

การพยากรณ์พลังงานไฟฟ้าโดยใช้เทคนิคการเรียนรู้ของเครื่องและระบบ IoT Energy Consumption Forecasting Using Machine Learning and IoT System

อัคค์สัจจา ดวงสุภาสิญจ์¹ และ วิลิตทิพย์ พันโยธา^{2*}

¹สาขาวิชาวิศวกรรมอุตสาหกรรม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลล้านนา

²ภาควิชาเทคโนโลยีวิศวกรรมอิเล็กทรอนิกส์ คณะวิทยาลัยเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

E-mail: wilaitip.p@cit.kmutnb.ac.th*

Akksatcha Duangsuphasin¹ and Wilaitip Punyota^{2*}

¹Department of Industrial Engineering, Faculty of Engineering, Rajamangala University of Technology Lanna

²Department of Electronics Engineering Technology, College of Industrial Technology,

King Mongkut's University of Technology North Bangkok

E-mail: wilaitip.p@cit.kmutnb.ac.th *

Received 29 Apr 2025; Revised 12 Jun 2025

Accepted 8 Aug 2025; Available online 30 Dec 2025

บทคัดย่อ

งานวิจัยนี้นำเสนอแบบจำลองการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของเครื่องปรับอากาศในห้องเซิร์ฟเวอร์ ด้วยการนำการเรียนรู้ของเครื่อง (Machine learning : ML) และระบบอินเทอร์เน็ตของสรรพสิ่ง (Internet of Things : IoT) การศึกษานี้รวบรวมข้อมูลอุณหภูมิ ความชื้นภายนอกห้องเซิร์ฟเวอร์ ค่าพลังงานไฟฟ้าของเครื่องปรับอากาศโดยใช้เทคโนโลยี IoT วิธีดำเนินการศึกษาแบ่งออกเป็น 3 ส่วน คือ ส่วนแรกรวบรวมข้อมูลอุณหภูมิ ความชื้น และค่าพลังงานไฟฟ้าด้วยระบบ IoT ส่วนที่สองสร้างแบบจำลองการพยากรณ์ปริมาณพลังงานไฟฟ้า ในบทความนี้ได้เลือกวิธีการพยากรณ์ 4 วิธีได้แก่ LSTM Bi-LSTM ANN และ ARIMA ส่วนสุดท้ายทำการเปรียบเทียบผลลัพธ์จากค่า MSE RMSE และ MAPE ผลการศึกษาพบว่า ระบบ IoT สามารถเก็บรวบรวมข้อมูลได้อย่างแม่นยำและรวดเร็ว ส่วน Machine Learning ช่วยเพิ่มความแม่นยำในการพยากรณ์ค่าพลังงานไฟฟ้าโดยสามารถเรียนรู้รูปแบบจากข้อมูลจำนวนมากที่เก็บผ่าน IoT ได้อย่างมีประสิทธิภาพ ส่วนการพยากรณ์ค่าพลังงานไฟฟ้านั้น วิธี LSTM เป็นโมเดลที่ได้ผลที่ดีที่สุดในด้านของความแม่นยำ โดยพิจารณาจากค่า MSE และ RMSE ที่ต่ำที่สุด ในขณะที่ ARIMA มีค่า MAPE ต่ำที่สุด ซึ่งแสดงให้เห็นว่าวิธี LSTM เหมาะสมสำหรับการพยากรณ์ค่าพลังงานไฟฟ้าในการศึกษานี้มากที่สุด อย่างไรก็ตามการเลือกรูปแบบการพยากรณ์ขึ้นอยู่กับลักษณะของปัญหาและความต้องการในการใช้งานจริง รูปแบบการพยากรณ์นี้ช่วยให้ผู้ใช้สามารถประเมินการใช้พลังงานล่วงหน้าและจัดการพลังงานอย่างมีประสิทธิภาพได้

คำหลัก: พลังงานไฟฟ้า การพยากรณ์ อินเทอร์เน็ตของสรรพสิ่ง การเรียนรู้ของเครื่อง

Abstract

The objective of this research is to propose the development of a forecasting model for the electricity consumption of air conditioning systems in server rooms using machine learning and Internet of Things (IoT) systems. The study collects data on external temperature, humidity, and air conditioning power consumption through IoT technology. The methodology consists of three main parts: (1) data collection of temperature, humidity, and electricity consumption using IoT systems; (2) development of an electricity consumption forecasting model; and (3) performance evaluation of the forecasting methods. Four forecasting methods are selected for comparison: Long Short-Term Memory (LSTM), Bidirectional LSTM (Bi-LSTM), Artificial Neural Network (ANN), and Autoregressive Integrated Moving Average (ARIMA). The performance is assessed based upon Mean Square Error (MSE), Root Mean Square Error (RMSE) and Mean Absolute Percentage Error (MAPE). The results indicate that the IoT system can collect data accurately and efficiently. Among the forecasting methods, LSTM demonstrated the highest accuracy in terms of the lowest MSE and RMSE values, while ARIMA exhibited the lowest MAPE. Machine Learning enhances the accuracy of electricity consumption forecasting by efficiently learning patterns from large datasets collected through IoT systems. These findings suggest that LSTM is the most appropriate model for forecasting electricity consumption. However, the choice of a forecasting model depends on the specific problem and practical requirements. This forecasting model enables users to estimate energy consumption in advance and manage energy more effectively.

Keywords: Energy, Forecasting, Internet of Thing, Machine learning

1. บทนำ

การใช้ไฟฟ้าในอาคารสำนักงานถือเป็นส่วนสำคัญที่ส่งผลต่อค่าใช้จ่ายด้านพลังงานและการจัดการทรัพยากรพลังงานในองค์กร การจัดการและใช้พลังงานอย่างมีประสิทธิภาพในอาคารสำนักงานไม่เพียงช่วยลดต้นทุน แต่ยังช่วยลดผลกระทบต่อสิ่งแวดล้อมในระยะยาวอีกด้วย ดาตาเซ็นเตอร์ (Data Center) หรือห้องเซิร์ฟเวอร์ในอาคารสำนักงานเป็นพื้นที่ที่มีการใช้พลังงานไฟฟ้าตลอดทั้งวัน เนื่องจากเซิร์ฟเวอร์และอุปกรณ์ที่เกี่ยวข้องต้องทำงานอย่างต่อเนื่องเพื่อรองรับการประมวลผลข้อมูลและการเชื่อมต่อระบบเครือข่ายในองค์กร ห้องเซิร์ฟเวอร์มีความต้องการพลังงานไฟฟ้าในปริมาณสูง เนื่องจากการทำงานที่ต้องใช้พลังงานอย่างต่อเนื่องและการระบายความร้อนจากอุปกรณ์ที่ทำงานตลอดเวลา อุณหภูมิและความชื้นเป็นปัจจัยสำคัญที่ส่งผลโดยตรงต่อการใช้พลังงานไฟฟ้า เนื่องจากเมื่ออุณหภูมิสูงขึ้นระบบระบายความร้อนจะต้องทำงานหนักขึ้นเพื่อ

รักษาอุณหภูมิให้เหมาะสม ซึ่งส่งผลให้เครื่องปรับอากาศใช้พลังงานมากขึ้น ในขณะเดียวกันความชื้นที่สูงเป็นผลให้พลังงานไฟฟ้าเพิ่มขึ้นเช่นกัน [1] เครื่องปรับอากาศในห้องเซิร์ฟเวอร์มีบทบาทสำคัญในการรักษาอุณหภูมิและความชื้นให้เหมาะสม โดยปกติอุณหภูมิที่เหมาะสมสำหรับห้องเซิร์ฟเวอร์จะอยู่ในช่วง 18-27°C และความชื้นสัมพัทธ์ควรอยู่ระหว่าง 40-60% เพื่อป้องกันความเสียหายที่อาจเกิดขึ้นกับอุปกรณ์ อย่างไรก็ตาม ระบบปรับอากาศเหล่านี้มักใช้พลังงานไฟฟ้าสูง เนื่องจากต้องทำงานตลอดเวลาเพื่อรองรับการทำงานของอุปกรณ์ในห้อง [2] เทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (Internet of Things: IoT) มีบทบาทสำคัญในการรวบรวมข้อมูลจากเซ็นเซอร์ที่ใช้วัดสภาพแวดล้อม เช่น อุณหภูมิ ความชื้น และปัจจัยอื่นที่เกี่ยวข้อง ซึ่งช่วยให้สามารถเข้าถึงข้อมูลได้อย่างมีประสิทธิภาพและทันเวลา การเรียนรู้ของเครื่อง (Machine Learning: ML) คือหนึ่งในสาขาของปัญญาประดิษฐ์ (Artificial Intelligence:

