

ประเมินการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนระยะปานกลางของ
การไฟฟ้าฝ่ายผลิตแห่งประเทศไทยด้วยโครงข่ายประสาทและอริมา
Evaluation of Medium-Term Renewable Energy Generation Forecasting of
EGAT Using Artificial Neural Networks and ARIMA

ศุภเสกข์ เกตุรักษา¹ และปฏิภาณ เกิดลาภ^{1*}

Sooppasek Katruksa¹ and Patiphan Kerdlap^{1*}

¹คณะวิศวกรรมศาสตร์ มหาวิทยาลัยอีสเทิร์นเอเซีย

¹School of Engineering, Eastern Asia University

*Corresponding author: patiphan@eau.ac.th

Received: November 29, 2024

Revised: February 26, 2025

Accepted: March 4, 2025

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียม (Neural Network) และแบบจำลอง ARIMA ในการพยากรณ์การผลิตไฟฟ้าจากพลังงานทดแทน โดยใช้ข้อมูลประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) ข้อมูลที่นำมาใช้ประกอบด้วย 2 รูปแบบ ได้แก่ รูปแบบที่ 1 ประกอบด้วยข้อมูลย้อนหลัง 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน และรูปแบบที่ 2 ประกอบด้วยข้อมูลย้อนหลัง 4 เดือน 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน ผลการวิจัยแสดงให้เห็นว่า โครงข่ายประสาทเทียมมีประสิทธิภาพสูงกว่า โดยมี ค่าเปอร์เซ็นต์ความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAPE) เท่ากับ ร้อยละ 3.3151 ขณะที่แบบจำลอง ARIMA มีค่า MAPE เท่ากับร้อยละ 7.4184 จากผลการศึกษาครั้งนี้ โครงข่ายประสาทเทียมได้รับการพิสูจน์ว่าสามารถรองรับความซับซ้อนของข้อมูลด้านการผลิตไฟฟ้าด้วยพลังงานทดแทนได้อย่างมีประสิทธิภาพ และเหมาะสมต่อการนำไปใช้พยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนในเชิงปฏิบัติ ซึ่งจะช่วยให้การไฟฟ้าฝ่ายผลิตแห่งประเทศไทยสามารถวางแผนจัดการพลังงานได้แม่นยำขึ้น ลดความสูญเสีย และเพิ่มประสิทธิภาพในการใช้ทรัพยากรพลังงาน ทั้งนี้สามารถนำไปประยุกต์เพื่อส่งเสริมศักยภาพของการไฟฟ้าฝ่ายผลิตด้านพลังงานทดแทนได้ต่อไปในอนาคต

คำสำคัญ: โครงข่ายประสาทเทียม อริมา การพยากรณ์การผลิตไฟฟ้าจากพลังงานทดแทน การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย

Abstract

This study aims to develop and evaluate Neural Network and ARIMA models' performance in forecasting electricity generation from renewable energy sources. The analysis used historical data on renewable energy generation from the Electricity Generating Authority of Thailand (EGAT). Two data sets were employed: the first data sets from the previous 3 months, 2 months, 1 month, and a month code, while the second data sets from the previous 4 months, 3 months, 2 months, 1 month, and a month code. The findings demonstrate that Neural Networks outperformed ARIMA models, achieving an MAPE of 3.3151%, compared to 7.4184% for ARIMA. This indicates that Neural Networks are better equipped to handle the inherent complexities of renewable energy generation data, making them more suitable for practical applications in electricity forecasting. These results suggest that the adoption of Neural Network models could enable EGAT to enhance the accuracy of its energy planning, minimize resource wastage, and optimize the utilization of renewable energy resources. Furthermore, this study underscores the potential for Neural Networks to advance EGAT's capabilities in renewable energy management, supporting future innovations in this domain.

Keywords: artificial neural networks, ARIMA, renewable energy generation forecasting, Electricity Generating Authority of Thailand (EGAT)



บทนำ

ปัจจุบัน การเปลี่ยนแปลงทางภูมิอากาศและความตระหนักด้านสิ่งแวดล้อมได้กระตุ้นให้เกิดการพัฒนาการใช้พลังงานทดแทนในภาคส่วนต่าง ๆ ทั่วโลก รวมถึงประเทศไทย การผลิตไฟฟ้าจากพลังงานทดแทน เช่น พลังงานแสงอาทิตย์ พลังงานลม และพลังงานชีวมวล ได้รับความสนใจเป็นพิเศษจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) เนื่องจากเป็นแหล่งพลังงานสะอาดที่ช่วยลดการปล่อยก๊าซเรือนกระจกและลดการพึ่งพาแหล่งพลังงานฟอสซิล อย่างไรก็ตาม การจัดการการผลิตไฟฟ้าด้วยพลังงานทดแทนยังคงเผชิญความท้าทายสำคัญ โดยเฉพาะในด้านการคาดการณ์ปริมาณการผลิตไฟฟ้าที่ผันแปรตามธรรมชาติ (Electricity Generating Authority of Thailand, 2024)

การพยากรณ์การผลิตไฟฟ้าจากพลังงานทดแทนจึงเป็นเครื่องมือสำคัญที่ช่วยให้สามารถบริหารจัดการระบบโครงข่ายไฟฟ้าได้อย่างเหมาะสม ลดความเสี่ยงของปัญหาด้านเสถียรภาพของระบบไฟฟ้า และช่วยให้หน่วยงานที่

เกี่ยวข้องสามารถวางแผนการผลิตและจ่ายไฟฟ้าได้อย่างมีประสิทธิภาพมากขึ้น การปรับปรุงความแม่นยำในการพยากรณ์จะช่วยลดต้นทุนในการดำเนินงาน ปรับสมดุลระหว่างอุปสงค์และอุปทาน และสนับสนุนการใช้พลังงานหมุนเวียนในระยะยาวได้ดียิ่งขึ้น

การทบทวนวรรณกรรมเน้นการพยากรณ์ด้านพลังงานไฟฟ้าเพื่อนำมาประยุกต์ใช้ในการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนและงานวิจัยด้านอื่นที่ใช้ตัวแบบในงานวิจัยนี้พยากรณ์ค่าต่าง ๆ ที่คล้ายคลึงกัน สำหรับการพยากรณ์ข้อมูลอนุกรมเวลาการหายใจของดินช่วยพยากรณ์ค่าในอนาคตตามรูปแบบทางประวัติย้อนหลังของข้อมูลงานวิจัยใช้ ARIMA--Autoregressive Integrated Moving Average ผลการทดลองบ่งชี้ว่าตัวแบบ Cluster-Arima ที่เสนอมีความแม่นยำอยู่ที่ร้อยละ 98.30 ซึ่งเป็นค่าความแม่นยำในระดับสูงนี้แสดงให้เห็นถึงประสิทธิภาพของแบบจำลองในการพยากรณ์ข้อมูลอนุกรมเวลาการหายใจของดิน ซึ่งมักได้รับอิทธิพลจากปัจจัยด้านสิ่งแวดล้อมต่าง ๆ (Wang et al., 2024)

งานวิจัยการพยากรณ์แบบผสม (DCEF) โดย การวิจัยใช้วิธีการพยากรณ์รวมกันแบบใหม่ชื่อ DCEF ซึ่ง รวมกับตัวแบบ ARIMA เพื่อพยากรณ์การปล่อยคาร์บอน รายวันการศึกษาระบุพารามิเตอร์หลักสามตัวของตัวแบบ ARIMA และใช้วิธีการค้นหาตารางเพื่อกำหนดชุดค่าผสมที่ เหมาะสมสำหรับพารามิเตอร์เหล่านี้ ผลการพยากรณ์บ่ง ชี้ว่าชุดพารามิเตอร์ที่เหมาะสมที่เลือกคือ (0,1,1) (1,0,1) และ (1,0,1) (Zhong et al., 2024)

