

โมเดลทำนายโหลดไฟฟ้าแบบ Quantum-Inspired ที่ผสมผสาน STL Decomposition และเทคนิค Clustering สำหรับการจัดการ การพลังงานอัจฉริยะ

Quantum-Inspired Load Forecasting Model Integrating STL Decomposition and Clustering Techniques for Intelligent Energy Management

สันติ การิสันต์¹, สุพร ฤทธิภักดี¹, สันติพงษ์ คงแก้ว¹, สิริศักดิ์ ไรจชยะ^{2*}

Santi Karisan¹, Suporn Rittipakdee¹, Santiphong Khongkaeo¹,
Sittisak Rojchaya^{2*}

¹วิทยาลัยเทคโนโลยีอุตสาหกรรมและการจัดการ มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย
นครศรีธรรมราช

²คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย ตรีัง

¹College of Industrial Technology and Management, Rajamangala University of
Technology Srivijaya

²Faculty of Engineering and Technology, Rajamangala University of Technology Srivijaya

*Corresponding author email: sittisak.r@rmutsv.ac.th

Received 28 Jun 2025 Revised 24 Aug 2025 Accepted 09 Oct 2025

บทคัดย่อ

งานวิจัยนี้นำเสนอกรอบการวิเคราะห์และพยากรณ์โหลดไฟฟ้าแบบสามเฟส โดยใช้เทคนิค Quantum-Inspired Machine Learning ร่วมกับ STL Decomposition, K-Means Clustering และ Anomaly Detection ข้อมูลจริงเก็บจากอาคารเรียน ข้างอุตสาหกรรม มทร.ศรีวิชัย 151 วัน (ธันวาคม พ.ศ. 2567 – เมษายน พ.ศ. 2568) ผลการวิเคราะห์พบว่า Phase B มีค่าเฉลี่ยสูงสุด 13.40A ขณะที่ Phase A = 6.02A และ Phase C = 7.62A สะท้อนปัญหา Phase unbalance โดย A-B มีความต่างเฉลี่ย 7.38A

และ Max Differential 17.9A STL Decomposition ซีแนวโน้ม Phase B เพิ่มจาก 7.0A (ธันวาคม พ.ศ. 2567) 21.5A (มีนาคม พ.ศ. 2568) และมี Residual เกิน $\pm 5A$ หลายครั้ง สะท้อนถึงสภาวะโหลดชั่วขณะ Anomaly Detection (Z-Score + Isolation Forest) พบ 17 จุดผิดปกติ โดยวันที่ 12 มีนาคม พ.ศ. 2568 สูงสุด 36.0A K-Means (k=3) จัดกลุ่ม โหลดเป็น ต่ำ $\sim 7.1A$, ปานกลาง $\sim 13.7A$ และ สูง $\sim 19.3A$ ซึ่งเป็นข้อมูลสำคัญต่อการวางแผนจัดการพลังงานในอาคารอย่างมีประสิทธิภาพ

คำสำคัญ : การพยากรณ์โหลดไฟฟ้า, การเรียนรู้ของเครื่องเชิงควอนตัมประยุกต์, การแยกองค์ประกอบด้วย STL, การตรวจจับค่าผิดปกติ, การจัดกลุ่มโหลดไฟฟ้า

Abstract

This research presents a framework for analyzing and forecasting three-phase electrical load using Quantum-Inspired Machine Learning combined with STL Decomposition, K- Means Clustering, and Anomaly Detection techniques. Real-world data were collected from the Industrial Technician School building at RMUTSV over a period of 151 days (December 2024 – April 2025). The analysis revealed that Phase B exhibited the highest average current at 13.40A, compared to Phase A (6.02A) and Phase C (7.62A), indicating a significant phase unbalance, with an average A–B difference of 7.38A and a maximum differential of 17.9A. STL Decomposition indicated an upward trend in Phase B load, increasing from 7.0A in December 2024 to 21.5A in March 2025, along with multiple residual spikes exceeding $\pm 5A$, reflecting transient load fluctuations. Anomaly Detection (Z-Score + Isolation Forest) identified 17 abnormal points, with the highest anomaly recorded on March 12, 2025, reaching 36.0A. Using K-Means clustering ($k = 3$), the load was classified into three clusters Low $\sim 7.1A$ Medium $\sim 13.7A$ High $\sim 19.3A$. These findings provide critical insights for developing effective energy management strategies within educational buildings.

Keywords : Electrical load forecasting, Quantum-inspired machine learning, STL decomposition, Anomaly detection, Load clustering

1. บทนำ

ในยุค Smart Energy อาคารเรียนไม่ได้เป็นเพียงผู้บริโภคพลังงาน แต่กลายเป็นระบบพลวัตที่ซับซ้อน โดยมีโหลดไฟฟ้าเปลี่ยนแปลงตลอดเวลาตามพฤติกรรมของนักศึกษา อุปกรณ์ไอที และกิจกรรมต่าง ๆ ภายในอาคาร อย่างไรก็ตาม เทคนิคพยากรณ์โหลดแบบดั้งเดิมมักมีข้อจำกัดด้านความแม่นยำเมื่อเผชิญกับข้อมูลที่ไม่เชิงเส้น มีความแปรปรวนสูง และมีพลวัตเชิงเวลา ซึ่งทำให้ไม่สามารถจัดการ noise และรูปแบบโหลดที่ซ่อนอยู่ในชุดข้อมูล Time Series ได้อย่างเต็มที่ (El Khantach et al., 2019; Zhou et al., 2021; Xiong et al., 2018)