AI) ที่สามารถพยากรณ์ ตัดสินใจ หรือแนะนำผลลัพธ์ตามข้อมูลที่มีได้อย่างแม่นยำ โดยหลักการการทำงานของ ML คือการนำข้อมูลจำนวนมากมาวิเคราะห์เพื่อเรียนรู้รูปแบบหรือความสัมพันธ์ภายในข้อมูลเหล่านั้น จากนั้นจึงสร้างแบบจำลอง (Model) ที่สามารถนำไปใช้กับข้อมูลใหม่เพื่อให้ได้ผลลัพธ์ที่ต้องการโดยไม่จำเป็นต้องเขียนโปรแกรมให้ระบุวิธีการไว้อย่างชัดเจน

จากที่กล่าวมาข้างต้นค่าพลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์มีความเชื่อมโยงโดยตรงกับอุณหภูมิและความชื้นในห้อง หากสามารถวัดและติดตามค่าอุณหภูมิและความชื้นในแต่ละช่วงเวลาได้อย่างต่อเนื่อง จะทำให้ผู้ใช้สามารถคาดการณ์พลังงานไฟฟ้าแต่ละช่วงเวลาล่วงหน้าได้ ซึ่งข้อมูลเหล่านี้จะช่วยให้การจัดการพลังงานมีประสิทธิภาพมากขึ้น การพยากรณ์พลังงานไฟฟ้าสามารถคาดการณ์แนวโน้มการใช้ไฟฟ้าในอนาคต และปรับแผนการทำงานให้เหมาะสมกับช่วงเวลาใช้งานจริง ซึ่งช่วยลดการสูญเสียพลังงานที่ไม่จำเป็น และสามารถวางแผนการทำงานของระบบให้สอดคล้องกับช่วงเวลาที่มีการใช้พลังงานสูงหรือต่ำได้ โดยเฉพาะในองค์กรขนาดใหญ่ที่มีห้องเซิร์ฟเวอร์จำนวนมาก นอกจากนี้การลดการใช้พลังงานที่ไม่จำเป็นยังส่งผลดีต่อสิ่งแวดล้อม ลดภาวะโลกร้อน ลดมลพิษ และรักษาทรัพยากรธรรมชาติให้คงอยู่ได้นานยิ่งขึ้น ดังนั้นงานวิจัยนี้มีจุดประสงค์เพื่อสร้างแบบจำลองการพยากรณ์ปริมาณการใช้พลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์ โดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) และเก็บข้อมูลด้วยระบบ IoT การพยากรณ์นี้ช่วยให้องค์กรสามารถวางแผนการใช้พลังงานได้อย่างมีประสิทธิภาพ

2. การจัดรูปแบบ

ทฤษฎีที่เกี่ยวข้อง 2 ทฤษฎี ได้แก่ อินเทอร์เน็ตของสรรพสิ่ง (IoT) และการเรียนรู้ของเครื่อง (Machine Learning) มีรายละเอียดดังต่อไปนี้

2.1 Internet of Things (IoT)

IoT เป็นแนวคิดที่เชื่อมโยงวัตถุ อุปกรณ์ และสิ่งของเข้าด้วยกันผ่านเครือข่ายอินเทอร์เน็ต โดยมีการฝังเทคโนโลยี เช่น วงจรอิเล็กทรอนิกส์ ซอฟต์แวร์ และเซ็นเซอร์ เพื่อให้วัตถุเหล่านี้สามารถสื่อสาร แลกเปลี่ยนข้อมูล และตอบสนองต่อสภาพแวดล้อมได้อย่างชาญฉลาด IoT ได้กลายเป็นหัวใจสำคัญของการพัฒนาเทคโนโลยีในยุคดิจิทัล เนื่องจากช่วยเพิ่มประสิทธิภาพในหลากหลายด้าน ทั้งการจัดการทรัพยากร พลังงาน และระบบอัตโนมัติในชีวิตประจำวัน [3]

2.2 การเรียนรู้ของเครื่อง (Machine Learning: ML)

Machine Learning (ML) เป็นเทคโนโลยีสำคัญในปัญญาประดิษฐ์ (AI) ที่มีความสามารถในการวิเคราะห์ แยกแยะ และตัดสินใจโดยอาศัยกระบวนการเรียนรู้ข้อมูล ซึ่งมีหลักการทำงานคล้ายกับสมองมนุษย์ ถือเป็นองค์ประกอบหลักของ AI ที่ช่วยให้ระบบคอมพิวเตอร์สามารถประมวลผลและตัดสินใจได้อย่างชาญฉลาด อีกทั้งยังสามารถพัฒนาให้มีประสิทธิภาพที่ดีขึ้นได้อย่างต่อเนื่อง ML เป็นแนวทางที่ทำให้คอมพิวเตอร์สามารถเรียนรู้และปรับปรุงการทำงานโดยอิงจากข้อมูลหรือสภาพแวดล้อมที่ป้อนเข้าไป โดยระบบจะเรียนรู้จากข้อมูลตัวอย่างเพื่อพัฒนาความสามารถในการทำงานให้แม่นยำยิ่งขึ้น [4]

2.2.1 Long Short-Term Memory (LSTM) และ Bidirectional LSTM (Bi-LSTM)

LSTM และ Bi-LSTM เป็นสถาปัตยกรรมประเภทหนึ่งของ Neural Network ซึ่งจัดอยู่ในกลุ่ม Deep Learning เป็นประเภทของ Recurrent Neural Network (RNN) ที่ได้รับการออกแบบมาเพื่อจัดการกับข้อมูลที่มีลำดับเวลา (time-series) และสามารถเก็บข้อมูลระยะยาวได้ดีกว่า RNN แบบดั้งเดิม โครงสร้างแบบจำลอง LSTM ดังแสดงในรูปที่ 1 การทำงานของ LSTM ถูกควบคุมโดยเกตสามตัวหลัก ได้แก่ Forget Gate, Input Gate และ Output Gate ซึ่งแต่ละตัวทำงานร่วมกันในการควบคุมข้อมูลที่ไหล

ผ่านหน่วยความจำและช่วยให้การเรียนรู้มีความแม่นยำ

Forget Gate ทำหน้าที่ประเมินข้อมูลอินพุตปัจจุบันร่วมกับข้อมูลจากชั้นซ่อนก่อนหน้า (hidden state) เพื่อใช้ตัดสินใจว่าข้อมูลใดในสถานะเซลล์ (cell state) ควรถูกลบออก โดยใช้งานฟังก์ชันซิกมอยด์ (sigmoid function) ซึ่งให้ผลลัพธ์อยู่ในช่วง 0 ถึง 1 โดยที่ค่าใกล้ 1 หมายถึงควรเก็บข้อมูลไว้ ส่วนค่าใกล้ 0 หมายถึงควรลบข้อมูลออก การคำนวณสามารถแสดงได้ตามสมการที่ 1

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

Input Gate ทำหน้าที่ตัดสินใจว่าข้อมูลใดควรถูกบันทึกลงในสถานะเซลล์ (cell state) โดยเริ่มจากการใช้ฟังก์ชันซิกมอยด์ (sigmoid) ในชั้นอินพุตเพื่อพิจารณาว่าข้อมูลใดจะถูกนำไปใช้ในการอัปเดต จากนั้นชั้นแทนด์ไฮเพอร์โบลิก (tanh) จะสร้างเวกเตอร์ใหม่ซึ่งใช้เป็นข้อมูลสำหรับเพิ่มเติมเข้าไปในสถานะเซลล์ ต่อมา LSTM จะทำการอัปเดตสถานะเซลล์โดยลบข้อมูลเก่าที่ได้ตัดสินใจไว้ก่อนหน้า และเพิ่มข้อมูลใหม่ที่ได้จากเวกเตอร์ที่สร้างขึ้น การคำนวณแสดงได้ตามสมการที่ 2 และ 3