สำหรับงานวิจัยศึกษาการพยากรณ์ไหลระยะสั้น ด้วยโครงข่ายประสาทเทียมและอริมาโดยใช้ชุดข้อมูลจาก Irish Social Science Data Archive--ISSDA ซึ่งรวมถึง ข้อมูลจากคณะกรรมการควบคุมพลังงาน (CER) สำหรับ 709 คริวเรือนในไอร์แลนด์ ชุดข้อมูลนี้ครอบคลุมของการ ใช้ไฟฟ้าในช่วงเวลาที่สำคัญ พบว่า โครงข่ายประสาทเทียม มีประสิทธิภาพเหนือกว่าตัวแบบอริมาอย่างมีนัยสำคัญในแง่ ของความแม่นยำค่าความผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของโครงข่ายประสาทเทียม ร้อยละ 1.80 ในขณะที่ตัวแบบ อริมา มีค่า MAPE ที่สูงกว่ามีค่าประมาณร้อยละ 2.61 (Tarmanini et al., 2023)

การศึกษาที่สี่เป็นการสำรวจวรรณกรรม โดยพบ ว่า โครงข่ายประสาทเทียมส่วนใหญ่ใช้ในการพยากรณ์ความ พร้อมใช้งานและกำลังผลิตของแหล่งพลังงานหมุนเวียน เช่นพลังงานแสงอาทิตย์และพลังงานลมช่วยพยากรณ์การ เปลี่ยนแปลงระยะสั้นและรายชั่วโมงในการผลิตพลังงานซึ่ง เป็นสิ่งสำคัญสำหรับการจัดการพลังงานและความเสถียร ของกริดได้ โดยการศึกษาได้กล่าวว่าข้อดีที่สำคัญอย่าง หนึ่งของโครงข่ายประสาทเทียม คือ ความสามารถในการ สร้างแบบจำลองความสัมพันธ์ที่ไม่เชิงเส้นที่ซับซ้อนใน ข้อมูลความสามารถนี้มีประโยชน์อย่างยิ่งในการพยากรณ์ พลังงานหมุนเวียน ซึ่งความสัมพันธ์ระหว่างตัวแปรอินพุต (เช่นสภาพอากาศ) และผลผลิต (การผลิตพลังงาน) มักไม่ เชิงเส้น (Abisoye et al., 2024)

งานวิจัยที่ห้า เป็นการศึกษาการพยากรณ์การผลิต ไฟฟ้าด้วยพลังงานลมโดยใช้รูปแบบผสมประกอบด้วย อัลกอริทึมการเรียนรู้ที่แตกต่างกันสามแบบ ได้แก่ โครงข่าย ประสาทประสาทเทียม (ANN) Support Vector Machine--SVM และ K-Nearest Neighbors--K-NN วิธีการหลายอัล กอริทึมนี้ช่วยให้ตัวแบบสามารถใช้ประโยชน์จากจุดแข็งของ

แต่ละอัลกอริทึมเพื่อความแม่นยำในการพยากรณ์ที่ดีขึ้น และแสดงให้เห็นถึงความแม่นยำในการพยากรณ์ที่เหนือ กว่า โดยมีค่าผิดพลาดสัมบูรณ์เฉลี่ยปกติ (NMAE) ที่ร้อยละ 5.54 ประสิทธิภาพนี้ดีกว่าตัวแบบอื่น ๆ ที่มีการทดสอบ อย่างมีนัยสำคัญ ซึ่งมีช่วง NMAE ตั้งแต่ร้อยละ 5.65 ถึง ร้อยละ 9.22 และต่ำกว่า NMAE เฉลี่ยที่พบในงานวิจัยอื่น อย่างมีนัยสำคัญ ซึ่งมีตั้งแต่ร้อยละ 6.73 ถึงร้อยละ 10.07 (AlShafeey & Csaki, 2024)

นอกจากงานวิจัยดังกล่าวข้างต้นยังมีงานวิจัยอื่น ๆ ที่เกี่ยวกับการพยากรณ์การใช้พลังงานไฟฟ้าที่ให้ผลการ ทดลองที่มีค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ต่ำกว่าร้อยละ 2 (Katruksa & Jiriwibhakorn, 2019, 2020; Banda & Folly, 2007); Dindem et al., 2019; Katruksa, 2013, 2020) ซึ่งได้ทดสอบพยากรณ์กับข้อมูลที่ทราบค่าจริงแล้ว เพื่อเปรียบเทียบค่าผิดพลาด ซึ่งได้ผลเป็นที่น่าพอใจและ เป็นเหตุผลเพียงพอที่ผู้วิจัยได้เลือกตัวแบบดังกล่าวในงาน วิจัยนี้ ซึ่งผู้วิจัยได้เห็นถึงประโยชน์ของการพยากรณ์นี้ เพื่อ วางแผนจัดการพลังงานได้แม่นยำขึ้น ลดความสูญเสีย และ เพิ่มประสิทธิภาพในการใช้ทรัพยากรพลังงาน ทั้งนี้สามารถ นำไปประยุกต์เพื่อส่งเสริมศักยภาพของการไฟฟ้าฝ่ายผลิต ด้านพลังงานทดแทน

งานวิจัยนี้ได้นำหลักที่วิธีการวิจัยจากการทบทวน วรรณกรรม มาประยุกต์ใช้ในการทดสอบพยากรณ์การ ผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิต แห่งประเทศไทย ซึ่งผู้วิจัยได้เห็นประโยชน์ของการศึกษา นี้โดยการพยากรณ์ได้ขึ้นอยู่กับประวัติการผลิตไฟฟ้าด้วย พลังงานทดแทนและรหัสเดือน ซึ่งจะบ่งบอกถึงแนวโน้ม ของการผลิตไฟฟ้าด้วยพลังงานทดแทน

การพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทน จึงเป็นเครื่องมือสำคัญที่ช่วยเพิ่มประสิทธิภาพในการ บริหารจัดการระบบโครงข่ายไฟฟ้าและการวางแผนการ จ่ายพลังงาน การศึกษานี้มุ่งเน้นการประยุกต์ใช้เทคนิคการ พยากรณ์ด้วยโครงข่ายประสาทเทียม (neural networks) และแบบจำลองอริมา (autoregressive integrated moving average) ซึ่งเป็นวิธีที่ได้รับการยอมรับใน ด้าน การวิเคราะห์ข้อมูลเชิงเวลา (time series analysis) เพื่อ นำเสนอแนวทางที่มีประสิทธิภาพและเหมาะสมสำหรับ การพยากรณ์ปริมาณการผลิตไฟฟ้าจากพลังงานทดแทน ในบริบทของประเทศไทย

วัตถุประสงค์การวิจัย

1. ศึกษาตัวแบบที่เหมาะสมสำหรับการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย

2. พยากรณ์ล่วงหน้าการผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยเพื่อประโยชน์ทางด้านการบริหารจัดการด้านพลังงานทดแทนและการสูญเสีย

3. ศึกษาแนวโน้มของการผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย 1 ปีล่วงหน้า

รูปแบบโครงข่ายประสาทเทียมสำหรับการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทน (Katruksa, 2013, 2020; Katruksa & Kullimratchai, 2024)

สำหรับการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ที่ใช้ในงานวิจัยการฝึกสอนและพยากรณ์ด้วยฟังก์ชันไม่เชิงเส้นดังต่อไปนี้

$$PD1(t) = f[G(t-4), G(t-3), G(t-2), G(t-1), M(t)] \quad (1)$$

โดยที่ t คือ ดัชนีเวลา

$PD(t)$ คือ ผลการพยากรณ์

$G(t-4), G(t-3), G(t-2), G(t-1)$ คือ ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 4 เดือน 3 เดือน 2 เดือน และ 1 เดือนตามลำดับ

