

SAC-01-016

การเปรียบเทียบประสิทธิภาพการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุด รายเดือนด้วยแบบจำลองปัญญาประดิษฐ์ Comparative Performance Analysis of Artificial Intelligence Models for Monthly Peak Electricity Load Time Series Forecasting

อรรณพ กางกั้น*

Unnop Kangkan*

คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

Faculty of Information Technology, Siam University

email: unnopkk@siam.edu

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยใช้แบบจำลองปัญญาประดิษฐ์ 5 รูปแบบ ได้แก่ (1) แบบจำลอง RNN (2) แบบจำลอง CNN (3) แบบจำลอง LSTM (4) แบบจำลองผสม RNN-LSTM และ (5) แบบจำลองผสม CNN-LSTM ข้อมูลที่นำมาใช้ศึกษาเป็นข้อมูลอนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนของประเทศไทย ตั้งแต่วันที่ 1 มกราคม 2529 ถึงวันที่ 31 ธันวาคม 2568 โดยแบ่งชุดข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลสำหรับพัฒนาและฝึกแบบจำลอง จำนวน 408 รายการ และชุดข้อมูลสำหรับทดสอบแบบจำลอง จำนวน 72 รายการ ผลการวิจัยพบว่า แบบจำลองผสม RNN-LSTM มีประสิทธิภาพโดยรวมสูงที่สุด การเรียนรู้ของแบบจำลองกับชุดข้อมูลเรียนรู้ มีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) เท่ากับ 423.89 เมกะวัตต์ ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) เท่ากับ 588.92 เมกะวัตต์ ค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (MAPE) เท่ากับ 2.47% เป็นค่าต่ำที่สุด และมีค่าสัมประสิทธิ์การตัดสินใจ (R^2) เท่ากับ 0.9932 เป็นค่าสูงที่สุด การทดสอบประสิทธิภาพของแบบจำลองกับชุดข้อมูลทดสอบมีค่า MAE เท่ากับ 988.47 เมกะวัตต์ ค่า RMSE เท่ากับ 1,243.24 เมกะวัตต์ ค่า MAPE เท่ากับ 3.29% เป็นค่าต่ำที่สุด และมีค่า R^2 เท่ากับ 0.7411 เป็นค่าสูงที่สุด และการประมาณการความแม่นยำในการพยากรณ์ มีค่า MMRE เท่ากับ 4.36% เป็นค่าต่ำที่สุด แบบจำลองผสม RNN-LSTM สามารถเรียนรู้รูปแบบของข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพ และให้ผลการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนได้ดีกว่าแบบจำลองอื่นที่ใช้ในการศึกษา

คำสำคัญ: การพยากรณ์อนุกรมเวลา อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน, แบบจำลองปัญญาประดิษฐ์

Abstract

The purposes of this research were to develop and compare the performance of monthly peak electricity load time series forecasting models using five artificial intelligence models, namely: (1) Recurrent Neural Network (RNN), (2) Convolutional Neural Network (CNN), (3) Long Short-Term Memory (LSTM), (4) Hybrid RNN-LSTM, and (5) Hybrid CNN-LSTM. The data used in this research consisted of the monthly peak electricity load time series data of Thailand from 1 January 1986 to 31 December 2025. The dataset was divided into two subsets, including 408 records for model development and training, and 72 records for model testing. The results indicated that the Hybrid RNN-LSTM model achieved the highest overall forecasting performance. During the training phase with the training dataset, the model yielded the lowest Mean Absolute Error (MAE) of 423.89 MW, the lowest Root Mean Squared Error (RMSE) of 588.92 MW, and the lowest Mean Absolute Percentage Error (MAPE) of 2.47%, while achieving the highest Coefficient of Determination (R^2) of 0.9932. During the testing phase with the testing dataset, the model also produced the lowest MAE of 988.47 MW, the lowest RMSE of 1,243.24 MW, and the lowest MAPE of 3.29%, while achieving the highest R^2 value of 0.7411. In addition, the forecasting accuracy estimation showed that the Hybrid RNN-LSTM model achieved the lowest Mean Magnitude of Relative Error (MMRE) of 4.36%. The findings indicated

that the Hybrid RNN-LSTM model could effectively learn the patterns of time series data and provided better forecasting performance for monthly peak electricity load time series than the other models used in this study.