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

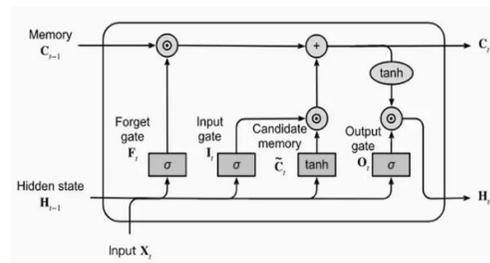
Output Layer ทำหน้าที่กำหนดผลลัพธ์ที่ LSTM จะส่งผลลัพธ์ออก โดยเริ่มจากการใช้ฟังก์ชันซิกมอยด์ (sigmoid) เพื่อตัดสินใจว่าส่วนใดของสถานะเซลล์ (cell state) จะถูกนำมาใช้เป็นผลลัพธ์ จากนั้นค่าที่ได้จะถูกส่งผ่านชั้นฟังก์ชันแทนด์ไฮเพอร์โบลิก (tanh) ซึ่งจำกัดค่าให้อยู่ระหว่าง -1 ถึง 1 เพื่อให้ได้เฉพาะข้อมูลที่สำคัญและเหมาะสมในการส่งต่อไปยังนิวรอนถัดไป การคำนวณตามสมการที่ 4 และ 5

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t \times \tanh(C_t)$$

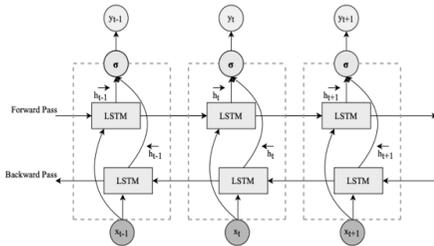
(5)

โดยที่ x_t คือ ข้อมูลอินพุตในช่วงเวลาปัจจุบัน h_t คือ สถานะชั้นซ่อน (hidden state) ใหม่ h_{t-1} คือ สถานะชั้นซ่อนของช่วงเวลาก่อนหน้า b_f, b_i, b_o คือ เวกเตอร์ไบแอส (Bias Vectors) W_f, W_i, W_o คือ เมทริกซ์น้ำหนัก (Weight Matrices) O_t คือ เวกเตอร์ผลลัพธ์ของ output gate σ คือ ฟังก์ชัน sigmoid \tilde{C}_t คือ สถานะเซลล์ (cell state) ในช่วงเวลา t [5]



รูปที่ 1 โครงสร้างแบบจำลอง LSTM [6]

Bi-LSTM (Bidirectional LSTM) เป็นการปรับปรุงจาก LSTM โดยการประมวลผลข้อมูลในสองทิศทาง คือ ทิศทางจากอดีตไปอนาคต (Forward) และทิศทางจากอนาคตไปอดีต (Backward) ซึ่งช่วยให้ Bi-LSTM สามารถเข้าใจข้อมูลได้ครบถ้วนมากขึ้น โดยไม่เพียงแต่ใช้ข้อมูลจากอดีต แต่ยังสามารถพิจารณาข้อมูลจากอนาคตได้ด้วย การทำงานแบบนี้จะช่วยให้ Bi-LSTM สามารถจับความสัมพันธ์ในข้อมูลที่ซับซ้อนกว่าการใช้ LSTM เพียงตัวเดียว ดังแสดงในรูปที่ 2 ใน Bi-LSTM จะมีการใช้ LSTM สองโมเดลทำงานพร้อมกัน โมเดลหนึ่งจะประมวลผลข้อมูลในทิศทางจากอดีตไปอนาคต (Forward LSTM) และอีกโมเดลหนึ่งจะประมวลผลข้อมูลจากอนาคตไปอดีต (Backward LSTM) ข้อมูลจากแต่ละทิศทางจะถูกส่งเข้าไปในหน่วยความจำ (Memory Cells) ของ LSTM โดยในแต่ละเวลา (time step) ข้อมูลจากทั้งสองทิศทางจะถูกเรียนรู้ร่วมกัน สามารถเรียนรู้ข้อมูลของอดีตและอนาคตพร้อมกัน ทำให้การทำนายผลมีความแม่นยำมากยิ่งขึ้น [6]



รูปที่ 2 โครงสร้างแบบจำลอง Bidirectional LSTM [6]

2.2.2 Artificial Neural Network (ANN)

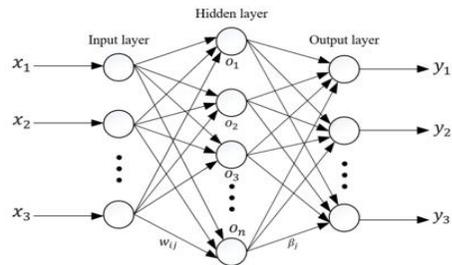
โครงข่ายประสาทเทียมหรือ ANN ได้รับความสนใจจากการทำงานของสมองมนุษย์ ANN ประกอบด้วยชุดของหน่วยประมวลผลที่เรียกว่า "นิวรอน" ซึ่งจัดเรียงในรูปแบบเลเยอร์ (Layers) โดยทั่วไปจะมี 3 เลเยอร์หลัก ได้แก่ Input Layer, Hidden Layers, และ Output Layer ดังแสดงในรูปที่ 3 นิวรอนแต่ละตัวเชื่อมโยงกันผ่านน้ำหนัก (Weights) และค่าน้ำหนักนี้จะถูกปรับระหว่างการเรียนรู้ (Training) เพื่อให้โมเดลสามารถทำนายหรือจัดหมวดหมู่ข้อมูลได้อย่างแม่นยำ การปรับค่าถ่วงน้ำหนักใช้กระบวนการ Backpropagation เพื่อคำนวณข้อผิดพลาดและปรับปรุงโมเดลให้ดีขึ้น

ข้อมูลนำเข้าจะถูกส่งผ่านจากชั้นอินพุตไปยังชั้นเอาต์พุตโดยใช้เทคนิคแบบ Feedforward กล่าวคือ ข้อมูลจะถูกส่งจากชั้นแรกไปยังชั้นสุดท้ายในทิศทางเดียว โดยไม่ย้อนกลับไปยังชั้นก่อนหน้า อย่างไรก็ตาม หากข้อมูลนำเข้าถูกส่งจากชั้นอินพุตไปยังชั้นเอาต์พุต และมีการใช้เทคนิค Backpropagation (BP) ซึ่งเป็นวิธีการปรับค่าน้ำหนักของโหนดที่เชื่อมต่อกัน โดยอิงจากความแตกต่างระหว่างผลลัพธ์ที่ได้จากโครงข่ายกับค่าผลลัพธ์จริง สมการทางคณิตศาสตร์ดังแสดงในสมการที่ (6)

$$y_1 = \sum_{i=1}^n w_{ij}x_j + \beta_j \quad (6)$$

โดยที่ โดยที่ x_j คือ คือข้อมูลอินพุตจากโหนดฝึกสอน, w_{ij} คือค่าน้ำหนักของการเชื่อมต่อระหว่างโหนดในชั้นอินพุต ชั้นซ่อน และชั้นเอาต์พุต, β_j คือค่าคงที่เบี่ยงเบน (bias) ของโหนดในชั้นซ่อนและชั้น

เอาต์พุต, และ n คือจำนวนของข้อมูลอินพุต โดยที่ i คือโหนดต้นทาง ($i = 1, \dots, n$) และ j คือโหนดปลายทาง ($j = 1, \dots, n$) กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม (ANN) โดยทั่วไปจะใช้วิธี Backpropagation (BP) ซึ่งเป็นอัลกอริทึมสำหรับปรับปรุงโครงข่ายประสาทเทียม (ANN) โดยทำการปรับค่าน้ำหนักและค่าคงที่เบี่ยงเบนของแต่ละโหนด เพื่อให้ผลลัพธ์จากชั้นเอาต์พุตใกล้เคียงกับค่าจริงมากที่สุด ซึ่งส่งผลให้ข้อผิดพลาดในการฝึกสอนลดลง [7]



รูปที่ 3 โครงสร้าง Artificial Neural Network (ANN) [6]

