



การพยากรณ์การส่งออกกล้วยไม้ไทยด้วยโครงข่ายประสาทเทียมและการค้นหาแบบกริดผสม การแยกโหนดเชิงประจักษ์

ณัฐกร โต๊ะสิงห์*

สาขาวิศวกรรมโลจิสติกส์ คณะศิลปศาสตร์และวิทยาศาสตร์ มหาวิทยาลัยราชภัฏศรีสะเกษ

ชรณินทร์ สัจจวิริยทรัพย์

สาขาวิศวกรรมโลจิสติกส์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

* ผู้นิพนธ์ประสานงาน โทรศัพท์ 09 5621 2045 อีเมล: Nathagorn.t@sskru.ac.th DOI: 10.14416/j.kmutnb.2026.06.008

รับเมื่อ 15 กรกฎาคม 2568 แก้ไขเมื่อ 2 กุมภาพันธ์ 2569 ตอรับเมื่อ 10 มีนาคม 2569 เผยแพร่ออนไลน์ 19 มิถุนายน 2569

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

บทคัดย่อ

งานวิจัยนี้พัฒนากรอบการพยากรณ์แบบผสมโดยบูรณาการการแยกโหนดเชิงประจักษ์ร่วมกับโครงข่ายประสาทเทียม และปรับค่าพารามิเตอร์ด้วยการค้นหาแบบกริด ระเบียบวิธีที่นำเสนอแยกสัญญาณการส่งออกรายเดือนออกเป็นฟังก์ชันโหนด แฝงและองค์ประกอบส่วนที่เหลือซึ่งเปลี่ยนข้อมูลเดิมเป็นปริภูมิใหม่ผ่านการแยกโหนดเชิงประจักษ์ จากนั้นออกแบบโครงข่ายประสาทเทียมเฉพาะสำหรับแต่ละองค์ประกอบเพื่อเรียนรู้ลักษณะข้อมูลที่แตกต่างกัน ใช้ข้อมูล 72 เดือน (พ.ศ. 2562–2567) จากสำนักงานเศรษฐกิจการเกษตร และประเมินด้วยวิธีการตรึงจุดกำเนิดการพยากรณ์แบบหน้าต่างขยาย ผลการศึกษาพบว่า ตัวแบบที่นำเสนอมีประสิทธิภาพเหนือกว่าตัวแบบทั่วไป ได้แก่ แบบอาร์มาและโหนดวินเทอร์ โดยชุดข้อมูลที่ 1 (18 ค่าสังเกต) ตัวแบบที่นำเสนอสามารถให้ค่าความแม่นยำร้อยละ 88.36 ซึ่งดีกว่าตัวแบบอื่น ๆ นอกจากนี้การใช้ข้อมูลเพิ่มเติมอีก 12 ค่า รวมกับข้อมูลชุดที่ 1 (30 ค่าสังเกต) ตัวแบบที่นำเสนอยังคงให้ความแม่นยำร้อยละ 88.19 ซึ่งยังคงประสิทธิภาพใกล้เคียงกับชุดทดสอบของข้อมูลที่ 1 ดังนั้นตัวแบบที่นำเสนอมีความแม่นยำสูงกว่าตัวแบบทั่วไป และยังคงให้ผลการพยากรณ์ที่มีความคงเส้นคงวาแม้เพิ่มจำนวนข้อมูลทดสอบ จึงสามารถนำไปประยุกต์ใช้เป็นเครื่องมือสนับสนุนผู้ส่งออกและผู้กำหนดนโยบายในการเพิ่มประสิทธิภาพการบริหารสินค้าคงคลัง ลดความเสี่ยงในห่วงโซ่อุปทาน และปรับปรุงการจัดสรรทรัพยากรสำหรับโลจิสติกส์ควบคุมอุณหภูมิได้ดียิ่งขึ้น

คำสำคัญ: ตัวแบบผสม EMD-ANN การพยากรณ์อนุกรมเวลา การส่งออกกล้วยไม้



Forecasting Thai Orchid Exports Using Artificial Neural Networks and Grid Search Integrated with Empirical Mode Decomposition

Nathagorn Tosing*

Department of Logistics Engineering, Faculty of Liberal Arts and Sciences, Sisaket Rajaphat University, Sisaket, Thailand

Thoranin Sujjaviriyasup

Department of Logistics Engineering, School of Engineering, University of the Thai Chamber of Commerce, Bangkok, Thailand

* Corresponding Author, Tel. 09 5621 2045, E-mail: Nathagorn.t@sskru.ac.th DOI: 10.14416/j.kmutnb.2026.06.008

Received 15 July 2025; Revised 2 February 2026; Accepted 10 March 2026; Published online: 19 June 2026

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

Abstract

Accurate forecasting of orchid exports is essential for production planning and cold-chain logistics in Thailand, yet export time series are often nonlinear and non-stationary. This study develops a hybrid forecasting framework that integrates Empirical Mode Decomposition (EMD) with Artificial Neural Networks (ANN) and tunes the parameters using grid search. The proposed methodology decomposes monthly export signals into the First Intrinsic Mode Function (IMF1) and a residual component, transforming the original series into component-wise learning targets. Separate ANN models are designed for each component to learn distinct data characteristics independently. The framework is validated using 72 months of monthly export data (2019–2024) obtained from the Office of Agricultural Economics. Model performance is evaluated using a rolling-origin expanding-window approach, which refits the model with all information available at each origin and tests forecasts on subsequent observations to reflect practical deployment. The results show that the proposed EMD–ANN model outperforms benchmark models, namely ARIMA and Holt–Winters. For Test Set 1 with 18 observations, the proposed model achieves an accuracy of 88.36%, exceeding the alternative models. When the evaluation is extended by adding 12 additional observations, resulting in 30 test observations in total, the proposed model maintains a comparable accuracy of 88.19%, demonstrating stable performance as the test horizon increases. Therefore, the proposed model provides higher predictive accuracy than traditional approaches while maintaining consistent forecasting performance under expanded testing conditions. It can serve as a robust decision-support tool for exporters and policymakers to improve inventory management, mitigate supply-chain risk, and enhance resource allocation for temperature-controlled logistics.

Keywords: Hybrid EMD–ANN Model, Time Series Forecasting, Orchid Export

Please cite this article as: N. Tosing and T. Sujjaviriyasup, "Forecasting Thai orchid exports using artificial neural networks and grid search integrated with empirical mode decomposition," *The Journal of KMUTNB*, vol. 36, no. 3, pp. 1–14, Jul.–Sep. 2026 (in Thai), Art. no. 263-8229, doi: 10.14416/j.kmutnb.2026.06.008.

1. บทนำ

กล้วยไม้เป็นพืชเศรษฐกิจสำคัญของประเทศไทย โดยเฉพาะกล้วยไม้ตัดดอกที่มีบทบาทต่อรายได้จากการส่งออก อย่างไรก็ตามปริมาณการส่งออกมีความผันผวนตามปัจจัยภายนอกหลายด้าน จึงทำให้การพยากรณ์ที่แม่นยำมีความจำเป็นต่อการวางแผนการผลิต การจัดการสินค้าคงคลัง และการตัดสินใจด้านโลจิสติกส์ของผู้ประกอบการ และผู้กำหนดนโยบาย [1], [2] ในด้านการผลิตอุตสาหกรรมกล้วยไม้เผชิญข้อจำกัดเชิงภูมิภาค และสิ่งแวดล้อม ที่ส่งผลต่อคุณภาพและความต่อเนื่องของอุปทาน โดยงานวิจัยชี้ว่าสภาพแวดล้อมมีผลต่อกระบวนการออกดอกและคุณภาพของกล้วยไม้ [3], [4] อีกทั้งกระบวนการขยายพันธุ์ เพาะเลี้ยงเนื้อเยื่อ และการพัฒนาต้นพันธุ์ส่งผลต่อความสม่ำเสมอของผลผลิตในระยะยาว [5], [6] ขณะที่ในส่วนปลายน้ำของระบบมีข้อจำกัดด้านเวลาอย่างชัดเจนจากช่วงหลังการเก็บเกี่ยวที่ต้องควบคุมคุณภาพเพื่อการส่งออก [7] ความแตกต่างระหว่างการตัดสินใจในส่วนต้นน้ำที่ใช้เวลานาน (เช่น การเพาะเลี้ยงเนื้อเยื่อ 8 วัน-14 เดือน) กับปลายน้ำที่มีกรอบเวลาสั้น (7-15 วัน) ทำให้ข้อมูลพยากรณ์มีบทบาทสำคัญต่อการจัดสรรทรัพยากร และการประสานการผลิต และการส่งมอบ [5]-[7] เมื่อพิจารณาในมิติห่วงโซ่อุปทาน (Supply Chain) กล้วยไม้เป็นสินค้าที่อ่อนไหวต่อเวลา การจัดการหลังการเก็บเกี่ยว การบรรจุภัณฑ์ และสภาพแวดล้อมระหว่างขนส่ง จึงเป็นปัจจัยกำหนดคุณภาพและมูลค่าในตลาดปลายทาง [7] งานวิจัยในบริบทผู้ส่งออกไทยยังเสนอกรอบความได้เปรียบในการแข่งขันและการจัดการคุณภาพในห่วงโซ่อุปทาน [8] รวมถึงความสัมพันธ์ระหว่างกิจกรรมโลจิสติกส์กับสมรรถนะโลจิสติกส์ของผู้ส่งออกกล้วยไม้ไทย [9] นอกจากนี้บทบาทของความไว้วางใจ การแบ่งปันข้อมูล และความคล่องตัว ถูกชี้ว่าเกี่ยวข้องกับสมรรถนะห่วงโซ่อุปทานอย่างยั่งยืน [10] ดังนั้นผลพยากรณ์ที่เชื่อถือได้จึงช่วยสนับสนุนการวางแผนกลยุทธ์การแข่งขันภายใต้ข้อจำกัดเชิงพื้นที่และคุณภาพของสินค้า ด้านระเบียบวิธีงานพยากรณ์อนุกรมเวลา (Time Series Forecasting) นิยมใช้ตัวแบบเชิงสถิติ เช่น ตัวแบบอาร์มา (ARIMA) [11]