Keywords: Time Series Forecasting, Monthly Peak Electricity Load Time Series, Artificial Intelligence Model

บทนำ

กระแสไฟฟ้าเป็นพลังงานที่มีความสำคัญต่อเศรษฐกิจของประเทศ เนื่องจากเป็นแหล่งพลังงานขั้นต้นของภาคอุตสาหกรรม ภาคธุรกิจ ตลอดจนภาคครัวเรือน ความต้องการใช้กระแสไฟฟ้ามีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง ส่งผลให้หน่วยงานด้านพลังงาน จำเป็นต้องวางแผนการผลิต และบริหารจัดการระบบไฟฟ้าให้มีความมั่นคง และเพียงพอต่อการใช้งาน จากรายงานสถานการณ์พลังงาน ปี 2568 ของกระทรวงพลังงาน (กระทรวงพลังงาน, 2568) พบว่า ความต้องการพลังไฟฟ้าสูงสุดในระบบ 3 การไฟฟ้า (System Peak) เกิดขึ้นเมื่อวันที่ 24 เมษายน เวลา 20.48 น. มีค่าประมาณ 34,620 เมกะวัตต์ (สำนักงานนโยบายและแผนพลังงาน, 2569) แม้ว่าจะลดลงจากปี 2567 ร้อยละ 5.9 แต่ยังคงอยู่ในระดับสูง สะท้อนให้เห็นถึงความสำคัญของการบริหารจัดการกำลังการผลิตไฟฟ้าให้สอดคล้องกับความต้องการใช้งานที่มีความผันผวน

จากบทความวิจัยเรื่อง Electricity Load Forecasting in Thailand Using Deep Learning Models (Phyo et al., 2019) ได้ศึกษาการพยากรณ์ความต้องการใช้ไฟฟ้าระยะสั้นของประเทศไทย โดยเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก ได้แก่ Long Short-Term Memory (LSTM) และ Deep Belief Network (DBN) ใช้ข้อมูลภาระไฟฟ้า (Electric Load) จากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) ซึ่งผ่านการทำความสะอาดข้อมูลและปรับข้อมูลให้อยู่ในรูปแบบที่เหมาะสมก่อนพัฒนาแบบจำลอง ผลการศึกษาพบว่า แบบจำลอง LSTM ให้ความแม่นยำในการพยากรณ์สูงกว่า DBN โดยมีค่า MAPE และ RMSE ต่ำกว่า เนื่องจาก LSTM สามารถเรียนรู้ความสัมพันธ์ของข้อมูลอนุกรมเวลาได้ดีกว่า จึงเหมาะสำหรับการพยากรณ์ความต้องการใช้ไฟฟ้าที่มีลักษณะเป็นข้อมูลอนุกรมเวลา

จากบทความวิจัยเรื่อง A Hybrid Residual Dilated LSTM and Exponential Smoothing Model for Mid-Term Electric Load Forecasting (Dudek et al., 2020) ได้พัฒนาแบบจำลองปัญญาประดิษฐ์แบบผสมระหว่าง Exponential Smoothing (ETS) และ Residual Dilated Long Short-Term Memory (RD-LSTM) สำหรับการพยากรณ์ความต้องการใช้ไฟฟ้าระยะกลาง โดยใช้ข้อมูลความต้องการใช้ไฟฟ้ารายเดือนของ 35 ประเทศในยุโรป ผู้วิจัยประยุกต์ใช้เทคนิค Ensembling เพื่อรวมผลการพยากรณ์จากหลายแบบจำลองและเพิ่มประสิทธิภาพของการพยากรณ์ จากนั้นจึงเปรียบเทียบผลลัพธ์กับแบบจำลองเชิงสถิติ ได้แก่ ARIMA และ ETS และแบบจำลองปัญญาประดิษฐ์ ได้แก่ LSTM, MLP และ ANFIS ผลการศึกษาพบว่า แบบจำลอง ETS+RD-LSTM ให้ประสิทธิภาพการพยากรณ์อยู่ในระดับสูง โดยมีค่า MAPE ต่ำ และมีความสามารถในการแข่งขันกับแบบจำลองสมัยใหม่ แสดงให้เห็นว่า การผสมผสานเทคนิคเชิงสถิติกับโครงข่ายประสาทเทียมเชิงลึก ช่วยเพิ่มความแม่นยำในการพยากรณ์ข้อมูลอนุกรมเวลาที่มีแนวโน้มและฤดูกาลได้อย่างมีประสิทธิภาพ

จากบทความวิจัยเรื่อง ตัวแบบพยากรณ์ปริมาณการใช้ไฟฟ้าของประเทศ (กนกกาญจน์ ศรีสุรินทร์ และคณะ, 2565) ได้สร้างตัวแบบพยากรณ์ปริมาณการใช้ไฟฟ้า และเปรียบเทียบวิธีการพยากรณ์ 4 วิธี คือ วิธีการแยกส่วนประกอบ วิธีการพยากรณ์ของโพลต์ วิธีการพยากรณ์ของวินเทอร์ และวิธีการพยากรณ์ของบ็อกซ์-เจนกินส์ ผลการศึกษาพบว่า ตัวแบบพยากรณ์ของวินเทอร์เป็นตัวแบบพยากรณ์ที่เหมาะสมที่สุด เนื่องจากมีค่าเฉลี่ยเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percentage Error : MAPE) ต่ำสุด