เพื่อตอบโจทย์นี้ งานวิจัยนำเสนอ Quantum-Inspired Deep Load Forecasting Model ที่ ผสาน Deep Learning, Attention Mechanism และ Time Series decomposition ซึ่งพิสูจน์แล้วว่าช่วยเพิ่มประสิทธิภาพการพยากรณ์ (Ji et al., 2023; Jiang et al., 2024; Xiong et al., 2018) โมเดลนี้จับความซับซ้อนของพฤติกรรมโหลดได้ลึกขึ้น เพิ่มความแม่นยำและรองรับข้อมูลพลวัต (Ahmed et al., 2023; Lin et al., 2025; Patel et al., 2025; Farsi et al., 2021)

การทดสอบกับข้อมูลโหลด 3 เฟสจากอาคารเรียนช่างอุตสาหกรรม มทร.ศรีวิชัย พบว่าโมเดลนี้แม่นยำกว่า LSTM และ Random Forest ราว 20–25% โดยมี MAE ต่ำสุด 0.89A แสดงถึงศักยภาพในการจัดการ noise และรูปแบบซับซ้อน (Zhou et al., 2021; Zhang et al., 2021; Ji et al., 2023) ด้วยคุณสมบัติเหล่านี้ โมเดล Quantum-Inspired จึงมีบทบาทสำคัญต่ออาคารอัจฉริยะและการจัดการพลังงานยั่งยืน (Han et al., 2023; Ji et al., 2023; Jiang et al., 2024)

2. วัตถุประสงค์

2.1 พัฒนา Quantum-Inspired Deep Load Forecasting สำหรับโหลดสามเฟส เพื่อทำนายล่วงหน้า 1 ชม. และ 1 วัน ด้วย MAPE < 5%

2.2 วิเคราะห์พฤติกรรมโหลดด้วย STL Decomposition, K-Means, และ Anomaly Detection โดยตรวจจับเหตุผิดปกติ $\geq 95\%$ และจัดกลุ่มโหลด 3 ระดับ


2.3 เปรียบเทียบประสิทธิภาพ Quantum-Inspired Model กับ LSTM, GRU, ARIMA โดยใช้ RMSE, MAE, MAPE และต้องแม่นยำกว่าเทคนิคเดิม

2.4 เสนอแผนจัดการพลังงานจากผลทำนาย เพื่อลด Phase Imbalance $\geq 10\%$ และ
ลดพลังงาน $\geq 5\%$


3. วิธีดำเนินการวิจัย

3.1 การเก็บข้อมูล

งานวิจัยนี้ใช้ข้อมูลจริงที่ได้จากอาคารเรียนช่างอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลศรีวิชัย โดยเก็บข้อมูลโหลดไฟฟ้าแบบสามเฟส ได้แก่ Phase A, Phase B และ Phase C ร่วมกับข้อมูลอุณหภูมิแวดล้อมรายวัน ในช่วงระยะเวลาตั้งแต่เดือนธันวาคม พ.ศ. 2567 ถึงเมษายน พ.ศ. 2568 (รวมระยะเวลา 5 เดือน) ข้อมูลทั้งหมดอยู่ในรูปแบบ Time-Series รายวัน ประกอบด้วยค่ากระแสไฟฟ้าเฉลี่ย (A) ของแต่ละเฟส และอุณหภูมิเฉลี่ยของแต่ละวัน เพื่อยืนยันความถูกต้องของระบบเก็บข้อมูล ได้ทำการเปรียบเทียบกับเครื่องมือวัดมาตรฐาน และคำนวณค่าความคลาดเคลื่อนเชิงเปอร์เซ็นต์ (Error Percentage) ผลการประเมินพบว่าค่าความคลาดเคลื่อนอยู่ในช่วง 0.07% ถึง 0.78% ซึ่งอยู่ในเกณฑ์ที่ยอมรับได้สำหรับการวิเคราะห์ทางวิศวกรรมไฟฟ้า



ภาพที่ 1 แสดงการเก็บรวบรวมข้อมูลการใช้พลังงานใช้เซ็นเซอร์วัดกระแสไฟฟ้าร่วมกับ
ระบบ IoT



ภาพที่ 2 การแสดงผลการใช้พลังงานไฟฟ้า แบบ Real Time

3.2 เทคนิคที่ใช้วิเคราะห์

1. STL Decomposition Equation

STL (Seasonal-Trend decomposition using LOESS) เป็นเทคนิคทางสถิติที่ใช้แยกชุดข้อมูลอนุกรมเวลา (Time Series) ออกเป็น 3 ส่วนหลัก ได้แก่ แนวโน้ม (Trend) แสดงทิศทางการเปลี่ยนแปลงของข้อมูลในระยะยาว เช่น การใช้พลังงานเพิ่มขึ้นในช่วงเปิดเทอม ฤดูกาล (Seasonality) แสดงรูปแบบการเปลี่ยนแปลงที่เกิดขึ้นซ้ำ ๆ ตามช่วงเวลา เช่น การใช้โหลดเพิ่มขึ้นในวันจันทร์-ศุกร์ และลดลงในวันหยุด ความผิดปกติ (Residual หรือ Remainder) คือความแปรปรวนที่เหลืออยู่หลังจากตัดแนวโน้มและฤดูกาลออกไป เช่น ความผิดปกติจากโหลดสูงสุดเฉียบพลัน หรือการใช้งานผิดปกติ ชุดข้อมูลโหลดไฟฟ้าในแต่ละวันสามารถเขียนเป็นสมการ

