



KKU SCIENCE JOURNAL

Journal Home Page : <https://ph01.tci-thaijo.org/index.php/KKUSciJ>

Published by the Faculty of Science, Khon Kaen University, Thailand



การพยากรณ์ระดับน้ำในเขื่อนภาคเหนือ ประเทศไทย โดยใช้ตัวแบบการพยากรณ์ การแยกส่วนประกอบแบบคลาสสิกและโฮลต์-วินเทอร์เสริมประสิทธิภาพโดยขั้นตอน วิธีหาค่าที่เหมาะสมที่สุดแบบแมลงหวี่

Forecasting Water Volume of Dam Reservoirs in Northern Thailand Using a Classical Decomposition and Holt-Winters Enhanced by Fruit Fly Optimization Algorithm

นัชชา วิมลสุจริต^{1*} วฐา มินเสน² พิมพกา ธาณินพงศ์² และ สาลินี อารังเลาะห์พันธุ์²Nutchha Vimolsutjarit^{1*}, Watha Minsan², Phimpaka Taninpong²and Salinee Thumronglaohapun²¹หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติประยุกต์และการวิเคราะห์เชิงลึก ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่
จังหวัดเชียงใหม่ 50200²ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ จังหวัดเชียงใหม่ 50200¹Master of Science Program in Applied Statistics and Analytics, Department of Statistics, Faculty of Science,
Chiang Mai University, Chiang Mai, Thailand 50200²Department of Statistics, Faculty of Science, Chiang Mai University, Chiang Mai, Thailand 50200

บทคัดย่อ

วัตถุประสงค์ของการศึกษาค้นคว้าครั้งนี้คือ เพื่อเปรียบเทียบประสิทธิภาพในการหาค่าพารามิเตอร์ที่เหมาะสมที่สุดของการพยากรณ์ที่ใช้เทคนิคการค้นหาค่าที่เหมาะสมที่สุดของแมลงหวี่ (FOA) ร่วมกับวิธีการพยากรณ์การแยกส่วนประกอบ (FOA-CD) และวิธีโฮลต์-วินเทอร์ (FOA-HW) กับตัวแบบพื้นฐานคือวิธีแยกส่วนประกอบแบบคลาสสิก (CD) และวิธีค้นหาแบบกริดเชิร์ชของโฮลต์-วินเทอร์ (Grid-HW) ข้อมูลที่ใช้ในการพยากรณ์ประกอบด้วยปริมาณน้ำเฉลี่ยรายเดือนในเขื่อนภาคเหนือของประเทศไทยจำนวน 8 เขื่อน โดยใช้ข้อมูลชุดฝึกฝนจำนวน 132 ชุดข้อมูล ทำการประเมินประสิทธิภาพของการพยากรณ์ด้วยค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ซึ่งผลการวิเคราะห์พบว่าวิธี FOA-CD มีประสิทธิภาพในการหาค่าพารามิเตอร์ที่เหมาะสมที่สุดดีกว่าวิธี CD ทั้ง 8 เขื่อน ในขณะที่วิธี FOA-HW มีประสิทธิภาพเทียบเท่ากับวิธี Grid-HW ในการคัดเลือกตัวแบบเพื่อพยากรณ์ล่วงหน้า 12 เดือน ใช้เกณฑ์การประเมิน RMSE ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) และค่าเปอร์เซ็นต์คลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) โดยพิจารณาค่าที่ดีที่สุด 2 ใน 3 ผลการเปรียบเทียบพบว่าวิธี CD มีประสิทธิภาพในการพยากรณ์สำหรับ 4 เขื่อน ในขณะที่ FOA-HW ก็สามารถพยากรณ์ได้อย่างมีประสิทธิภาพเช่นเดียวกันสำหรับ 4 เขื่อน โดยวิธี FOA-HW แสดงความสามารถในการพยากรณ์ที่มีความแม่นยำและความเหมาะสมมากกว่าในบางกรณี

*Corresponding Author, E-mail: nutch.22463@gmail.com

Received date: 13 February 2025 | Revised date: 11 May 2025 | Accepted date: 28 May 2025

doi: 10.14456/kkusci.2025.17

ABSTRACT

This study aims to investigate the efficiency of finding the optimal parameters for forecasting using Fruit Fly Optimization Algorithm with Classical Decomposition model (FOA-CD) and Holt-Winter Exponential Smoothing (FOA-HW) were compared with classic forecasting model that Classical Decomposition (CD) and Holt-Winter Exponential Smoothing with grid search (Grid-HW). The forecast data were the average monthly water volume from 8 dam reservoirs in northern Thailand, which comprise 132 training datasets. The model's performance was evaluated using the Root Mean Squared Error (RMSE). The results indicated that FOA-CD was more efficient in finding the optimal parameters compared to the CD across all 8 dam reservoirs, while FOA-HW performed comparably to Grid-HW. Model selection for 12-months-ahead forecasting, the evaluation criteria included RMSE, Mean Absolute Error (MAE), and Mean Absolute Percentage Error (MAPE), with the best 2 out of 3 metrics considered. The results revealed that the CD method was effective for forecasting in 4 dam reservoirs. The FOA-HW method also demonstrated comparable effectiveness for other 4 dam reservoirs. Moreover, the FOA-HW method showed superior forecasting accuracy and suitability in certain cases.