จากบทความวิจัยเรื่อง A Deep Learning Approach for Short-Term Electricity Demand Forecasting: Analysis of Thailand Data (Shiwakoti et al., 2024) ได้พยากรณ์ความต้องการใช้ไฟฟ้า โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก ได้แก่ Recurrent Neural Network (RNN) ร่วมกับ Long Short-Term Memory (LSTM) และ Gated Recurrent Unit (GRU) สำหรับการพยากรณ์ข้อมูลอนุกรมเวลา ออกแบบการทดลองเป็น 3 สถานการณ์ ได้แก่ (1) ใช้ข้อมูลความต้องการไฟฟ้าตลอดทั้งวัน (2) ใช้ข้อมูลเฉพาะวันทำงาน และ (3) ใช้ข้อมูลเฉพาะวันหยุด ผลการศึกษาพบว่า แบบจำลอง RNN-GRU ให้ประสิทธิภาพโดยรวมดีที่สุด สถานการณ์ข้อมูลตลอดทั้งวันและวันทำงาน ขณะที่ RNN-LSTM ให้ผลลัพธ์ที่ดีกว่าในกรณีข้อมูลวันหยุด ซึ่งสะท้อนว่า โครงสร้างของข้อมูลและลักษณะความผันผวนของพฤติกรรมผู้ใช้มีผลต่อประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ

งานวิจัยนี้จึงนำเสนอการเปรียบเทียบประสิทธิภาพการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนด้วยแบบจำลองปัญญาประดิษฐ์ เพื่อช่วยให้หน่วยงานที่เกี่ยวข้องทั้งภาครัฐและภาคเอกชน สามารถนำไปใช้คาดการณ์ปริมาณความต้องการในการใช้กระแสไฟฟ้าได้ล่วงหน้า เพื่อการวางแผนตัดสินใจ กำหนดนโยบายบริหารจัดการพลังงานไฟฟ้าได้อย่างมีประสิทธิภาพ โดยผู้วิจัยได้นำแบบจำลองปัญญาประดิษฐ์ ใน 5 รูปแบบ ได้แก่ (1) แบบจำลอง RNN (2) แบบจำลอง CNN (3) แบบจำลอง LSTM

(4) แบบจำลองผสม RNN-LSTM และ (5) แบบจำลองผสม CNN-LSTM มาประยุกต์ใช้ในการพยากรณ์และเปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้ข้อมูลอนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน ตั้งแต่วันที่ 1 มกราคม 2529 ถึงวันที่ 31 ธันวาคม 2568 มาเป็นข้อมูลในการพัฒนาและทดสอบแบบจำลอง

การทบทวนวรรณกรรม

อนุกรมเวลา (Time Series) คือ ชุดข้อมูลที่จัดเก็บอย่างต่อเนื่อง และมีการจัดเรียงตามช่วงเวลาต่าง ๆ (Han & Kamber, 2001) เช่น รายวัน รายเดือน รายปี เป็นต้น องค์ประกอบของข้อมูลอนุกรมเวลาที่มีผลให้เกิดความผันแปรในข้อมูลคือ แนวโน้ม (Trend) วัฏจักร (Cyclical) ฤดูกาล (Seasonal) และความผิดปกติ (Irregular) (Lind et al., 2010)

Recurrent Neural Network (RNN) เป็นโครงข่ายประสาทเทียมที่ออกแบบมาเพื่อประมวลผลข้อมูลแบบลำดับเวลา (Sequential Data) โดยสามารถจดจำข้อมูลก่อนหน้า และนำมาใช้ร่วมกับข้อมูลปัจจุบันได้ เหมาะสำหรับงานที่ข้อมูลมีความต่อเนื่องตามเวลา เช่น การวิเคราะห์อนุกรมเวลา การรู้จำเสียงพูด และการประมวลผลภาษาธรรมชาติ เป็นต้น โครงสร้างของ RNN จะมีการส่งข้อมูลย้อนกลับภายในเครือข่าย ทำให้แบบจำลองสามารถเก็บสถานะของข้อมูลในช่วงเวลาก่อนหน้าไว้ได้ เมื่อมีข้อมูลใหม่เข้ามา เครือข่ายจะใช้ทั้งข้อมูลปัจจุบันและสถานะเดิมในการคำนวณผลลัพธ์

Convolution Neural Network (CNN) เป็นโครงข่ายประสาทเทียมที่ออกแบบมาเพื่อเรียนรู้คุณลักษณะสำคัญของข้อมูลโดยอัตโนมัติผ่านกระบวนการ Convolution หลักการทำงานของ CNN จะมีการใช้ Kernel เลื่อนผ่านข้อมูลเพื่อตรวจจับรูปแบบ หรือคุณลักษณะสำคัญของข้อมูล โดยแต่ละ Kernel จะสามารถเรียนรู้รูปแบบของข้อมูลได้อย่างอัตโนมัติ (Goodfellow et al., 2016)

