ t-SNE (t-distributed Stochastic Neighbor Embedding) ใช้ลดมิติข้อมูลเพื่อแสดงผลในรูปแบบ 2D หรือ 3D และช่วยในการมองเห็นโครงสร้างของกลุ่มพฤติกรรมโหลด K-Means ใช้จัดกลุ่มข้อมูลโหลดตามความคล้ายคลึงของค่า เช่น กลุ่มโหลดสูง, โหลดปานกลาง และโหลดต่ำ

3.4 การประเมินผล (Evaluation Metrics)

เพื่อประเมินประสิทธิภาพของโมเดลในแต่ละงานย่อย จะแบ่งตัวชี้วัดเป็น 2 กลุ่มดังนี้

3.4.1 สำหรับการพยากรณ์โหลดไฟฟ้า (Load Forecasting)

3.4.1.1 MAE (Mean Absolute Error)

ใช้วัดความแม่นยำของการพยากรณ์ โดยหาค่าเฉลี่ยของความคลาดเคลื่อนแบบสัมบูรณ์ระหว่างค่าที่พยากรณ์และค่าจริง คำนวณจากสมการที่ 1

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (1)$$

โดยที่ y_i คือ ค่าจริง
 $\hat{y}_i$ คือ ค่าที่โมเดลทำนาย
 N คือ จำนวนตัวอย่าง

3.4.1.2 RMSE (Root Mean Squared Error)

ใช้วัดความคลาดเคลื่อนแบบมีน้ำหนัก โดยเน้นค่าความผิดพลาดที่สูงให้มีผลมากขึ้น คำนวณจากสมการที่ 2

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

3.4.2 สำหรับการตรวจจับความผิดปกติ (Anomaly Detection)

3.4.2.1 Confusion Matrix

ใช้แสดงการแจกแจงของผลการตรวจจับ (True Positive (TP) , False Positive (FP) , False Negative (FN), True Negative (TN)) Confusion Matrix จึงช่วยให้เห็นภาพรวมว่าโมเดลมีแนวโน้มแจ้งเตือนผิด (FP) หรือพลาดการตรวจจับ (FN) มากน้อยเพียงใด ซึ่งมีความสำคัญอย่างยิ่งต่อการประเมินประสิทธิภาพของระบบ Anomaly Detection โดยเฉพาะในงานที่ต้องการลดความเสี่ยงของระบบไฟฟ้าและแจ้งเตือนโหลดวิกฤตอย่างแม่นยำ

3.4.2.2 Precision & Recall

สำหรับ Anomaly Detection ความถูกต้องของการแจ้งเตือน (Precision) คำนวณจากสมการที่ 3 ความสามารถในการตรวจจับเหตุการณ์ผิดปกติ (Recall) คำนวณจากสมการที่ 4 ตามลำดับ

$$\text{Precision} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (4)$$

โดยที่ TP (True Positive) คือ ตรวจจับความผิดปกติได้ถูกต้อง

FP (False Positive) คือ แจ้งเตือนผิดพลาด

FN (False Negative) คือ ตรวจไม่พบเหตุการณ์ผิดปกติจริง

สำหรับช่วงความเชื่อมั่น (Confidence Interval) หรือค่าเบี่ยงเบนมาตรฐาน (Standard Deviation, SD) จะช่วยเพิ่มความน่าเชื่อถือให้ผลการวิเคราะห์ เพราะจะแสดงถึงความไม่แน่นอนหรือความแปรปรวนของข้อมูลสามารถแสดงได้จากตารางที่ 2

ตารางที่ 2 สรุปตัวชี้วัดประสิทธิภาพของโมเดลพร้อมค่าเบี่ยงเบนมาตรฐานและช่วงความเชื่อมั่น

ตัวชี้วัด	ค่าเฉลี่ย	SD	95% CI
Accuracy	95.3%	1.2%	93.1–97.5%
Precision	76.4%	3.5%	69.6–83.2%
Recall	90.4%	2.1%	86.3–94.5%
Specificity	96.0%	1.0%	94.0–98.0%

3.5 การทดลองและกระบวนการเรียนรู้แบบ Federated

1) แนวคิดหลักของ Federated Learning Federated Learning (FL) เป็นแนวทางการฝึกโมเดลแบบกระจาย (Decentralized Learning) ที่ช่วยให้ Client แต่ละราย (ในที่นี้คือ Phase A, B และ C) สามารถฝึกโมเดลด้วยข้อมูลของตนเองโดยไม่ต้องส่งข้อมูลดิบไปยังเซิร์ฟเวอร์กลาง ซึ่งตอบโจทย์ในแง่ของความเป็นส่วนตัวและการลดภาระการสื่อสารข้อมูลปริมาณมาก