แต่ข้อมูลเศรษฐกิจด้านการส่งออกจำนวนมากที่มีลักษณะไม่เป็นเชิงเส้นและไม่คงที่ (Nonlinear and non-stationary) ทำให้แนวทางเชิงเส้นเพียงอย่างเดียวอาจมีข้อจำกัดในบางสถานการณ์ [12] จึงเกิดแนวทางในการพัฒนาตัวแบบผสม (Hybrid) ที่ผสานสถิติกับการเรียนรู้ของเครื่อง (Machine Learning) เพื่อเพิ่มความยืดหยุ่นและความแม่นยำ [13] ในกลุ่มตัวแบบผสมแนวทางการแยกองค์ประกอบก่อนเรียนรู้ (Decomposition-learning) ได้รับความสนใจเพิ่มขึ้น โดยการแยกสัญญาณเป็นองค์ประกอบย่อยก่อนนำไปพยากรณ์ [14] งานเชิงประจักษ์รายงานว่าการผสาน การแยกโหมดเชิงประจักษ์ (Empirical Mode Decomposition; EMD) กับโครงข่ายประสาทเทียม (Artificial Neural Network; ANN) สามารถช่วยปรับปรุงสมรรถนะการพยากรณ์ในหลายบริบท [15]-[17] ขณะเดียวกันยังมีการประยุกต์วิธีอื่น เช่น ตัวแบบผสมวิธีเชิงเอนแซมเบิล (Ensemble) ของการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียม (EEMD-ANN) [18] และตัวแบบผสมการสลายโหมดแบบแปรผันกับโครงข่ายประสาทเทียม (VMD-ANN) [19] อย่างไรก็ตามงานวิจัยนี้เลือกใช้วิธีการแยกโหมดเชิงประจักษ์เป็นแกนหลักด้วยเหตุผลสำคัญ 3 ประการ ได้แก่ 1) มีงานที่ประยุกต์ใช้การแยกโหมดเชิงประจักษ์ร่วมกับโครงข่ายประสาทเทียมในงานพยากรณ์อนุกรมเวลา [15], [20] 2) เมื่อเทียบกับวิธีเชิงเอนแซมเบิลของการแยกโหมดเชิงประจักษ์ซึ่งต้องอาศัยกระบวนการเชิงเอนแซมเบิลและการจัดการสัญญาณรบกวน (Noise) เพิ่มเติม [18] การใช้การแยกโหมดเชิงประจักษ์ทำให้กระบวนการมีความตรงไปตรงมาและเอื้อต่อการทำซ้ำ (Reproducibility) และ 3) เมื่อเทียบกับการสลายโหมดแบบแปรผันที่ต้องกำหนดพารามิเตอร์สำคัญ เช่น จำนวนโหมด (Modes) [19] การแยกโหมดเชิงประจักษ์ลดภาระการปรับพารามิเตอร์ในบริบทข้อมูลรายเดือนที่มีขนาดตัวอย่างจำกัดสำหรับบริบทประเทศไทยงานที่พยากรณ์การส่งออกกล้วยไม้โดยตรงยังมีจำนวนจำกัดและส่วนใหญ่ยังอยู่ในกรอบสถิติและการผสานตัวแบบพื้นฐานมากกว่าแนวทางการแยกองค์ประกอบก่อนเรียนรู้ [21]-[23] โดยมีรายงานผลเปรียบเทียบวิธีเชิงสถิติหลายวิธี และพบค่าร้อยละ

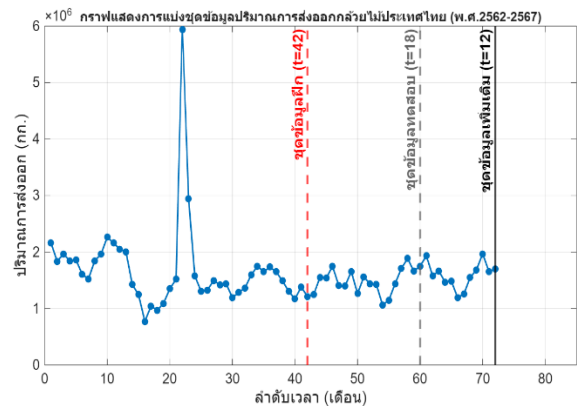
ความคลาดเคลื่อนสัมบูรณ์เฉลี่ยต่ำสุด 17.4132 ในชุดข้อมูลที่ศึกษา [21] ขณะทำงานใช้ตัวแบบผสมระหว่างอาร์มาและซัพพอร์ตเวกเตอร์แมชชีน (ARIMA-SVM) รายงานการลดความคลาดเคลื่อนเมื่อเทียบกับตัวแบบอาร์มาเพียงอย่างเดียว (ลดร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 4.63%) [24] ดังนั้นช่องว่างองค์ความรู้ของงานนี้คือการพัฒนาและประเมินตัวแบบผสมที่รองรับลักษณะไม่เป็นเชิงเส้นและไม่คงที่ของข้อมูลส่งออกกล้วยไม้ไทยผ่านกรอบการผสมการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียม (EMD-ANN) อย่างเป็นระบบและโปร่งใส

ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาตัวแบบพยากรณ์แบบผสมการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียมสำหรับการพยากรณ์ปริมาณการส่งออกกล้วยไม้รายเดือนของประเทศไทย และเปรียบเทียบกับตัวแบบอนุกรมเวลาพื้นฐาน ได้แก่ ตัวแบบอาร์มา และตัวแบบโพลีโนเมียล โดยประเมินประสิทธิภาพด้วยตัวชี้วัดมาตรฐาน 3 เกณฑ์ ได้แก่ ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) เพื่อสนับสนุนการตัดสินใจด้านการผลิต สินค้าคงคลัง และโลจิสติกส์ของอุตสาหกรรมกล้วยไม้ไทย

2. วิธีการทดลอง

2.1 ข้อมูลและการเตรียมข้อมูล

ข้อมูลที่ใช้ในงานวิจัยนี้เป็นข้อมูลทุติยภูมิจากสำนักงานเศรษฐกิจการเกษตร (สศก.) ได้แก่ ปริมาณการส่งออกกล้วยไม้ของประเทศไทยแบบรายเดือน หน่วยเป็น กิโลกรัม ครอบคลุมช่วง มกราคม พ.ศ. 2562-ธันวาคม พ.ศ. 2567 รวม 72 เดือน โดยข้อมูลมีลักษณะเป็นอนุกรมเวลาที่สะท้อนความผันผวนของการส่งออกจากอิทธิพลของฤดูกาลและเหตุการณ์ภายนอกบางช่วง ดังนั้นจึงนำเสนอ กราฟข้อมูลดิบ (รูปที่ 1) เพื่อแสดงภาพรวมรูปแบบการเปลี่ยนแปลงในแต่ละช่วงเวลาและค่าผิดปกติและการเปลี่ยนแปลงฉับพลัน (Spike) ซึ่งเป็นปัจจัยสำคัญที่อาจส่งผลกระทบต่อความยากและความคลาดเคลื่อนในการพยากรณ์



รูปที่ 1 กราฟแสดงปริมาณการส่งออกกล้วยไม้ของประเทศไทยในรูปแบบรายเดือนมกราคม 2562-ธันวาคม 2567

ในขั้นตอนการเตรียมข้อมูล (Data Pre-processing) ได้ดำเนินการตรวจสอบความครบถ้วนและความสอดคล้องของข้อมูลเบื้องต้น ได้แก่ การตรวจสอบค่าที่ขาดหาย (Missing Values) การตรวจสอบหน่วยวัดให้เป็นมาตรฐานเดียวกัน และการตรวจสอบค่าผิดปกติเบื้องต้นจากกราฟอนุกรมเวลา เพื่อให้มั่นใจว่าข้อมูลอยู่ในสภาพพร้อมต่อการประมวลผล จากนั้นจึงจัดรูปข้อมูลให้อยู่ในรูปแบบอนุกรมเวลา (Time Series) รายเดือนด้วยความถี่เท่ากับ 12 (Frequency = 12) เพื่อรองรับการนำไปใช้กับตัวแบบเปรียบเทียบ ได้แก่ ตัวแบบอาร์มา และตัวแบบโพลีโนเมียลทั้งแบบบวกและแบบคูณ และรองรับขั้นตอนการแยกโหมดเชิงประจักษ์ ก่อนเข้าสู่กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมในตัวแบบผสมที่นำเสนอ