คำสำคัญ: การค้นหาที่เหมาะสมที่สุดของแมลงหวี่ การพยากรณ์ ปริมาณน้ำในเขื่อน

Keywords: Fruit Fly Optimization Algorithm, Forecasting, Reservoir Water Volume

บทนำ

เขื่อน เป็นสิ่งก่อสร้างขนาดใหญ่สำหรับกั้นทางน้ำเพื่อใช้ในการกักเก็บน้ำ โดยส่วนบนของเขื่อนจะประกอบด้วยส่วนที่เรียกว่าทางน้ำล้น สำหรับให้น้ำที่สูงกว่าระดับที่ต้องการไหลผ่านมาที่ฝั่งปลายน้ำ แนวคิดในการสร้างเขื่อนเริ่มต้นมาจากความต้องการจะแก้ไขปัญหาการขาดแคลนน้ำ และพลังงานที่ประชากรทั่วโลกประสบอยู่ การสร้างเขื่อนนั้นสามารถช่วยแก้ปัญหาน้ำฉับพลัน โดยจะช่วยทำหน้าที่ชะลอความเร็วของน้ำให้น้ำไหลผ่านเฉพาะตามปริมาณที่เหมาะสม (ศานิกานต์, 2565)

ปัจจุบันประเทศไทยเผชิญกับวิกฤติน้ำทั้งสถานการณ์ภัยแล้ง น้ำท่วม รวมถึงปัญหาแหล่งน้ำเสื่อมโทรม ในปี พ.ศ. 2564 ประเทศไทยเผชิญวิกฤตภัยแล้งหนักเนื่องจากปริมาณฝนสะสมในปี พ.ศ. 2563 มีค่าน้อยกว่าปกติประมาณร้อยละ 4 ทำให้ฤดูแล้งมีน้ำไม่เพียงพอส่งผลกระทบต่อภาคการเกษตร (รอยล, 2564) ตลอดระยะเวลา 2 - 3 ปีที่ผ่านมาประเทศไทยต้องเผชิญกับความแปรปรวนของธรรมชาติซึ่งส่งผลกระทบต่อปริมาณน้ำฝนของประเทศไทย ซึ่งปัญหาน้ำท่วมและภัยแล้งได้ก่อให้เกิดความเสียหายและส่งผลกระทบต่อเศรษฐกิจของประเทศไทยอย่างมาก โดยเฉพาะในด้านการเกษตรและอุตสาหกรรมที่ต้องอาศัยผลผลิตทางการเกษตรเป็นวัตถุดิบ ดังนั้นจึงจำเป็นต้องพัฒนาแผนการจัดการน้ำอย่างเหมาะสมและมีประสิทธิภาพเพื่อลดผลกระทบและสร้างความยั่งยืนในการใช้ทรัพยากรน้ำของประเทศไทยให้เกิดขึ้น นอกจากนี้ยังต้องใช้ข้อมูลในอดีตมาช่วยในการตัดสินใจในการพยากรณ์เพื่อช่วยคาดการณ์ปริมาณน้ำในเขื่อนเพื่อจัดการปริมาณน้ำอย่างมีประสิทธิภาพ

การพยากรณ์จึงมีความสำคัญเป็นอย่างมากเพื่อช่วยในการช่วยตัดสินใจและวางแผนปริมาณน้ำในเขื่อน ในอนาคตโดยวิธีการพยากรณ์อนุกรมเวลามีบทบาทสำคัญในช่วงหลายปีที่ผ่านมา เช่น วิธีโฮลต์-วินเทอร์ (Holt-Winters: HW) เป็นวิธีการพยากรณ์อนุกรมเวลาตามฤดูกาล ซึ่งประสิทธิภาพและความแม่นยำของวิธี HW ขึ้นอยู่กับการเลือกพารามิเตอร์การศึกษาที่ผ่านมามีวิธีเมตาฮีริสติกส์ (Metaheuristic Method) สามารถปรับปรุงประสิทธิภาพและความแม่นยำของการพยากรณ์ได้ โดยเป็นวิธีการที่ช่วยในการแก้ปัญหาคาดการณ์เพิ่มประสิทธิภาพที่ซับซ้อนโดยเลียนแบบกระบวนการทางธรรมชาติ ถูกใช้อย่างแพร่หลายในปัจจุบัน เช่น วิธีเชิงพันธุกรรม (Genetic Algorithm: GA) ถูกคิดค้นขึ้นในปี พ.ศ. 2531 โดย Goldberg