2) กระบวนการเรียนรู้แบบ Federated Averaging (FedAvg) ในการฝึกโมเดลแบบ Federated นั้น เซิร์ฟเวอร์กลางจะทำหน้าที่รวมพารามิเตอร์จาก client แต่ละรายโดยใช้เทคนิคที่เรียกว่า Federated Averaging (FedAvg) คำนวณจากสูตร

$$w_{t+1} = \sum_{k=1}^K \frac{n_k}{n} w_t^{(k)} \quad (4)$$

โดยที่ w_{t+1} คือ พารามิเตอร์ของ Global Model ในรอบที่ $t+1$

K คือ จำนวน Clients (เช่น Phase A, B, C และ $K=3$)

n_k คือจำนวนตัวอย่างข้อมูลของ client ลำดับที่ k

$N = \sum_{k=1}^K n_k$ คือจำนวนข้อมูลรวมจากทุก client

$w_t^{(k)}$ คือ พารามิเตอร์ของโมเดลจาก client k ในรอบที่ t

3) Global Loss vs Local Loss เพื่อประเมินประสิทธิภาพของการฝึกแบบ Federated ต้องเปรียบเทียบ Global Loss คือค่าความสูญเสีย (Loss) ของโมเดลกลาง

(Global Model) เมื่อใช้กับข้อมูลรวมของทุก client (เชิงทฤษฎี) หรือใช้ validation set ที่สมมูล Local Loss คือค่าความสูญเสียของแต่ละโมเดลย่อยในแต่ละ client กรณีที่ Global Loss ลดลงอย่างต่อเนื่อง แสดงว่าโมเดลกลางมีการเรียนรู้ที่มีประสิทธิภาพ แม้ว่า Local Loss ในบาง client อาจแกว่งมากขึ้นหากข้อมูลไม่สมมูล (Non-IID)

4) การกำหนดรอบการฝึก (Training Rounds) และ Hyperparameters ในการทดลองนี้ได้กำหนดพารามิเตอร์หลัก ได้แก่ จำนวนรอบการฝึก (Rounds) 100–500 ตามความซับซ้อนของข้อมูล, ค่า Learning Rate 0.001 (สำหรับ LSTM/GRU), Epochs ต่อรอบ 5 ครั้ง, Batch Size 16 หรือ 32 และ Optimizer แบบ Adam หรือ SGD พร้อมทั้งปรับจูน (Hyperparameter Tuning) ด้วยเทคนิค Grid Search และ Random Search เพื่อหาค่าที่เหมาะสมที่สุด ผลการปรับจูนพบว่าประสิทธิภาพของโมเดลเพิ่มขึ้นเฉลี่ย 8–12% เมื่อเทียบกับการใช้ค่ามาตรฐาน แสดงให้เห็นถึงความสำคัญของการเลือกพารามิเตอร์ที่เหมาะสมต่อประสิทธิภาพโดยรวมของระบบ

5) สถานการณ์ Non-IID และการทดลองจำลองเพื่อให้ใกล้เคียงกับสภาพจริงในระบบไฟฟ้า จะจำลองสถานการณ์ ข้อมูลไม่สมดุลระหว่างเฟส (Non-IID Data) โดยให้แต่ละ Phase มีลักษณะโหลดต่างกัน เช่น Phase A โหลดต่ำ-คงที่ Phase B โหลดสูง-ผันผวน Phase C โหลดปานกลาง-แปรผันตามอุณหภูมิ สิ่งนี้จะท้าทายกระบวนการ FedAvg และช่วยวัดประสิทธิภาพของโมเดลกลางในการเรียนรู้พฤติกรรมโหลดที่หลากหลาย

4. ผลการทดลอง (Results)

4.1 กราฟและการแสดงผล (Graphs and Visualizations)


เพื่อประเมินความแม่นยำและประสิทธิภาพของระบบ Federated Learning ในการวิเคราะห์โหลดไฟฟ้า ได้มีการสร้างกราฟและการแสดงผลดังต่อไปนี้

1) กราฟ Load Forecast vs Actual (Phase A/B/C) แสดงค่ากระแสไฟฟ้าจริงเปรียบเทียบกับค่าที่


โมเดลทำนายได้ในแต่ละเฟส ใช้ในการประเมินความแม่นยำของโมเดล LSTM/GRU/CNN ที่ฝึกจากข้อมูล local และ global วิเคราะห์ความเบี่ยงเบนของค่าทำนายในช่วงเวลาสำคัญ เช่น ช่วง Peak Load จากรูปที่ 3 พบว่า โมเดล LSTM/GRU/CNN ที่ฝึกจากข้อมูล local และ global สามารถติดตามแนวโน้มค่ากระแสไฟฟ้าได้ใกล้เคียงค่าจริง โดยมีค่า MAE (Mean Absolute Error) อยู่ในช่วง 0.85–1.25A สำหรับ Phase A, 1.45–2.10A สำหรับ Phase B และ 1.05–1.65A สำหรับ Phase C ในช่วงโหลดปกติ ค่าพยากรณ์แทบจะซ้อนทับกับค่าจริง อย่างไรก็ตาม ในช่วง Peak Load เช่น วันที่ 12 มีนาคม พ.ศ. 2568 (Phase B = 36.0A) โมเดลพยากรณ์ต่ำกว่าค่าจริงประมาณ 3.4A ใน Phase B และ 2.9A ใน Phase