2.2.3 Autoregressive Integrated Moving Average (ARIMA)

ARIMA เป็นโมเดลทางสถิติที่ใช้ในการพยากรณ์อนุกรมเวลา (Time Series) ที่ได้รับความนิยมอย่างแพร่หลาย โมเดลนี้ใช้หลักการวิเคราะห์ความสัมพันธ์ระหว่างค่าในอดีตของข้อมูล เพื่อทำนายค่าในอนาคต ARIMA สามารถจับรูปแบบของข้อมูลได้ เช่น แนวโน้ม ฤดูกาล และความผันผวน ทำให้เหมาะสำหรับการวิเคราะห์ข้อมูลที่มีลักษณะเป็นลำดับเวลา ประกอบด้วย 4 ขั้นตอนดังนี้ (1) ขั้นตอนการให้ออนุกรมเวลาอยู่ในรูปแบบ stationary โดยการ differencing (2) การกำหนดองค์ประกอบของพารามิเตอร์ ได้แก่ค่า p เป็นพารามิเตอร์ของ AR (Autoregressive), d เป็นพารามิเตอร์ของ I (Integrated) และ q เป็นพารามิเตอร์ของ MA (Moving average) โดยทั่วไปแบบจำลอง ARIMA จะแสดงเป็น ARIMA (p,d,q) (3) การประเมินค่าพารามิเตอร์ของโมเดลและทดสอบว่าโมเดลนั้นเหมาะสมหรือไม่ และ (4) การใช้โมเดลที่มีพารามิเตอร์ที่เลือกไว้อย่าง

เหมาะสมในการทำนาย สมการทางคณิตศาสตร์ของ ARIMA (p, d, q) แสดงในสมการที่ 7

$$\Delta^d y_t = \theta_0 + \sum_{i=1}^p \varphi_i \Delta^d y_{t-i} + \epsilon_t + \sum_{j=1}^q \theta_j \epsilon_{t-j} \quad (7)$$

โดยที่ $\Delta^d y_t$ คือข้อมูลที่ผ่านการ differencing แล้วจำนวน d ครั้ง, φ_i คือ ค่าสัมประสิทธิ์ของส่วน AR, θ_j คือ ค่าสัมประสิทธิ์ของส่วน MA, ϵ_t คือ white noise หรือค่าความคลาดเคลื่อน โมเดล ARIMA เป็นโมเดลที่พัฒนาขึ้นจากกระบวนการวนรอบ (iterative cycle) ซึ่งจะใช้ข้อมูลจากอนุกรมเวลาเพื่อสร้างโครงสร้างทางคณิตศาสตร์สำหรับการพยากรณ์ การพัฒนาเหล่านี้จะช่วยให้สามารถทำนายแนวโน้มในอนาคตได้จากข้อมูลที่มีอยู่ โดยอาศัยความสัมพันธ์เชิงเส้นระหว่างค่าในอดีตกับค่าปัจจุบัน [8]

2.3 การประเมินความแม่นยำของแบบจำลอง

ความสามารถของการพยากรณ์ถูกกำหนดโดยการประเมินความแม่นยำที่ใช้กันโดยทั่วไป ได้แก่ รากของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) มีสูตรดังสมการที่ 8 ค่าความผิดพลาดกำลังสองเฉลี่ย (Mean Square Error: MSE) มีสูตรดังสมการที่ 9 และค่าร้อยละของความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) สูตรดังสมการที่ 10

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{\text{actual}} - y_{\text{predicted}})^2} \quad (8) \\ \text{MSE} &= \frac{1}{N} \sum_{i=1}^N (y_{\text{predicted}} - y_{\text{actual}})^2 \quad (9) \end{aligned}$$

$$\text{MAPE} = \frac{100\%}{N} \sum_{i=1}^N \left| \frac{y_{\text{actual}} - y_{\text{predicted}}}{y_{\text{actual}}} \right| \quad (10)$$

โดยที่ค่า N คือจำนวนข้อมูล, y_{actual} คือค่าจริงของข้อมูล, $y_{\text{predicted}}$ คือค่าพยากรณ์ของข้อมูล หากค่า MAE, RMSE และ MAPE มีค่าเข้าใกล้ศูนย์หมายความว่าแบบจำลองสามารถพยากรณ์ข้อมูลได้

อย่างแม่นยำ เนื่องจากมีความคลาดเคลื่อนระหว่างค่าจริงและค่าที่พยากรณ์น้อยมาก [9]

2.4 การทบทวนวรรณกรรม

งานวิจัยที่นำ IoT มาประยุกต์ใช้ในการเก็บข้อมูลได้แก่ การใช้ระบบตรวจวัดอุณหภูมิภายในห้องเซิร์ฟเวอร์ด้วยการประยุกต์ใช้เทคโนโลยี IoT ทำให้ทราบปัญหาความเสียหายของอุปกรณ์และเข้าไปแก้ไขปัญหาได้ทันที [3] การพัฒนาระบบตรวจวัดการใช้พลังงานไฟฟ้าให้แสดงค่าแรงดันไฟฟ้า ค่ากระแสไฟฟ้า ค่ากำลังไฟฟ้า ค่าพลังงานไฟฟ้าต่อหน่วยแบบทันทีทันใด ผลการศึกษาพบว่า สามารถวัดค่ากำลังไฟฟ้าได้ โดยมีค่าความผิดพลาดร้อยละ 2.05 [10] การสร้างแบบจำลองการพยากรณ์อุณหภูมิและความชื้นโดยใช้ IoT และใช้วิธีเพิ่มประสิทธิภาพด้วยอัลกอริทึมวาวซึ่งเป็นหนึ่งในวิธีทางเมตาฮิวริสติก ร่วมกับเทคนิคหน่วยความจำระยะสั้น (Improved Whale Optimization Algorithm LSTM: IWOA-LSTM) ผลที่ได้คือแบบจำลอง IWOA-LSTM ที่พัฒนาขึ้นมีความแม่นยำสูง ส่งผลให้มีข้อมูลการพยากรณ์ที่ดีกว่าแบบจำลองการพยากรณ์อื่น [11] การสร้างรูปแบบการพยากรณ์การใช้พลังงานไฟฟ้าซึ่งเก็บข้อมูลจากมิเตอร์ไฟฟ้าด้วยโปรแกรม xViwe โดยใช้ตัวแบบพยากรณ์ 8 ตัวแบบ เช่น Naive Bayes, Generalized linear Model, Logistic Regression เป็นต้น ผลลัพธ์ที่ได้คือตัวแบบพยากรณ์ที่เหมาะสมกับชุดข้อมูลของแต่ละมิเตอร์ไฟฟ้า [12] การสร้างแบบจำลองการคาดการณ์พลังงานบนพื้นฐาน IoT ที่สามารถประมาณการใช้พลังงานได้ ผลการวิเคราะห์โมเดลมีความแม่นยำสูงกว่าถึง 90% ในระยะเวลาฝึกที่สั้นกว่า 29.2 วินาที [13] การคาดการณ์การใช้พลังงานของอาคารแห่งหนึ่งด้วยวิธี LSTM แบบจำลองใช้ข้อมูลพลังงานของปีก่อนหน้าและสภาพอากาศที่คาดการณ์ไว้เป็นพารามิเตอร์อินพุตเพื่อคาดการณ์ในวันถัดไป ข้อมูลการใช้พลังงานจะเปลี่ยนไปขึ้นอยู่กับว่าวันถัดไปเป็นวันธรรมดา วันหยุดสุดสัปดาห์หรือวันหยุด จากการวิเคราะห์สรุปได้ว่าอุณหภูมิและปริมาณน้ำฝนเป็นพารามิเตอร์ที่สำคัญในการฝึกอบรม โมเดลที่เสนอมีค่า RMSE ที่ดีที่สุดเมื่อเปรียบเทียบกับ Support