and Holland (1988) วิธีอาณานิคมมด (Ant Colony Optimization: ACO) ถูกคิดค้นในปี พ.ศ. 2549 โดย Dorigo *et al.* (2006) วิธีแบบกลุ่มอนุภาค (Particle Swarm Optimization: PSO) ถูกคิดค้นขึ้นในปี พ.ศ. 2538 โดย Kennedy and Eberhart (1995) ขั้นตอนวิธีแบบหิ่งห้อย (Firefly Algorithm: FA) ถูกคิดค้นในปี พ.ศ. 2552 โดย Yang (2009) วิธีการค้นหาแบบนกกาเหว่า (Cuckoo Search: CS) ถูกคิดค้นในปี พ.ศ. 2552 โดย Yang and Deb (2009) และวิธีการหาค่าเหมาะที่สุดแบบวาฬ (Whale Optimization Algorithm: WOA) ถูกคิดค้นในปี พ.ศ. 2559 โดย Mirjalili and Lewis (2016) ได้รับความนิยมในการแก้ปัญหาการเพิ่มประสิทธิภาพที่ซับซ้อน งานวิจัยในปี พ.ศ. 2565 โดย Khairalla (2022) ยืนยันว่าวิธีเมตา-ฮิวริสติกส์ สามารถเพิ่มความแม่นยำและประสิทธิภาพของตัวแบบการพยากรณ์อนุกรมเวลาได้อย่างมีนัยสำคัญ ซึ่งสอดคล้องกับงานวิจัยของ Minsan and Minsan (2023) ในปี พ.ศ. 2566 ได้ทำการศึกษาการผสมผสานกันระหว่างวิธีการแยกส่วนประกอบ (Classical Decomposition: CD) และวิธี HW ร่วมกับ WOA ในการทำการพยากรณ์รายได้รัฐบาลต่อเดือน โดยพบว่า การผสมผสานได้ผลดีที่สุด ในปีต่อมา Minsan and Minsan (2024) ได้ศึกษาการผสมผสานกันระหว่างวิธี CD และ วิธี HW ร่วมกับ WOA ในการทำการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่ในภาคใต้ 4 แห่งของประเทศไทย รวมถึงศึกษาวิธี CD และ HW ที่ได้รับการปรับปรุงด้วย WOA กรณีศึกษาการพยากรณ์ PM2.5 ใน 8 จังหวัดภาคเหนือของประเทศไทย (ปรารณาและวฐา, 2567b) นอกจากนี้ Minsan *et al.* (2024) ยังได้ทำการศึกษาการผสมผสานกันระหว่างวิธี CD และวิธี HW ร่วมกับ (Cuckoo Search: CS) ในการทำการพยากรณ์ค่าฝุ่น PM2.5 รายสัปดาห์ใน 8 จังหวัดภาคเหนือของประเทศไทย สุดท้าย ปรารณาและวฐา (2567a) ยังได้ต่อยอดวิธี CS โดยผสมผสานกับวิธี CD และ HW ศึกษาการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำขนาดใหญ่รายเดือน ในภาคตะวันออกเฉียงของประเทศไทย และในปี พ.ศ. 2562 Jiang *et al.* (2020) ได้ทำการศึกษาการผสมผสานระหว่างวิธี HW ร่วมกับ (Fruit fly optimization algorithm: FOA) ในการพยากรณ์ปริมาณการใช้ไฟฟ้า เมืองฉงชิ่งในประเทศจีน เปรียบเทียบกับวิธีการพยากรณ์อื่น ๆ พบว่า วิธีผสมผสานระหว่างวิธี HW ร่วมกับ FOA มีประสิทธิภาพสูงสุด และมีระยะเวลาดำเนินการสั้นกว่าวิธีอื่น ๆ วิธี FOA ถูกคิดค้นขึ้นโดย Pan ในปี พ.ศ. 2555 (Pan, 2012) เป็นแนวคิดจากพฤติกรรมในการค้นหาอาหารของแมลงหวี่ แมลงหวี่มีความสามารถในการตรวจจับ และการรับรู้ถึงการมีอยู่ของแหล่งอาหารด้วยการตรวจจับฟอสฟอรัสในอากาศ ในการค้นหาอาหารของแมลงหวี่จะใช้รูปแบบการตรวจจับตำแหน่งอาหารและบินไปยังตำแหน่งนั้นทันที