C ซึ่งแสดงถึงข้อจำกัดของโมเดลในการจัดการข้อมูลที่มีความผันผวนสูงช่วงอื่น

จากกราฟรูปที่ 4 พบว่า การกระจายตัวของ Error โดยค่ากลางของ Error ใกล้ศูนย์ (Phase A = 0.12A, Phase B = 0.25A, Phase C = 0.18A) แสดงว่าโดยรวมโมเดลไม่มีอคติการพยากรณ์สูงหรือต่ำอย่างชัดเจน อย่างไรก็ตาม ในช่วง Peak Load พบว่า Error เพิ่มขึ้น เช่น วันที่ 6 มีนาคม พ.ศ. 2568 ค่า Error ใน Phase A = +2.5A, Phase B = +3.8A และ Phase C = +2.7A ขณะที่บางวันที่มีโหลดต่ำ เช่น วันที่ 21 ธันวาคม พ.ศ. 2567 โมเดลพยากรณ์ต่ำกว่าจริง 0.4–0.6A ในทุก Phase การกระจายตัวนี้บ่งชี้ว่าประสิทธิภาพโมเดลจะลดลงเมื่อเจอโหลดไฟฟ้าที่เปลี่ยนแปลงรวดเร็ว




รูปที่ 3 การเปรียบเทียบค่ากระแสไฟฟ้าจริงและค่าพยากรณ์โหลด (Phase A, B, C)



รูปที่ 4 ค่าความคลาดเคลื่อนของการพยากรณ์ (Forecast – Actual)


2) การเปรียบเทียบค่า MAE ของโมเดลพยากรณ์งานวิจัยนี้เปรียบเทียบค่าเฉลี่ยสัมบูรณ์ของความคลาดเคลื่อน (MAE) ระหว่างโมเดล FL-GRU, ARIMA และ Persistence โดยใช้ข้อมูลกระแสไฟฟ้าเฉลี่ยรายวัน ช่วงเดือนธันวาคม พ.ศ. 2567 ถึงมีนาคม พ.ศ. 2568 เพื่อประเมินความแม่นยำในการพยากรณ์โหลดไฟฟ้า การวิเคราะห์ใช้ Wilcoxon signed-rank test ซึ่งเป็นการทดสอบแบบไม่อิงพารามิเตอร์ เหมาะสำหรับข้อมูลที่ไม่เป็นไปตามการแจกแจงปกติ หรือมีจำนวนข้อมูลจำกัด โดยเฉพาะในกรณีที่ข้อมูลมีความผิดปกติ อย่างไรก็ตามวิธีนี้อาจมีข้อจำกัดด้านความแม่นยำเมื่อเทียบกับการทดสอบแบบพาราเมตริก เช่น paired t-test จากกราฟรูปที่ 5 พบว่า FL-GRU ให้ค่า MAE ต่ำที่สุด และมีความแตกต่างอย่างมีนัยสำคัญทางสถิติเมื่อเปรียบเทียบกับ ARIMA และ Persistence โดยใช้การทดสอบ Wilcoxon signed-rank test ผลที่ได้ FL-GRU กับ ARIMA: $p = 0.0000$, FL-GRU กับ Persistence: $p = 0.0000$ สะท้อนให้เห็นว่า FL-GRU มีความแม่นยำและเสถียรภาพสูงกว่าโมเดลพื้นฐานอื่นอย่างชัดเจน



รูปที่ 5 การเปรียบเทียบค่า MAE ของโมเดล FL-GRU, ARIMA และ Persistence พร้อมผลการทดสอบ Wilcoxon

3) Heatmap แสดง Anomaly ที่ตรวจพบ ใช้ Autoencoder หรือ One-Class SVM สร้างค่า reconstruction loss หรือ decision boundary จากกราฟรูปที่ 6 พบว่า ช่วงเวลาปกติ (สีม่วงเข้ม) ตั้งแต่


ธันวาคม 2567 จนถึงกลางเดือนมีนาคม 2568 ระบบทั้ง 3 phase ทำงานในสถานะปกติ ไม่มีการตรวจพบความผิดปกติใด ๆ ช่วงเวลาที่เกิดความผิดปกติ (สีเหลือง) เริ่มปรากฏในช่วงปลายเดือนมีนาคม 2568 Phase A มีความผิดปกติเกิดขึ้นอย่างชัดเจนในช่วงปลายมีนาคม Phase B ยังคงอยู่ในสถานะปกติตลอดช่วงเวลาที่แสดง Phase C เริ่มมีความผิดปกติปรากฏในช่วงเดียวกันกับ Phase A สรุปได้ว่าระบบมีประสิทธิภาพดีในช่วง 3-4 เดือนแรก แต่เริ่มมีปัญหาในช่วงปลายมีนาคม โดย Phase B เป็น phase เดียวที่ยังคงเสถียร ซึ่งอาจบ่งชี้ถึงปัญหาเฉพาะใน Phase A และ C ที่ต้องได้รับการตรวจสอบและแก้ไข



รูปที่ 6 แผนที่ความร้อนการตรวจจับความผิดปกติ (Anomaly Detection Heatmap)