Vector Regression (SVR) , Gaussian Process Regression (GPR) [14] การพัฒนาตัวแบบเพื่อใช้ในการพยากรณ์ราคาเศษเหล็กโดยใช้วิธีทางสถิติและเทคนิคการเรียนรู้ของเครื่อง ได้แก่ Linear regression, Support vector regression, XGBoost และ LSTM พบว่า เทคนิค LSTM สามารถพยากรณ์ได้แม่นยำมากที่สุด โดยมีค่า MAPE เท่ากับ 4.34% [10] การสร้างโมเดลการพยากรณ์ระยะสั้นของโหลดพลังงานไฟฟ้าและราคาค่าไฟฟ้ารายชั่วโมง โดยใช้ 4 อัลกอริทึมหลัก ได้แก่ ANN, LSTM, GRU และ ANFIS แสดงให้เห็นว่า การใช้โมเดล ML/DL เพื่อพยากรณ์โหลดและราคาค่าไฟฟ้าจะให้ผลลัพธ์ที่แม่นยำยิ่งขึ้นเมื่อพิจารณาปัจจัยภายนอก โดยเฉพาะเมื่อระบบมีความผันผวนสูงตามฤดูกาลและช่วงเวลาที่มิโหลดหรือราคาพุ่งสูง ช่วยให้สามารถคาดการณ์ได้ใกล้เคียงความเป็นจริงมากขึ้น [15] การสร้างระบบการพยากรณ์พลังงานไฟฟ้ารายเดือนโดยอาศัยเทคนิคการเรียนรู้เชิงลึก โดยได้ศึกษาการทำงานของโมเดลโครงข่ายประสาทเทียมเชิงลึก 3 ประเภท ได้แก่ โครงข่าย Fully Connected, โครงข่าย Convolutional Neural Network (CNN) และโครงข่าย Long Short-Term Memory (LSTM) พร้อมทั้งศึกษาผลกระทบของเทคนิคการทำข้อมูลให้เป็นมาตรฐาน (Normalization) ต่อประสิทธิภาพของโมเดล จากการทดลองกับข้อมูลจริงพบว่า ระบบที่นำเสนอสามารถทำนายการใช้พลังงานรายเดือนได้อย่างมีประสิทธิภาพ โดยมีค่าความคลาดเคลื่อนแบบสัมบูรณ์ (Absolute Error) เท่ากับ 31.83 กิโลวัตต์-ชั่วโมง และค่าความคลาดเคลื่อนแบบสัมพัทธ์ (Relative Error) เท่ากับ 17.29% [16]

จากการศึกษางานวิจัยข้างต้นพบว่า การประยุกต์ใช้เทคโนโลยี IoT ในการตรวจวัดและบันทึกข้อมูลทำให้ได้ข้อมูลแบบเรียลไทม์ ผู้ใช้งานสามารถติดตามการเปลี่ยนแปลงของอุณหภูมิและความชื้นได้ทันที ส่วนการสร้างตัวแบบเพื่อพยากรณ์ค่าพลังงานไฟฟ้าส่วนใหญ่จะเป็นการวัดค่าจากมิเตอร์ไฟฟ้า ค่าข้อมูลพลังงานและสภาพอากาศที่คาดการณ์ไว้ของปีก่อนหน้า เทคนิคการเรียนรู้ของเครื่องเป็นเครื่องมือที่มีความแม่นยำในการพยากรณ์ปริมาณพลังงานไฟฟ้า

ช่วยให้สามารถวางแผนการใช้พลังงานล่วงหน้าและปรับปรุงการจัดการทรัพยากรได้อย่างเหมาะสม รวมถึง LSTM เป็นเครื่องมือที่มีความสามารถในการพยากรณ์ข้อมูลที่มีการเปลี่ยนแปลงตามเวลาในระยะยาวได้เป็นอย่างดี ดังนั้นในงานวิจัยนี้จึงเลือกใช้เทคนิค LSTM, Bi-LSTM, ANN และ ARIMA สร้างตัวแบบจำลองการพยากรณ์ค่าพลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์

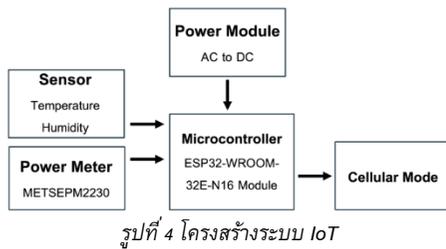
3. วิธีดำเนินการวิจัย

งานวิจัยนี้ได้ดำเนินการตามแผนงานที่มีการจัดเตรียมไว้อย่างเป็นระบบ โดยเริ่มจากการศึกษาและวิเคราะห์ข้อมูล เก็บข้อมูล เตรียมข้อมูล สร้างแบบจำลองการพยากรณ์ ทดสอบแบบจำลอง

3.1 การเก็บข้อมูล

งานวิจัยนี้สร้างระบบ IoT สำหรับเก็บข้อมูลอุณหภูมิ ความชื้น ภายนอกและพลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์ของอาคารสำนักงาน 1 ห้อง ระบบ IoT ประกอบด้วย 5 ส่วน ได้แก่ 1) Microcontroller ESP32-WROOM-32E-N16 รองรับการเชื่อมต่อ WiFi และ Bluetooth 4.2 2) Power Module ชดแปลงไฟ 220 โวลต์กระแสสลับ เป็น 5 โวลต์กระแสตรง 3) Sensor SHT20 สำหรับวัดอุณหภูมิและความชื้น 4) Power Meter รุ่น METSEPM2230 สำหรับวัดค่าพลังงานไฟฟ้า 5) Cellular Mode สำหรับเชื่อมต่ออุปกรณ์เข้ากับอินเทอร์เน็ต อุปกรณ์ทั้งสามส่วนสื่อสารผ่านโปรโตคอล Modbus RS485 ดังแสดงในรูปที่ 4 ข้อมูลอุณหภูมิ ความชื้น และพลังงานไฟฟ้าถูกรวบรวมเป็นเวลา 16 เดือน เริ่มตั้งแต่วันที่ 1 มกราคม พ.ศ. 2566 และสิ้นสุดในวันที่ 30 เมษายน พ.ศ. 2567 โดยทำการเก็บข้อมูลทุก 1 ชั่วโมง ในระบบ IoT การถ่ายโอนข้อมูลถูกออกแบบให้ใช้โปรโตคอล Message Queuing Telemetry Transport (MQTT) โดยอาศัยเครือข่าย Wi-Fi และ Cellular เพื่อส่งข้อมูลไปยัง MQTT Broker ซึ่งมีหน้าที่เป็นตัวกลางในการรับและส่งข้อความระหว่างอุปกรณ์ที่ใช้โปรโตคอล MQTT โดยจะคอยจัดการการเชื่อมต่อ รับข้อความจากผู้ส่ง (Publisher) และกระจายข้อความไปยังผู้รับ

(Subscriber) ที่สมัครรับข้อมูลไว้ในหัวข้อเดียวกัน (Topic) นอกจากนี้ยังช่วยให้การสื่อสารเป็นแบบที่ไม่ต้องรอการตอบรับ (asynchronous) และลดภาระการเชื่อมต่อระหว่างอุปกรณ์โดยตรง จากนั้นข้อมูลจะถูกนำไปประมวลผลและจัดเก็บในฐานข้อมูลสองประเภท ได้แก่ InfluxDB สำหรับข้อมูลที่เป็นลำดับเวลา (Time Series) และ MySQL สำหรับข้อมูลเชิงสัมพันธ์ (Relational Data) สุดท้ายข้อมูลที่ได้จะถูกแสดงผลผ่านเว็บไซต์เพื่อให้ใช้งานได้ง่ายและสะดวก



รูปที่ 4 โครงสร้างระบบ IoT

3.2 การเตรียมข้อมูล

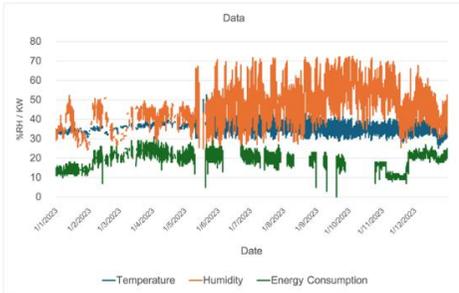
ในขั้นตอนการเตรียมข้อมูลเพื่อใช้ในกระบวนการพยากรณ์ ข้อมูลที่ใช้ประกอบด้วยข้อมูลอุณหภูมิมีหน่วยเป็นองศาเซลเซียส ข้อมูลความชื้นสัมพัทธ์มีหน่วยเป็น %RH (Relative Humidity) และข้อมูลการใช้พลังงานไฟฟ้าเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์มีหน่วยเป็นกิโลวัตต์ ข้อมูลเหล่านี้ได้จากการเก็บรวบรวมในขั้นตอนก่อนหน้าด้วยระบบ IoT ข้อมูลทั้งหมดถูกจัดเก็บในรูปแบบไฟล์ CSV เพื่อให้ใช้งานได้ง่ายในกระบวนการวิเคราะห์และการสร้างแบบจำลองการพยากรณ์ ไฟล์ CSV เป็นรูปแบบที่เหมาะสมและเป็นมาตรฐานสำหรับการนำข้อมูลเข้าสู่โปรแกรม Python ข้อมูลที่ใช้ในงานวิจัยนี้มีทั้งหมด 8,760 ข้อมูล โดยได้จากการเก็บข้อมูลทุก 1 ชั่วโมงอย่างต่อเนื่อง (เริ่มตั้งแต่วันที่ 1 มกราคม พ.ศ. 2566 จนถึงวันที่ 31 ธันวาคม พ.ศ. 2566) ข้อมูลที่ได้จากระบบ IoT ดังแสดงในรูปที่ 5