ทั้งนี้ ข้อมูลทั้งหมดมีจำนวน 72 เดือน โดยแบ่งออกเป็น 3 ส่วน ได้แก่ ข้อมูลฝึก (Training Set) จำนวน 42 เดือนแรก (ลำดับที่ 1-42) ข้อมูลทดสอบ (Test Set) จำนวน 18 เดือน (ลำดับที่ 43-60) และข้อมูลเพิ่มเติม (Additional Set) จำนวน 12 เดือน (ลำดับที่ 61-72) ดังแสดงในรูปที่ 1

2.2 ตัวแบบอาร์มาตัวแบบทั่วไปสำหรับการเปรียบเทียบ

งานวิจัยนี้กำหนดให้ตัวแบบอาร์มาเป็นตัวแบบทั่วไป

(Baseline Model) สำหรับใช้เปรียบเทียบประสิทธิภาพกับตัวแบบพยากรณ์แบบผสมที่นำเสนอ เนื่องจากตัวแบบอาร์มีมาเป็นวิธีพยากรณ์อนุกรมเวลาที่ได้รับการยอมรับอย่างกว้างขวาง มีโครงสร้างเชิงสถิติที่ชัดเจน และสามารถอธิบายความสัมพันธ์เชิงเวลาโดยอาศัยข้อมูลในอดีตได้อย่างเป็นระบบ ภายใต้โครงสร้าง ARIMA(p,d,q) ซึ่งประกอบด้วยส่วนอัตถถดถอย (Autoregressive; AR) อันดับ p ส่วนการหาผลต่าง (Differencing) อันดับ d เพื่อให้ข้อมูลมีลักษณะคงที่ และส่วนค่าเฉลี่ยเคลื่อนที่ (Moving Average; MA) อันดับ q ในรูปทั่วไป ตัวแบบ ARIMA สามารถเขียนได้ดังสมการที่ (1)

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1-B)^d (Y_t - \mu) = \left(1 - \sum_{j=1}^q \theta_j B^j\right) \varepsilon_t \quad (1)$$

เมื่อ Y_t คือ ปริมาณการส่งออกกล้วยไม้ ณ เวลาที่ t

ε_t คือ ค่าความคลาดเคลื่อน ณ เวลาที่ t

μ คือ ค่าเฉลี่ย

B คือ ตัวแปลงย้อนกลับ (Backward Operator)

d คือ อันดับการหาผลต่าง

p และ q คือ ลำดับของตัวแบบอาร์มีมา

สำหรับข้อมูลอนุกรมเวลารายเดือนซึ่งมีรูปแบบฤดูกาล งานวิจัยนี้ขยายตัวแบบเป็นตัวแบบอาร์มีมาเชิงฤดูกาล (Seasonal ARIMA) โดยกำหนดคาบฤดูกาลเท่ากับ 12 เดือน ดังสมการที่ (2)

$$\phi(B)\Phi(B^{12})(1-B)^d(1-B^{12})^d Y_t = \theta(B)\Theta(B^{12})\varepsilon_t \quad (2)$$

ในเชิงปฏิบัติการสร้างตัวแบบอาร์มีมาดำเนินการภายใต้แนวคิดการตรึงจุดกำเนิดการพยากรณ์ (Rolling-origin) เพื่อสะท้อนการพยากรณ์เชิงปฏิบัติแบบไม่ใช้ข้อมูลอนาคต โดยในรอบแรก จะใช้ข้อมูลตั้งแต่เดือนที่ 1 ถึงเดือนสุดท้ายของข้อมูลเรียนรู้สำหรับประมาณค่าพารามิเตอร์ และพยากรณ์ล่วงหน้า 1 เดือน ($h = 1$) จากนั้นเลื่อนขยายข้อมูลเรียนรู้เมื่อข้อมูลจริงเปิดเผยเพื่อสร้างตัวแบบที่เหมาะสมกับข้อมูล

ใหม่และทำการพยากรณ์ไปข้างหน้าและทำซ้ำตลอดช่วงทดสอบ การเลือกโครงสร้างของตัวแบบ $(p,d,q)(P,D,Q)_{12}$ ใช้วิธีคัดเลือกอัตโนมัติด้วยฟังก์ชัน auto.arima() โดยพิจารณาเกณฑ์สารสนเทศ AICc ผลการพยากรณ์จากตัวแบบอาร์มีมาจะถูกประเมินประสิทธิภาพด้วยตัวชี้วัดมาตรฐานทั้ง 3 เกณฑ์เพื่อใช้เป็นฐานในการเปรียบเทียบกับตัวแบบอื่นในงานวิจัยนี้

2.3 ตัวแบบโฮลต์-วินเทอร์

งานวิจัยนี้ใช้ตัวแบบโฮลต์-วินเทอร์ (Holt-Winters Exponential Smoothing) เป็นตัวแบบเปรียบเทียบ เนื่องจากเหมาะสมกับอนุกรมเวลารายเดือนที่มีองค์ประกอบของระดับ (Level) แนวโน้ม (Trend) และฤดูกาล (Seasonality) โดยหลักการของวิธีนี้คือ การถ่วงน้ำหนักข้อมูลในอดีตแบบเอ็กซ์โปเนนเชียล เพื่อให้ค่าประมาณขององค์ประกอบต่าง ๆ ปรับตัวตามข้อมูลล่าสุดอย่างต่อเนื่อง

สำหรับตัวแบบโฮลต์-วินเทอร์แบบบวก (Additive Holt-Winters) สามารถเขียนสมการพื้นฐานได้ดังสมการที่ (3)-(6)

$$l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (4)$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m} \quad (5)$$

$$\hat{y}_{t+1} = l_t + b_t + s_{t-m+1} \quad (6)$$

ตัวแบบโฮลท์วินเทอร์แบบเชิงการคูณ ดังสมการที่ (7)-(10)

$$l_t = \alpha \left(\frac{y_t}{s_{t-m}} \right) + (1-\alpha)(l_{t-1} + b_{t-1}) \quad (7)$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (8)$$

$$s_t = \gamma \left(\frac{y_t}{(l_{t-1} + b_{t-1})} \right) + (1-\gamma)s_{t-m} \quad (9)$$

$$\hat{y}_{t+1} = (l_t + b_t)s_{t-m+1} \quad (10)$$

เมื่อ \hat{y}_{t+1} คือ ค่าพยากรณ์ ณ เวลาที่ $t + 1$

Y_t คือ ค่าพยากรณ์ ณ เวลาที่ t

α คือ ค่าการปรับเรียบ โดยมีค่าระหว่าง 0 ถึง 1 สำหรับระดับข้อมูล

β คือ ค่าการปรับเรียบ โดยมีค่าระหว่าง 0 ถึง 1 สำหรับแนวโน้ม

γ คือ ค่าการปรับเรียบ โดยมีค่าระหว่าง 0 ถึง 1 สำหรับฤดูกาล

l_t คือ ค่าประมาณระดับ ณ เวลาที่ t

b_t คือ ค่าประมาณแนวโน้ม ณ เวลาที่ t

s_t คือ ค่าประมาณฤดูกาล ณ เวลาที่ t

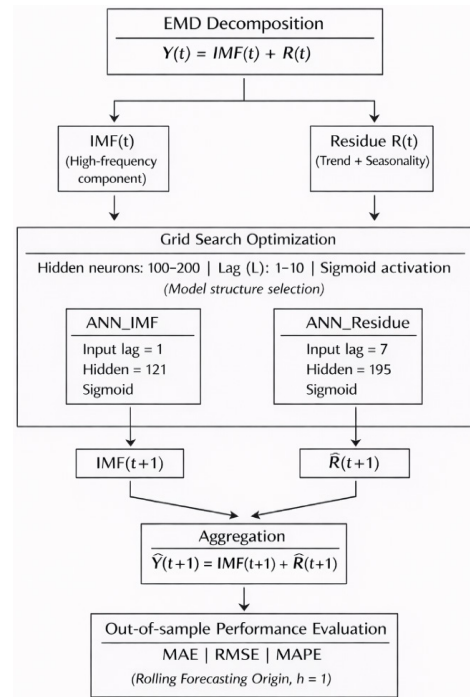
m คือ ค่าจำนวนของฤดูกาล

ในการทดลอง ข้อมูลถูกจัดให้อยู่ในรูปอนุกรมเวลารายเดือน (Frequency = 12) และค่าพารามิเตอร์การปรับเรียบ α, β, γ ถูกประมาณจากข้อมูลฝึกในแต่ละรอบ ภายใต้แนวคิดการตรึงจุดกำเนิดการพยากรณ์ โดยทำการพยากรณ์ล่วงหน้า 1 เดือน ($h = 1$) เพื่อสะท้อนการพยากรณ์เชิงปฏิบัติแบบไม่ใช้ข้อมูลอนาคต ผลลัพธ์จากทั้งตัวแบบแบบบวกและแบบคูณถูกนำไปประเมินประสิทธิภาพด้วยตัวชี้วัดมาตรฐานทั้ง 3 เกณฑ์ เพื่อใช้เปรียบเทียบกับตัวแบบอาร์มา และตัวแบบผสมที่นำเสนอลักษณะคล้ายกันตลอดช่วงทดสอบ