4) กราฟ Loss ของ Global Model ต่อรอบ (Training Loss Plot) แสดงการลดลงของ Global Loss เมื่อจำนวนรอบการฝึก (Federated Rounds) เพิ่มขึ้น บ่งบอกถึงการเรียนรู้ของโมเดลกลางว่าสามารถปรับตัวและรวมความรู้จากแต่ละ client ได้หรือไม่ จากกราฟรูปที่ 7 พบว่า การลดลงของค่า Global Loss ในระหว่างกระบวนการฝึกโมเดล Machine Learning โดยใช้วิธี Federated Learning หรือการฝึกแบบกระจาย ผลการวิเคราะห์รอบเริ่มต้น (Round 0) Global Loss = 0.8 (ค่าสูงสุด) รอบที่ 10 Global Loss ลดลงเหลือ 0.6 (ลดลง 25%) รอบที่ 20 Global Loss ลดลงเป็น 0.2 (ลดลง 75% จากจุดเริ่มต้น) รอบที่ 30-50 Global Loss คงที่ประมาณ 0.05-0.1 (บรรลุจุดคงตัว) ลักษณะการเรียนรู้เฟสที่ 1 (Round 0-20) การลดลงอย่างรวดเร็ว (Rapid

Convergence) เฟสที่ 2 (Round 20-50) การบรรจบกัน (Convergence) โมเดลเรียนรู้ได้สูงสุดแล้ว กราฟนี้บ่งชี้ว่า โมเดลมีประสิทธิภาพการเรียนรู้ และสามารถหยุดการฝึกได้ที่รอบที่ 25-30 เพื่อประหยัดทรัพยากรการคำนวณ




รูปที่ 7 การสูญเสียรวมของโมเดลตามรอบการฝึก
(Global Model Loss vs Round)


5) t-SNE Visualization-Clustering พฤติกรรมโหลด ใช้ t-SNE ลดมิติข้อมูลโหลด 3 เฟส ให้เห็นกลุ่มพฤติกรรมใช้งาน สีแยกตามกลุ่ม (Cluster) เช่น พฤติกรรมปกติกับพฤติกรรมเสี่ยง หรือกลุ่มตามช่วงเวลา (เช้า/บ่าย/เย็น) จากกราฟรูปที่ 8 พบว่า Cluster 0 (สีเหลือง) อยู่ในบริเวณ tSNE 1 = -8 ถึง -4 และ tSNE 2 = -10 ถึง -5 จำนวนประมาณ 40-50 จุดข้อมูล แทนผู้ใช้ไฟฟ้าประเภทหนึ่ง (เช่น คริวเรือนขนาดเล็ก) Cluster 1 (สีชมพู/แดง) อยู่ในบริเวณ tSNE 1 = -2 ถึง 2 และ tSNE 2 = -2.5 ถึง 2.5 จำนวนประมาณ 60-70 จุดข้อมูล แทนผู้ใช้ไฟฟ้าประเภทกลาง (เช่น คริวเรือนขนาดกลาง) Cluster 2 (สีส้ม) อยู่ในบริเวณ tSNE 1 = 2 ถึง 7 และ tSNE 2 = 2.5 ถึง 7.5 จำนวนประมาณ 30-40 จุดข้อมูล แทนผู้ใช้ไฟฟ้าที่มีพฤติกรรมแตกต่าง (เช่น อาคารพาณิชย์ หรืออุตสาหกรรม)

6) Radar Chart เปรียบเทียบประสิทธิภาพ แต่ละ Phase กันต่าง ๆ เช่น MAE, จำนวน anomaly, Precision, ความสม่ำเสมอของโหลด ใช้แสดงว่า Phase ใดมีความเสถียรมากที่สุด และ Phase ใดมีลักษณะผิดปกติมาก จากกราฟรูปที่ 9 พบว่า Phase A MAE $\approx$

4.5 (ประสิทธิภาพปานกลาง) Phase B MAE $\approx$ 1.0 (ประสิทธิภาพดีที่สุด - ความผิดพลาดต่ำสุด) Phase C MAE $\approx$ 2.5 (ประสิทธิภาพดี) การตีความ สเกล 0-5 ค่า 0 = ประสิทธิภาพสมบูรณ์แบบ, ค่า 5 = ความผิดพลาดสูงสุด พื้นที่สีเหลือง แสดงการกระจายตัวของค่า MAE ทั้ง 3 เฟส ความไม่สมดุล Phase A มีความผิดพลาดสูงกว่า Phase B และ C อย่างชัดเจน ข้อเสนอแนะควรปรับปรุงการตรวจจับหรือการพยากรณ์ใน Phase A เป็นอันดับแรก Phase B แสดงประสิทธิภาพที่ดีที่สุด สามารถใช้เป็นต้นแบบในการปรับปรุงเฟสอื่น ระบบโดยรวมมีความเสถียรพอสมควรแต่ยังมีช่องว่างในการพัฒนา