Long Short-Term Memory (LSTM) เป็นโครงข่ายประสาทเทียมที่พัฒนาขึ้นจากโครงข่ายประสาทเทียมแบบ RNN ที่ถูกพัฒนาขึ้นเพื่อประมวลผลข้อมูลที่มีลักษณะความสัมพันธ์เป็นลำดับก่อนหลังหรือข้อมูลอนุกรมเวลา โดยสามารถเรียนรู้ข้อมูลที่มีลำดับยาว ๆ ได้ดี เนื่องจากมีโครงสร้างที่ภายในประกอบด้วยหน่วยประมวลผล (Cell) ที่เชื่อมโยงกัน โดยแต่ละ Cell ประกอบด้วยหน่วยย่อย ดังนี้ (1) Forget gate ทำหน้าที่ควบคุมการเก็บค่า ลดค่า หรือลืมค่าของข้อมูลที่เข้าไปใน Cell (2) Input gate ทำหน้าที่ควบคุมการเพิ่มค่าใหม่ที่สำคัญเข้าไปใน Cell และ (3) Output gate ทำหน้าที่รวบรวมและกำหนดค่าที่จะส่งออกไปประมวลผลให้กับ Cell ถัดไป (กอบเกียรติ สระอุบล, 2565)

ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) เป็นค่าที่ชี้วัดความถูกต้องของการพยากรณ์เพื่อวัดประสิทธิภาพของแบบจำลอง ถ้า MAE มีค่าน้อยจะแสดงว่า แบบจำลองมีความแม่นยำในการพยากรณ์สูง สูตรการคำนวณดังนี้ (Mendenhall & Sincich, 2003)

$$MAE = \frac{\sum_{i=1}^n |Y_i - \hat{Y}_i|}{n} \quad (1)$$

ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) เป็นค่าที่ชี้วัดความคลาดเคลื่อนของการพยากรณ์ คำนวณจากการหารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ถ้า RMSE มีค่าน้อยจะแสดงถึงความคลาดเคลื่อนต่ำ แบบจำลองจะมีประสิทธิภาพในการพยากรณ์ผลลัพธ์ได้ดี สูตรการคำนวณดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2)$$

โดยที่ Y_i คือ ค่าประมาณการจากแบบจำลอง

$\hat{Y}_i$ คือ ค่าจริงที่ใช้ในการสร้างแบบจำลอง

n คือ จำนวนข้อมูล

ค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R^2) เป็นค่าชี้วัดที่ใช้ประเมินความสามารถของแบบจำลองในการอธิบายความแปรปรวน (Variation) ของตัวแปรตาม (Dependent Variable) จากตัวแปรอิสระ (Independent Variables) หรือจากข้อมูลในอดีตของตัวแปรนั้น สูตรการคำนวณดังนี้

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} \quad (3)$$

โดยที่ SS_{res} คือ ผลรวมกำลังสองของความคลาดเคลื่อนระหว่างค่าจริงและค่าที่แบบจำลองพยากรณ์ได้

$$SS_{res} = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4)$$

SS_{tot} คือ ผลรวมกำลังสองของความแตกต่างระหว่างค่าจริงกับค่าเฉลี่ยของข้อมูล

$$SS_{tot} = \sum_{i=1}^n (Y_i - \bar{Y})^2 \quad (5)$$

Y_i คือ ค่าจริง

$\hat{Y}_i$ คือ ค่าที่พยากรณ์ได้

$\bar{Y}$ คือ ค่าเฉลี่ยของค่าจริง

ค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) เป็นค่าชี้วัดที่ใช้ประเมินความแม่นยำของแบบจำลอง โดยแสดงขนาดของความคลาดเคลื่อนระหว่างค่าที่พยากรณ์กับค่าจริงเป็นเปอร์เซ็นต์ สูตรการคำนวณดังนี้

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (6)$$

โดยที่ Y_i คือ ค่าจริง

$\hat{Y}_i$ คือ ค่าที่พยากรณ์ได้

n คือ จำนวนข้อมูล

ค่าความคลาดเคลื่อนสัมพัทธ์ (Magnitude of Relative Error: MRE) การประมาณความแม่นยำจากการสร้างแบบจำลอง โดยการตรวจสอบกับชุดข้อมูลที่ทราบค่าจริง (Actual Data) กับผลลัพธ์จากการประมาณค่าของชุดข้อมูลใหม่ (Predicted Data) ซึ่งมีสูตรการคำนวณดังนี้

$$MRE_i = \frac{|Actual_i - Predicted_i|}{Actual_i} \quad (7)$$

ค่าเฉลี่ยความคลาดเคลื่อนสัมพัทธ์ (Mean Magnitude of Relative Error: MMRE) ใช้กับชุดข้อมูลที่มีปริมาณมาก เพื่อเป็นดัชนีชี้วัดประสิทธิภาพโดยรวมของแบบจำลอง ถ้าค่า MMRE มีค่าน้อยแสดงว่า ค่าที่ได้จากการประมาณมีความใกล้เคียงกับค่าจริงมาก สูตรการคำนวณดังนี้

$$MMRE = \frac{1}{n} \sum_{i=1}^n \frac{|Actual_i - Predicted_i|}{Actual_i} \times 100 \quad (8)$$