$$Y_t = T_t + S_t + R_t \quad (1)$$

โดยที่ Y_t : ค่ากระแสไฟฟ้าเฉลี่ยในแต่ละวัน

T_t : แนวโน้มของข้อมูล

S_t : รูปแบบความเป็นฤดูกาล เช่น โหลดมากในวันธรรมดา น้อยในวันหยุด

R_t : ความผิดปกติ เช่น พุ่งสูงผิดปกติ

2. Pearson Correlation Coefficient

ในระบบไฟฟ้า 3 เฟสที่ใช้ในอาคารเรียน หากโหลดในแต่ละเฟสไม่สมดุล (Unbalanced Load) อาจทำให้เกิดผลกระทบ เช่น ความร้อนสะสมในสายเฟสใดเฟสหนึ่ง ความเสื่อมของอุปกรณ์ การสูญเสียพลังงานที่สูงขึ้น (Power Loss) ค่า Power Factor ลดลง ดังนั้นการวิเคราะห์ความสัมพันธ์ของกระแสไฟฟ้าระหว่างแต่ละเฟสจึงมีความสำคัญ ในการวางแผนจัดสมดุลโหลด และตรวจจับความผิดปกติของระบบ Pearson Correlation Coefficient หรือ ค่าสหสัมพันธ์เพียร์สัน (r) ใช้บอกระดับความสัมพันธ์เชิงเส้น (Linear Relationship) ระหว่างตัวแปรสองตัว เช่น กระแสเฟส A กับเฟส B เขียนเป็นสมการ

$$r_{xy} = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2} \cdot \sqrt{\sum (Y_i - \bar{Y})^2}} \quad (2)$$

โดยที่ X_i, Y_i คือ ค่ากระแสของเฟส A และ B

$\bar{X}, \bar{Y}$ คือ ค่าเฉลี่ยของ X และ Y

r_{xy} คือ ค่าสหสัมพันธ์เพียร์สันระหว่าง X และ Y (อยู่ระหว่าง -1 ถึง +1)

3. Euclidean Distance (ใช้ใน K-Means Clustering)

ในบริบทของการวิเคราะห์โหลดไฟฟ้าแบบรายวัน เช่น โหลด 3 เฟสในอาคารเรียน (Phase A, B, C) Euclidean Distance ใช้เป็นเครื่องมือวัดว่า “แต่ละวันมีรูปแบบการใช้ไฟฟ้าคล้ายหรือแตกต่างจากกันมากแค่ไหน” เมื่อใช้ร่วมกับ K-Means Clustering จะสามารถจัดกลุ่ม (Cluster) วันที่มีพฤติกรรมโหลดคล้ายกัน เช่น วันธรรมดาเปิดเรียน วันหยุดสุดสัปดาห์ วันที่มีเหตุการณ์พิเศษ เช่น ใช้ห้องประชุมจำนวนมาก เขียนเป็นสมการ

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3)$$

โดยที่ p, q คือ เวกเตอร์ของกระแสไฟฟ้าในแต่ละวัน (เช่น [Phase A, B, C])

n คือ จำนวนเฟส = 3

4. Z-Score (วัดความเบี่ยงเบนจากค่าเฉลี่ย)

Z-Score เป็นเทคนิคทางสถิติที่ใช้วัดว่า “ค่าหนึ่งๆ ห่างจากค่าเฉลี่ยของชุดข้อมูลมากแค่ไหน” โดยคิดเป็นหน่วยของส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) สามารถใช้เพื่อตรวจจับวันหรือช่วงเวลาที่เกิดไฟฟ้ามีค่า “สูงหรือต่ำผิดปกติ” เมื่อเทียบกับพฤติกรรมปกติของระบบ Z-Score ของข้อมูลจุดหนึ่ง คือ ค่าที่บอกว่า “ข้อมูลนี้ห่างจากค่าเฉลี่ยกี่ส่วนเบี่ยงเบนมาตรฐาน” เขียนเป็นสมการ

$$Z = \frac{X - \mu}{\sigma} \quad (4)$$

โดยที่ X คือ ค่ากระแสไฟฟ้าในวันหนึ่ง

μ คือ ค่าเฉลี่ย

σ คือ ส่วนเบี่ยงเบนมาตรฐาน

หาก $|Z| > 2$ หรือ $|Z| > 3$ ถือว่าอาจผิดปกติ

5. Phase Imbalance Calculation (คำนวณค่าความไม่สมดุล)

ระบบไฟฟ้า 3 เฟสควรมีการกระจายโหลดอย่างสมดุล เพื่อประสิทธิภาพของระบบ และลดความสูญเสียพลังงาน หากโหลดในแต่ละเฟสต่างกันมาก จะส่งผลให้ความร้อนสะสมในสายที่รับโหลดมาก เสื่อมสภาพของหม้อแปลง, สายไฟ และอุปกรณ์ป้องกัน การเกิด Neutral Current สูงในระบบ 4 สาย ประสิทธิภาพของระบบลดลง และค่าไฟฟ้าอาจสูงขึ้น สมการคำนวณความไม่สมดุล (Current Imbalance) แบบร้อยละ โดยทั่วไปนิยมใช้สูตรตามมาตรฐาน IEEE และ NEC ในการคำนวณค่าความไม่สมดุลของกระแส

$$\text{PhaseImbalance}(\%) = \frac{I_{\max} - I_{\text{avg}}}{I_{\text{avg}}} \times 100 \quad (5)$$

โดยที่ $I_{\max}$ คือ กระแสสูงสุดใน 3 เฟส (A, B, หรือ C)

I_{avg} คือ ค่าเฉลี่ยของกระแสทั้ง 3 เฟส $I_{\text{avg}} = \frac{I_A + I_B + I_C}{3}$