3.3 สร้างแบบจำลองการพยากรณ์

การสร้างแบบจำลองการพยากรณ์ค่าพลังงานไฟฟ้าของเครื่องปรับอากาศเริ่มต้นด้วยการนำเข้าข้อมูลในรูปแบบไฟล์ CSV ซึ่ง ประกอบด้วยค่าอุณหภูมิ ความชื้น และค่าพลังงานไฟฟ้าของ

เครื่องปรับอากาศ โดยสร้างแบบจำลองเพื่อใช้ในการพยากรณ์ข้อมูลด้วยวิธีการที่หลากหลาย ได้แก่ วิธี LSTM, Bi-LSTM, ANN และ ARIMA แบบจำลอง LSTM และ Bi-LSTM ถูกออกแบบให้มีโครงสร้างชั้นซ่อนจำนวนสามชั้นขนาด 128, 64 และ 32 ตามลำดับ และมีเอาต์พุตเป็นค่าเดียว สำหรับแบบจำลอง ANN มีโครงสร้างชั้นซ่อนสองชั้นคือ 64 และ 32 หน่วยตามลำดับ และให้ผลลัพธ์เพียงค่าเดียวเช่นกัน ซึ่งค่าพารามิเตอร์เหล่านี้ได้ถูกปรับแต่งจากการทดลองหลายครั้งเพื่อให้ได้ผลลัพธ์ที่แม่นยำที่สุดในส่วนของโมเดล ARIMA ซึ่งเป็นแบบจำลองทางสถิติ ได้เลือกใช้พารามิเตอร์ $(p, d, q) = (3, 2, 2)$ โดยที่ $p=3$ หมายถึง ค่าลำดับเชิงเวลาในอดีตที่นำมาใช้ในส่วนของการ Autoregressive (AR) โดยพิจารณาความสัมพันธ์ของข้อมูลย้อนหลัง 3 ช่วงเวลา $d=2$ หมายถึง จำนวนครั้งของการหาความแตกต่าง (Differencing) เพื่อลดแนวโน้มและทำให้ข้อมูลอยู่ในสถานะนิ่ง (Stationary) $q=2$ หมายถึง จำนวนค่าความคลาดเคลื่อนในอดีตที่นำมาประเมินในส่วนของการ Moving Average (MA) โดยพิจารณาจากความผิดพลาดของการพยากรณ์ 2 ช่วงเวลาก่อนหน้า โดยอ้างอิงจากการวิเคราะห์ข้อมูลเชิงเวลาและพิจารณาความเหมาะสมของโมเดลตามหลักเกณฑ์ทางสถิติ เพื่อให้สอดคล้องกับลักษณะของข้อมูลที่ใช้ในการพยากรณ์ สำหรับการฝึกฝนแบบจำลอง LSTM, Bi-LSTM, ANN ได้กำหนดอัตราการเรียนรู้ (Learning rate) เท่ากับ 0.0001 ซึ่งเป็นค่าที่นิยมใช้ทั่วไปในการปรับค่าน้ำหนัก และลดโอกาสในการเกิดปัญหา overfitting ในขณะที่แบบจำลอง ARIMA ไม่จำเป็นต้องใช้อัตราการเรียนรู้ เนื่องจากใช้วิธีการประมาณค่าพารามิเตอร์จากข้อมูลโดยตรง แทนการเรียนรู้แบบที่ละขั้นหรือแบบวนซ้ำ หลังจากนั้นข้อมูลถูกแบ่งออกเป็นสองชุด ได้แก่ ชุดข้อมูลสำหรับการฝึกฝนโมเดล (training set) จำนวน 80% ของข้อมูลทั้งหมด และชุดข้อมูลสำหรับการทดสอบ (testing set) จำนวน 20% ของข้อมูล พร้อมทั้งกำหนดและปรับค่าพารามิเตอร์เพื่อให้ได้แบบจำลองการพยากรณ์ที่เหมาะสมที่สุด โดยข้อมูลที่ใช้สำหรับการฝึกฝนคือข้อมูลตั้งแต่วันที่ 1 มกราคม ถึงวันที่ 31

ธันวาคม พ.ศ. 2566 ค่าพารามิเตอร์ที่ใช้ในแบบจำลองดังแสดงในตารางที่ 1



รูปที่ 5 ข้อมูลที่ได้จากระบบ IoT

3.4 ทดสอบแบบจำลอง

ในขั้นตอนนี้ได้ทดสอบแบบจำลองการพยากรณ์พลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์ โดยใช้ข้อมูลจริงระหว่างวันที่ 1 มกราคม ถึงวันที่ 30 เมษายน พ.ศ. 2567 รวมระยะเวลา 4 เดือน ทั้งนี้การเก็บข้อมูลถูกจำกัดในช่วงเวลาดังกล่าวเนื่องจากห้องเซิร์ฟเวอร์มีการปิดปรับปรุงชั่วคราวทำให้ไม่สามารถเก็บข้อมูลเพิ่มเติมได้ การทดสอบแบบจำลองมีวัตถุประสงค์เพื่อประเมินความแม่นยำของแบบจำลองที่พัฒนาขึ้น โดยพิจารณาจากค่าความคลาดเคลื่อน ได้แก่ RMSE, MSE และ MAPE ค่าเหล่านี้บ่งบอกถึงความแม่นยำของผลการพยากรณ์ได้

ตารางที่ 1 ค่าพารามิเตอร์ที่ใช้ในแบบจำลอง

| Model | Output shape | Learning rate |
|---------|--------------------|---------------|
| LSTM | (None,128,64,32,1) | 0.0001 |
| Bi-LSTM | (None,128,64,32,1) | |
| ANN | (None,64,32,1) | |
| ARIMA | (3,2,2) | - |

4. ผลการดำเนินงาน

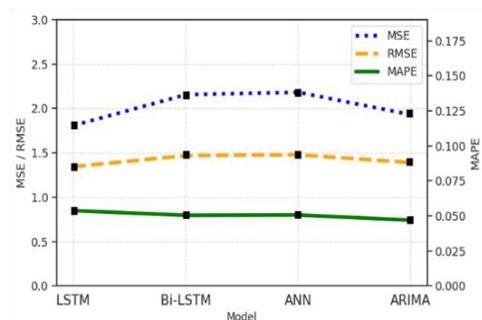
การทดลองครั้งนี้ได้นำผลลัพธ์โมเดล LSTM, Bi-LSTM, ANN และ ARIMA มาเปรียบเทียบความแม่นยำในการพยากรณ์ค่าการใช้พลังงานไฟฟ้าของ

เครื่องปรับอากาศ โดยใช้เกณฑ์การประเมินผล 3 ค่า ได้แก่ MSE, RMSE และ MAPE ซึ่งค่าเหล่านี้เข้าใกล้ศูนย์ หมายความว่า ตัวแบบจำลองมีความแม่นยำสูง [8] ผลการประเมินดังแสดงในตารางที่ 2