โดยที่ $Actual_i$ คือ ค่าจริงของข้อมูล

$Predicted_i$ คือ ค่าพยากรณ์จากข้อมูล


n คือ จำนวนข้อมูล

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองในการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนด้วยแบบจำลองปัญญาประดิษฐ์
2. เพื่อเปรียบเทียบประสิทธิภาพแบบจำลองปัญญาประดิษฐ์ที่เหมาะสมในการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน


วิธีดำเนินการวิจัย

ผู้วิจัยได้เขียนชุดคำสั่งงานด้วยภาษา Python โดยใช้โปรแกรม Jupyter Notebook ในการประมวลผลกับข้อมูลอนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพแบบจำลองปัญญาประดิษฐ์ทั้ง 5 รูปแบบ ได้แก่ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM ตามกระบวนการในภาพที่ 1 ดังนี้



ภาพที่ 1 กระบวนการพัฒนาแบบจำลองและการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน

1. การจัดการข้อมูล ผู้วิจัยได้รวบรวมข้อมูลทุติยภูมิ ข้อมูลอนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนตั้งแต่วันที่ 1 มกราคม 2529 ถึงวันที่ 31 ธันวาคม 2568 จากเว็บไซต์ที่เผยแพร่ของสำนักนโยบายและแผนพลังงาน กระทรวงพลังงาน (ดังภาพที่ 2) โดยใช้โปรแกรมสเปรดชีตในการจัดการข้อมูลทั้งหมดให้อยู่ในรูปแบบของแฟ้มข้อมูลชนิด CSV จากนั้น จึงให้โปรแกรมดำเนินการตรวจสอบข้อมูล และปรับขนาดข้อมูลด้วยวิธี Min-Max Normalization ให้อยู่ในช่วง 0-1 ดำเนินการสร้างชุดข้อมูลลำดับเวลาโดยการกำหนดค่า Look Back และแปลงข้อมูลให้อยู่ในรูปแบบที่เหมาะสม เพื่อให้แบบจำลองสามารถเรียนรู้ลำดับเวลาของข้อมูลในการเตรียมข้อมูลเพื่อเข้าสู่กระบวนการพัฒนาแบบจำลอง และทดสอบประสิทธิภาพของแบบจำลอง กำหนดให้มีการแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ (1) ชุดข้อมูลเรียนรู้ (Training Data set) สำหรับฝึกแบบจำลอง ใช้ข้อมูลตั้งแต่วันที่ 1 มกราคม 2529 ถึงวันที่ 31 ธันวาคม 2562 จำนวน 408 รายการ คิดเป็น 85% ของจำนวนข้อมูลทั้งหมด (2) ชุดข้อมูลทดสอบ (Testing Data set) ใช้ข้อมูลตั้งแต่วันที่ 1 มกราคม 2563 ถึง 31 ธันวาคม 2568 จำนวน 72 รายการ คิดเป็น 15% ของจำนวนข้อมูลทั้งหมด



ภาพที่ 2 ข้อมูลอนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนตั้งแต่วันที่ 1 ม.ค. 2529 ถึงวันที่ 31 ธ.ค. 2568

2. การพัฒนาและฝึกแบบจำลองจากข้อมูลชุดเรียนรู้ ได้ดำเนินการพัฒนาและฝึกแบบจำลองปัญญาประดิษฐ์ทั้ง 5 รูปแบบ ได้แก่ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM กำหนดให้ใช้ Optimizer แบบ Adam และ Loss Function แบบ Mean Squared Error (MSE) เพื่อช่วยให้โมเดลเรียนรู้ได้มีประสิทธิภาพมากขึ้น กำหนดจำนวน Epoch เท่ากับ 300 รอบ และ Batch Size เท่ากับ 16 เพื่อให้เหมาะสมกับลักษณะข้อมูลอนุกรมเวลา นอกจากนี้ ยังประยุกต์ใช้เทคนิค Early Stopping และ Dropout เพื่อช่วยลดปัญหาการเกิด Overfitting

3. การประมวลผล และผลลัพธ์ โดยนำข้อมูลชุดทดสอบมาทำการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน เพื่อประเมินประสิทธิภาพของแบบจำลองปัญญาประดิษฐ์แต่ละรูปแบบ โดยใช้ตัวชี้วัดประสิทธิภาพ ได้แก่ ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ค่าสัมประสิทธิ์การตัดสินใจ (R^2) และค่าความคลาดเคลื่อนร้อยละสัมบูรณ์เฉลี่ย (MAPE) จากนั้น จึงนำผลการประเมินประสิทธิภาพของแบบจำลองทั้งหมดมาเปรียบเทียบ เพื่อวิเคราะห์และคัดเลือกแบบจำลองที่มีความเหมาะสม และให้ประสิทธิภาพสูงสุดสำหรับการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยพิจารณาจากค่า MAE ต่ำที่สุด และค่า R^2 ที่สูงที่สุด ในการประมาณการความแม่นยำการพยากรณ์ของแบบจำลอง พิจารณาจากค่า MRE และ MMRE ต่ำที่สุด