เนื่องจากงานวิจัยยังมีการนำ FOA มาประยุกต์ใช้ในการประมาณค่าพารามิเตอร์ของแบบจำลอง HW เท่านั้นและในบริบทของการเปรียบเทียบประสิทธิภาพกับวิธีเดิม เช่น กริดเซิร์ช ซึ่งเป็นประเด็นที่ยังขาดการศึกษาอย่างเพียงพอ ดังนั้นในการศึกษานี้ผู้วิจัยมีความสนใจที่จะต่อยอดการศึกษาของ Jiang *et al.* (2020) โดยนำวิธี FOA มาผสมผสานกับวิธี HW และวิธี CD ตามแนวทางของปรารณาและวฐา (2567a; 2567b) Minsan and Minsan (2023; 2024) และ Minsan *et al.* (2024) เพื่อหาค่าพารามิเตอร์ที่เหมาะสมที่สุด การปรับปรุงค่าพารามิเตอร์ดังกล่าวช่วยเพิ่มความแม่นยำในการทำนาย และลดข้อผิดพลาดของแบบจำลอง ทำให้สามารถนำไปใช้งานกับข้อมูลใหม่ได้อย่างมีประสิทธิภาพ ซึ่งจะส่งผลให้ผลลัพธ์มีความน่าเชื่อถือยิ่งขึ้น โดยวิธี HW ต้องการประมาณค่าพารามิเตอร์ 3 ค่า คือ ค่าคงที่ปรับระดับ (α) ค่าคงที่ปรับแนวโน้ม (β) และค่าคงที่ปรับฤดูกาล (γ) และวิธี CD ต้องการประมาณค่าพารามิเตอร์ 2 ค่าคือ β_0 และ β_1 โดยใช้การประมาณค่าพารามิเตอร์ด้วยวิธี FOA เพื่อให้ได้ประสิทธิภาพและความแม่นยำในการพยากรณ์สูงสุด

วิธีการดำเนินการวิจัย


1. การจัดเตรียมข้อมูล

ผู้วิจัยได้ทำการเก็บรวบรวมข้อมูลปริมาณน้ำเฉลี่ยรายเดือนในเขื่อนภาคเหนือของประเทศไทยจำนวน 8 เขื่อน จากเว็บไซต์กรมชลประทาน (ศูนย์ประมวลวิเคราะห์สถานการณ์น้ำ กรมชลประทาน, 2567) ได้แก่ เขื่อนแควน้อยบำรุงแดน เขื่อนก๊วกอหมา เขื่อนก๊วกลม เขื่อนภูมิพล เขื่อนสิริกิติ์ เขื่อนแม่งัดสมบูรณ์ชล เขื่อนแม่กวงอุดมธารา และเขื่อนแม่มอก โดย

ทำการแบ่งข้อมูลปริมาณน้ำเฉลี่ยรายเดือนของแต่ละเขื่อนออกเป็นจำนวน 2 ชุดข้อมูล คือ ข้อมูลชุดเรียนรู้ (Training Data Set) ประกอบด้วยข้อมูลตั้งแต่ เดือนมกราคม พ.ศ. 2552 ถึงเดือนธันวาคม พ.ศ. 2565 จำนวน 132 ชุดข้อมูล และข้อมูลชุดทดสอบ (Testing Data Set) ประกอบด้วยข้อมูลตั้งแต่ เดือนมกราคม พ.ศ. 2566 ถึงเดือนธันวาคม พ.ศ. 2566 จำนวน 12 ชุดข้อมูล ได้ทำการตรวจสอบข้อมูลและพบว่ามีความสูญหายในข้อมูลของทั้ง 8 เขื่อน การสูญหายของข้อมูลอาจเกิดขึ้นได้จากหลายสาเหตุ เช่น ความผิดพลาดในขั้นตอนการจัดเก็บข้อมูล หรือข้อผิดพลาดที่เกิดจากอุปกรณ์บ่อนข้อมูล ในการศึกษาครั้งนี้ได้เลือกใช้วิธีประมาณค่าสูญหายโดยการแทนค่าสูญหายด้วยค่ากลางของแต่ละเดือนในปีก่อนหน้า รวมถึงพิจารณาแนวโน้มและฤดูกาลของข้อมูลร่วมด้วย ทั้งนี้ ได้ทำการตรวจสอบแนวโน้มและฤดูกาลของข้อมูลซึ่งแสดงผลดังรูปที่ 1 และรูปที่ 2 ทำการวิเคราะห์โดยฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation Function: ACF) จากรูปที่ 1 ACF ของข้อมูลอนุกรมเวลาปรับฤดูกาล พบว่าค่าความสัมพันธ์มีการลดลงอย่างช้า ๆ และยังคงมีค่าสัมประสิทธิ์ที่เป็นบวกต่อเนื่องในหลายๆ lag ซึ่งบ่งชี้ว่าข้อมูลมีแนวโน้ม ACF ในรูปที่ 2 ของข้อมูลอนุกรมเวลาปรับแนวโน้ม แสดงถึงข้อมูลที่มีลักษณะความผันแปรตามฤดูกาล เนื่องจากมีลักษณะเป็นคลื่นสลับขึ้นลงที่ค่อนข้างสม่ำเสมอ และมีค่ามากที่สุดในช่วงเวลาซ้ำกว่ากันใน lag 12 ของแต่ละเขื่อน