2.4 ตัวแบบที่นำเสนอ

งานวิจัยนี้นำเสนอตัวแบบพยากรณ์แบบผสมระหว่างการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียม เพื่อเพิ่มความแม่นยำในการพยากรณ์ปริมาณการส่งออกกล้วยไม้ของประเทศไทย ซึ่งมีลักษณะเป็นพลวัตซับซ้อน ไม่เชิงเส้น และไม่คงที่ตามเวลา แนวคิดหลักของตัวแบบคือ การลดความซับซ้อนของอนุกรมเวลาดั้งเดิมโดยการแยกข้อมูลออกเป็นองค์ประกอบย่อยที่มีคุณลักษณะต่างกัน แล้วสร้างตัวแบบพยากรณ์เฉพาะสำหรับองค์ประกอบย่อยแต่ละส่วน ก่อนรวมผลพยากรณ์กลับเป็นค่าพยากรณ์สุดท้ายของระบบ [20] ทั้งนี้ ลำดับขั้นตอนการทำงานโดยรวมของตัวแบบที่นำเสนอแสดงดังรูปที่ 2

2.4.1 การแยกองค์ประกอบด้วยการแยกโหมดเชิง




รูปที่ 2 ขั้นตอนการทำงานของตัวแบบที่นำเสนอ (EMD-ANN)

ประจักษ์

โดยให้ Y_t แทนปริมาณการส่งออกกล้วยไม้ ณ เวลา t ขั้นตอนแรกใช้เทคนิคการแยกโหมดเชิงประจักษ์เพื่อแยกอนุกรมเวลาดั้งเดิมออกเป็นองค์ประกอบย่อย โดยในงานวิจัยนี้กำหนดค่า $\max.imf = 1$ เพื่อสกัดฟังก์ชันโหมดแผลงลำดับที่ 1 (IMF_1) และส่วนที่เหลือ (Residue, R_t) [20] ดังสมการที่ (11)

$$Y_t = IMF_t + R_t \quad (11)$$

การกำหนดให้มีฟังก์ชันโหมดแผลงเพียงหนึ่งองค์ประกอบมีวัตถุประสงค์เพื่อแยกสัญญาณความถี่สูงและรูปแบบระยะสั้นของข้อมูลออกจากโครงสร้างแนวโน้มและฤดูกาลที่สะท้อนพลวัตระยะยาว ซึ่งจะคงอยู่ในส่วนที่เหลือส่งผลให้ขั้นตอนการเรียนรู้ด้วยโครงข่ายประสาทเทียม สามารถทำได้มีประสิทธิภาพมากขึ้น เนื่องจากแต่ละองค์ประกอบมีคุณลักษณะเชิงสถิติและระดับความซับซ้อนแตกต่างกันอย่าง



รูปที่ 3 การเปรียบเทียบข้อมูลอนุกรมเวลาด้านฉบับและข้อมูลฟังก์ชันโหมดแฝง

ชัดเจน (ตัวอย่างเชิงประจักษ์สามารถอธิบายประกอบด้วยรูปเปรียบเทียบข้อมูลอนุกรมเวลาด้านฉบับและข้อมูลฟังก์ชันโหมดแฝงแสดงดังรูปที่ 3)

ทั้งนี้ ในแต่ละรอบของการพยากรณ์แบบตรงจุดกำเนิดเลื่อนขยายจุดข้อมูล กระบวนการแยกโหมดเชิงประจักษ์จะดำเนินการใหม่โดยใช้เฉพาะข้อมูลที่มีอยู่ ณ เวลานั้นเพื่อหลีกเลี่ยงการใช้ข้อมูลอนาคต

2.4.2 การจัดรูปแบบข้อมูลด้วยการฝังข้อมูลแบบหน่วงเวลา

หลังการแยกองค์ประกอบข้อมูลของแต่ละองค์ประกอบ (ฟังก์ชันโหมดแฝง และส่วนที่เหลือ) ถูกแปลงให้อยู่ในรูปแบบการเรียนรู้แบบมีผู้สอน (Supervised Learning) ด้วยเทคนิคการจัดข้อมูลแบบหน่วงเวลา (Time Delay Embedding) โดยกำหนดให้ค่าข้อมูลย้อนหลังจำนวน L ค่า เป็นตัวแปรอิสระ และค่าถัดไปหนึ่งช่วงเวลาเป็นตัวแปรตาม เพื่อรองรับการพยากรณ์ล่วงหน้า 1 ช่วงเวลา (One-step-ahead) กล่าวคือ สร้างชุดข้อมูล (X_t, y_t) ตามสมการที่ (12)

$$X_t = (x_{t-1}, x_{t-2}, \dots, x_{t-L}), y_t = x_t \quad (12)$$

เมื่อ x_t แทนค่าในองค์ประกอบนั้น ๆ ณ เวลา t โดยค่า L ทำหน้าที่กำหนดจำนวนโหนดในชั้นนำเข้า (Input Nodes) ของโครงข่าย และถือเป็นพารามิเตอร์สำคัญต่อความสามารถในการเรียนรู้ความสัมพันธ์เชิงเวลา ทั้งนี้ เนื่องจากฟังก์ชันโหมดแฝงและส่วนที่เหลือ มีลักษณะต่างกัน ค่า L จึงถูกคัดเลือกแยกสำหรับแต่ละองค์ประกอบผ่านกระบวนการค้นหาแบบกริดในขั้นตอนถัดไป

2.4.3 การค้นหาพารามิเตอร์ด้วยการค้นหาแบบกริด

เพื่อกำหนดโครงสร้างของโครงข่ายประสาทเทียมที่เหมาะสม งานวิจัยนี้ใช้การค้นหาแบบกริด (Grid search) โดยทดลองค่าหน่วงย้อนหลัง L ตั้งแต่ 1–10 และจำนวนโหนดในชั้นซ่อน (Hidden Neurons) ตั้งแต่ 100–200 โหนด (เพิ่มทีละ 1) สำหรับองค์ประกอบย่อยแต่ละส่วน รวมเป็น 1,010 ชุดพารามิเตอร์ต่อองค์ประกอบ ในแต่ละชุดพารามิเตอร์จะทำการฝึกโครงข่ายประสาทเทียมบนข้อมูลฝึก และคำนวณค่ารากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย เพื่อใช้เป็นการคัดเลือกโครงสร้างที่เหมาะสมที่สุดในเชิงตัวแบบขององค์ประกอบนั้น ๆ

ผลการค้นหาพบว่าโครงข่ายประสาทเทียมสำหรับองค์ประกอบฟังก์ชันโหมดแฝงเหมาะสมที่ค่า $L = 1$ และจำนวนโหนดชั้นซ่อนเท่ากับ 121 โหนด ขณะที่โครงข่ายประสาทเทียมสำหรับองค์ประกอบส่วนที่เหลือเหมาะสมที่ค่า $L = 7$ และจำนวนโหนดชั้นซ่อนเท่ากับ 195 โหนด ซึ่งสะท้อนถึงระดับความซับซ้อนของข้อมูลที่แตกต่างกันระหว่างองค์ประกอบความถี่สูง (ฟังก์ชันโหมดแฝง) และองค์ประกอบโครงสร้างระยะยาวและฤดูกาล (ส่วนที่เหลือ)

ทั้งนี้ กระบวนการค้นหาแบบกริดถูกใช้เพื่อคัดเลือกโครงสร้างของตัวแบบเท่านั้น โดยอาศัยเฉพาะข้อมูลในชุดข้อมูลฝึก ขณะที่การประเมินประสิทธิภาพการพยากรณ์จะดำเนินการแยกต่างหากภายใต้กรอบการพยากรณ์แบบเลื่อนจุดกำเนิดในขั้นตอนถัดไป เพื่อหลีกเลี่ยงการใช้ข้อมูลอนาคตและความเอนเอียงในการประเมินผล

2.4.4 การสร้างโครงข่ายประสาทเทียม แยกตามองค์ประกอบ

หลังจากได้โครงสร้างที่เหมาะสมแล้ว งานวิจัยสร้างโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feedforward Neural Network) แยกสำหรับฟังก์ชันโหมดแฝงและส่วนที่เหลือ โดยใช้ฟังก์ชัน nnet ตัวแบบถูกกำหนดให้มีชั้นซ่อนจำนวน 1 ชั้น และใช้ฟังก์ชันกระตุ้นแบบซิกมอยด์ในชั้นซ่อนเพื่อรองรับความสัมพันธ์ที่ไม่เชิงเส้นของข้อมูล ขณะที่ชั้นผลลัพธ์กำหนดเป็น 1 โหนด พร้อมฟังก์ชันเชิงเส้น (linout = TRUE) เพื่อให้เหมาะสมกับการพยากรณ์ค่าต่อเนื่อง การประมาณค่าน้ำหนัก