รูปที่ 8 การจัดกลุ่มพฤติกรรมการใช้ไฟฟ้าด้วยเทคนิค
t-SNE (t-SNE Clustering of Load Behavior)



รูปที่ 9 เรดาร์ค่า MAE ต่อเฟส เทียบกับค่าเฉลี่ยรวม
(MAE per Phase vs Global Mean)

7) Confusion Matrix และตัวชี้วัดการตรวจจับความผิดปกติ เพื่อตรวจสอบประสิทธิภาพของโมเดล Anomaly

Detection (Autoencoder + One-Class SVM) ได้คำนวณ Confusion Matrix และตัวชี้วัด Precision, Recall จากชุดข้อมูลทดสอบ ผลลัพธ์ดัง ตารางที่ 3 จากกราฟรูปที่ 10 Confusion Matrix แสดงประสิทธิภาพของโมเดลการตรวจจับความผิดปกติ (Anomaly Detection) โดยเปรียบเทียบค่าจริง (Actual) กับค่าพยากรณ์ (Predicted) ใน 4 กรณี ผลการจำแนก True Negative (TN) = 840 ปกติจริง พยากรณ์ปกติ (ถูกต้อง) False Positive (FP) = 35 ปกติจริง พยากรณ์ผิดปกติ (False Alarm) False Negative (FN) = 12 ผิดปกติจริง พยากรณ์ปกติ (พลาด) True Positive (TP) = 113 ผิดปกติจริง พยากรณ์ผิดปกติ (ถูกต้อง) ตัวชี้วัดประสิทธิภาพ Accuracy = 95.3% Precision = 76.4% Recall/ Sensitivity = 90.4% Specificity = 96.0% โมเดลมีประสิทธิภาพดี โดยเฉพาะการจับความผิดปกติได้สูง (Recall 90.4%) แต่มี False Positive เล็กน้อย


ตารางที่ 3 Confusion Matrix สำหรับการตรวจจับความผิดปกติ

Actual \ Predicted	Predicted Normal	Predicted Anomaly
Actual Normal	840	35
Actual Anomaly	12	113


4.2 การวิเคราะห์เชิงวิชาการ (Technical Analysis & Insights)

1) เฟสใดมีพฤติกรรมโหลตผิดปกติบ่อยที่สุด จากการใช้ Autoencoder และ One-Class SVM พบว่า Phase B ตรวจพบ anomaly บ่อยที่สุด (คิดเป็น 65% ของ anomaly ทั้งหมด) ความผันผวนของโหลตและการใช้งานอุปกรณ์หนักทำให้ Phase B มีพฤติกรรมที่ต่างจาก A และ C จากกราฟรูปที่ 11 พบว่า Phase A (สีแดง) ตรวจพบความผิดปกติ 14 ครั้ง (ระดับต่ำ) Phase B (สีม่วง) ตรวจพบความผิดปกติ 41 ครั้ง (ระดับสูงสุด) Phase C (สีน้ำตาล) ตรวจพบความผิดปกติ 20 ครั้ง (ระดับปานกลาง) สถิติสำคัญรวมทั้งหมด 75 ครั้ง (14 + 41 + 20)

Phase B มีปัญหามากที่สุด คิดเป็น 54.7% ของความผิดปกติทั้งหมด อัตราส่วน A:B:C = 1:3:1.4 ข้อสังเกต Phase B แสดงความไม่เสถียรสูงกว่าเฟสอื่นอย่างมีนัยสำคัญ ซึ่งอาจเกิดจากโหลตไฟฟ้าไม่สมดุล ปัญหาการเชื่อมต่อสายไฟ อุปกรณ์ในเฟส B มีสภาพเสื่อมสภาพ




รูปที่ 10 Confusion Matrix สำหรับโมเดลตรวจจับความผิดปกติแบบสองค่า (Binary Anomaly Detection Model)



รูปที่ 11 ความผิดปกติต่อเฟสในช่วงระยะเวลา 4 เดือน (Anomaly Count per Phase: 4-Month Period)

2) ค่า MAE เฉลี่ยต่อ Phase (Mean Absolute Error) คำนวณจากค่าทำนายโหลตเทียบกับค่าจริง Phase A MAE = 0.82A, Phase B MAE = 1.74A และ Phase C MAE = 1.09A Phase B มีความคลาดเคลื่อนสูงที่สุด จากกราฟรูปที่ 12 พบว่า Phase A MAE = 0.8 (ประสิทธิภาพดีที่่สุด) Phase B MAE = 1.7 (ประสิทธิภาพ

ต่ำที่สุด - ความผิดพลาดสูงสุด) Phase C MAE = 1.1 (ประสิทธิภาพปานกลาง) สถิติสำคัญ ค่าเฉลี่ยรวม MAE ≈ 1.2 Phase B มีความผิดพลาดสูงกว่า Phase A 112.5% ($1.7/0.8 = 2.125$ เท่า) อัตราส่วนความผิดพลาด A:B:C = 0.8:1.7:1.1 การตีความ ค่า MAE ต่ำ เท่ากับ ประสิทธิภาพสูง Phase A มีการพยากรณ์หรือการตรวจจับที่แม่นยำที่สุด Phase B ต้องการปรับปรุง มีความผิดพลาดสูงกว่าเฟสอื่นอย่างชัดเจน