รูปที่ 1 ACF ของข้อมูลอนุกรมเวลาปรับฤดูกาลของทั้งหมด 8 เขื่อน



รูปที่ 2 ACF ของข้อมูลอนุกรมเวลาปรับแนวโน้มของทั้งหมด 8 เซียน

2. วิธีการพยากรณ์แบบแยกส่วนประกอบแบบคลาสสิกของอนุกรมเวลา (Classical Decomposition: CD)

วิธีการแยกส่วนประกอบแบบคลาสสิกของอนุกรมเวลา เป็นวิธีที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่าง ๆ คือ แนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cycle) และเหตุการณ์ผิดปกติ (Irregular) จากแต่ละส่วนประกอบที่แยกออกมาจะทำให้เห็นลักษณะการเคลื่อนไหวของอนุกรมเวลาแต่ละส่วน (ทรงศิริ, 2539) โดยในงานวิจัยครั้งนี้ข้อมูลที่ทำมาทำการพยากรณ์ไม่มีส่วนของวัฏจักร และเหตุการณ์ผิดปกติ ดังนั้นตัวแบบพยากรณ์แบ่งออกได้เป็นตัวแบบการบวก และตัวแบบการคูณ ดังสมการที่ (1) และ (2)

ตัวแบบการบวก (Additive Model)

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

ตัวแบบการคูณ (Multiplicative Model)

$$Y_t = T_t \times S_t \quad (2)$$

โดยที่	Y	แทนข้อมูลอนุกรมเวลา
	T	แทนส่วนประกอบของแนวโน้ม
	S	แทนส่วนประกอบของฤดูกาล
	t	แทนช่วงเวลา ซึ่งมีค่าตั้งแต่ 1 ถึง n โดยที่ n แทนจำนวนข้อมูลในอนุกรมเวลา

3. วิธีโฮลต์-วินเทอร์ (Holt-Winters: HW)

การพยากรณ์โดยใช้วิธี HW เป็นวิธีการคาดการณ์อนุกรมเวลาที่สำคัญ วิธีการนี้มีจำนวนพารามิเตอร์อยู่ทั้งหมด 3 พารามิเตอร์ คือ ค่าคงที่ปรับระดับ (α) ค่าคงที่ปรับแนวโน้ม (β) และค่าคงที่ปรับฤดูกาล (γ) ค่าของพารามิเตอร์เหล่านี้อยู่ระหว่าง 0 ถึง 1 สามารถแบ่งได้เป็น 2 ประเภท คือ การปรับให้เรียบด้วยเส้นโค้งเลขชี้กำลังแบบโฮลต์-วินเทอร์แบบบวก (Holt-Winters additive exponential smoothing: HWA) ใช้กับการพยากรณ์อนุกรมเวลาที่มีอัตราส่วนของความผันแปรตามฤดูกาลต่อค่าแนวโน้มคงที่ และการปรับให้เรียบด้วยเส้นโค้งเลขชี้กำลังแบบโฮลต์-วินเทอร์แบบคูณ (Holt-Winters multiplicative exponential smoothing: HWM) ใช้กับการพยากรณ์อนุกรมเวลาที่มีอัตราส่วนของความผันแปรตามฤดูกาลต่อค่าแนวโน้มเพิ่มขึ้นหรือลดลงตามเวลาที่เปลี่ยนแปลงไป (Winters, 1960)

ตัวแบบพยากรณ์กรณีแบบบวก

$$\hat{y}_{t+m} = (T_t + b_t m) + S_{t+m-L} \quad (3)$$

เมื่อ	$\hat{y}_{t+m}$	แทนค่าพยากรณ์ ณ เวลา t โดยที่ m แทนจำนวนช่วงเวลาที่ต้องการพยากรณ์ไปข้างหน้า
	T_t	แทนระดับของอนุกรมเวลา
	b_t	แทนแนวโน้มของอนุกรมเวลา
	S_t	แทนฤดูกาลของอนุกรมเวลา
	t	แทนช่วงเวลา ซึ่งมีค่าตั้งแต่ 1 ถึง n โดยที่ n แทนจำนวนข้อมูลในอนุกรมเวลา
	L	แทนความยาวของรอบฤดูกาล