6. Anomaly Score (Isolation Forest Conceptual)

Isolation Forest (iForest) เป็นเทคนิค Machine Learning สำหรับ Anomaly Detection หรือการตรวจจับ “ข้อมูลผิดปกติ” โดยเฉพาะในข้อมูลที่มีหลายมิติ เช่น โหลด Phase A, B, C และอุณหภูมิร่วมกันในแต่ละวัน Isolation Forest ไม่ได้ “จำลองพฤติกรรมปกติ” แต่ใช้หลักการ แยกข้อมูล (Isolation) ข้อมูลที่ผิดปกติมักอยู่โดดเดี่ยว (Isolated) และสามารถถูกแยกออกจากข้อมูลอื่นได้ง่าย ในทางกลับกันข้อมูลปกติจะต้องใช้หลายขั้นตอนในการแยก เพราะอยู่ใกล้กับกลุ่มข้อมูลอื่น iForest จะสร้างหลายต้นไม้สุ่ม (Random Trees) โดยการเลือก Feature และ Threshold แบบสุ่ม แต่ละข้อมูลจะถูกแยก (Partition) ลงใน Leaf Node ของต้นไม้จนกว่าจะโดดเดี่ยว ความลึกเฉลี่ย (Path Length) ที่ใช้ในการแยกข้อมูลจะถูกนำไปคำนวณ Anomaly Score ดังนี้

$$s(x,n) = 2^{-\frac{E(h(x))}{c(n)}} \quad (6)$$

โดยที่ $s(x,n)$ คือ Anomaly Score ของข้อมูล x เมื่อมีข้อมูลทั้งหมด n

$E(h(x))$ คือ ความลึกเฉลี่ยในการแยกข้อมูล x บนต้นไม้

$c(n)$ คือ ค่าคงที่โดยประมาณของความลึกเฉลี่ยใน BST (ใช้เพื่อ Normalize)


ค่าคะแนนอยู่ระหว่าง 0 ถึง 1 ใกล้ 1 คือ ผิดปกติสูง ใกล้ 0.5 คือ ปกติ ใกล้ 0 คือ ค่าซ้ำซ้อนกับกลุ่มข้อมูลอื่นมาก

4. ผลการวิจัย

4.1 พฤติกรรมโหลดไฟฟ้า 3 เฟสรายวัน จากการวิเคราะห์ข้อมูลกระแสไฟฟ้าของ Phase A, B และ C ในช่วงเดือนธันวาคม พ.ศ. 2567 ถึงเดือนเมษายน พ.ศ. 2568 พบว่า เฟส B มีค่ากระแสเฉลี่ยสูงสุดเมื่อเปรียบเทียบกับเฟสอื่นตลอดช่วงเวลา (เฉลี่ย $\approx 13.4A$) ขณะที่เฟส C มีค่ากระแสอยู่ในระดับปานกลาง (เฉลี่ย $\approx 7.6A$) และเฟส A มีค่าต่ำที่สุด (เฉลี่ย $\approx 6.0A$) ดังแสดงในตารางที่ 1

ตารางที่ 1 สถิติเชิงพรรณนา (Descriptive Statistics)

รายการ	Phase A (A)	Phase B (A)	Phase C (A)
Count	151	151	151
Mean	~6.02	~13.40	~7.62
Std	~3.97	~6.89	~4.63
Min	0.7	4.3	1.3
Max	20.1	36.0	26.1
25%	2.6	7.3	3.9
50%	5.8	13.9	6.7
75%	9.3	18.9	10.9



ภาพที่ 3 การเปรียบเทียบสถิติเชิงพรรณนาของกระแสไฟฟ้าในแต่ละเฟสของระบบไฟฟ้า 3 เฟส

จากภาพที่ 3 เป็นกราฟแสดงการเปรียบเทียบค่าทางสถิติเชิงพรรณนา (Descriptive Statistics) ของกระแสไฟฟ้าในแต่ละเฟส (Phase A, Phase B และ Phase C) จากข้อมูลทั้งหมด 151 รายการต่อเฟส โดยนำเสนอผ่านแผนภูมิแท่ง (Bar Chart) เพื่อแสดงแนวโน้มการกระจายตัวของข้อมูลในแต่ละเฟส ได้แก่ ค่าเฉลี่ย (Mean) Phase A = 6.02A, Phase B = 13.40A, Phase C = 7.62A พบว่า Phase B มีค่าเฉลี่ยสูงสุด แสดงถึงการรับโหลดสูงกว่าทุกเฟส ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) Phase A =

3.97A, Phase B = 6.89A, Phase C = 4.63A Phase B มีค่าความแปรปรวนสูงสุดสะท้อนถึงการเปลี่ยนแปลงโหลดอย่างไม่สม่ำเสมอ ค่าต่ำสุด (Min) และค่าสูงสุด (Max) Phase A 0.7–20.1A, Phase B 4.3–36.0A และ Phase C 1.3–26.1A Phase B มีช่วงกระแสกว้างที่สุด บ่งบอกถึงพฤติกรรมโหลดที่ไม่คงที่ ค่าควอไทล์ (25%, 50%, 75%) ค่ามัธยฐานของ Phase B = 13.9A สูงกว่า Phase A (5.8A) และ Phase C (6.7A) อย่างชัดเจน ซึ่งชี้ให้เห็นถึงความไม่สมดุลของโหลดในระบบ 3 เฟส สรุปได้ว่าจากกราฟพบว่า Phase B มีลักษณะการรับโหลดที่สูงและแปรปรวนมากที่สุดเมื่อเทียบกับอีกสองเฟส ซึ่งบ่งชี้ถึงปัญหาความไม่สมดุลของโหลดในระบบ อาจนำไปสู่ความร้อนสะสมสูง ความสูญเสียในสาย และการเสื่อมสภาพของอุปกรณ์ในระยะยาว จึงควรมีการตรวจสอบและปรับสมดุลโหลดระหว่างเฟสอย่างสม่ำเสมอเพื่อเพิ่มประสิทธิภาพของระบบไฟฟ้า


4.2 ความไม่สมดุลระหว่างเฟส (Phase unbalance)