$M(t)$ คือ รหัสเดือน รูปแบบโครงข่ายประสาทเทียมแบบการแพร่ย้อนกลับ (feedforward backpropagation neural network)

สำหรับงานวิจัยประกอบด้วยชั้นอินพุต ซึ่งประกอบด้วย ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนและรหัสเดือน ชั้นซ่อนมีรูปแบบ 2 ชั้นซ่อน ซึ่งฝึกสอนด้วยฟังก์ชันถ่ายโอนแทนซิกมอยด์ และชั้นเอาต์พุตประมวลผลด้วยฟังก์ชันถ่ายโอนลอจิสติกมอยด์ ภาพ 1 แสดงโครงสร้างของโครงข่ายประสาทแบบ 2 ชั้นซ่อน ซึ่งนิเวศในชั้นอินพุต

จะส่งสัญญาณไปยังนิเวศในชั้นซ่อนแรกและส่งต่อไปยังชั้นซ่อนที่ 2 และสุดท้ายสัญญาณจะถูกส่งต่อไปยังชั้นเอาต์พุต

Levenberg-Marquardt Algorithm เป็นตัวฝึกสอนโครงข่ายประสาท ซึ่งระหว่างฝึกสอนค่า weights และ biases จะถูกปรับโดยสมการ (2) และ (3) ตามลำดับ

$$\Delta W = (J^T(w)J(w) + \mu I)^{-1} J^T(w).e \quad (2)$$

$$\Delta b = (J^T(b)J(w) + \mu I)^{-1} J^T(b).e \quad (3)$$

โดยที่ $J(w)$ คือ Jacobian matrix ของ derivatives ของ error เทียบกับ weight

$J(b)$ คือ Jacobian matrix ของ derivatives ของ error เทียบกับ bias

e คือ matrix ของ errors ระหว่าง target data และ neural network output

μ คือ ค่าคงที่ ซึ่งค่าเริ่มต้นจะถูกเซตค่าต่ำ ๆ

สำหรับการวัดประสิทธิภาพการฝึกสอนและการพยากรณ์โดยค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์น้อยที่สุด (Mean Absolute Percentage Error) หาได้จากสมการที่ (4)

$$MAPE = \frac{1}{n} \sum_{k=1}^n \left| \frac{Real\ result_i - Predicted\ result_i}{Real\ result_i} \right| \times 100\% \quad (4)$$

โดยที่ $Real\ result_i$ คือ ค่าจริงการผลิตไฟฟ้าด้วยพลังงานทดแทนของ กฟผ.

$Predicted\ result_i$ คือ ค่าการผลิตไฟฟ้าด้วยพลังงานทดแทนที่ได้จากการพยากรณ์ด้วยโครงข่ายประสาทเทียม

n คือ จำนวนข้อมูลฝึกสอนหรือทดสอบพยากรณ์

ฟังก์ชันถ่ายโอนหรือฟังก์ชันกระตุ้น (activation function) จะใช้ในการคำนวณเอาต์พุต ซึ่งในนิวรอนที่อยู่ในชั้นเดียวกันจะใช้ฟังก์ชันถ่ายโอนเดียวกัน สำหรับฟังก์ชันถ่ายโอนที่ใช้งานวิจัยนี้ มี 2 ฟังก์ชัน ดังนี้

1) ฟังก์ชันถ่ายโอนแบบล็อกซิกมอยด์ (Log-Sigmoid Transfer Function) ซึ่งเป็นฟังก์ชันที่ใช้สำหรับชั้นเอาต์พุตในกรณีศึกษาสามารถอธิบายได้ด้วยสมการที่ (5)

$$a(n) = \frac{1}{1 + e^{-n}} \quad (5)$$

2) ฟังก์ชันถ่ายโอนแบบแทนซิกมอยด์ (Tan-Sigmoid Transfer Function) ได้ถูกใช้ในชั้นซ่อนของงานนี้ สามารถอธิบายได้ด้วยสมการที่ (6)

$$a(n) = \frac{1 - e^{-n}}{1 + e^{-n}} \quad (6)$$

สามารถอธิบายกระบวนการฝึกสอนและพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนได้ ดังนี้

ขั้นตอนที่ 1 จัดหาและเตรียมข้อมูล

ขั้นตอนที่ 2 แบ่งชุดข้อมูลออกเป็น 2 รูปแบบ รูปแบบที่ 1 ประกอบด้วยประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทน ย้อนหลัง 3 เดือน 2 เดือน 1 เดือน และ

รหัสเดือน และรูปแบบที่ 2 ประกอบด้วยประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทน ย้อนหลัง 4 เดือน 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน

ขั้นตอนที่ 3 รับข้อมูลเพื่อแบ่งเป็นชุดฝึกสอนและชุดทดสอบ


ขั้นตอนที่ 4 ปรับจำนวนชั้นซ่อน จำนวนรอบการทำซ้ำ โครงสร้าง จำนวนรอบต่อโครงสร้าง และฟังก์ชันถ่ายโอน

ขั้นตอนที่ 5 เปรียบเทียบเอาต์พุต และ MAPE ทั้ง 2 รูปแบบ เพื่อเลือกรูปแบบที่ให้ผลการจำลองที่ดีที่สุด

ขั้นตอนที่ 6 เลือกวิธีการพยากรณ์เป็น EXPERT MODELLER เพื่อให้โปรแกรมเลือกอริมาที่มีค่า p,d และ q ที่เหมาะสมกับชุดข้อมูลที่ให้ค่า MAPE น้อยสุด


ขั้นตอนที่ 7 เลือกข้อมูลที่ต้องการให้แสดงผล เช่น ค่าพยากรณ์ MAPE R-SQUARE เป็นต้น แล้วจะได้ โมเดลอริมาที่มีค่าคงที่ ค่าสัมประสิทธิ์ ค่าคลาดเคลื่อนที่เหมาะสมที่สุดเพื่อใช้ในการทดสอบพยากรณ์

ขั้นตอนที่ 8 เปรียบเทียบผลที่ได้จากโครงข่ายประสาทเทียมแบบ 2 ชั้นซ่อน ด้วยข้อมูลรูปแบบที่ 1 และรูปแบบที่ 2 ดังแสดงในภาพ 2



ภาพ 1 รูปแบบโครงข่ายประสาทเทียม 2 ชั้นซ่อน สำหรับพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทน ดัดแปลงโดยได้รับอนุญาต จากผู้แต่ง “MATLAB (MathWorks, 2024)”

Note. From “Matlab R2024a (Computer software)”, by MathWorks, 2024, retrieved from <https://www.mathworks.com/products/matlab.html>



ภาพ 2 Flow Chart ทดสอบการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนด้วยโครงข่ายประสาทเทียม

บอกซ์-เจนกินส์ (Box & Jenkins) (Tripathi et al., 2021; Singh et al., 2024)

แบบจำลอง Box-Jenkins ARIMA–Autoregressive Integrated Moving Average เป็นวิธีที่นิยมใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา โดยเฉพาะเมื่อข้อมูลไม่อยู่ในสถานะคงที่ (non-stationary) แบบจำลองนี้ประกอบด้วย 3 ส่วนหลัก:

1) ส่วน Autoregressive–AR: การถดถอย (regression) ของค่าปัจจุบันในอนุกรมเวลาโดยใช้ค่าก่อนหน้า

2) ส่วน Integrated–I: ระดับของการทำให้ข้อมูลคงที่โดยการคำนวณความแตกต่างระหว่างค่าข้อมูลในอนุกรมเวลา