เชื่อมต่อดำเนินการด้วยกระบวนการเพิ่มประสิทธิภาพภายในของ nnet ตามค่าเริ่มต้นของฟังก์ชัน โดยกำหนดค่าพารามิเตอร์เริ่มต้นเท่าเดิม เพื่อให้ผลลัพธ์สามารถทำซ้ำได้ กำหนดค่า MaxNWts = 4000 เพื่อรองรับจำนวนพารามิเตอร์ของโครงข่าย และปิดการแสดงผลระหว่างการฝึกด้วย trace = FALSE ทั้งนี้การฝึกโครงข่ายใช้ค่าเริ่มต้นของฟังก์ชัน ได้แก่ จำนวนรอบการปรับค่ามากที่สุด (Epoch) = 100 ค่าถ่วงน้ำหนักการลดทอน (Decay) = 0 และช่วงค่าน้ำหนักเริ่มต้นแบบสุ่ม (Rang) = 0.7 เพื่อให้การประมาณค่าน้ำหนักเชื่อมต่อสามารถดำเนินการได้อย่างเสถียรภายใต้ข้อจำกัดของขนาดข้อมูล

งานวิจัยไม่ทำการปรับสเกลข้อมูลก่อนการฝึกโครงข่าย และใช้ข้อมูลบนสเกลเดิมตลอดกระบวนการ เพื่อสะท้อนสภาพข้อมูลจริงในการพยากรณ์และคงความหมายของหน่วยการวัดในการประเมินผล

2.4.5 การรวมผลพยากรณ์

ค่าพยากรณ์สุดท้ายของอนุกรมเวลาด้านฉบับได้จากการรวมผลพยากรณ์ขององค์ประกอบย่อยทั้งสองแบบบวกดังสมการที่ (13)

$$\hat{Y}_{t+1} = \widehat{IMF}_{t+1} + \hat{R}_{t+1} \quad (13)$$

การรวมผลแบบบวกสอดคล้องกับหลักการของการแยกโหมดเชิงประจักษ์ ที่องค์ประกอบย่อยทั้งหมดรวมกันเท่ากับสัญญาณต้นฉบับ โดยผลลัพธ์ \hat{Y}_{t+1} จะถูกนำไปประเมินความแม่นยำด้วยเกณฑ์วัดประสิทธิภาพทั้ง 3 เกณฑ์ ภายใต้กรอบการพยากรณ์แบบเลื่อนจุดกำเนิดเดียวกับตัวแบบเปรียบเทียบ เพื่อให้การเปรียบเทียบมีความเป็นธรรมและสะท้อนการใช้งานจริง

2.5 การตรวจสอบความแม่นยำของตัวแบบด้วยการตั้งจุดกำเนิดการพยากรณ์

งานวิจัยนี้ประเมินความสามารถในการพยากรณ์สถานการณ์จริงด้วยแนวคิดการตรวจสอบแบบไขว้สำหรับอนุกรมเวลา (Cross-validation) แบบตั้งจุดกำเนิดการ

พยากรณ์ (Rolling-origin) โดยใช้การขยายหน้าต่างข้อมูล (Expanding Window) และพยากรณ์ล่วงหน้า 1 ช่วงเวลา (One-step-ahead; $h = 1$)

ข้อมูลทั้งหมดมี 72 เดือน แบ่งเป็น 3 ชุด ได้แก่ ชุดข้อมูลฝึก (1–42), ชุดข้อมูลทดสอบ (43–60) และชุดข้อมูลเพิ่มเติม (61–72)

1) การประเมินชุดข้อมูลที่ 1 (43–60) เริ่มจากประมาณค่าตัวแบบที่เหมาะสมที่สุดด้วยข้อมูลช่วง 1–42 แล้วพยากรณ์ค่าในตำแหน่ง 43 จากนั้นเปรียบเทียบกับค่าจริงเพื่อคำนวณความคลาดเคลื่อน เมื่อค่าจริงของตำแหน่ง 43 ถูกเปิดเผย จะนำข้อมูลตำแหน่ง 43 มารวมกับข้อมูลฝึกเดิม (ขยายเป็น 1–43) และทำการประมาณค่าตัวแบบใหม่เพื่อพยากรณ์ตำแหน่ง 44 ทำซ้ำกระบวนการนี้จนถึงตำแหน่ง 60 รวมเป็น 18 ค่าพยากรณ์ เมื่อพยากรณ์ครบทุกค่าในชุดข้อมูลทดสอบจะนำความคลาดเคลื่อนมาคำนวณหาประสิทธิภาพตามเกณฑ์วัดประสิทธิภาพทั้ง 3 เกณฑ์ เพื่อประเมินประสิทธิภาพของตัวแบบพยากรณ์ที่เหมาะสมที่สุด

2) การประเมินชุดข้อมูลที่ 2 (43–72) เพื่อประเมินความทนทานของตัวแบบที่เหมาะสมที่สุดในชุดทดสอบบนช่วงเวลาที่ยาวขึ้น จึงใช้ข้อมูลเพิ่มเติม (61–72) เพื่อขยายช่วงการประเมิน โดยใช้ขั้นตอน การตั้งจุดกำเนิดการพยากรณ์แบบเดียวกับข้อ (1) ตั้งแต่ตำแหน่ง 43 ถึง 72 รวมเป็น 30 ค่าพยากรณ์ ทั้งนี้ ชุดข้อมูลที่ 2 เป็นการขยายช่วงประเมินจากชุดข้อมูลที่ 1 ไม่ใช่การสร้างชุดทดสอบใหม่แยกอิสระ

เพื่อให้การประเมินเป็นธรรมและทำซ้ำได้ ค่าพารามิเตอร์โครงสร้างของแต่ละตัวแบบ (รวมถึงค่า ไฮเปอร์พารามิเตอร์ของโครงข่ายประสาทเทียม) จะถูกกำหนดจากข้อมูลชุดฝึกเท่านั้น และถูกตรึงไว้ตลอดการประเมิน เพื่อสร้างตัวแบบที่เหมาะสมและพยากรณ์ล่วงหน้า 1 ช่วงเวลา ($h = 1$) ทั้งนี้ ขั้นตอนการวิเคราะห์และการประเมินผลทั้งหมดดำเนินการด้วยโปรแกรม R

3. ผลการทดลองและอภิปรายผลการทดลอง

3.1 ภาพรวมของการทดลองและวิธีการ

งานวิจัยนี้ได้พัฒนาตัวแบบพยากรณ์แบบผสมระหว่างการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียม เพื่อใช้

ในการพยากรณ์ปริมาณการส่งออกกล้วยไม้ของประเทศไทย โดยมีวัตถุประสงค์หลักเพื่อเปรียบเทียบประสิทธิภาพกับตัวแบบดั้งเดิม ได้แก่ ตัวแบบอาร์มีมา ตัวแบบโพลต์-วินเทอร์ ทั้งแบบบวกและแบบคูณ ในการทดลองครั้งนี้ได้ใช้ข้อมูลสำหรับฝึกตัวแบบจำนวน 42 เดือน (1-42) และทดสอบด้วยข้อมูลสองชุดคือ ชุดข้อมูลทดสอบจำนวน 18 เดือน (43-60) และชุดข้อมูลทดสอบเพิ่มเติม จำนวน 30 เดือน (43-72) เพื่อประเมินความทนทานของตัวแบบในช่วงเวลาที่ยาวขึ้น


3.2 ผลลัพธ์จากชุดทดสอบที่ 1 (กรกฎาคม 2565-ธันวาคม 2566)

3.2.1 ผลการประเมินเชิงปริมาณ

การประเมินความแม่นยำด้วยการพยากรณ์ล่วงหน้า 1 ช่วงเวลา ภายใต้การตรึงจุดกำเนิดการพยากรณ์ สำหรับชุดทดสอบที่ 1 (ลำดับ 43-60; กรกฎาคม 2565-ธันวาคม 2566) แสดงดังตารางที่ 1 พบว่าตัวแบบที่นำเสนอ (EMD-ANN) ให้ค่าความคลาดเคลื่อนต่ำสุด โดยมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 162,724.7 กิโลกรัม รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย 198,832.9 กิโลกรัม และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 11.64% ต่ำกว่า ตัวแบบอาร์มีมา (ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 13.42% และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย 223,278.1 กิโลกรัม) และต่ำกว่า ตัวแบบโพลต์-วินเทอร์ทั้งแบบบวก และแบบคูณ อย่างชัดเจน (ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยอยู่ในช่วง 21.02-23.48% และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยอยู่ในช่วง 377,418.7-527,002.7 กิโลกรัม) ทั้งนี้ ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 11.64% สะท้อนความคลาดเคลื่อนเฉลี่ยเชิงร้อยละที่ต่ำกว่าตัวแบบทั่วไป ขณะที่รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยที่ต่ำกว่า (ลดลงจากอาร์มีมา 24,445.2 กิโลกรัม) บ่งชี้ว่าสามารถลดความผิดพลาดขนาดใหญ่ได้ดีกว่าภายใต้กรอบการประเมินเดียวกันในงานวิจัยนี้