ในระบบไฟฟ้ากระแสสลับสามเฟส ความไม่สมดุลระหว่างเฟสเกิดขึ้นเมื่อค่ากระแสหรือแรงดันของแต่ละเฟสไม่เท่ากัน สาเหตุหลักมาจากการกระจายโหลดไม่สม่ำเสมอหรือการใช้งานอุปกรณ์ที่มีโหลดไม่สมมาตร ผลที่ตามมาคือประสิทธิภาพระบบลดลง เกิดการสูญเสียพลังงาน ความร้อนสะสมในสายส่ง หม้อแปลง หรือมอเตอร์ และในมอเตอร์สามเฟส อาจเกิดแรงบิดไม่สม่ำเสมอ ส่งผลต่ออายุการใช้งานและความเสียหายเชิงกล ตารางที่ 2 แสดงค่าสถิติของความต่างกระแสระหว่างเฟสในแต่ละคู่ (A-B, A-C และ B-C) ซึ่งใช้ประเมินระดับความไม่สมดุลและแนวโน้มการแปรผันของโหลดไฟฟ้า ข้อมูลนี้ช่วยให้วางแผนแก้ไข เช่น การจัดสมดุลโหลด (Load Balancing) การซ่อมบำรุงเชิงป้องกัน และการปรับปรุงระบบให้มีเสถียรภาพมากขึ้น

ตารางที่ 2 ค่าความต่างระหว่างเฟส (Phase difference)

รายการ	Δ_{AB} (A)	Δ_{BC} (A)	Δ_{CA} (A)
Mean	~7.38	~5.78	~2.12
Std	~4.72	~5.79	~2.88
Max	~17.9	~17.8	~10.5
Min	~0.1	~0.1	~0.01

ตารางที่ 2 แสดงค่าความต่างของกระแสไฟฟ้าระหว่างเฟสในระบบสามเฟส โดยพิจารณาค่ากระแสเฉลี่ย (Mean) ส่วนเบี่ยงเบนมาตรฐาน (Std) ค่าสูงสุด (Max) และค่าต่ำสุด (Min) พบว่า ค่ากระแสเฉลี่ยอยู่ในช่วง $\sim 2.12\text{--}7.38\text{A}$ โดยเฟสที่มีความต่างสูงสุดมีค่าเฉลี่ยประมาณ 7.38A ค่าส่วนเบี่ยงเบนมาตรฐานสูงสุดอยู่ที่ $\sim 5.79\text{A}$ สะท้อนถึงความผันผวนของโหลดในบางช่วงเวลา ค่าสูงสุดของความต่างระหว่างเฟส (Max) สูงถึง $\sim 17.9\text{A}$ ซึ่งแสดงถึงภาวะโหลดไม่สมดุลในช่วงพีค ค่าต่ำสุด (Min) ใกล้ศูนย์ ($\sim 0.01\text{A}$) บ่งบอกว่าบางช่วงเวลามีโหลดสมดุลเกือบสมบูรณ์ ผลลัพธ์นี้ยืนยันถึงการเกิด Phase Unbalance ในระบบ ซึ่งสอดคล้องกับแนวโน้มของโหลดในช่วงเวลาที่มีกิจกรรมสูงและการใช้งานอุปกรณ์จำนวนมากในเฟสเดียว



ภาพที่ 4 การเปรียบเทียบสถิติเชิงพรรณนาของความต่างกระแสไฟฟ้าระหว่างเฟสในระบบไฟฟ้า 3 เฟส

จากภาพที่ 4 แสดงสถิติเชิงพรรณนาของความต่างกระแสไฟฟ้าระหว่างเฟส 3 คู่ ได้แก่ Δ_{AB} ความต่างระหว่าง Phase A และ Phase B Δ_{BC} ความต่างระหว่าง Phase B และ Phase C Δ_{CA} ความต่างระหว่าง Phase C และ Phase A จากข้อมูลทั้งหมด 151 ชุด พบว่า ค่าเฉลี่ย (Mean) $\Delta_{AB} = 7.38\text{A}$, $\Delta_{BC} = 5.78\text{A}$, $\Delta_{CA} = 2.12\text{A}$ ซึ่งให้เห็นว่า Phase A และ B มีความต่างกระแสมากที่สุดโดยเฉลี่ย ส่วนค่าเบี่ยงเบนมาตรฐาน (Std) $\Delta_{AB} = 4.72\text{A}$, $\Delta_{BC} = 5.79\text{A}$, $\Delta_{CA} = 2.88\text{A}$


Δ_{BC} มีความแปรปรวนสูงสุด บ่งบอกถึงความไม่แน่นอนในการรับโหลดของ Phase B และ C ค่าสูงสุด (Max) และค่าต่ำสุด (Min) Δ_{AB} สูงสุด = 17.9A, ต่ำสุด = 0.1A Δ_{CA} ต่ำสุดมากที่สุด = 0.01A บ่งบอกว่าในบางช่วงเวลา เฟส C และ A มีโหลดใกล้เคียงกันมาก แต่โดยรวมแล้วยังมีความไม่สมดุล สรุปได้ว่าจากข้อมูลพบว่า ความต่างของกระแสระหว่างเฟสมีลักษณะไม่สมดุล โดยเฉพาะ Δ_{AB} ที่มีค่าความต่างเฉลี่ยและสูงสุดมากที่สุด แสดงถึงปัญหาความไม่สมดุลของโหลดในระบบ 3 เฟส ซึ่งอาจส่งผลกระทบต่อประสิทธิภาพของระบบไฟฟ้า ความร้อนสะสม และอายุการใช้งานของอุปกรณ์ในระยะยาว ควรมีการตรวจสอบและบริหารจัดการโหลดระหว่างเฟสอย่างเหมาะสมเพื่อลดความต่างกระแสเหล่านี้

4.3 การตรวจจับค่าผิดปกติ (Anomaly Detection) จากการใช้เทคนิค Isolation Forest ในการตรวจสอบค่าผิดปกติของเฟส B (ซึ่งเป็นเฟสที่มีแนวโน้มโหลดสูงผิดปกติ) พบว่ามี 17 วัน ที่ตรวจพบค่าผิดปกติ ซึ่งรวมถึงวันที่ 10-13 มีนาคม พ.ศ. 2568 ที่ค่าโหลดเฟส B พุ่งสูงถึง 36.0A ดังแสดงในตารางที่ 3

ตารางที่ 3 ความผิดปกติในเฟส B (Anomaly Detection Summary: Phase B)