3) ส่วน Moving Average–MA: การใช้ค่าความคลาดเคลื่อนจากการพยากรณ์ในอดีต

แบบจำลอง ARIMA สามารถแสดงได้ในรูป ARIMA (p, d, q) ซึ่ง:

- p: ลำดับของส่วนถดถอยเชิงเส้น (autoregressive order)
- d: ระดับของการทำให้ข้อมูลคงที่ (degree of differencing)
- q: ลำดับของส่วนค่าเฉลี่ยเคลื่อนที่ (moving average order)

สมการทางคณิตศาสตร์

$$Y_t = \theta_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (7)$$

โดยที่:

Y_t คือ ค่าของอนุกรมเวลา ณ เวลา t

$e_t \sim N(0, \sigma^2)$ คือ ค่าความคลาดเคลื่อนแบบสุ่มที่มีค่าเฉลี่ยเป็นศูนย์และความแปรปรวนคงที่

ϕ_i คือ ค่าสัมประสิทธิ์ของส่วนถดถอยเชิงเส้น (AR Coefficients)

θ_j คือ ค่าสัมประสิทธิ์ของส่วนค่าเฉลี่ยเคลื่อนที่ (MA Coefficients)

จากภาพ 3 สามารถอธิบายกระบวนการฝึกสอนและพยากรณ์การใช้พลังงานไฟฟ้าได้ ดังนี้

ขั้นตอนที่ 1 จัดหาและเตรียมข้อมูล

ขั้นตอนที่ 2 รับข้อมูลรูปแบบที่ 2 ซึ่งเป็นรูปแบบที่ให้ผลการทดสอบดีที่สุดด้วยโครงข่ายประสาทเทียมเพื่อแบ่งเป็นชุดเรียนรู้หรือสังเกตการณ์และชุดทดสอบ

ขั้นตอนที่ 3 นำชุดข้อมูลชุดเข้าโปรแกรม SPSS

ขั้นตอนที่ 4 เลือก tab analyze และ forecasting

ขั้นตอนที่ 5 กำหนดอินพุตเป็นตัวแปรต้นหรือตัวแปรอิสระ เอาต์พุตเป็นตัวแปรตามหรือค่าพยากรณ์


ขั้นตอนที่ 6 เลือกวิธีการพยากรณ์เป็น EXPERT MODELLER เพื่อให้โปรแกรมเลือกวิธีที่มีค่า p d และ q ที่เหมาะสมกับชุดข้อมูลที่ให้ค่า MAPE น้อยสุด

ขั้นตอนที่ 7 เลือกข้อมูลที่ต้องการให้แสดงผล เช่น ค่าพยากรณ์ MAPE R-SQUARE เป็นต้น แล้วจะได้โมเดลวิธีที่มีค่าคงที่ ค่าสัมประสิทธิ์ ค่าคลาดเคลื่อนที่เหมาะสมที่สุดเพื่อใช้ในการทดสอบพยากรณ์

ขั้นตอนที่ 8 เพิ่มข้อมูลชุดอินพุตที่จะทดสอบพยากรณ์ โดยไม่ต้องใส่ค่าในตัวแปรเอาต์พุตแล้วกดรันโปรแกรมเพื่อทดสอบพยากรณ์ นำค่าพยากรณ์เปรียบเทียบกับค่าจริงเพื่อคำนวณค่า MAPE เพื่อเปรียบเทียบกับค่า MAPE ที่ได้จากการพยากรณ์ด้วยตัวแบบโครงข่ายประสาทเทียม

ข้อมูลที่ใช้ฝึกสอนและทดสอบพยากรณ์ด้วยโครงข่ายประสาทเทียมและตัวแบบวิธี

ข้อมูลที่ใช้ในการเรียนรู้โครงข่ายประสาทเทียมและตัวแบบวิธีในงานวิจัยนี้ ได้ใช้ข้อมูลการผลิตไฟฟ้าด้วยพลังงานทดแทนของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) เดือนมกราคม 2553 ถึง เดือนธันวาคม 2566 ซึ่งแบ่งอินพุตเป็น 2 รูปแบบ โดยรูปแบบที่ 1 ประกอบด้วยประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน ส่วนรูปแบบที่ 2 ประกอบด้วย ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 4 เดือน 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน ทั้งนี้ข้อมูลย้อนหลังจำนวน 13 ปี ถูกนำมาใช้ในการฝึกสอนและพัฒนาแบบจำลอง เพื่อเปรียบเทียบประสิทธิภาพระหว่างตัวแบบทางสถิติ (ARIMA) และตัวแบบการเรียนรู้เชิงลึก (ANN) ตัวอย่างข้อมูลฝึกสอนและทดสอบพยากรณ์แสดงในตาราง 1 และตาราง 2 ตามลำดับ



ภาพ 3 Flow Chart ทดสอบการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนด้วยอริมา

ตาราง 1

ตัวอย่างชุดข้อมูลฝึกสอน

ลำดับที่	เดือน/ปี	อินพุต			รหัสเดือน	เอาต์พุต
		ประวัติการผลิตไฟฟ้า ด้วยพลังงานทดแทน ย้อนหลัง 3 เดือน (จิกะวัตต์-ชั่วโมง)	ประวัติการผลิตไฟฟ้า ด้วยพลังงานทดแทน ย้อนหลัง 2 เดือน (จิกะวัตต์-ชั่วโมง)	ประวัติการผลิตไฟฟ้า ด้วยพลังงานทดแทน ย้อนหลัง 1 เดือน (จิกะวัตต์-ชั่วโมง)		
1	01-2553	158.0650	154.7671	192.2169	1	357.7444
2	02-2553	154.7671	192.2169	357.7444	2	322.3372
3	03-2553	192.2169	357.7444	322.3372	3	366.1750
4	04-2553	357.7444	322.3372	366.1750	4	332.7011
5	05-2553	322.3372	366.1750	332.7011	5	302.0655
6	06-2553	366.1750	332.7011	302.0655	6	275.5147
7	07-2553	332.7011	302.0655	275.5147	7	252.8817
8	08-2553	302.0655	275.5147	252.8817	8	233.2814
9	09-2553	275.5147	252.8817	233.2814	9	222.7252
.....						
.....						
.....						
148	04-2565	1997.88	1855.63	1891.89	4	1892.81
149	05-2565	1855.63	1891.89	1892.81	5	1894.91
150	06-2565	1891.89	1892.81	1894.91	6	1803.68
151	07-2565	1892.81	1894.91	1803.68	7	1825.85
152	08-2565	1894.91	1803.68	1825.85	8	1790.18
153	09-2565	1803.68	1825.85	1790.18	9	1595.77
154	10-2565	1825.85	1790.18	1595.77	10	1738.55
155	11-2565	1790.18	1595.77	1738.55	11	1489.68
156	12-2565	1595.77	1738.55	1489.68	12	2099.25

Note. From “Capacity, generation, peak, consumption, import, export and fuel used”, by Energy Policy and Planning Office, 2024, retrieved from <https://www.eppo.go.th/index.php/th/energy-information/static-energy/static-electricity>

ตาราง 2

ตัวอย่างชุดข้อมูลทดสอบพยากรณ์

ลำดับที่	เดือน/ปี	อินพุต			รหัสเดือน	เอาต์พุต
		ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 3 เดือน (จิกะวัตต์-ชั่วโมง)	ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 2 เดือน (จิกะวัตต์-ชั่วโมง)	ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 1 เดือน (จิกะวัตต์-ชั่วโมง)		
1	01-2566	1738.5517	1489.6796	2099.2520	1	2245.7986
2	02-2566	1489.6796	2099.2520	2245.7986	2	1942.5686
3	03-2566	2099.2520	2245.7986	1942.5686	3	2116.0793
4	04-2566	2245.7986	1942.5686	2116.0793	4	1919.6675
5	05-2566	1942.5686	2116.0793	1919.6675	5	1886.6043
6	06-2566	2116.0793	1919.6675	1886.6043	6	1899.3970
7	07-2566	1919.6675	1886.6043	1899.3970	7	1926.8466
8	08-2566	1886.6043	1899.3970	1926.8466	8	2012.7159
9	09-2566	1899.3970	1926.8466	2012.7159	9	1686.9614
10	10-2566	1926.8466	2012.7159	1686.9614	10	1667.3367
11	11-2566	2012.7159	1686.9614	1667.3367	11	1746.6856
12	12-2566	1686.9614	1667.3367	1746.6856	12	2128.0372