ค่า T_t b_t และ S_t คำนวณจากสมการที่ (4) - (6)

$$T_t = \alpha(Y_t - S_{t-L}) + (1 - \alpha)(T_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta(T_t - T_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

$$S_t = \gamma(y_t - T_t) + (1 - \gamma)S_{t-L} \quad (6)$$

ตัวแบบพยากรณ์กรณีแบบคูณ

$$\hat{y}_{t+m} = (T_t + b_t m)S_{t+m-L} \quad (7)$$

ค่า T_t b_t และ S_t คำนวณจากสมการที่ (8) - (10)

$$T_t = \alpha \frac{Y_t}{S_{t-L}} + (1 - \alpha)(T_{t-1} + b_{t-1}) \quad (8)$$

$$b_t = \beta(T_t - T_{t-1}) + (1 - \beta)b_{t-1} \quad (9)$$

$$S_t = \gamma \frac{y_t}{T_t} + (1 - \gamma)S_{t-L} \quad (10)$$

เมื่อ α β และ γ แทนค่าคงที่โดยมีค่าระหว่าง 0 ถึง 1

Y_t แทนอนุกรมเวลา ณ เวลา t

ค่าเริ่มต้น ณ เวลา t ของสมการที่ (4) - (6) และ (8) - (10) เขียนแทนได้ในสมการที่ (11) - (13)

$$T_0 = \frac{1}{12} \sum_{t=1}^{12} y_t \quad (11)$$

$$S_{0k} = y_k - T_0 \quad \text{กรณีแบบบวก} \quad (12)$$

$$S_{0k} = \frac{y_k}{T_0} \quad \text{กรณีแบบคูณ}$$

$$b_0 = 0 \quad (13)$$

เมื่อ k แทนเวลาที่พิจารณา โดยมีค่า $k = 1, 2, \dots, 12$

โดยในการศึกษานี้ได้ทำการพิจารณาค่าพารามิเตอร์ทั้ง 3 ตัว โดยใช้วิธีการค้นหาแบบกริดเสิร์ช ซึ่งเป็นเทคนิคที่นิยมใช้ในการเรียนรู้ของเครื่อง (Machine Learning) เพื่อหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับตัวแบบ โดยทำการกำหนดการเปลี่ยนแปลงค่าของพารามิเตอร์ในทศนิยม 2 ตำแหน่ง เริ่มต้นจาก 0.01 ถึง 0.99 อัตราเพิ่มครั้งละ 0.01 ส่งผลให้มีรอบการวนซ้ำรวมทั้งสิ้น 970,299 รอบ เรียกการศึกษานี้ว่า Grid-HW (ปรารณาและวุฐา, 2567a) โดยเมื่อสิ้นสุดกระบวนการจะเลือกค่าพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : RMSE) ที่ต่ำสุด

$$Objective \min RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (14)$$

เมื่อ $\hat{Y}_t$ แทนค่าพยากรณ์ที่ได้จากวิธี Grid-HW

4. ขั้นตอนวิธีหาค่าเหมาะที่สุดแบบแมลงหิว (FOA)

ขั้นตอนวิธีหาค่าเหมาะที่สุดแบบแมลงหิว หรือ FOA ถูกนำเสนอโดย Pan ในปี ค.ศ. 2012 เป็นแนวคิดจากพฤติกรรมในการค้นหาแหล่งอาหารของแมลงหิว แมลงหิวมีความสามารถในการตรวจจับ และการรับรู้ถึงการมีอยู่ของแหล่งอาหารด้วยการตรวจจับฟอสฟอรัสในอากาศ โดยอวัยวะการรับรู้ของแมลงหิวสามารถพบกลิ่นได้ทุกชนิดที่ลอยอยู่ในอากาศ และยังสามารถกลิ่นอาหารจากที่อยู่ห่างออกไป 40 กิโลเมตร ในการค้นหาอาหารของแมลงหิวจะใช้รูปแบบการตรวจจับตำแหน่งอาหารอย่างละเอียดและบินไปยังตำแหน่งนั้นทันที จากนั้นแมลงหิวจะเริ่มบินไปหาอาหารตามความแรงของกลิ่นอาหาร จนกระทั่งไปถึงจุดที่อาหารอยู่ (Pan, 2012) โดยทั่วไปขั้นตอนการค้นหาแบบแมลงหิวอธิบายได้ดังรูปที่ 3