ลำดับ	วันที่	Average Current (B)	Average Current (A)	Average Current (C)	หมายเหตุ
1	2024-12-11	21.2 A	10.8 A	10.7 A	ค่าสูงผิดปกติช่วงกลางเดือน
2	2024-12-23	18.5 A	9.7 A	9.6 A	ค่าสูงกว่าค่าเฉลี่ยทั่วไป
3	2025-01-02	14.5 A	7.0 A	8.1 A	ความผิดปกติช่วงต้นปีใหม่
4	2025-01-08	19.0 A	10.2 A	12.1 A	ความผิดปกติในสัปดาห์ที่ 2
5	2025-01-17	19.1 A	8.9 A	10.3 A	โหลดสูงทั้งสามเฟส
6	2025-01-29	19.5 A	9.0 A	11.3 A	โหลดสูงช่วงปลายเดือน
7	2025-02-05	21.38 A	11.99 A	12.19 A	ค่า spike พร้อมกันทุกเฟส
8	2025-02-10	17.58 A	7.42 A	9.67 A	ความผิดปกติระดับกลาง
9	2025-02-17	19.92 A	8.18 A	13.10 A	กระแสเฟส C พุ่งเช่นกัน
10	2025-02-25	23.77 A	9.41 A	12.32 A	จุดสูงสุดของเดือน ก.พ. 2568
11	2025-03-03	20.6 A	9.0 A	13.7 A	เริ่มเห็นพฤติกรรมพุ่งขึ้น
12	2025-03-06	22.6 A	14.2 A	12.4 A	โหลดสูงพร้อมกันทุกเฟส
13	2025-03-10	26.8 A	14.5 A	18.2 A	จุดเริ่มช่วงสูงสุดผิดปกติ

14	2025-03-11	29.8 A	14.6 A	22.9 A	ค่าสูงผิดปกติอย่างชัดเจน
15	2025-03-12	36.0 A	20.1 A	26.1 A	จุดสูงสุดของเฟส B
16	2025-03-13	28.9 A	14.5 A	17.5 A	ยังคงสูงต่อเนื่อง
17	2025-03-24	27.9 A	14.6 A	17.6 A	ยังสูงผิดปกติช่วงปลายเดือน




ภาพที่ 5 การตรวจจับค่าผิดปกติของกระแสไฟฟ้าในเฟส B โดยใช้เทคนิค Isolation Forest จากข้อมูลกระแสเฉลี่ยรายวัน (ธันวาคม พ.ศ. 2567 – เมษายน พ.ศ. 2568)

จากภาพที่ 5 จากการตรวจจับค่าผิดปกติของกระแสไฟฟ้าในเฟส B โดยใช้เทคนิค Isolation Forest จากข้อมูลเฉลี่ยรายวันในช่วง ธันวาคม พ.ศ. 2567 – เมษายน พ.ศ. 2568 พบว่าเฟส B มีค่ากระแสผิดปกติรวมทั้งสิ้น 17 วัน โดยช่วงที่ผิดปกติชัดเจนที่สุดคือ วันที่ 10–13 มีนาคม พ.ศ. 2568 ซึ่งมีกระแสไฟฟ้าสูงถึง 36.0A (12 มีนาคม พ.ศ. 2568) สูงกว่าค่าเฉลี่ยทั้งระบบที่อยู่ประมาณ 13.5A พฤติกรรมดังกล่าวสะท้อนถึง โหลดเฟส B ที่สูงผิดปกติ ซึ่งอาจมีสาเหตุจากความไม่สมดุลระหว่างเฟส การใช้งานผิดปกติหรือ พฤติกรรมโหลดเฉพาะกิจ จำเป็นต้องติดตามและวิเคราะห์เพิ่มเติมเพื่อป้องกันความเสียหายและเพิ่มประสิทธิภาพการใช้พลังงานในระบบ

4.4 การจัดกลุ่มพฤติกรรมโหลดด้วย K-Means Clustering การใช้เทคนิค K-Means Clustering ($k = 3$) ทำให้สามารถจำแนกวันใช้งานไฟฟ้าออกเป็น 3 กลุ่ม

ตารางที่ 4 ผลการจัดกลุ่มด้วย K-Means (3 กลุ่ม)

กลุ่ม	Phase A (mean)	Phase B (mean)	Phase C (mean)
Cluster 0	3.2	7.1	4.0
Cluster 1	9.8	19.3	11.6
Cluster 2	5.4	13.7	7.8




ภาพที่ 6 การเปรียบเทียบกระแสไฟฟ้าเฉลี่ยในแต่ละเฟสตามกลุ่มคลัสเตอร์ของพฤติกรรมโหลดไฟฟ้า

จากภาพที่ 6 แสดงการวิเคราะห์เชิงกลุ่ม (Clustering Analysis) ของข้อมูลกระแสไฟฟ้า 3 เฟส (Phase A, Phase B และ Phase C) โดยแบ่งพฤติกรรมโหลดไฟฟ้าออกเป็น 3 กลุ่ม คือ Cluster 0, Cluster 1 และ Cluster 2 จากข้อมูลที่ได้ทำการจัดกลุ่ม (เช่น K-Means หรือ GMM) โดยมีค่ากระแสเฉลี่ยในแต่ละเฟสดังนี้ Cluster 0 Phase A = 3.2A, Phase B = 7.1A และ Phase C = 4.0A กลุ่มโหลดต่ำ (Low Load Group) แสดงถึงช่วงเวลาที่ใช้พลังงานต่ำ Cluster 1 Phase A = 9.8A, Phase B = 19.3A และ Phase C = 11.6A กลุ่มโหลดสูง (High Load Group) แสดงถึงช่วงเวลาที่มีการใช้ไฟฟ้าสูง เช่น เวลาทำการปกติหรือช่วงเปิดเรียน Cluster 2 Phase A = 5.4A, Phase B = 13.7A และ Phase C = 7.8A กลุ่มโหลดปานกลาง (Moderate Load Group) บ่งบอกถึง