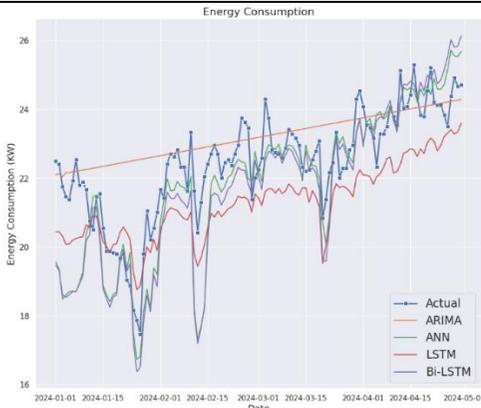
ตารางที่ 2 ผลลัพธ์การพยากรณ์ทั้ง 4 วิธี

| | ARIMA | ANN | LSTM | Bi-LSTM |
|------|--------------|-------|--------------|---------|
| MSE | 1.931 | 2.183 | <u>1.807</u> | 2.155 |
| RMSE | 1.390 | 1.478 | <u>1.344</u> | 1.468 |
| MAPE | <u>4.69%</u> | 5.06% | 5.37% | 5.04% |

จากผลการทดลองโมเดล ARIMA มีค่า MSE เท่ากับ 1.931, RMSE เท่ากับ 1.390 และ MAPE เท่ากับ 4.69 ซึ่งแสดงให้เห็นถึงความแม่นยำในการทำนายที่ดี และ MAPE ต่ำที่สุด 4.69% ซึ่งเป็นตัวชี้วัดความผิดพลาดที่ต่ำที่สุด โดยแสดงถึงความสามารถในการพยากรณ์ค่าที่ใกล้เคียงกับค่าจริงที่สุด โมเดล ANN มีค่า MSE เท่ากับ 2.183, RMSE เท่ากับ 1.478 และ MAPE เท่ากับ 5.06 โมเดล ANN มีผลลัพธ์ที่ด้อยที่สุดในค่าของ MSE และ RMSE โดยมีค่า MSE สูงสุดเท่ากับ 2.183 และ RMSE สูงสุดเท่ากับ 1.478 แสดงให้เห็นว่า ANN มีความคลาดเคลื่อนสูงที่สุดในทุกโมเดล



รูปที่ 6 ผลการเปรียบเทียบค่าความผิดพลาดของแบบจำลอง



รูปที่ 7 ผลการเปรียบเทียบค่าการพยากรณ์
กับค่าพลังงานจริง

โมเดล LSTM มีค่า MSE เท่ากับ 1.807, RMSE เท่ากับ 1.344 และ MAPE เท่ากับ 5.37 ซึ่งเป็นโมเดลที่มีค่า MSE และ RMSE ต่ำที่สุดสะท้อนถึงความแม่นยำในการพยากรณ์ที่สูง แม้ว่าค่า MAPE จะสูงกว่าบางโมเดลก็ตาม โมเดล Bi-LSTM มีค่า MSE เท่ากับ 2.14, RMSE เท่ากับ 1.46 และ MAPE เท่ากับ 5.06 ซึ่งมีค่า MSE และ RMSE ที่คล้ายกับ ANN แต่ยังคงมีความแม่นยำน้อยกว่าทั้ง ARIMA และ LSTM ซึ่งหมายความว่าโมเดล Bi-LSTM ไม่ได้มีความแม่นยำในการทำนายผลลัพธ์ได้ดีเท่ากับ ARIMA และ LSTM เนื่องจาก LSTM มีความสามารถในการจดจำความสัมพันธ์ระยะยาวของข้อมูล ส่งผลให้เหมาะสมกับการพยากรณ์ข้อมูลด้านพลังงานไฟฟ้า ซึ่งมีรูปแบบการใช้งานที่เปลี่ยนแปลงตามช่วงเวลา ผลการทดสอบการพยากรณ์ทั้ง 4 ดังแสดงในรูปที่ 6 ผลลัพธ์การพยากรณ์ในแต่ละวิธี ซึ่งเปรียบเทียบค่าจากการพยากรณ์กับค่าพลังงานไฟฟ้าที่ใช้จริงในปีถัดไป (ปี 2567) ตั้งแต่วันที่ 1 มกราคม ถึงวันที่ 30 เมษายน 2567 ดังแสดงในรูปที่ 7

5. สรุป

งานวิจัยนี้นำเสนอการสร้างแบบจำลองการพยากรณ์ค่าพลังงานไฟฟ้าของเครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์ ข้อมูลที่นำมาใช้ในงานวิจัยคือข้อมูลอุณหภูมิ ความชื้นและค่าพลังงานไฟฟ้าของ

เครื่องปรับอากาศภายในห้องเซิร์ฟเวอร์ของอาคารแห่งหนึ่งซึ่งถูกเก็บข้อมูลด้วยเทคโนโลยี IoT ผลลัพธ์ของการศึกษานี้พบว่าระบบ IoT สามารถเก็บข้อมูลแบบเรียลไทม์จากอุปกรณ์ผ่านเซ็นเซอร์ที่เชื่อมต่ออินเทอร์เน็ตได้อย่างถูกต้องและแม่นยำ สามารถลดความคลาดเคลื่อนของข้อมูลที่อาจเกิดขึ้นจากการเก็บข้อมูลด้วยวิธีการบันทึกแบบเดิม ส่วน Machine Learning ช่วยเพิ่มความแม่นยำในการพยากรณ์ค่าพลังงานไฟฟ้าโดยสามารถเรียนรู้รูปแบบจากข้อมูลจำนวนมากที่เก็บผ่านระบบ IoT ได้อย่างแม่นยำ งานวิจัยนี้ได้สร้างสร้างตัวแบบจำลองการพยากรณ์และเปรียบเทียบผลลัพธ์การพยากรณ์ค่าพลังงานไฟฟ้า 4 วิธี ได้แก่วิธี LSTM, Bi-LSTM, ANN และ ARIMA จากผลการวิเคราะห์พบว่าวิธี LSTM เป็นแบบจำลองที่มีความแม่นยำสูงที่สุด โดยพิจารณาจากค่า MSE และ RMSE ที่ต่ำที่สุด ในขณะที่ ARIMA มีความโดดเด่นในด้านความคลาดเคลื่อนสัมพัทธ์ (MAPE) ต่ำที่สุด ซึ่งแสดงให้เห็นว่า LSTM เหมาะสมสำหรับการพยากรณ์ค่าพลังงานไฟฟ้ามากที่สุด เนื่องจากการพยากรณ์มีแนวโน้มเคลื่อนที่ตามค่าจริง และมีค่า MSE ต่ำที่สุด LSTM มีประสิทธิภาพในการพยากรณ์ดีกว่าโมเดลอื่น เนื่องจากโครงสร้างภายในของโมเดลที่ถูกออกแบบมาเฉพาะเพื่อจัดการกับข้อมูลลำดับเวลา (time series) ที่มีความซับซ้อนและความสัมพันธ์ระยะยาวในข้อมูล โดยโครงสร้างหลักของ LSTM ประกอบด้วยเซลล์หน่วยความจำ (memory cell) ที่สามารถเก็บรักษาข้อมูลในระยะยาวได้ และมีการควบคุมการไหลของข้อมูลผ่านเกต 3 ชนิด ได้แก่ Forget Gate, Input Gate, และ Output Gate ซึ่งช่วยให้โมเดลสามารถจดจำข้อมูลที่สำคัญและลืมข้อมูลที่ไม่จำเป็นได้อย่างมีประสิทธิภาพ อย่างไรก็ตามการเลือกโมเดลขึ้นอยู่กับลักษณะของปัญหาและความต้องการในการใช้งานจริง การพยากรณ์ด้วยเทคนิค Machine Learning มีข้อได้เปรียบเหนือกว่าวิธีการพยากรณ์แบบดั้งเดิมอย่างชัดเจน เนื่องจาก ML สามารถประมวลผลข้อมูลจำนวนมากที่มีความซับซ้อนและหลากหลายได้โดยไม่ต้องพึ่งพาสมมติฐานตายตัวหรือสูตรเฉพาะทางคณิตศาสตร์เหมือนวิธีดั้งเดิม ML ยังสามารถเรียนรู้

และปรับปรุงประสิทธิภาพจากข้อมูลใหม่ได้อย่างต่อเนื่อง ทำให้ผลการพยากรณ์มีความแม่นยำสูงและมีความยืดหยุ่นต่อการเปลี่ยนแปลงของข้อมูล นอกจากนี้ ML ยังสามารถนำไปใช้ในการพยากรณ์แบบเรียลไทม์ ซึ่งเหมาะสมกับสภาพแวดล้อมที่ต้องการการตอบสนองอย่างรวดเร็ว ในขณะที่วิธีการดั้งเดิมต้องปรับปรุงหรือปรับแต่งด้วยบุคคลและขาดความสามารถในการรองรับข้อมูลที่เปลี่ยนแปลงอย่างต่อเนื่อง