Note. From “Capacity, generation, peak, consumption, import, export and fuel used”, by Energy Policy and Planning Office, 2024, retrieved from <https://www.eppo.go.th/index.php/th/energy-information/static-energy/static-electricity>

ผลการจำลอง


ในการทดลองนี้ได้จัดข้อมูลทดลอง โดยข้อมูลสำหรับฝึกสอน 156 ชุด และข้อมูลทดสอบพยากรณ์ 12 ชุด และมีการฝึกสอนและทดสอบพยากรณ์เพื่อให้ผลการทดลองดีที่สุด โดยการปรับจำนวนชั้นซ่อน จำนวนรอบการทำซ้ำ โครงสร้าง จำนวนรอบต่อโครงสร้าง และฟังก์ชันถ่ายโอนสำหรับโครงข่ายประสาทเทียม 2 ชั้นซ่อน ส่วนตัวแบบอริมาได้ใช้ EXPERT MODELER เพื่อค้นหาตัวแบบอริมาที่ให้ผลการทดลองดีที่สุด โดยการทดลองนี้ได้แบ่งข้อมูลเป็น 2 รูปแบบ รูปแบบที่ 1 ประกอบด้วยอินพุต ประวัติการผลิต

ไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน ส่วนรูปแบบที่ 2 ประกอบด้วยอินพุต ประวัติการผลิตไฟฟ้าด้วยพลังงานทดแทนย้อนหลัง 4 เดือน 3 เดือน 2 เดือน 1 เดือน และรหัสเดือน โดยเริ่มทดสอบพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนด้วยโครงข่ายประสาทเทียม และเปรียบเทียบผลการพยากรณ์ด้วยข้อมูลรูปแบบที่ 1 และรูปแบบที่ 2 เมื่อได้รูปแบบที่ดีที่สุดได้นำไปทดสอบพยากรณ์ด้วยตัวแบบอริมา แล้วดำเนินการเปรียบเทียบเพื่อหาตัวแบบที่ดีที่สุด

1. ผลการทดลองรูปแบบที่ 1 และรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ้อน


จากภาพ 4-5 และสรุปลงในตาราง 3 พบว่า ค่า R รวมของข้อมูลรูปแบบที่ 2 (0.90063) สูงกว่าเมื่อเทียบกับข้อมูลรูปแบบที่ 1 (0.8857) ค่า R สำหรับ Training และ Validation สำหรับข้อมูลรูปแบบที่ 2 คือ 0.88515 และ 0.88867 ตามลำดับ ซึ่งสูงกว่าข้อมูลรูปแบบที่ 1 ซึ่งมีค่า 0.87061 และ 0.78905 ตามลำดับซึ่งบ่งชี้ว่าข้อมูลรูปแบบที่ 2 สามารถเรียนรู้และพยากรณ์ได้ดีกว่า

จากภาพ 6-7 และตาราง 4 พบว่า ข้อมูลรูปแบบที่ 2 มีค่า Best Validation Performance ดีกว่าข้อมูลรูปแบบที่ 1 ($0.0072649 < 0.01621$) ซึ่งข้อมูลรูปแบบที่ 2 มีค่า MSE น้อยกว่าและนิ่งหลังจาก epoch 10 ซึ่งสะท้อนว่ามีการฝึกสอนจนถึงจุดที่เหมาะสมที่สุด ดังนั้นเพื่อลดความผิดพลาด Validation Error ให้น้อยที่สุดในการพยากรณ์ ควรเลือกข้อมูลรูปแบบที่ 2 ในการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทน



ภาพ 4 แสดงการวิเคราะห์การถดถอยของการฝึกสอนชุดข้อมูลรูปแบบที่ 1 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ้อน ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Note. From “Matlab R2024a (Computer software)”, by MathWorks, 2024, retrieved from <https://www.mathworks.com/products/matlab.html>




ภาพ 5 แสดงการวิเคราะห์การถดถอยของการฝึกสอนชุดข้อมูลรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ่อน ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Note. From “Matlab R2024a (Computer software)”, by MathWorks, 2024, retrieved from <https://www.mathworks.com/products/matlab.html>

ตาราง 3


การเปรียบเทียบการวิเคราะห์การถดถอยของการฝึกสอนชุดข้อมูลรูปแบบที่ 1 และข้อมูลรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ่อน

กรณี	ข้อมูลรูปแบบที่ 1	ข้อมูลรูปแบบที่ 2	รูปแบบที่ดีกว่า
Training (R)	0.87061	0.88515	ข้อมูลรูปแบบที่ 2
Validation (R)	0.78905	0.88867	ข้อมูลรูปแบบที่ 2
All (R)	0.8857	0.90063	ข้อมูลรูปแบบที่ 2



ภาพ 6 ค่าผิดพลาดกำลังสองเฉลี่ย และจำนวนรอบการฝึกสอนของรูปแบบที่ 1 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้น
ซ่อน ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Note. From “Matlab R2024a (Computer software)”, by MathWorks, 2024, retrieved from <https://www.mathworks.com/products/matlab.html>




ภาพ 7 ค่าผิดพลาดกำลังสองเฉลี่ย และจำนวนรอบการฝึกสอนของรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้น
ซ่อน ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Note. From “Matlab R2024a (Computer software)”, by MathWorks, 2024, retrieved from <https://www.mathworks.com/products/matlab.html>

ตาราง 4

การเปรียบเทียบค่าผิดพลาดกำลังสองเฉลี่ย และจำนวนรอบการฝึกสอนของข้อมูลรูปแบบที่ 1 และข้อมูลรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ้อน

คุณสมบัติ	ข้อมูลรูปแบบที่ 1	ข้อมูลรูปแบบที่ 2
Best Validation Performance	0.01621 (Epoch 7)	0.0072649 (Epoch 10)
จุดเริ่ม Overfitting	เร็วกว่ารูปแบบที่ 2	ช้ากว่า (Epoch 10)
ค่า MSE โดยรวม	สูงกว่า	ต่ำกว่า



ภาพ 8 ผลการทดสอบพยากรณ์ของชุดข้อมูลรูปแบบที่ 1 และ รูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ้อน

ตาราง 5

การเปรียบเทียบผลการทดสอบพยากรณ์ของชุดข้อมูลรูปแบบที่ 1 และรูปแบบที่ 2 ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ่อน