ผลการวิจัย

ผู้วิจัยดำเนินการวัดประสิทธิภาพของแบบจำลองปัญญาประดิษฐ์ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM ในการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยใช้ชุดข้อมูลเรียนรู้และชุดข้อมูลทดสอบ ตามขั้นตอนการวิจัยได้ผลการทดสอบแบ่งได้เป็น 3 ส่วน ดังนี้

1. การทดสอบประสิทธิภาพของแบบจำลองกับข้อมูลชุดเรียนรู้จำนวน 408 รายการ เพื่อวิเคราะห์ความสามารถในการเรียนรู้ข้อมูลของแบบจำลอง ได้ผลลัพธ์ดังตารางที่ 1

ตารางที่ 1

การเปรียบเทียบประสิทธิภาพแบบจำลองกับชุดข้อมูลเรียนรู้

Model	MAE	RMSE	R^2	MAPE (%)
RNN	619.44	816.05	0.9860	3.77
CNN	706.18	961.79	0.9793	4.00
LSTM	645.73	903.26	0.9829	3.91
RNN-LSTM	423.89	588.92	0.9932	2.47
CNN-LSTM	650.11	910.07	0.9814	3.59

จากตารางที่ 1 แสดงการเปรียบเทียบประสิทธิภาพแบบจำลองการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยใช้ชุดข้อมูลเรียนรู้จำนวน 408 รายการ จากแบบจำลองปัญญาประดิษฐ์ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM เมื่อพิจารณาค่า MAE, RMSE, R^2 และค่า MAPE เป็นดัชนีชี้วัดประสิทธิภาพ พบว่า แบบจำลองผสม RNN-LSTM มีประสิทธิภาพสูงที่สุด เนื่องจากมีค่า MAE ต่ำที่สุดเท่ากับ 423.89 ค่า RMSE ต่ำที่สุด เท่ากับ 588.92 ค่า R^2 สูงที่สุดเท่ากับ 0.9932 และค่า MAPE ต่ำที่สุด เท่ากับ 2.47% รองลงมา คือ แบบจำลอง RNN มีค่า MAE เท่ากับ 619.44 ค่า RMSE เท่ากับ 816.05 ค่า R^2 เท่ากับ 0.9860 และค่า MAPE เท่ากับ 3.77%


2. การทดสอบประสิทธิภาพของแบบจำลองกับชุดข้อมูลทดสอบ จำนวน 72 รายการ เพื่อดำเนินการวิเคราะห์ความสามารถในการพยากรณ์ข้อมูล ได้ผลลัพธ์ดังตารางที่ 2

ตารางที่ 2

การเปรียบเทียบประสิทธิภาพแบบจำลองกับชุดข้อมูลทดสอบ

Model	MAE	RMSE	R^2	MAPE (%)
RNN	1,842.09	2,418.89	0.3283	5.90
CNN	1,721.07	2,149.79	0.2497	5.73
LSTM	1,600.06	2,241.03	0.1698	5.19
RNN-LSTM	988.47	1,243.24	0.7411	3.29
CNN-LSTM	1,695.88	2,134.26	0.2605	5.60

จากตารางที่ 2 แสดงการเปรียบเทียบประสิทธิภาพแบบจำลองการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนโดยใช้ชุดข้อมูลทดสอบ จำนวน 72 รายการ จากแบบจำลองปัญญาประดิษฐ์ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM เมื่อพิจารณาค่า MAE, RMSE, R^2 และค่า MAPE เป็นดัชนีชี้วัดประสิทธิภาพ พบว่า แบบจำลองผสม RNN-LSTM มีประสิทธิภาพสูงที่สุด เนื่องจากมีค่า MAE ต่ำที่สุดเท่ากับ 988.47 ค่า RMSE ต่ำที่สุดเท่ากับ 1,243.24 ค่า R^2 สูงที่สุดเท่ากับ 0.7411 และค่า MAPE ต่ำที่สุดเท่ากับ 3.29% รองลงมาคือแบบจำลอง LSTM ที่มีค่า MAE เท่ากับ 1,600.06 และค่า MAPE เท่ากับ 5.19% แม้ว่าจะมีค่า RMSE เท่ากับ 2,241.03 และค่า R^2 เท่ากับ 0.1698



ภาพที่ 3 การพยากรณ์ปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนของแบบจำลองผสม RNN-LSTM เทียบกับข้อมูลชุดทดสอบ