แบบจำลองการพยากรณ์พลังงานไฟฟ้านี้ช่วยให้ผู้ใช้สามารถทำนายการใช้พลังงานล่วงหน้า เพื่อกำหนดวิธีประหยัดพลังงานและเพิ่มการผลิตไฟฟ้าให้เพียงพอ การประยุกต์ใช้ข้อมูลพยากรณ์ยังช่วยในการปรับปรุงการจัดการพลังงานอย่างมีประสิทธิภาพ เช่น การปรับตั้งค่าเครื่องปรับอากาศและอุปกรณ์ภายในห้องให้เหมาะสมตามช่วงเวลาของการใช้พลังงาน ถึงแม้เทคโนโลยี IoT จะช่วยเพิ่มประสิทธิภาพในการเก็บและประมวลผลข้อมูลได้แบบเรียลไทม์ แต่ยังมีข้อจำกัดที่สำคัญ ได้แก่ ความเสถียรของระบบที่อาจได้รับผลกระทบจากปัญหาสัญญาณอินเทอร์เน็ตหรือการเชื่อมต่อที่ไม่ต่อเนื่อง การจัดการข้อมูลขนาดใหญ่จากเซ็นเซอร์จำนวนมากซึ่งต้องใช้ทรัพยากรในการจัดเก็บและประมวลผลสูง อาจทำให้ระบบล่าช้าหรือไม่สามารถรองรับข้อมูลได้ทั้งหมด แนวทางการพัฒนาในอนาคตเพื่อเพิ่มความแม่นยำของโมเดลสามารถทำได้โดยการผสมเทคนิคต่าง ๆ เช่น โมเดล LSTM, Bi-LSTM, ANN ผสมผสานกับโมเดล ARIMA หรืออัลกอริทึมอื่น ๆ การปรับปรุงโครงสร้างภายในโมเดลให้ซับซ้อนขึ้น การเลือกข้อมูลนำเข้าเช่น สภาพอากาศและฤดูกาล รวมถึงการปรับแต่งพารามิเตอร์ การป้องกัน overfitting และการฝึกฝนข้อมูลแบบเรียลไทม์ ซึ่งจะช่วยทำให้โมเดลสามารถพยากรณ์ข้อมูลที่มีความซับซ้อนและเปลี่ยนแปลงตามเวลาได้แม่นยำยิ่งขึ้น ข้อเสนอแนะของงานวิจัยนี้คือ ควรเก็บข้อมูลที่ต้องการทดสอบอย่างน้อย 1 ปี เพื่อทดสอบความแม่นยำของแบบจำลองการพยากรณ์ในแต่ละฤดูกาล

เอกสารอ้างอิง

- [1] ปรีชา อากาศศ และ กุสภานา ภูษาธา. การศึกษาความสัมพันธ์ระหว่างอุณหภูมิภายนอกและการใช้พลังงานของเครื่องปรับอากาศของอาคารอเนกประสงค์มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี. วารสารวิชาการประชุมสภาข้าราชการ พนักงาน และลูกจ้าง มหาวิทยาลัยแห่งประเทศไทย (ปชมท). 2562; 8(2): 80-89.
- [2] อัญญา สีหะสิงห์ และ ศุภธา ศรีเผด็จ. ความชื้นในห้องพักที่มีห้องน้ำในตัวส่งผลต่อค่าไฟฟ้าจากเครื่องปรับอากาศ. วารสารสารศาสตร์. 2564; ฉบับที่ 4: 908-919.
- [3] นรินทร์ พนาวาส. การพัฒนาระบบเฝ้าระวังความปลอดภัยห้องค้ำเต้าขึ้นเตอร์ด้วยเทคโนโลยีอินเทอร์เน็ตเพื่อสรรพสิ่ง. วารสารสหศาสตร์ศรีปทุม ชลบุรี. 2567; 10(1): 61-76.
- [4] อรรถกร เก่งพล และ อลงกรณ์ คล้ายคลึง. การประยุกต์ใช้ตัวแบบโครงข่ายประสาทเทียมแบบคอนโวลูชัน และตัวแบบทางคณิตศาสตร์ในการคัดแยกมะนาวตามมาตรฐานสินค้าเกษตร เลขที่ มกษ. 27-2560 โดยใช้เครื่องจักรเรียนรู้. เอกสารสืบเนื่องจากการประชุมวิชาการข่ายงานวิศวกรรมอุตสาหกรรมประจำปี พ.ศ. 2567. 15-17 พฤษภาคม พ.ศ. 2567; โรงแรมเซ็นทารา. จังหวัดอุบลราชธานี; 2567. หน้า 497-505.
- [5] Laghrissi F, Douzi S, Douzi K, Hssina B. 2021. "Intrusion detection systems using long short term memory (LSTM)". Big Data, Vol. 8(1).
- [6] Naik D, Jaidhar CD. A novel Multi-Layer Attention Framework for visual description prediction using bidirectional LSTM. International Journal of Big Data. 2022; 9.
- [7] Punyota W, Kengpol A. 2021. "Prediction of Vegetarian Food Preferences for the Aging Society", Proceeding of the International

- Conference on Engineering and Technology; 2021 May 27-28; Krabi, Thailand. 2021.
- [8] Wen T, Liu Y, Bai YH, Liu H, et al. Modeling and forecasting CO₂ emissions in China and its regions using a novel ARIMA-LSTM model. *International Journal of Heliyon*. 2023; 9.
- [9] ทรรตมล วงศ์จิตสุขเกษม และ ดาริชา สุธีวงศ์. การพยากรณ์ราคาเศษเหล็กในประเทศไทยโดยใช้เทคนิคทางสถิติและการเรียนรู้ของเครื่อง. เอกสารสืบเนื่องจากการประชุมวิชาการข่ายงานวิศวกรรมอุตสาหกรรมประจำปี พ.ศ. 2567. 15-17 พฤษภาคม พ.ศ. 2567; โรงแรมเซ็นทารา. จังหวัดอุบลราชธานี; 2567. หน้า 255-261.
- [10] ไกรวิทย์ ชูชาติ. การพัฒนาระบบตรวจวัดการใช้พลังงานไฟฟ้าในอาคารบนแพลตฟอร์มอินเทอร์เน็ตของสรรพสิ่ง กรณีศึกษาอาคารศรีวิศวะวิทยา [วิทยานิพนธ์ วิศวกรรมศาสตรมหาบัณฑิต]. มหาวิทยาลัยสงขลานครินทร์. 2565.
- [11] Wassef Hasan M. 2023. Building an IoT temperature and humidity forecasting model based on long short-term memory (LSTM) with improved whale optimization algorithm. *International Journal of Memories - Materials, Devices, Circuits and Systems*. 2023; 6.
- [12] ภาณุเดช คุณชม. การพยากรณ์การใช้พลังงานไฟฟ้าของอาคารสำนักงานด้วยแบบจำลองการขับเคลื่อนด้วยข้อมูล [อินเทอร์เน็ต]. 2565. [เข้าถึงเมื่อ 23 พฤศจิกายน 2564]. เข้าถึงได้จาก: <https://libdoc.dpu.ac.th/thesis/Panudet.Khun.pdf>
- [13] Balaji S, Karthik S. Energy Prediction in IoT Systems Using Machine Learning Models. *International Journal of Computers, Materials & Continua*. 2022; 75(1): 443-459.
- [14] Faiq M, Tan KG, Liew CP, Hossain F, Tso C, Lim LL, et al. Prediction of energy consumption in campus buildings using long short-term memory. *International Journal of Alexandria Engineering*. 2023; 67: 65-76.
- [15] El-Azab HI, Swief RA, El-Amary NH, Temraz HK. Machine and deep learning approaches for forecasting electricity price and energy load assessment on real datasets. *International Journal of Ain Shams Engineering*. 2024; 15(4).
- [16] Berriel RF, Lopes AT, Rodrigues A, Varejão FM, Oliveira-Santos T. Proceedings of the International Joint Conference on Neural Networks (IJCNN); 2017 May 4-19; Anchorage, AK, USA. 2017. p.4283-4290