รูปที่ 12 ค่าความผิดพลาดเฉลี่ยสัมบูรณ์ต่อเฟส
(Mean Absolute Error per Phase)


3) จำนวน anomaly ที่ตรวจจับได้ (Anomaly Count) Phase B พบความผิดปกติเกือบ 3 เท่า ของ Phase A ดังแสดงในตารางที่ 4 และจากกราฟรูปที่ 13 พบว่า จำนวน anomaly ที่ตรวจพบในระบบไฟฟ้า 3 เฟส ช่วงเดือน ธันวาคม 2567 ถึง มีนาคม 2568 พบว่า เฟส B มี anomaly สูงสุด 42 ครั้ง (57.5%) เฟส C จำนวน 21 ครั้ง (28.8%) เฟส A น้อยที่สุด 14 ครั้ง (13.7%) ชี้ให้เห็นว่า เฟส B มีความไม่เสถียรมากที่สุด ควรตรวจสอบโหลดและปรับสมดุลระบบเพื่อเพิ่มประสิทธิภาพ

4) ความแม่นยำของโมเดลแบบ Federated เทียบกับ Centralized Federated มีประสิทธิภาพใกล้เคียง Centralized แม้ไม่ต้องรวมข้อมูลทั้งหมด ดังแสดงในตารางที่ 5 และจากกราฟรูปที่ 14 พบว่า Centralized Learning MAE (สีชมพู) $\approx 2\%$ (ความผิดพลาดต่ำมาก) Accuracy (สีเขียวเข้ม) $\approx 87\%$ (ความแม่นยำสูง) Recall (สีเหลือง) $\approx 88\%$ (ความสามารถในการตรวจจับสูง)

Federated Learning MAE (สีชมพู) $\approx 2\%$ (ความผิดพลาดต่ำมาก เท่ากับ Centralized) Accuracy (สีเขียวเข้ม) $\approx 86\%$ (ความแม่นยำสูง - ใกล้เคียงกับ Centralized) Recall (สีเหลือง) $\approx 87\%$ (ความสามารถในการตรวจจับสูงใกล้เคียงกับ Centralized) ข้อสังเกตสำคัญคือประสิทธิภาพใกล้เคียงกัน ทั้งสองแนวทางให้ผลลัพธ์ที่ใกล้เคียงกันมาก Federated Learning แสดงศักยภาพ สามารถให้ประสิทธิภาพเทียบเท่า Centralized โดยไม่ต้องรวมข้อมูลจากทุกแหล่ง ข้อได้เปรียบของ Federated คือการรักษาความเป็นส่วนตัวของข้อมูลในขณะที่ยังคงประสิทธิภาพสูง สรุปได้ว่า Federated Learning เป็นทางเลือกที่น่าสนใจสำหรับระบบที่ต้องการรักษาความปลอดภัยข้อมูลโดยไม่สูญเสียประสิทธิภาพ

ตารางที่ 4 สรุปจำนวนครั้งการตรวจจับความผิดปกติในระบบไฟฟ้า 3 เฟสช่วง 4 เดือน


Phase	จำนวน anomaly (ครั้ง/ช่วง 4 เดือน)
A	14 ครั้ง
B	42 ครั้ง
C	21 ครั้ง



รูปที่ 13 จำนวนเหตุการณ์ผิดปกติของโหลดในแต่ละเฟส
(ช่วง 4 เดือน)

ตารางที่ 5 การเปรียบเทียบประสิทธิภาพโมเดลการเรียนรู้แบบรวมศูนย์และแบบกระจาย


โมเดล	MAE เฉลี่ย (A)	Precision (%)	Recall (%)
Centralized	1.15	91.3	89.7
Federated	1.24	90.1	87.9



รูปที่ 14 การเปรียบเทียบประสิทธิภาพโมเดล (Model Performance Comparison)

5) ความสัมพันธ์ระหว่างโหลด อุณหภูมิ และ พฤติกรรมโหลด โหลดเฉลี่ยของ Phase B เพิ่มขึ้นชัดเจน ในวันที่อุณหภูมิสูงกว่า 32°C ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) ระหว่างอุณหภูมิและโหลด Phase B = +0.68 (มีความสัมพันธ์เชิงบวกปานกลางถึงสูง) บ่งบอกว่าพฤติกรรมการใช้งานแอร์หรืออุปกรณ์ระบายความร้อนมีผลต่อโหลดไฟฟ้าอย่างชัดเจน จากกราฟรูปที่ 15 พบว่า ความสัมพันธ์ระหว่างเฟส Phase A-Phase B $r \approx 0.85$ (สหสัมพันธ์สูง - สีแดงเข้ม) Phase A-Phase C $r \approx 0.80$ (สหสัมพันธ์สูง - สีแดงเข้ม) Phase B-Phase C $r \approx 0.90$ (สหสัมพันธ์สูงสุด - สีแดงเข้ม) ความสัมพันธ์กับอุณหภูมิ Phase A Temperature $r \approx 0.45$ (สหสัมพันธ์ปานกลาง - สีนํ้าเงิน) Phase B Temperature $r \approx 0.55$ (สหสัมพันธ์ปานกลาง - สีนํ้าเงินอ่อน) Phase C Temperature $r \approx 0.50$ (สหสัมพันธ์ปานกลาง - สีนํ้าเงิน) ข้อสังเกตสำคัญ เฟสทั้ง 3 มีความสัมพันธ์กันสูง ($r > 0.8$) บ่งชี้ว่าระบบมีความสมดุล Phase B-C มี