3.2.2 การวิเคราะห์และการเปรียบเทียบ

จากการวิเคราะห์ปริมาณการส่งออกกล้วยไม้รายเดือน ดังรูปที่ 4



รูปที่ 4 ปริมาณส่งออกกล้วยไม้จริงและค่าพยากรณ์ (กรกฎาคม 2565-ธันวาคม 2566)

ตารางที่ 1 เกณฑ์การวัดประสิทธิภาพของตัวแบบพยากรณ์ จากข้อมูลชุดทดสอบที่ 1

ตัวแบบ	ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (กิโลกรัม)	รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (กิโลกรัม)	ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (%)
ตัวแบบอาร์มีมา	181,311.80	223,278.10	13.42
ตัวแบบโพลต์-วินเทอร์แบบบวก	370,246.30	527,002.70	23.48
ตัวแบบโพลต์-วินเทอร์แบบคูณ	322654.90	377,418.70	21.02
ตัวแบบที่นำเสนอ (EMD-ANN)	162,724.70	198,832.90	11.64

หมายเหตุ: ชุดทดสอบที่ 1 คือข้อมูลลำดับที่ 43-60

พบว่าตัวแบบที่นำเสนอ (EMD-ANN) สามารถติดตามแนวโน้มข้อมูลจริงได้ใกล้เคียง โดยเฉพาะช่วงที่ปริมาณส่งออกเพิ่มขึ้นอย่างรวดเร็ว เช่น เดือนตุลาคม 2565 และ ตุลาคม 2566 ขณะที่ตัวแบบอาร์มีมา และตัวแบบโพลต์-วินเทอร์ ทั้งแบบบวก และแบบคูณ มีแนวโน้มพยากรณ์ค่าสูงเกินจริง และตัวแบบโพลต์-วินเทอร์ยังให้ค่าพยากรณ์ที่ผันผวนสูง ในบางช่วง จนไม่สอดคล้องกับข้อมูลจริงในเวลาเดียวกัน และเมื่อพิจารณาร่วมกับผลเชิงปริมาณในตารางที่ 1 ซึ่งระบุว่าตัวแบบที่นำเสนอให้ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยต่ำสุด (11.64%) และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด (198,832.9 กิโลกรัม) จึงสรุปได้ว่า

ตัวแบบที่นำเสนอเป็นรูปแบบที่ให้ความแม่นยำดีที่สุดภายใต้กรอบการประเมินเดียวกันในงานวิจัยนี้ นอกจากนี้แนวโน้มที่ตัวแบบผสมแบบแยกสัญญาณแล้วเรียนรู้ให้ความแม่นยำเหนือกว่าตัวแบบดั้งเดิม


3.3 ผลลัพธ์จากชุดทดสอบเพิ่มเติม (กรกฎาคม 2565-ธันวาคม 2567)

3.3.1 ผลการประเมินเชิงปริมาณ

การประเมินความแม่นยำด้วยการพยากรณ์ล่วงหน้า 1 ช่วงเวลา ภายใต้การตั้งจุดกำเนิดการพยากรณ์ สำหรับชุดทดสอบเพิ่มเติม (ชุดทดสอบที่ 2 ลำดับ 43-72; กรกฎาคม 2565-ธันวาคม 2567) ซึ่งเป็นการขยายช่วงประเมินจากชุดทดสอบแรก เพื่อทดสอบความทนทานบนช่วงเวลาที่ยาวขึ้น ดังตารางที่ 2 พบว่าตัวแบบที่นำเสนอยังคงให้ค่าความคลาดเคลื่อนต่ำสุด โดยมีค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 173,811.8 กิโลกรัม รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย 210,811.5 กิโลกรัม และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 11.81% ต่ำกว่าตัวแบบอาร์มา (ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 12.36% และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย 212,462.4 กิโลกรัม) และต่ำกว่า ตัวแบบโฮลต์-วินเทอร์ทั้งแบบบวกและแบบคูณอย่างชัดเจน (ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยอยู่ในช่วง 20.10-21.90% และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยอยู่ในช่วง 403,990.4-464,156.0 กิโลกรัม) ทั้งนี้ ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 11.81% ที่ยังคงอยู่ในระดับใกล้เคียงกับชุดทดสอบแรก สะท้อนว่าตัวแบบที่นำเสนอสามารถรักษาความแม่นยำได้เมื่อขยายช่วงเวลาประเมิน ขณะที่ค่ารากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยที่ยังอยู่ในระดับต่ำเมื่อเทียบกับตัวแบบทั่วไป บ่งชี้ถึงความสามารถในการลดความผิดพลาดขนาดใหญ่ได้อย่างสม่ำเสมอภายใต้กรอบการประเมินเดียวกันในงานวิจัยนี้

3.3.2 การวิเคราะห์และการเปรียบเทียบ

จากการวิเคราะห์ปริมาณการส่งออกกล้วยไม้รายเดือนในชุดทดสอบที่ 2 (กรกฎาคม 2565-ธันวาคม 2567)



รูปที่ 5 ปริมาณส่งออกกล้วยไม้จริงและค่าพยากรณ์ (กรกฎาคม 2565-ธันวาคม 2567)

แสดงดังรูปที่ 5 พบว่าตัวแบบที่นำเสนอสามารถติดตามแนวโน้มข้อมูลจริงได้ใกล้เคียงอย่างต่อเนื่องตลอดช่วงประเมินที่ยาวขึ้น แม้ในช่วงที่ข้อมูลเปลี่ยนแปลงชัดเจน เช่น เดือนมิถุนายน 2567 ที่ปริมาณส่งออกเพิ่มสูงขึ้น ขณะที่ตัวแบบอาร์มามีแนวโน้มให้ค่าพยากรณ์เรียบและปรับตัวช้ากว่า ทำให้สะท้อนความผันผวนและฤดูกาลได้ไม่เพียงพอบางส่วนตัวแบบโฮลต์-วินเทอร์ทั้งแบบบวกและแบบคูณ มีแนวโน้มคลาดเคลื่อนมากขึ้นเมื่อปริมาณส่งออกเปลี่ยนแปลงรวดเร็ว ส่งผลให้เส้นพยากรณ์เบี่ยงเบนจากข้อมูลจริงเด่นชัดกว่าตัวแบบอื่น เมื่อพิจารณาพร้อมกับผลเชิงปริมาณในตารางที่ 2 ซึ่งแสดงว่าตัวแบบที่นำเสนอให้ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย และรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยต่ำสุด ในชุดทดสอบที่ 2 จึงสะท้อนว่าแนวทางการแยกองค์ประกอบก่อนเรียนรู้ช่วยให้ผลพยากรณ์มีความสอดคล้องกับข้อมูลจริง และมีความทนทานเมื่อขยายช่วงเวลาประเมินภายใต้กรอบการประเมินเดียวกันในงานวิจัยนี้

3.4 การเปรียบเทียบระหว่างชุดทดสอบ

การประเมินผลจากสองช่วงทดสอบแสดงให้เห็นว่าชุดทดสอบที่ 2 เป็นการขยายช่วงประเมินจากชุดทดสอบที่ 1 (จากลำดับ 43-60 เป็น 43-72) เพื่อประเมินความทนทานของตัวแบบเมื่อช่วงเวลาที่ยาวขึ้น ผลการเปรียบเทียบพบว่า ตัวแบบที่นำเสนอสามารถรักษาประสิทธิภาพได้อย่างต่อเนื่อง โดยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเปลี่ยนจาก 11.64% (ชุดทดสอบที่ 1) เป็น 11.81%

ตารางที่ 2 เกณฑ์การวัดประสิทธิภาพของตัวแบบพยากรณ์ จากข้อมูลชุดทดสอบที่ 2

ตัวแบบ	ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (กิโลกรัม)	รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (กิโลกรัม)	ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (%)
ตัวแบบอาร์มีมา	174,555.50	212,462.40	12.36
ตัวแบบโพลต์-วินเทอร์แบบบวก	325,334.30	464,156.00	20.10
ตัวแบบโพลต์-วินเทอร์แบบคูณ	345,974.00	403,990.40	21.90
ตัวแบบที่นำเสนอ (EMD-ANN)	173,811.80	210,811.50	11.81

หมายเหตุ: ชุดข้อมูลทดสอบที่ 2 คือข้อมูลลำดับที่ 43-72

(ชุดทดสอบที่ 2) ซึ่งสะท้อนว่าความคลาดเคลื่อนโดยรวมยังคงอยู่ในระดับใกล้เคียงเดิมเมื่อขยายช่วงประเมิน

เมื่อพิจารณาจากค่ารากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย ซึ่งสะท้อนความคลาดเคลื่อนโดยรวมและให้ข้อมูลที่ความผิดพลาดขนาดใหญ่พบว่าในชุดทดสอบที่ 1 ตัวแบบที่นำเสนอมีค่าต่ำกว่าตัวแบบอาร์มีมาอยู่ 24,445.2 กิโลกรัม ต่ำกว่าตัวแบบโพลต์-วินเทอร์แบบคูณอยู่ 178,585.8 กิโลกรัม และต่ำกว่าตัวแบบโพลต์-วินเทอร์แบบบวกอยู่ 328,169.8 กิโลกรัม ขณะที่ในชุดทดสอบที่ 2 ตัวแบบที่นำเสนอมีค่าต่ำกว่าตัวแบบอาร์มีมาอยู่ 1,650.9 กิโลกรัม ต่ำกว่าตัวแบบโพลต์-วินเทอร์แบบคูณอยู่ 193,178.9 กิโลกรัม และต่ำกว่าตัวแบบโพลต์-วินเทอร์แบบบวกอยู่ 253,344.5 กิโลกรัม สะท้อนว่าความแม่นยำของตัวแบบที่นำเสนอมีความสม่ำเสมอแม้ขยายช่วงประเมิน