เดือน-ปี	ค่าจริง (Actual)	ค่าพยากรณ์ รูปแบบที่ 1	ค่าพยากรณ์ รูปแบบที่ 2	PE (รูปแบบที่ 1)	PE (รูปแบบที่ 2)	MAPE (รูปแบบที่ 1)	MAPE (รูปแบบที่ 2)	ใกล้เคียง
01-2566	2245.7986	2070.8173	2116.0145	7.7915	5.7790			รูปแบบที่ 2
02-2566	1942.5686	1967.2415	1961.3354	1.2701	0.9661			รูปแบบที่ 2
03-2566	2116.0793	1971.2731	2128.9485	6.8431	0.6082			รูปแบบที่ 2
04-2566	1919.6675	1885.7977	1905.8558	1.7644	0.7195			รูปแบบที่ 2
05-2566	1886.6043	1908.0913	1928.7495	1.1389	2.2339			รูปแบบที่ 1
06-2566	1899.397	1875.3856	1855.3164	1.2642	2.3208			รูปแบบที่ 1
07-2566	1926.8466	1896.5518	1925.7624	1.5722	0.0563			รูปแบบที่ 2
08-2566	2012.7159	1857.8765	1875.9164	7.6931	6.7968			รูปแบบที่ 2
09-2566	1686.9614	1769.4775	1838.756	4.8914	8.9981			รูปแบบที่ 1
10-2566	1667.3367	1667.5755	1726.4053	0.0143	3.5427			รูปแบบที่ 1
11-2566	1746.6856	1699.6991	1638.2289	2.6900	6.2093			รูปแบบที่ 1
12-2566	2128.0372	2060.5023	2095.0441	3.1736	1.5504			รูปแบบที่ 2
สรุป						3.3422	3.3151	

จากภาพ 8 เป็นกราฟแสดงการเปรียบเทียบผลการทดสอบพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้น ซ่อนพบว่า ค่าพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนของข้อมูลรูปแบบที่ 1 และรูปแบบที่ 2 โดยรวมกราฟใกล้เคียงค่าจริงทั้งสองรูปแบบ โดยสามารถสรุปให้ชัดเจนมากขึ้นด้วยตาราง 5 โดยเปรียบเทียบค่าความคลาดเคลื่อนแต่ละเดือนพบว่า ผลการพยากรณ์ด้วยข้อมูลรูปแบบที่ 2 ใกล้เคียงกับค่าจริงทั้งหมด 8 เดือน ซึ่งมากกว่าผลพยากรณ์ด้วยข้อมูลรูปแบบที่ 1 ซึ่งใกล้เคียง 7 เดือนซึ่งใกล้เคียงกัน ในทำนองเดียวกันค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAPE) ของข้อมูลรูปแบบที่ 2 คือร้อยละ 3.3151 ซึ่งมีค่ามากกว่า ชุดข้อมูลรูปแบบที่ 1 ที่มีค่าเท่ากับร้อยละ 3.3422

เพราะฉะนั้นจากการวิเคราะห์ภาพ 4 ถึง 8 และตาราง 3 ถึง 5 ค่าการวิเคราะห์การถดถอย ค่าผิดพลาดกำลังสองเฉลี่ย กราฟแนวโน้ม ค่าความคลาดเคลื่อนรวมถึงค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ของข้อมูลทั้งสองรูปแบบจะไม่แตกต่างกันอย่างชัดเจน แต่ก็แสดงให้เห็นว่าข้อมูลรูปแบบที่ 2 มีค่าดังกล่าวที่ดีกว่าข้อมูลรูปแบบที่ 1 เล็กน้อย สรุปได้ว่า การเพิ่มจำนวนตัวแปรอินพุต (ข้อมูลย้อนหลัง) ในรูปแบบที่ 2 ช่วยให้ตัวแบบเรียนรู้แนวโน้มของข้อมูลได้ดีขึ้น ส่งผลให้ค่าความผิดพลาดลดลง และทำให้การพยากรณ์แม่นยำขึ้น ซึ่งเป็นเหตุผลเพียงพอที่จะเลือกข้อมูลรูปแบบที่ 2 ในการพยากรณ์ด้วยตัวแบบอริมาเพื่อหาตัวแบบการพยากรณ์ที่ดีที่สุดต่อไป

2. ผลการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนด้วยตัวแบบอริมาและเปรียบเทียบกับการพยากรณ์ด้วยโครงข่ายประสาทเทียม 2 ชั้นซ่อน

ในขั้นตอนนี้ได้นำชุดข้อมูลรูปแบบที่ 2 ซึ่งเป็นชุดข้อมูลที่ให้ผลดีที่สุดของการพยากรณ์ด้วยโครงข่ายประสาทเทียมแบบ 2 ชั้นซ่อน เพื่อนำมาเรียนรู้และพยากรณ์ด้วยตัวแบบอริมาได้ผลการวิเคราะห์ดังตาราง 8-9 และภาพ 13

จากตาราง 6 EXPERT MODELER ได้เลือกตัวแบบที่เหมาะสมกับข้อมูลที่ใช้ในการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนคือ ARIMA (0,1,1) ค่า $p = 0$ ซึ่งเป็นส่วน AR หรือ AutoRegressive แสดงว่า ไม่มีการแสดงผลกระทบจากค่าที่ผ่านมา ส่วนค่า $d = 1$ เป็น Integrated หมายความว่า ข้อมูลต้องถูกทำให้เป็น stationarity โดยการทำการ Differencing 1 ครั้ง และค่า $q = 1$ แสดงให้เห็นว่า MA หรือ Moving Average ใช้ค่าความคลาดเคลื่อน errors 1 ค่าที่ผ่านมา ส่วน VAR00006 คือค่าเป้าหมายที่ต้องการพยากรณ์

จากตาราง 7 พบว่า ตัวแปรที่ใช้ในการพยากรณ์มี 1 ตัวแปร ค่าต่อมา คือ Stationary R-squared มีค่าเท่ากับ 0.587 แสดงให้เห็นว่าตัวแบบสามารถอธิบายความแปรปรวนของข้อมูลหลังการทำให้เป็น stationarity หลังจาก differencing ได้ระดับปานกลาง ซึ่งค่านี้ถ้าเข้าใกล้ 1 แสดงว่าอธิบายได้ดี ส่วนค่า R-squared มีค่าเป็น 0.977 แสดงว่า ความสามารถในการอธิบายความแปรปรวนของข้อมูลที่ใช้การพยากรณ์ได้ดีมาก คือ ร้อยละ 97.70 ค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ร้อยละ 5.460 ซึ่งต่ำกว่าร้อยละ 10 แสดงว่ามีการเรียนรู้รูปแบบของข้อมูลได้ดีก่อนทดสอบพยากรณ์ ต่อมาเป็นค่าสถิติ Ljung-Box Q (18) ซึ่งเป็นการทดสอบที่ใช้ตรวจสอบว่าค่าคลาดเคลื่อนของตัวแบบมีความสัมพันธ์เชิงเวลาหรือไม่ ซึ่งมีความสำคัญในการพิจารณาคุณภาพของตัวแบบอริมา มีค่า Statistics=21.161, DF=18-1=17 ซึ่งเป็นจำนวนองศาอิสระที่ใช้ในการทดสอบ โดยคำนวณจากจำนวนของค่า Lag ที่ใช้ในการทดสอบ ลบด้วยจำนวนพารามิเตอร์ที่ประมาณค่าไว้ในตัวแบบ ARIMA (0,1,1) ซึ่งมี 1 พารามิเตอร์ (คือ MA(1)) มีผลต่อค่าความน่าจะเป็น (p-value) ของสถิติ Ljung-Box (18) และ Sig.=0.219 (ค่าความมีนัยสำคัญทางสถิติ p-value) ซึ่งมี

ค่าน้อยกว่า 0.05 แสดงว่าค่าคงเหลือไม่มีความสัมพันธ์กัน อย่างมีนัยสำคัญ ซึ่งเหมาะสมกับตัวแบบอริมา และสุดท้ายเป็นค่า Number of Outliers เป็น 0 แสดงว่าไม่มีชุดข้อมูลที่แตกต่างจากแนวโน้มของข้อมูลส่วนใหญ่ หรือไม่มีค่าผิดปกติอย่างมากเมื่อเปรียบเทียบกับพยากรณ์ของตัวแบบ