3. การประมาณการความแม่นยำในการพยากรณ์ โดยให้แบบจำลองพยากรณ์ข้อมูลปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนในระยะเวลา 3 เดือนข้างหน้า (ม.ค. 2569 - มี.ค. 2569) จากนั้น นำมาเปรียบเทียบกับข้อมูลจริงจากสำนักงานนโยบายและแผนพลังงาน กระทรวงพลังงาน ที่เผยแพร่ในช่วงเวลาที่ดำเนินการวิจัย โดยใช้ค่า MRE และ MMRE ได้ผลลัพธ์ดังตารางที่ 3

ตารางที่ 3

การเปรียบเทียบความแม่นยำในการพยากรณ์ของแบบจำลอง

	RNN			CNN		LSTM		RNN-LSTM		CNN-LSTM	
เดือน	ข้อมูลจริง	พยากรณ์	MRE	พยากรณ์	MRE	พยากรณ์	MRE	พยากรณ์	MRE	พยากรณ์	MRE
ม.ค. 2569	29,198.90	27,701.08	0.0513	32,191.88	0.1025	30,610.03	0.0483	29,672.73	0.0162	31,420.39	0.0761
ก.พ. 2569	31,974.50	27,509.61	0.1396	32,204.55	0.0072	30,566.56	0.0440	30,642.40	0.0417	31,362.68	0.0191
มี.ค. 2569	34,109.20	27,884.26	0.1825	32,200.48	0.0560	30,508.41	0.1056	31,619.59	0.0730	31,325.61	0.0816
MMRE			12.44%		5.52%		6.60%		4.36%		5.89%

จากตารางที่ 3 การเปรียบเทียบความแม่นยำในการพยากรณ์ของแบบจำลอง พบว่า แบบจำลองผสม RNN-LSTM มีประสิทธิภาพโดยรวมสูงสุดพิจารณาจากค่า MMRE เท่ากับ 4.36% รองลงมา คือ แบบจำลอง CNN มีค่า MMRE เท่ากับ 5.52% และเมื่อพิจารณาการพยากรณ์ในแต่ละเดือน พบว่า แบบจำลอง RNN-LSTM มีความแม่นยำในการพยากรณ์สูงสุดในเดือน ม.ค. 2569 มีค่า MRE เท่ากับ 0.0162 แบบจำลอง CNN มีความแม่นยำในการพยากรณ์สูงสุดในเดือน ก.พ. และ มี.ค. 2569 เนื่องจากค่า MRE เท่ากับ 0.0072 และ 0.0560 ตามลำดับ

สรุปและอภิปรายผล

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลอง และเปรียบเทียบประสิทธิภาพแบบจำลองปัญญาประดิษฐ์ที่เหมาะสมในการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยใช้แบบจำลองปัญญาประดิษฐ์ RNN, CNN, LSTM, แบบจำลองผสม RNN-LSTM และ CNN-LSTM โดยข้อมูลที่น่าสนใจใช้ศึกษาเป็นข้อมูลการใช้กระแสไฟฟ้าสูงสุดรายเดือนของประเทศไทย ตั้งแต่วันที่ 1 มกราคม 2529 ถึงวันที่ 31 ธันวาคม 2562 จำนวน 408 รายการเป็นชุดข้อมูลเรียนรู้ และตั้งแต่วันที่ 1 มกราคม 2563 ถึง 31 ธันวาคม 2568 จำนวน 72 รายการเป็นชุดข้อมูลทดสอบ

จากผลการทดลอง พบว่า แบบจำลองผสม RNN-LSTM มีประสิทธิภาพสูงที่สุด เนื่องจากในช่วงการเรียนรู้ของแบบจำลองกับชุดข้อมูลเรียนรู้ มีค่า MAE เท่ากับ 423.89 เมกะวัตต์ ค่า RMSE เท่ากับ 588.92 เมกะวัตต์ ค่า MAPE เท่ากับ 2.47% เป็นค่าต่ำที่สุด และมีค่า R^2 เท่ากับ 0.9932 เป็นค่าสูงที่สุด ในช่วงการทดสอบประสิทธิภาพของแบบจำลองกับชุดข้อมูลทดสอบ มีค่า MAE เท่ากับ 988.47 เมกะวัตต์ ค่า RMSE เท่ากับ 1,243.24 เมกะวัตต์ ค่า MAPE เท่ากับ 3.29% เป็นค่าต่ำที่สุด และมีค่า R^2 เท่ากับ 0.7411 เป็นค่าสูงที่สุด และในช่วงการประมาณการความแม่นยำในการพยากรณ์ มีค่า MMRE เท่ากับ 4.36% เป็นค่าต่ำที่สุดเมื่อเทียบกับแบบจำลอง RNN, CNN, LSTM และ CNN-LSTM