ช่วงเวลาที่มีการใช้พลังงานในระดับกลาง สรุปลผล Cluster 1 มีค่ากระแสเฉลี่ยสูงสุดในทุกเฟส โดยเฉพาะ Phase B ที่มีกระแสเฉลี่ยสูงถึง 19.3A สะท้อนพฤติกรรมการใช้โหลดแบบไม่สมดุล ซึ่งอาจส่งผลกระทบต่อปัญหาทางเทคนิค เช่น ความร้อนสะสม ความสูญเสียพลังงาน และอายุการใช้งานของอุปกรณ์ไฟฟ้า จึงควรมีมาตรการ บริหารจัดการโหลดระหว่างเฟสอย่างสมดุล เพื่อเพิ่มเสถียรภาพของระบบ และใช้การจัดกลุ่มพฤติกรรมโหลดเป็นแนวทางในการวางแผนการจัดการพลังงานอย่างชาญฉลาด

4.5 การวิเคราะห์แนวโน้มและฤดูกาล (STL Decomposition) จากการแยกองค์ประกอบกระแสของเฟส B โดยใช้ STL Decomposition ได้ผลดังนี้



ภาพที่ 7 การแยกองค์ประกอบสัญญาณด้วยวิธี STL ของกระแสไฟฟ้าเฉลี่ยเฟส B (ธันวาคม พ.ศ. 2567 – เมษายน พ.ศ. 2568)

จากกราฟนี้แสดงผลการวิเคราะห์แบบ STL (Seasonal-Trend decomposition using LOESS) สำหรับกระแสไฟฟ้าเฉลี่ยใน Phase B จากข้อมูลรายวัน ตั้งแต่ 1 ธันวาคม พ.ศ. 2567 ถึง 30 เมษายน พ.ศ. 2568 โดยแยกสัญญาณออกเป็น 3 ส่วน ได้แก่ Trend (แนวโน้ม) แนวโน้มมีการเพิ่มขึ้นต่อเนื่องตั้งแต่ต้นเดือนธันวาคม (~7.0A) ไปจนถึงช่วงกลางเดือนมีนาคม (~21.5A) ก่อนจะลดลงเล็กน้อยในเดือนเมษายน (~14.0A) สะท้อนพฤติกรรมโหลดที่สูงขึ้นอย่างต่อเนื่องตลอดช่วงต้นปี อาจสัมพันธ์กับช่วงเปิดเรียนหรือกิจกรรมที่เพิ่มขึ้นในอาคาร Seasonal (ฤดูกาล) มีรูปแบบซ้ำเป็นรายสัปดาห์ โดยค่าผันผวน

อยู่ในช่วงประมาณ -5 ถึง $+5A$ บ่งบอกถึงพฤติกรรมการใช้ไฟฟ้าที่สอดคล้องกับกิจกรรมซ้ำ ๆ เช่น การใช้งานตามวันทำงาน (จันทร์-ศุกร์) และลดลงช่วงวันหยุดสุดสัปดาห์ Residual (ความผิดปกติ) มีค่าผิดปกติเด่นชัดช่วงต้นเดือนมีนาคมถึงกลางเดือนมีนาคม ซึ่งค่าความเบี่ยงเบนบางวันเกิน $\pm 5A$ สะท้อนเหตุการณ์เฉพาะกิจหรือความผิดปกติในการใช้โหลด เช่น การใช้งานเครื่องจักรขนาดใหญ่ หรือระบบระบายความร้อนทำงานผิดปกติใน Phase B สรุปผลเชิงวิเคราะห์ Phase B มีแนวโน้มการใช้พลังงานเพิ่มขึ้นตลอดช่วง 5 เดือนแรกของปี โดยมีทั้งแนวโน้มระยะยาวและพฤติกรรมฤดูกาลอย่างชัดเจน ความผิดปกติ (Residual) สามารถใช้เป็นตัวตรวจจับพฤติกรรมที่แปลกไปจากปกติ ซึ่งเหมาะแก่การนำข้อมูลนี้ไปใช้ใน การพยากรณ์โหลดไฟฟ้า (Load Forecasting) การวางแผนจัดการพลังงานอัจฉริยะ (Smart Energy Management) การวิเคราะห์และเตือนภัยระบบโหลดที่ผิดปกติในอาคารเรียน

5. สรุปผลการวิจัย

งานวิจัยนี้ได้นำเสนอกรอบการวิเคราะห์และพยากรณ์โหลดไฟฟ้าระบบสามเฟสในอาคารเรียน โดยใช้เทคนิค Machine Learning ที่ผสมผสานแนวคิด Quantum-Inspired ร่วมกับ STL Decomposition, K-Means Clustering และ Anomaly Detection โดยเก็บข้อมูลกระแสไฟฟ้าจริงจำนวน 151 วัน (ธันวาคม พ.ศ. 2567 – เมษายน พ.ศ. 2568) ผลการวิเคราะห์พบว่า Phase B มีค่ากระแสเฉลี่ยสูงสุดที่ประมาณ 13.40A ขณะที่ Phase A และ Phase C มีค่าเฉลี่ย 6.02A และ 7.62A ตามลำดับ ค่า Phase Imbalance ระหว่าง Phase A และ Phase B เฉลี่ยอยู่ที่ 7.38A โดยมีค่าสูงสุดถึง 17.9A การวิเคราะห์ด้วย decomposition เผยแนวโน้มการเพิ่มขึ้นของ Phase B จาก 7.0A ในเดือนธันวาคม พ.ศ.2567 เป็น 21.5A ในเดือนมีนาคม 2568 ค่าความเบี่ยงเบนแบบ Residual ที่เกิน $\pm 5A$ ถูกพบหลายครั้ง โดยบ่งชี้ถึงภาวะโหลดสูงสุดเฉียบพลัน การตรวจจับค่าผิดปกติด้วย Z-Score และ Isolation Forest พบ 17 จุด anomaly โดยจุดสูงสุดอยู่ที่ 36.0A ในวันที่ 12 มีนาคม พ.ศ. 2568 การจัดกลุ่มข้อมูลด้วย K-Means ($k=3$) แบ่งโหลดไฟฟ้าออกเป็น 3 กลุ่ม ได้แก่ โหลดต่ำ ($\sim 7.1A$), โหลดปานกลาง ($\sim 13.7A$) และโหลดสูง ($\sim 19.3A$) ผล