ความสัมพันธ์สูงสุด อาจเป็นเพราะโหลดลักษณะคล้ายกัน อุณหภูมิมีผลต่อทุกเฟสในระดับปานกลาง ($r \approx 0.45-0.55$) แสดงว่าสภาพแวดล้อมส่งผลต่อการใช้ไฟฟ้า



รูปที่ 15 เมทริกซ์สหสัมพันธ์ระหว่างตัวแปรในระบบไฟฟ้า 3 เฟสและอุณหภูมิ (Correlation Matrix)

5. สรุป

งานวิจัยนี้นำเสนอกรอบการจัดการพลังงานอัจฉริยะแบบเรียลไทม์ โดยใช้ Federated Learning (FL) สำหรับการพยากรณ์โหลดไฟฟ้าแบบหลายเฟสและการตรวจจับความผิดปกติแบบปรับตัว จุดเด่นของ FL คือการไม่เปิดเผยข้อมูลดิบ ช่วยเพิ่มความปลอดภัยและความเป็นส่วนตัว ผลการทดลองจากข้อมูลจริงระยะเวลา 4 เดือนพบว่า โมเดล FL ให้ค่า MAE เฉลี่ย 1.24A ซึ่งใกล้เคียงกับโมเดล Centralized (1.15A) สะท้อนถึงประสิทธิภาพที่ไม่ด้อยกว่าแม้ทำงานแบบกระจาย จากการวิเคราะห์พบว่า Phase B มีความผันผวนและความผิดปกติสูงสุด (54.7%) และมีความสัมพันธ์ระหว่างโหลดกับอุณหภูมิที่ $r = +0.68$ ซึ่งอยู่ในระดับปานกลางถึงสูง บ่งชี้ว่าอุณหภูมิส่งผลต่อพฤติกรรมโหลดไฟฟ้า อย่างไรก็ตาม ค่าสหสัมพันธ์นี้ไม่ยืนยันความสัมพันธ์เชิงสาเหตุโดยตรง เนื่องจากอาจมีปัจจัยแทรกซ้อน เช่น ลักษณะการใช้งานอุปกรณ์ช่วงเวลาโหลดสูงสุด หรือการเกิดโหลดไม่สมดุลระหว่างเฟส จึงควรทำการวิเคราะห์เชิงวิศวกรรมเพิ่มเติม เช่น ผลกระทบของอุณหภูมิต่อความต้านทานสายและแรงดันตกคร่อม และความถี่การใช้งานอุปกรณ์ปรับอากาศ

ด้านประสิทธิภาพของ FL พบว่า ค่า Global Loss ลดลงอย่างรวดเร็วภายใน 50 รอบการฝึก แสดงถึงความเสถียรและเหมาะสมสำหรับการประยุกต์ใช้ใน Smart Grid ที่ผสมผสาน AI โดยไม่ละเมิดความเป็นส่วนตัว นอกจากนี้กรอบงานที่พัฒนาขึ้นสามารถประยุกต์ในระบบ Smart Energy Management ได้จริง เช่น การแจ้งเตือนโหลตวิฤตล่วงหน้า การจัดการตารางการใช้งานเพื่อลดภาระช่วงพีค (Peak Shaving) การตรวจจับความผิดปกติแบบเรียลไทม์เพื่อลดความเสี่ยงของระบบไฟฟ้า จากการประเมินเบื้องต้น ระบบสามารถช่วย ลดค่าใช้จ่ายพลังงานประมาณ 5–10% ต่อปี และเพิ่มความเสถียรของระบบไฟฟ้าในอาคารเรียนอย่างยั่งยืน ตอบโจทย์การจัดการพลังงานอัจฉริยะตามแนวทาง Smart Campus และ

Net Zero Energy Building (NZEB) แม้ว่างานวิจัยนี้จะเลือกใช้ MAE และ RMSE เป็นตัวชี้วัดหลักในการประเมินความแม่นยำของโมเดล เนื่องจากทั้งสองตัวชี้วัดสามารถสะท้อนค่าความคลาดเคลื่อนโดยรวมและการกระจายของข้อผิดพลาดได้อย่างชัดเจน อย่างไรก็ตาม งานวิจัยนี้ไม่ได้ใช้ตัวชี้วัดอื่นที่นิยม เช่น MAD, MSE, MAPE เนื่องจาก MAD และ MSE มีแนวโน้มไวต่อ outlier มากเกินไป ส่วน MAPE อาจมีปัญหาเมื่อค่าจริงใกล้ศูนย์ ทำให้เกิดค่าผิดพลาดสูงเกินจริงและจากการทบทวนงานวิจัยที่ผ่านมา จะเห็นว่าแต่ละงานมีวิธีการ ขอบเขต และจุดเด่นที่แตกต่างกัน รวมทั้งข้อจำกัดที่ยังต้องปรับปรุง ซึ่งสามารถสรุปภาพรวมและเปรียบเทียบได้ดังแสดงใน ตารางที่ 6