จากภาพ 9 แสดงข้อมูลของ Model VAR00006-Model_1 จากการวิเคราะห์ ARIMA (0,1,1) Observed (เส้นสีแดง) แสดงข้อมูลจริง (historical data) ที่ใช้ในการสร้างตัวแบบ ARIMA เป็นการฝึกสอนเพื่อให้มีแนวโน้มในการพยากรณ์ดังแสดงเส้น Forecast (เส้นสีน้ำเงิน) ซึ่งเป็นการทดสอบพยากรณ์ช่วงเดือน มกราคม 2566 ถึงเดือน ธันวาคม 2566 ส่วนเส้นแนวตั้งสีดำเป็นเส้นแบ่งระหว่างข้อมูลจริง (observed) หรือช่วงการฝึกสอน และข้อมูลพยากรณ์ (forecast) เพื่อเปรียบเทียบค่าเป้าหมายจะพบว่าแนวโน้มข้อมูลจริง (สีแดง) มีลักษณะเป็นขาขึ้น (uptrend) และมีการพยากรณ์ (สีฟ้า) ต่อเนื่องจากแนวโน้มของข้อมูลสังเกตหรือฝึกสอน เป็นแนวโน้มต่อเนื่องกัน จากกราฟ ไม่มีสัญญาณของการ overfitting (ซับซ้อนเกิน) หรือ underfitting (เรียบเกินไป) การแบ่งข้อมูลสังเกตหรือการฝึกสอนและข้อมูลพยากรณ์อย่างชัดเจน ช่วยให้สามารถประเมินประสิทธิภาพของการพยากรณ์โดยเปรียบเทียบกับค่าเป้าหมาย ดังนั้นแสดงว่า ARIMA (0,1,1) สามารถเรียนรู้แนวโน้มของข้อมูลได้ดี และการพยากรณ์ในช่วงเวลาถัดไป (สีฟ้า) ซึ่งสอดคล้องกับข้อมูลที่ใช้เรียนรู้ในอดีต

ตาราง 6

ผลการเลือก ARIMA (0,1,1) ด้วย EXPERT MODELER ของโปรแกรม SPSS ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง


Model Description		
Model Type		
Model ID	VAR00006	Model_1
		ARIMA (0,1,1)

Note. From “IBM SPSS statistics (Computer software)”, by IBM Corp., 2024, retrieved from <https://www.ibm.com/products/spss-statistics>

ตาราง 7


ค่าสถิติผลการวิเคราะห์ด้วย ARIMA (0,1,1) ของโปรแกรม SPSS ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Model Statistics								
	Model Fit Statistics				Ljung Box Q (18)			
	Number of Predictors	Stationary R. squared	R. squared	MAPE	Statistics	DF	Sig.	Number of Outliers
VAR00006-Model_1	1	.587	.977	5.460	21.161	17	.219	0



ภาพ 9 ข้อมูลอนุกรมเวลา เปรียบเทียบระหว่าง Observed (ค่าจริงที่สังเกตได้) กับ Forecast (ค่าพยากรณ์) ดัดแปลงโดยได้รับอนุญาตจากผู้แต่ง

Note. From “IBM SPSS statistics (Computer software)”, by IBM Corp., 2024, retrieved from <https://www.ibm.com/products/spss-statistics>



ภาพ 10 การเปรียบเทียบผลการพยากรณ์ด้วยโครงข่ายประสาทเทียม 2 ชั้นซ่อน และตัวแบบอริมา

ตาราง 8

แสดงการเปรียบเทียบผลการพยากรณ์ด้วยโครงข่ายประสาทเทียม 2 ชั้นซ่อน และตัวแบบอริมา

เดือน-ปี	ค่าจริง (Actual)	ค่าพยากรณ์ ด้วย ARIMA	ค่าพยากรณ์ ด้วย ANN	APE (ARIMA) %	APE (ANN) %	MAPE (ARIMA) %	MAPE (ANN) %	ใกล้เคียง ค่าจริงที่สุด
01-2566	2245.7986	1895.5400	2116.0145	15.5962	5.7790			ANN
02-2566	1942.5686	1812.4000	1961.3354	6.7008	0.9661			ANN
03-2566	2116.0793	1836.1100	2128.9485	13.2306	0.6082			ANN
04-2566	1919.6675	1837.7100	1905.8558	4.2694	0.7195			ANN
05-2566	1886.6043	1828.1400	1928.7495	3.0989	2.2339			ANN
06-2566	1899.397	1774.2600	1855.3164	6.5882	2.3208			ANN
07-2566	1926.8466	1784.5400	1925.7624	7.3855	0.0563			ANN
08-2566	2012.7159	1736.7300	1875.9164	13.7121	6.7968			ANN
09-2566	1686.9614	1630.8900	1838.756	3.3238	8.9981			ARIMA
10-2566	1667.3367	1690.5500	1726.4053	1.3922	3.5427			ARIMA
11-2566	1746.6856	1599.6300	1638.2289	8.4191	6.2093			ANN
12-2566	2128.0372	2015.1800	2095.0441	5.3033	1.5504			ANN
				สรุป		3.3422	3.3151	

วิเคราะห์ประกอบกันระหว่างภาพ 10 และตาราง 8 จะพบว่า แนวโน้มผลการพยากรณ์ด้วยโครงข่ายประสาทเทียมจะใกล้เคียงค่าจริงมากกว่าจำนวน 10 เดือน ส่วนตัวแบบอริมาจะใกล้เคียงค่าจริงมากกว่าเพียง 2 เดือน คือ เดือน 10 และ เดือน 11 นอกจากนี้เมื่อเปรียบเทียบกับ ค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAPE) ของโครงข่ายประสาทเทียม 2 ชั้นซ่อนมีค่าร้อยละ 3.3151 ซึ่งมีค่าน้อยกว่าค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ (MAPE) ของตัวแบบอริมาซึ่งมีค่าร้อยละ 7.4181 ซึ่งข้อมูลดังกล่าวข้างต้น บ่งชี้ได้ว่าโครงข่ายประสาทเทียม 2 ชั้นซ่อนมีประสิทธิภาพดีกว่าตัวแบบอริมาอย่างชัดเจน

บทสรุปและข้อเสนอแนะ

งานวิจัยนี้เปรียบเทียบประสิทธิภาพของการพยากรณ์การผลิตไฟฟ้าด้วยพลังงานทดแทนระหว่างโครงข่ายประสาทเทียม 2 ชั้นซ่อน และตัวแบบอริมา โดยใช้ข้อมูลการผลิตไฟฟ้าด้วยพลังงานทดแทนจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) ผลการวิจัยชี้ให้เห็นว่าโครงข่ายประสาทเทียม 2 ชั้นซ่อน ให้ผลการพยากรณ์ที่แม่นยำกว่าด้วยค่า MAPE เพียงร้อยละ 3.3151 เมื่อเทียบกับอริมาที่มีค่า MAPE ร้อยละ 7.4184 ซึ่งแสดงถึงความสามารถของโครงข่ายประสาทเทียม 2 ชั้นซ่อนในการจัดการข้อมูลที่มีความซับซ้อนและแนวโน้มที่เปลี่ยนแปลงสูงในด้านพลังงานทดแทน โดยเฉพาะในบริบทของประเทศไทย งานวิจัยนี้สรุปว่าโครงข่ายประสาทเทียม 2 ชั้นซ่อน เป็นทางเลือกที่เหมาะสมสำหรับการนำไปใช้จริงเพื่อเพิ่มประสิทธิภาพการจัดการพลังงานและสนับสนุนการวางแผนพลังงานที่ยั่งยืนของ กฟผ.