Algorithm Pseudo code of the original FOA

1. Initial Objective Function
2. Initialization
 - Set maxgen, sizepop
 - for $g = 1:\text{maxgen}$
 - for $i = 1:\text{sizepop}$
 - / Random initial the position of fruit fly population
 - $x_0 = \text{random}(\text{uniform}), y_0 = \text{random}(\text{uniform})$
3. Process
 - 3.1 Random distance and direction to randomly for food searching of any individual fruit fly
 - $X_i = x_0 + \text{rand}(FR), Y_i = y_0 + \text{rand}(FR)$
 - 3.2 Calculate the distance to the initialization location
 - $\text{Dist}_i = \sqrt{X_i^2 + Y_i^2}$
 - And calculate the smell concentration judgment value
 - $S_i = 1 / \text{Dist}_i$
 - 3.3 Calculate the smell concentration
 - $\text{Smell}_i = \text{function minimum RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}$
 - 3.4 Fine out the fruit fly with minimal smell concentration among the swam
 - $[\text{bestSmell}, \text{bestIndex}] = \min(\text{Smell}_i)$
 - / Update x_0 and y_0
- end for
 - if $\text{smell}_i > \text{bestsmell}$ then
 - $x_0 = X_{\text{bestIndex}}$
 - $y_0 = Y_{\text{bestIndex}}$
 - end if
- end for

รูปที่ 3 รหัสเทียม Pseudo code ของ FOA (Wang et al., 2015)

5. การประยุกต์ขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดแบบแมลงหวี่ในการหาค่าประมาณพารามิเตอร์

ในการประยุกต์ใช้ขั้นตอนวิธีหาค่าที่เหมาะสมที่สุดแบบแมลงหวี่ สำหรับการพยากรณ์ CD และการพยากรณ์ HW มีค่าที่ต้องการประมาณ คือ β_0 β_1 α β และ γ โดยมีขั้นตอนดังนี้

1) กำหนดฟังก์ชันของวัตถุประสงค์

โดยฟังก์ชันของวัตถุประสงค์ที่ใช้ในการหาค่าผลลัพธ์คือ ฟังก์ชันจุดประสงค์เพื่อหาค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยที่ต่ำที่สุด ดังสมการที่ (15)

$$\text{Function minRMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (15)$$

โดยที่	Y_t	แทนค่าของข้อมูลจริง
	$\hat{Y}_t$	แทนค่าพยากรณ์
	n	แทนจำนวนข้อมูลอนุกรมเวลา
	t	แทนช่วงเวลา ซึ่งมีค่าตั้งแต่ 1 ถึง n

2) กำหนดค่าเริ่มต้น

การกำหนดค่าเริ่มต้นของแมลงหวี่ได้กำหนดจำนวนประชากรแมลงหวี่ $sizepop = 50$ จำนวนการวนรอบสูงสุด $maxgen = 100$ และค่าตำแหน่งเริ่มต้นของแมลงหวี่ (x_0, y_0) ที่เกิดจากสุ่มการแจกแจงแบบยูนิฟอร์ม

3) การประมวลผล

3.1) คำนวณค่าตำแหน่งใหม่ของแมลงหวี่แต่ละตัว X_i Y_i

3.2) จากนั้นทำการคำนวณค่าระยะทาง ($Dist_i$) และนำมาคำนวณค่าเข้มข้นของกลิ่นอาหาร (S_i) โดยในที่นี้จะให้ S_i แทนค่าพารามิเตอร์ที่ต้องการหา ซึ่งในแต่ละวิธีมีพารามิเตอร์ดังนี้ วิธี CD มีพารามิเตอร์คือ β_0 และ β_1 และวิธี HW มีพารามิเตอร์คือ α β และ γ โดยในการประมาณค่าพารามิเตอร์ของวิธี CD และ HW ต้องดำเนินการแยกกัน เนื่องจากแต่ละวิธีมีขั้นตอนการคำนวณและโครงสร้างของแบบจำลองที่แตกต่างกัน

3.3) ทำการแทนค่าพารามิเตอร์ลงในตัวแบบพยากรณ์ และทำการคำนวณค่าฟังก์ชันวัตถุประสงค์โดยให้ฟังก์ชันวัตถุประสงค์คือ RMSE แทนค่าเข้มข้นของกลิ่น

3.4) ทำการค้นหาและเก็บค่าความเข้มข้นของกลิ่นและฟังก์ชัน X_i Y_i ของแมลงหวี่ที่ดีที่สุด ซึ่งถ้าได้ผลลัพธ์ออกมาพบว่ามีความน้อยกว่าผลลัพธ์ที่ได้ในครั้งก่อนหน้า ค่าผลลัพธ์ในครั้งก่อนหน้านั้นจะถูกแทนที่ด้วยผลลัพธ์ใหม่ที่ได้ออกมา โดยจะทำการทำซ้ำเช่นนี้ไปเรื่อย ๆ จนกว่าค่าที่ได้จากฟังก์ชันวัตถุประสงค์มีค่าคงที่

4) การประมวลผลซ้ำและการเลือกผลลัพธ์

ทำการทำซ้ำในข้อที่ 3) จนกว่าจะครบตามจำนวนการวนรอบสูงสุดคือ 100 รอบ และทำการเลือกค่า S_i ที่ทำให้ฟังก์ชันวัตถุประสงค์มีค่าต่ำที่สุดออกมา