ในเชิงปฏิบัติความแตกต่างของรากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยมีความหมายต่อการวางแผนการส่งออกและโลจิสติกส์ เนื่องจากความคลาดเคลื่อนระดับแสนกิโลกรัมต่อเดือนอาจกระทบการจอร์จวางแผน การเตรียมทรัพยากรควบคุมอุณหภูมิ และการจัดตารางการขนส่ง ดังนั้นการเลือกใช้ตัวแบบที่ให้ความคลาดเคลื่อนต่ำและคงที่ในทั้ง

ช่วงทดสอบระยะสั้นและช่วงที่ยาวขึ้น จึงช่วยลดความเสี่ยงเชิงปฏิบัติการได้มากกว่าในบริบทการส่งออกกล้วยไม้รายเดือน

3.5 อภิปรายผลการทดลอง

ผลการประเมินภายใต้กรอบการตรึงจุดกำเนิดการพยากรณ์ แบบขยายหน้าต่างและพยากรณ์ล่วงหน้า 1 ช่วงเวลาสะท้อนว่าตัวแบบผสมระหว่างการแยกโหมตเชิงประจักษ์กับโครงข่ายประสาทเทียมให้ค่าความคลาดเคลื่อนต่ำกว่าตัวแบบทั่วไป (ตัวแบบอาร์มีมา และตัวแบบโพลต์-วินเทอร์) เมื่อพิจารณาจากค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย รากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย และร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย ตามตารางที่ 1 และ 2 โดยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยในชุดทดสอบที่ 1 และ 2 มีค่าใกล้เคียงกัน (11.64% และ 11.81%) และค่ารากของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยอยู่ในช่วง 198,832.9-210,811.5 กิโลกรัม จึงตีความได้ว่าความแม่นยำมีความสม่ำเสมอ เมื่อขยายช่วงเวลาประเมินภายใต้กติกาเดียวกัน ทั้งนี้ งานทบทวนวรรณกรรมล่าสุดชี้ว่าการเปรียบเทียบตัวแบบเชิงสถิติกับตัวแบบปัญญาประดิษฐ์ควรวีถ่วงรอบประเมินที่ทำซ้ำได้เพื่อให้ข้อสรุปเชิงปฏิบัติมีน้ำหนัก [12]

ในเชิงเหตุผลของวิธีการการแยกโหมตเชิงประจักษ์ช่วยแยกอนุกรมเวลาเป็นส่วนย่อยและแนวโน้ม (ส่วนที่เหลือ) ทำให้รูปแบบข้อมูลในแต่ละส่วนชัดเจนและเอื้อต่อการเรียนรู้ของโครงข่ายประสาทเทียม ซึ่งสอดคล้องกับแนวคิดการใช้การแยกโหมตเชิงประจักษ์ เพื่อจัดการความซับซ้อนของสัญญาณและลดผลกระทบของสัญญาณรบกวนในเชิงแนวคิด [16] และสอดคล้องกับงานที่ชี้ว่าการแยกองค์ประกอบมักช่วยเพิ่มขีดความสามารถของตัวแบบในข้อมูลที่ไม่มีเชิงเส้นและมีความผันผวน [15] อย่างไรก็ตามเมื่อเปรียบเทียบกับงานก่อนหน้าซึ่งชี้ให้เห็นว่าความจำเพาะของข้อมูลมีผลต่อการเลือกวิธีอย่างมีนัยสำคัญ [14] โดยใช้แนวทางการแยกโหมตเชิงประจักษ์ กับตัวแบบผสมระหว่างตัวแบบอาร์มีมา กับโครงข่ายประสาทเทียม ในชุดข้อมูลอนุกรมเวลาที่มีคุณลักษณะเฉพาะของโดเมนของตน ในส่วนบริบทสินค้าเกษตรมีการใช้เทคนิคการแยกองค์ประกอบอีกแบบ (เช่น CEEMDAN)

และโครงข่ายที่ต่างไปเพื่อรองรับลักษณะข้อมูลราคาและความผันผวนคนละรูปแบบ [17] ดังนั้นผลของงานนี้จึงควรถูกตีความบนบริบทปริมาณส่งออกกล้วยไม้รายเดือนที่มีจำนวนข้อมูลจำกัด และความผันผวนตามฤดูกาลและตลาดซึ่งทำให้การออกแบบกรอบประเมินแบบการตรึงจุดกำเนิดการพยากรณ์และการเลือกพารามิเตอร์ด้วยการค้นหาแบบกริด มีบทบาทในการลดการพึ่งพาคัลยพิณิจของผู้วิจัยและเพิ่มการทำซ้ำได้ของกระบวนการพัฒนาตัวแบบ มากกว่าการอ้างว่าเป็นวิธีที่ดีที่สุดในทุกบริบท

ในมิติเศรษฐกิจและโลจิสติกส์ความแม่นยำและความสม่ำเสมอของผลพยากรณ์ช่วยลดความไม่แน่นอนในการวางแผนการผลิต การจัดหาปัจจัยการผลิต การกำหนดปริมาณส่งออก และการจัดตารางการขนส่ง โดยเฉพาะสินค้าที่อ่อนไหวต่อเวลาและคุณภาพอย่างกล้วยไม้ ซึ่งต้องอาศัยการประสานงานด้านโลจิสติกส์อย่างใกล้ชิด งานที่ศึกษากิจกรรมโลจิสติกส์ของผู้ส่งออกกล้วยไม้ไทยสะท้อนความสำคัญของการวางแผนและการจัดการข้อมูลเพื่อยกระดับสมรรถนะโลจิสติกส์ [9] และกรอบแนวคิดด้านโซ่อุปทานของผู้ส่งออกกล้วยไม้ไทยชี้ว่าคุณภาพการจัดการโซ่อุปทานเกี่ยวข้องกับความสามารถในการแข่งขัน [8] อย่างไรก็ตามหากต้องการอภิปรายความไม่มีอคติในเชิงสถิติ ควรเพิ่มเติมตัวชี้วัดอคติจากข้อผิดพลาดพยากรณ์ (เช่น ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย หรือร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย) และการตรวจสอบรูปแบบข้อผิดพลาดตามหลักอนุกรมเวลา เพื่อเพิ่มความสมบูรณ์ของข้อสรุป [11]

4. สรุปผลการทดลอง

งานวิจัยนี้พัฒนาตัวแบบผสมระหว่างการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียม โดยมีกรอบการทำงานประกอบด้วย 1) ใช้การแยกโหมดเชิงประจักษ์แยกอนุกรมเวลาออกเป็นองค์ประกอบย่อย (ฟังก์ชันโหมดแฝงและส่วนที่เหลือ) 2) สร้างตัวแบบโครงข่ายประสาทเทียม สำหรับองค์ประกอบแต่ละส่วน (IMF-ANN และ RES-ANN) โดยกำหนดโครงสร้างอินพุตแบบหน่วงเวลาให้เหมาะกับลักษณะขององค์ประกอบ (ฟังก์ชันโหมดแฝงมีลักษณะผันผวนระยะสั้น

จึงใช้ค่าข้อมูลย้อนหลัง (lag) สั้น ขณะที่ส่วนที่เหลือสะท้อนแนวโน้มจึงใช้ค่าข้อมูลย้อนหลังยาวขึ้น) และ 3) รวมผลพยากรณ์จากทุกองค์ประกอบเป็นค่าพยากรณ์สุดท้าย ซึ่งช่วยลดความซับซ้อนของสัญญาณก่อนเข้าสู่กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม ตามแนวคิดการแยกองค์ประกอบแล้วเรียนรู้ที่ใช้กันในงานพยากรณ์อนุกรมเวลา