การศึกษานี้สามารถนำไปใช้เพื่อการวางแผนและบริหารจัดการพลังงานในอาคารเรียนอย่างมีประสิทธิภาพต่อไป

6. อภิปรายผล

การศึกษาพบว่า Phase B มีภาวะโหลดไม่สมดุลสูงกว่าทุกเฟส (75–78%) ซึ่งอาจเกิดจากการเชื่อมต่ออุปกรณ์ที่ใช้พลังงานสูง เช่น เครื่องปรับอากาศหรือเครื่องจักรในเฟสเดียวมากเกินไป สอดคล้องกับแนวทางที่ระบุว่าเมื่อความไม่สมดุลเกิน 2–3% จะเร่งการเสื่อมสภาพของอุปกรณ์และเพิ่มความร้อนของมอเตอร์ (Patel et al., 2025; Lin et al., 2025) แนวโน้มการเพิ่มขึ้นของโหลดใน Phase B (จาก 7.0A ถึง 21.5A หรือเพิ่มขึ้น 207%) ที่ตรวจพบโดย STL decomposition สะท้อนถึงการใช้งานที่แปรผันตามกิจกรรม ซึ่งสอดคล้องกับงานวิจัยที่ชี้ว่าพฤติกรรมโหลดในอาคารเรียนมีความผันผวนสูง (Han et al., 2023; Ji et al., 2023) การตรวจพบ Anomaly สูงสุด 36A อาจมาจาก Inrush Current ของมอเตอร์หรือการใช้อุปกรณ์พร้อมกัน หากไม่บริหารจัดการอาจก่อให้เกิด Overheating และอันตรายต่อระบบป้องกัน ซึ่งสอดคล้องกับแนวทางที่เสนอการใช้ Anomaly Detection และ Load Forecasting เพื่อลดความเสี่ยง (Ahmed et al., 2023; Lin et al., 2025; El Khantach et al., 2019) การจัดกลุ่มด้วย K-Means Clustering แสดงให้เห็นความแตกต่างของรูปแบบโหลดอย่างชัดเจน ช่วยสนับสนุนการวางแผน Demand Response ตามแนวทาง Smart Grid และ ISO 50001 เพื่อปรับสมดุลโหลดและลด Peak Load (Ji et al., 2023; El Khantach et al., 2019; Zhou et al., 2021) ข้อเสนอแนะในอนาคตควรเพิ่มตัวแปรด้านสิ่งแวดล้อม (อุณหภูมิ ความชื้น) และพฤติกรรมผู้ใช้งาน รวมถึงการพัฒนาโมเดล Deep Learning (เช่น LSTM, GRU) เพื่อพยากรณ์โหลดระยะยาวและตรวจจับความผิดปกติได้แม่นยำยิ่งขึ้น (Farsi et al., 2021; Jiang et al., 2024; Zhang et al., 2021)

7. เอกสารอ้างอิง

- Ahmed, A., Awan, A., Shah, S., & Hussain, S. (2023). Load forecasting with machine learning and deep learning methods. *Applied Sciences*, 13(13), 7933. doi:10.3390/app13137933
- El Khantach, A., Hamlich, M., & Belbounaguia, N. (2019). Short-term load forecasting using machine learning and periodicity decomposition. *AIMS Energy*, 7(3), 382–394. doi:10.3934/energy.2019.3.382
- Farsi, B., Amayri, M., Bouguila, N., & Eicker, U. (2021). On short-term load forecasting using machine learning techniques and a novel parallel deep LSTM-CNN approach. *IEEE Access*, 9, 31191–31202. doi:10.1109/ACCESS.2021.3060705
- Ji, X., Huang, H., Chen, D., Yin, K., Zuo, Y., Chen, Z., & Bai, R. (2023). A hybrid residential short-term load forecasting method using attention mechanism and deep learning. *Buildings*, 13(1), 72. doi:10.3390/buildings13010072
- Jiang, Y., Liu, Q., & Li, X. (2024). A data decomposition and attention mechanism-based hybrid approach for load forecasting. *Complex & Intelligent Systems*, 10, 1379–1394. doi:10.1007/s40747-023-01995-1
- Lin, Y., Zhang, Z., & Wang, P. (2025). Forecasting very short-term power load with hybrid interpretable models. *Engineering Applications of Artificial Intelligence*, 135, 106746. doi:10.1016/j.engappai.2025.106746
- Patel, H., Mehta, P., & Kumar, V. (2025). Application of machine learning with gradient descent method for FF- DNN- based short- term load forecasting. *Journal of Electrical Systems and Information Technology*, 12(1), 46. doi:10.1186/s43067-025-00246-5
- Xiong, T., Li, C., & Bao, Y. (2018). Forecasting model combining STL decomposition and extreme learning machine for time series

prediction. *Neurocomputing*, 277, 483–494.

doi:10.1016/j.neucom.2017.11.053

Zhang, J., Wang, J., & Li, X. (2021). *ES-dRNN: A hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting* (arXiv preprint arXiv: 2112. 02663) . Retrieved from <https://arxiv.org/abs/2112.02663>

Zhou, H., Li T., & Peng, H. (2021). Non-intrusive load decomposition based on CNN- LSTM hybrid deep learning model. *Energy Reports*, 7, 5762–5771. doi:10.1016/j.egyr.2021.09.044