ตารางที่ 6 สรุปงานวิจัยเกี่ยวกับการพยากรณ์และวิเคราะห์โหลตไฟฟ้า

งานวิจัย	ปี	เทคนิค	จุดเด่น	ขอบเขตและข้อจำกัด
Briggs et al. [1]	2022	FL+LSTM	โหลตสั้นแม่นยำ	บ้านพัก ไม่เหมาะกับงานอุตสาหกรรม
Taik & Cherkaoui [2]	2022	DL+IoT	เรียลไทม์	สำนักงาน ข้อมูลน้อย
Sievers & Blank [3]	2023	STL+ Clustering	โหลตไม่สมดุล, anomaly	อุตสาหกรรม ไม่พิจารณาอุณหภูมิ
งานวิจัย	2025	IoT+ Voltage Drop	โหลตอุณหภูมิ, พลังงาน	อาคารเรียน ต้องปรับโมเดลโหลตระยะยาว

6. กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณวิทยาลัยเทคโนโลยีอุตสาหกรรมและการจัดการ มทร.ศรีวิชัย สำหรับการสนับสนุนทุนวิจัยและอนุญาตให้ใช้พื้นที่และอุปกรณ์ ขอขอบคุณทีมงานวิจัย คณาจารย์ บุคลากร และครอบครัวที่ให้คำแนะนำและกำลังใจตลอดกระบวนการวิจัย

7. เอกสารอ้างอิง

- [1] C. Briggs, Z. Fan and P. Andras, “Federated learning for short-term residential load

forecasting,” arXiv preprint arXiv:2105.13325, May 2022.

- [2] A. Taik and S. Cherkaoui, “Electrical load forecasting using edge computing and federated learning,” arXiv preprint arXiv:2201.11248, Jan. 2022.
- [3] J. Sievers and T. Blank, “Secure short-term load forecasting for smart grids with transformer-based federated learning,” arXiv preprint arXiv:2310.17477, Oct. 2023.

- [4] S. Bose and K. Kim, “Federated short-term load forecasting with personalization layers for heterogeneous clients (PL-FL),” arXiv preprint arXiv:2309.13194, Sep. 2023.
- [5] R. Rahman, N. Kumar and D. C. Nguyen, “Electrical load forecasting in smart grid: A personalized federated learning approach,” in *Proc. IEEE Consumer Communications & Networking Conf. (CCNC)*, Las Vegas, NV, USA, Jan. 2025, pp. 1–6.
- [6] R. Rahman, P. Moriano, S. U. Khan and D. C. Nguyen, “Electrical load forecasting over multihop smart metering networks with federated learning,” arXiv preprint arXiv:2502.17226, Feb. 2025.
- [7] Z. Zhang, S. Rath, J. Xu and T. Xiao, “Federated learning for smart grid: A survey on applications and potential vulnerabilities,” arXiv preprint arXiv:2409.10764, May 2025.
- [8] A. Wallis, S. Hauke, H. Jörg and K. Ziegler, “Federated learning for distributed load forecasting: Addressing data imbalance in smart grids,” in *Proc. ENERGY 2025 Conf.*, 2025, pp. 13–18.
- [9] M. Zhang, Y. Li, H. Wang, X. Chen and J. Wu, “Enhancing smart grid load forecasting: An attention-based deep learning approach,” *Energy Reports*, vol. 12, pp. 567–578, Mar. 2024.
- [10] Y. Liu, Z. Dong, B. Liu, Y. Xu and Z. Ding, “FedForecast: A federated learning framework for short-term individual load forecasting,” *International Journal of Electrical Power & Energy Systems*, vol. 148, p. 108964, Oct. 2023.
- [11] American National Standards Institute, ANSI C12.20-2010: American National Standard for Electricity Meters—0.1, 0.2, and 0.5 Accuracy Classes. Washington, DC, USA: ANSI, 2010.
- [12] Z. Tang, Y. Yan, D. Wu, T. Yang, R. Dong, S. Hao, W. Wang, Y. Chen and Y. Tian, “A survey of integrating federated learning with smart grids: Application prospect, privacy preserving and challenges analysis,” in *Proc. Int. Conf. Big Data and Security (ICBDS)*, Singapore, Dec. 2022, pp. 227–240.
- [13] H. Chen, Y. Zhang, Z. Wang, J. Zhao, and X. Guan, “Federated online learning for adaptive load forecasting across dynamic smart grid environments,” *International Journal of Electrical Power & Energy Systems*, vol. 170, p. 109482, Feb. 2025.