ข้อเสนอแนะการปรับปรุงข้อมูลเพื่อเพิ่มประสิทธิภาพการพยากรณ์

1. พิจารณาเพิ่มตัวแปรที่เกี่ยวข้อง เช่น ข้อมูลสภาพอากาศ หรือปัจจัยเศรษฐกิจที่อาจมีผลต่อการผลิต

ไฟฟ้าจากพลังงานทดแทน เพื่อเพิ่มความแม่นยำและความครอบคลุมของโมเดล

2. การใช้งานร่วมกับอริมา แทนที่จะเปรียบเทียบแยกกัน การพิจารณาการใช้งานโครงข่ายประสาทเทียม และอริมาร่วมกัน เช่น การใช้อริมาสำหรับการตรวจจับแนวโน้ม (trend) และโครงข่ายประสาทเทียมสำหรับการจับความสัมพันธ์ที่ซับซ้อน อาจเพิ่มประสิทธิภาพการพยากรณ์

3. การทดสอบในสถานการณ์จริงควรนำรูปแบบโครงข่ายประสาทเทียมที่พัฒนาไปทดลองใช้งานในสถานการณ์จริง พร้อมกับการเก็บข้อมูลเพื่อประเมินความแม่นยำและประสิทธิภาพในระยะยาว

การศึกษาเพิ่มเติมในอนาคต

1. การประยุกต์ใช้เทคโนโลยี AI อื่น ๆ ควรทดลองใช้เทคโนโลยี Machine Learning ขั้นสูง เช่น XGBoost Random Forest หรือแม้กระทั่ง Deep Learning แบบ Generative Adversarial Networks--GANs เพื่อสำรวจประสิทธิภาพและความสามารถของเทคนิคอื่น ๆ ในการพยากรณ์ข้อมูลที่ซับซ้อน

2. การผสมผสานเทคนิคหลายรูปแบบการผสมผสานโครงข่ายประสาทเทียมและอริมา รวมถึงโมเดลพยากรณ์อื่น ๆ ในลักษณะผสม (hybrid models) เพื่อดึงจุดเด่นของแต่ละวิธีมาใช้ร่วมกัน อาจช่วยเพิ่มความแม่นยำและความน่าเชื่อถือในการพยากรณ์

3. การปรับตัวกับข้อมูลแบบเรียลไทม์ (real-time data) การศึกษาเพิ่มเติมควรเน้นการพัฒนาแบบที่สามารถรับมือกับข้อมูลแบบเรียลไทม์ เช่น การผลิตไฟฟ้ารายชั่วโมงหรือรายวัน ซึ่งต้องใช้โมเดลที่สามารถปรับตัวได้เร็วและมีประสิทธิภาพสูง



References

- Abisoye, B. O., Sun, Y., & Zenghui, W. (2024). A survey of artificial intelligence methods for renewable energy forecasting: Methodologies and insights. *Renewable Energy Focus*, 48, 100529. <https://doi.org/10.1016/j.ref.2023.100529>
- AlShafeey, M., & Csaki, C. (2024). Adaptive machine learning for forecasting in wind energy: A dynamic, multi-algorithmic approach for short and long-term predictions. *Heliyon*, 10, e34807. <https://doi.org/10.1016/j.heliyon.2024.e34807>
- Banda, E., & Folly, K. A. (2007). Short Term Load Forecasting Using Artificial Neural Network. *2007 IEEE Lausanne Power Tech* (pp. 108-112). Lausanne: IEEE
- Dindem, P., Jirivibhakorn, S., & Keturksa, S. (2019). Long-term electricity demand forecasting for the EGAT system using neural networks. In *Proceedings of the 42nd Electrical Engineering Conference* (pp. 41-44). Bangkok: Mahidol University. (in Thai)
- Energy Policy and Planning Office. (2024). *Capacity, generation, peak, consumption, import, export and fuel used*. Retrieved from <https://www.eppo.go.th/index.php/th/energy-information/static-energy/static-electricity> (in Thai)
- Electricity Generating Authority of Thailand. (2024). *Renewable energy: Background and development*. Retrieved from <https://www.egat.co.th/home/renewables> (in Thai)
- IBM Corp. (2024). *IBM SPSS statistics (computer software)*. Retrieved from <https://www.ibm.com/products/spss-statistics>. (in Thai)
- Jiriwibhakorn, S. (2011). *Applications of neural networks in power system*. Bangkok: Faculty of Engineering King Mongkut's Institute of Technology Ladkrabang. (in Thai)
- Jiriwibhakorn, S. (2022). *Forecasting machines in power systems*. Bangkok: Faculty of Engineering King Mongkut's Institute of Technology Ladkrabang. (in Thai)
- Katruksa, S. (2013). *Facility energy sage modeling and medium term load forecasting with artificial Neural Networks And Adaptive Neuro-Fuzzy Inference Systems: An exploratory Study* (Master's thesis). King Mongkut's Institute of Technology Ladkrabang. (in Thai)
- Katruksa, S. (2020). *Mid-term load forecasting based on artificial neural networks and adaptive Neuro-Fuzzy Inference Systems: An exploratory study* (Doctoral dissertation). KingMongkut's Institute of Technology Ladkrabang. (in Thai)
- Katruksa, S., & Jiriwibhakorn, S. (2015). Facility energy usage modeling and medium term load forecasting with Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems. *Kasetsart Engineering Journal*, 28(91), 61-69. <https://ph01.tci-thaijo.org/index.php/kuengj/article/view/79349/63422> (in Thai)
- Katruksa, S., & Jiriwibhakorn, S. (2019). Application data for electricity load forecasting models. *The 5th International Conference on Engineering, Applied Sciences and Technology* (pp. 450-453). Luang Prabang: PDR.

- Katruksa, S., & Jiriwibhakorn, S. (2020). Evaluation of mid-term load forecasting case study based on Adaptive Neuro-Fuzzy Inference System (ANFIS) and Artificial Neural Networks (ANNs). *International Review of Electrical Engineering (I.R.E.E.)*, 15(4), 283-293. <https://doi.org/10.15866/iree.v15i4.17766>
- Katruksa, S., & Kullimratchai, P. (2024). Application of Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems in The Electrical Power System. *EAU Heritage Journal Science and Technology*, 18(1), 1–19. <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/266469> (in Thai)
- MathWorks. (2024). *Matlab R2024a (Computer software)*. Retrieved from <https://www.mathworks.com/products/matlab.html> (in Thai)
- Meesut, P. (2009). *Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference Systems. Management Information Systems*. Bangkok: King Mongkut's University of Technology North Bangkok. (in Thai)
- Singh, S., Parmar, K. S., & Kumar, J. (2024). Development of multi-forecasting model using Monte Carlo simulation coupled with wavelet denoising-ARIMA model. *Mathematics and Computers in Simulation*, 2024, Related articles. <https://doi.org/10.1016/j.matcom.2024.10.040>.
- Tarmanini, C., Sarma, N., Gezegin, C., & Ozgonenel, O. (2023). Short term load forecasting based on ARIMA and ANN approaches. *Energy Reports*, 9, 550–557. <https://doi.org/10.1016/j.egyr.2023.01.060>
- Tripathi, P. K., Sen, R., & Upadhyay, S. K. (2021). A Bayes algorithm for model compatibility and comparison of ARMA (p, q) models. *Statistics in Transition New Series*, 22(2), 95–123. https://www.econstor.eu/bitstream/10419/236830/1/10.21307_stattrans-2021-018.pdf
- Wang, G., Su, H., Mo, L., Yi, X., & Wu, P. (2024). Forecasting of soil respiration time series via clustered ARIMA. *Computers and Electronics in Agriculture*, 225, 109315. <https://doi.org/10.1016/j.compag.2024.109315>
- Zhong, W., Zhai, D., Xu, W., Gong, W., Yan, C., Zhang, Y., & Qi, L. (2024). Accurate and efficient daily carbon emission forecasting based on improved ARIMA. *Applied Energy*, 376, 124232. <https://doi.org/10.1016/j.apenergy.2024.124232>