ผลการประเมินแบบพยากรณ์ล่วงหน้า 1 ช่วงเวลาภายใต้การตรึงจุดกำเนิดการพยากรณ์พบว่าตัวแบบที่นำเสนอให้ความคลาดเคลื่อนต่ำสุดในทั้งสองชุดทดสอบ สะท้อนความสม่ำเสมอของผลพยากรณ์ เมื่อเปลี่ยนช่วงเวลาประเมิน ทั้งยังต่ำกว่าตัวแบบทั่วไป (ตัวแบบอาร์มา และตัวแบบโพลต์-วินเทอร์ทั้งสองรูปแบบ) ภายใต้กรอบการประเมินเดียวกันในงานวิจัยนี้ ในเชิงองค์ความรู้งานวิจัยนี้ต่อยอดจากงานในบริบทกล้วยไม้ไทยที่ส่วนใหญ่ยังอาศัยตัวแบบเชิงสถิติ ตัวแบบเดียว โดยแสดงให้เห็นว่าการใช้แนวทางการแยกโหมดเชิงประจักษ์กับโครงข่ายประสาทเทียมสามารถรับมือความไม่แน่นอนเชิงเส้นและความไม่คงที่ของข้อมูลส่งออกได้ดีขึ้น และเติมเต็มช่องว่างของการประยุกต์กรอบวิธีแบบผสมแยกองค์ประกอบก่อนแล้วจึงเรียนรู้ในโจทย์การส่งออกกล้วยไม้ไทย ในเชิงประยุกต์ผลพยากรณ์ที่มีความคลาดเคลื่อนต่ำและคงที่ช่วยสนับสนุนการตัดสินใจของผู้ประกอบการและผู้กำหนดนโยบาย เช่น การวางแผนปริมาณส่งออกและการบริหารสินค้าคงคลัง การบรรจุภัณฑ์ การวางแผนโลจิสติกส์และทรัพยากรควบคุมอุณหภูมิ รวมถึงการกำหนดแนวทางเชิงนโยบายในระดับอุตสาหกรรม (เช่น การบริหารโควตาการส่งออกหรือการบริหารห่วงโซ่อุปทานระดับประเทศ)

อย่างไรก็ตามเพื่อยกระดับความโปร่งใสและที่น่าเชื่อถือของการใช้งานจริงงานวิจัยในอนาคตควรพิจารณา 1) การวิเคราะห์ความไวของพารามิเตอร์หลัก (เช่น จำนวนองค์ประกอบจากการแยกโหมดเชิงประจักษ์ ค่าข้อมูลย้อนหลัง โครงสร้างเครือข่าย) เพื่อประเมินความเสถียรของตัวแบบเมื่อข้อมูลหรือพารามิเตอร์เปลี่ยนแปลง และ 2) การเปรียบเทียบเชิงสถิติของความแม่นยำระหว่างตัวแบบเมื่อมีการทดสอบที่เหมาะสม

เอกสารอ้างอิง

- [1] P. Heedjun, N. Poojom, and S. Putnuan, "Increasing the potential of air orchid exports in Thailand," in *Proceedings of the International Conference on Business Tourism and Applied Sciences (ICBTS) Vietnam 2025*, Hanoi, Vietnam, 2025, pp. 343–349.
- [2] Trade Policy and Strategy Office (TPSO). (2025, Mar.). Trends of Thailand's cut-flower trade in international markets. Ministry of Commerce. [Online]. Available: <https://uploads.tpsso.go.th/ส่งออกเทรนด์การค้าไม้ตัดดอกของไทยในตลาดต่างประเทศ.pdf> (in Thai).
- [3] E. S. Runkle, "Environmental control of the flowering process of *Phalaenopsis* orchids," *Acta Horticulturae*, no. 1262, pp. 7–12, Nov. 2019, doi: 10.17660/ActaHortic.2019.1262.2.
- [4] K. Jakovljević, T. Mišljenović, V. Djordjević, A. van der Ent, M. Cosić, G. Andrejić, and J. Sinžar-Sekulić, "Elemental and ecophysiological profiles of orchid *Dactylophiza Sambucina* show distinct responses to contrasting geological substrates," *Flora*, vol. 303, Jun. 2023, Art. no. 152276, doi: 10.1016/j.flora.2023.152276.
- [5] P. Nongdam, D. G. Beleski, L. Tikendra, A. Dey, V. Varte, S. EL Merzougui, V. M. Pereira, P. R. Barros, and W. A. Vendrame, "Orchid micropropagation using conventional semi-solid and temporary immersion systems: A review," *Plants*, vol. 12, no. 5, 2023, Art. no. 1136, doi: 10.3390/plants12051136.
- [6] C. A. Zanello and J. C. Cardoso, "PLBs induction and clonal plantlet regeneration from leaf segment of commercial hybrids of *Phalaenopsis*," *The Journal of Horticultural Science and Biotechnology*, vol. 94, no. 5, pp. 627–631, Sep. 2019, doi: 10.1080/14620316.2019.1600384.
- [7] W. Poonsri, "Effects of active and passive modified atmosphere packaging on biochemical properties of cut *Dendrobium* orchid flowers," *Heliyon*, vol. 7, no. 6, Jun. 2021, doi: 10.1016/j.heliyon.2021.e07197.
- [8] K. Pungam and W. Atthirawong, "A supply chain management quality management and competitive advantage framework for Thai orchid exporters," *Acta Horticulturae*, no. 1262, pp. 23–30, Nov. 2019, doi: 10.17660/ActaHortic.2019.1262.4.
- [9] O. Bualom and P. Fuggate, "Logistics activities and logistics performance of thai exporters exporting cut orchid flowers to vietnam," *Journal of International Studies*, vol. 20, no. 2, pp. 225–253, Aug. 2024, doi: 10.32890/jis2024.20.2.8.
- [10] S. Kim, "The critical role of trust, information sharing, and agility in advancing sustainable supply chain performance in Korea," *Sage Open*, vol. 15, no. 3, Aug. 2025, Art. no. 21582440251, doi: 10.1177/21582440251367158.
- [11] I. Rojas and H. Pomares, Eds., "Time series analysis and forecasting: Selected contributions from the ITISE conference," in *Contributions to Statistics. Cham: Springer International Publishing*, 2016. doi: 10.1007/978-3-319-28725-6.
- [12] E. H. Houssein, M. Mohamed, E. M. G. Younis, and W. M. Mohamed, "Artificial intelligence and classical statistical models for time series forecasting: A comprehensive review," *Journal*



- of *Big Data*, vol. 12, no. 1, pp. 271, Dec. 2025, doi: 10.1186/s40537-025-01318-z.
- [13] M. Choudhary, S. Jain, and G. Arya, “Classical models vs deep learning: Time series analysis,” in *Advancements in Interdisciplinary Research*, 2023, pp. 276–286, doi: 10.1007/978-3-031-23724-9_26.
- [14] Ü. Ç. Büyüksahin and Ş. Ertekin, “Improving forecasting accuracy of time series data using a new ARIMA-ANN hybrid method and empirical mode decomposition,” *Neurocomputing*, vol. 361, pp. 151–163, Oct. 2019, doi: 10.1016/j.neucom.2019.05.099.
- [15] J. Deng, F. Ye, D. Yin, X. Song, I. Tsang, and H. Xiong, “Parsimony or capability? decomposition delivers both in long-term time series forecasting,” *Advances in Neural Information Processing Systems*, vol. 37, pp. 66687–66712, Dec. 2024, doi: 10.52202/079017-2130.
- [16] N. Ahmad, X. Yi, M. Tayyab, M. H. Zafar, and N. Akhtar, “Water resource management and flood mitigation: Hybrid decomposition EMD-ANN model study under climate change,” *Sustainable Water Resources Management*, vol. 10, no. 2, 2024, doi: 10.1007/s40899-024-01048-9.
- [17] P. Pandit, A. Sagar, B. Ghose, M. Paul, O. Kisi, D. K. Vishwakarma, L. Mansour, and K. K. Yadav, “Hybrid modeling approaches for agricultural commodity prices using CEEMDAN and time delay neural networks,” *Scientific Reports*, vol. 14, no. 1, Nov. 2024, Art. no. 26639, doi: 10.1038/s41598-024-74503-4.
- [18] G. Napolitano, F. Serinaldi, and L. See, “Impact of EMD decomposition and random initialisation of weights in ANN hindcasting of daily stream flow series: An empirical examination,” *Journal of Hydrology*, vol. 406, no. 3, pp. 199–214, Sep. 2011, doi: 10.1016/j.jhydrol.2011.06.015.
- [19] M. Sibtain, X. Li, H. Bashir, and M. I. Azam, “A hybrid model for runoff prediction using variational mode decomposition and artificial neural network,” *Water Resources*, vol. 48, no. 5, pp. 701–712, Sep. 2021, doi: 10.1134/S0097807821050171.
- [20] C. Yin, N. Wei, J. Wu, C. Ruan, X. Luo, and F. Zeng, “An empirical mode decomposition-based hybrid model for sub-hourly load forecasting,” *Energies*, vol. 17, no. 2, pp. 307, 2024, doi: 10.3390/en17020307.
- [21] Y. Koetpan and S. Adsavakulchai, “Results of comparison of the efficiency of machine learning algorithms for predicting orchid yield in Thailand,” *Advanced Science Journal*, vol. 22, no. 1, pp. 227–237, May 2022 (in Thai).
- [22] W. Riansut, “A model for forecasting the export quantity of orchids from Thailand,” *KMUTT Research and Development Journal*, vol. 45, no. 4, pp. 455–467, 2022 (in Thai), doi: 10.14456/kmuttrd.2022.26.
- [23] P. Tantrabundit, L. Phothong, and A. Sukprasert, “The creation of prediction model for the volumes of Thailand’s orchid exports by applying machine learning methodologies,” *Journal of Business, Innovation and Sustainability*, vol. 19, no. 4, Dec. 2024.
- [24] T. Sujjaviriyasup and K. Pitiruek, “Hybrid ARIMA-support vector machine model for agricultural production planning,” *Applied Mathematical Sciences*, vol. 7, pp. 2833–2840, Jan. 2013, doi: 10.12988/ams.2013.13251.