จากผลการวิจัยแสดงให้เห็นประเด็นสำคัญเกี่ยวกับความสามารถของโมเดลในการอธิบายความแปรปรวนของชุดข้อมูลเรียนรู้ และชุดข้อมูลทดสอบ กล่าวคือ แบบจำลองทุกตัวจะสามารถอธิบายความแปรปรวนของข้อมูลชุดเรียนรู้ได้มากกว่า 97% (ค่า R^2 อยู่ในช่วง 0.9793 – 0.9932) มีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ยอยู่ในช่วง 2.47% – 4.00% เมื่อพิจารณาความสามารถของแบบจำลอง RNN, CNN, LSTM และแบบจำลองผสม CNN-LSTM ในการอธิบายความแปรปรวนของชุดข้อมูลทดสอบ พบว่า ได้ค่าไม่เกิน 33% (ค่า R^2 อยู่ในช่วง 0.1698-0.3283) ซึ่งอาจเกิดจากปัญหาการจำข้อมูลเดิมมากเกินไป (Overfitting) ซึ่งอาจไม่เหมาะกับชุดข้อมูลที่มีความสัมพันธ์กันในระยะยาว ยกเว้นแบบจำลองผสม RNN-LSTM ที่ให้ผลดีที่สุด เพราะสามารถอธิบายความแปรปรวนของชุดทดสอบได้ถึง 74.11% และมีความคลาดเคลื่อนเฉลี่ยเพียง 3.29%

ข้อเสนอแนะ

จากการศึกษา การเปรียบเทียบประสิทธิภาพของแบบจำลองการพยากรณ์อนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน โดยใช้แบบจำลองปัญญาประดิษฐ์ สามารถสรุปข้อเสนอแนะได้ดังต่อไปนี้

1. เนื่องจากมีปัจจัยอื่นที่มีผลกระทบต่ออนุกรมเวลาปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือน ดังนั้น ในอนาคตอาจมีการเพิ่มปัจจัยที่เกี่ยวข้องกับปริมาณการใช้กระแสไฟฟ้าสูงสุดรายเดือนเข้ามาใช้ในการพัฒนาแบบจำลอง
2. เนื่องจากแบบจำลองที่ได้จะมีความเหมาะสมกับชุดข้อมูลที่ไม่เหมือนกัน การพยากรณ์ด้วยแบบจำลองที่ได้อาจไม่สอดคล้องกับชุดข้อมูลในอนาคต ดังนั้น จึงควรปรับปรุงแบบจำลองให้เหมาะสมกับชุดข้อมูลที่จะเกิดขึ้น รวมทั้งอาจใช้แบบจำลองปัญญาประดิษฐ์ที่หลากหลายเพื่อความแม่นยำในการพยากรณ์
3. สามารถนำแบบจำลองปัญญาประดิษฐ์มาทำงานร่วมกับโปรแกรมประยุกต์ (Application Software) ในการใช้งานบนอุปกรณ์ต่าง ๆ เพื่อให้ผู้ใช้สามารถเรียกดูผลลัพธ์จากการพยากรณ์ได้ทันที

เอกสารอ้างอิง

- กนกกาญจน์ ศรีสุรินทร์, ศรีนัย ตันวัฒนะพงษ์, ธนาศักดิ์ ช่ายกระโทก และอัจฉรา ชินนิยมพาณิชย์. (2565). ตัวแบบพยากรณ์ปริมาณการใช้ไฟฟ้าของประเทศ. ใน *การประชุมมหาดใหญ่วิชาการระดับชาติและนานาชาติ ครั้งที่ 13* (น. 33-89). มหาวิทยาลัยมหาดใหญ่.
- กระทรวงพลังงาน. (2568). *สถานการณ์พลังงานปี 2568*. <https://www.dede.go.th/articles?id=453&>
- กอบเกียรติ สระอุบล. (2565). *เรียนรู้ AI: Deep Learning ด้วย Python*. อินเทอร์เน็ต.
- Dudek, G., Petka, P., & Smyl, S. (2022). A hybrid residual dilated LSTM and exponential smoothing model for mid-term electric load forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, 33(7), 2879–2891.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Han, J., & Kamber, M. (2001). *Data mining: Concepts and techniques*. Academic Press.
- Lind, D. A., Marchal, W. G., & Wathen, S. A. (2010). *Statistical techniques in business & economics* (15th ed.). McGraw-Hill.
- Mendenhall, W., & Sincich, T. (2003). *A second course in statistics: Regression analysis* (6th ed.). Pearson Education.
- Phyo, P. P., Jeenanunta, C., & Hashimoto, K. (2019). Electricity load forecasting in Thailand using deep learning models. *International Journal of Electrical and Electronic Engineering & Telecommunications*, 8(4), 221–225.
- Shiwakoti, R. K., Charoenlarnopparut, C., & Chapagain, K. (2024). A deep learning approach for short-term electricity demand forecasting: Analysis of Thailand data. *Applied Sciences*, 14(10), Article 3971.