6. การประเมินประสิทธิภาพ

การประเมินประสิทธิภาพของการศึกษานี้แบ่งออกเป็น 2 ส่วนดังนี้

ส่วนที่ 1 คือ ข้อมูลชุดฝึกฝน ประเมินประสิทธิภาพโดยใช้ตัวชี้วัดคือ RMSE ต่ำที่สุด เพื่อระบุแนวทางในการสร้างแบบจำลอง โดยจะเปรียบเทียบค่าต่ำที่สุดของ RMSE เป็นคู่คือ วิธี CD เปรียบเทียบกับวิธี FOA-CD และ Grid-HW เปรียบเทียบกับวิธี FOA-HW โดยที่

เมื่อ	n	แทนจำนวนของข้อมูลชุดฝึกฝน
	Y_t	แทนค่าจริงของข้อมูลชุดฝึกฝน
	$\hat{Y}_t$	แทนค่าพยากรณ์ของข้อมูลชุดฝึกฝน

ส่วนที่ 2 คือข้อมูลชุดทดสอบ ซึ่งใช้สำหรับประเมินประสิทธิภาพของตัวแบบโดยใช้เกณฑ์การประเมิน 3 ตัว ได้แก่ ค่า RMSE (Root Mean Squared Error) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) และค่าเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ตามสมการที่ (16) ถึง (18) ทั้งนี้ จะทำการเลือกตัวแบบที่มีประสิทธิภาพดีที่สุดโดยพิจารณาจากเกณฑ์การคัดเลือกตัวแบบที่ดีที่สุด 2 ใน 3 เพื่อให้การตัดสินใจมีความรอบด้าน และมีความแม่นยำมากขึ้น (Belton and Stewart, 2002) เพื่อนำไปใช้ในการพยากรณ์ล่วงหน้าเป็นระยะเวลา 12 เดือน

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (16)$$

$$MAE = \frac{\sum_{t=1}^n |Y_t - \hat{Y}_t|}{n} \quad (17)$$

$$MAPE = 100 \times \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \quad (18)$$

โดยที่ Y_t แทนค่าจริงของข้อมูลชุดทดสอบ
 $\hat{Y}_t$ แทนค่าพยากรณ์ของข้อมูลชุดทดสอบ
 n แทนจำนวนของข้อมูลชุดทดสอบ

ผลการวิจัยและวิจารณ์ผล

1. เปรียบเทียบประสิทธิภาพในข้อมูลชุดฝึกฝน

เปรียบเทียบประสิทธิภาพข้อมูลชุดฝึกฝนของวิธี FOA-CD และ FOA-HW โดยเปรียบเทียบกับตัวแบบพื้นฐานคือ CD และ Grid-HW ในข้อมูลปริมาณน้ำเฉลี่ยรายเดือนในเขื่อนภาคเหนือของประเทศไทยจำนวน 8 เขื่อนใช้เกณฑ์การประเมิน RMSE ผลลัพธ์ได้ดังตารางที่ 1

ตารางที่ 1 แสดงค่า RMSE ในข้อมูลชุดฝึกฝนของแต่ละเขื่อน

ตัวแบบ	เขื่อนน้อยบำรุงแดน	ก๊วยคอง	ก๊วยหลุม	ก๊วยมู	สิริกิติ์	แม่กวาง	แม่จัต	แม่มอก
FOA-CD	140.216*	39.795*	18.175*	1585.435*	973.256*	39.998*	50.615*	19.850*
CD	140.501	39.976	18.222	1608.668	974.762	41.867	52.507	19.917
FOA-HW	98.182	18.317	11.878	669.960*	430.632*	19.364*	20.650*	11.624
Grid-HW	84.417*	16.970*	11.710*	795.823	484.464	32.488	22.932	11.587*

หมายเหตุ * คือค่า RMSE ที่มีค่าต่ำสุดระหว่างวิธี FOA-CD กับ CD และระหว่างวิธี FOA-HW กับ Grid-HW

การประเมินประสิทธิภาพของการพยากรณ์ข้อมูลชุดฝึกฝนพบว่า วิธี FOA-CD และ FOA-HW ช่วยเพิ่มความแม่นยำในการปรับค่าพารามิเตอร์ให้เหมาะสมกับข้อมูลส่งผลให้ตัวแบบ HW และ CD มีประสิทธิภาพที่ดียิ่งขึ้น โดยพิจารณาจากค่า RMSE ที่ลดลง เมื่อเปรียบเทียบระหว่างวิธี CD และ FOA-CD พบว่า วิธี FOA-CD สามารถลดค่า RMSE ลงเมื่อเทียบกับ CD อย่างชัดเจน ในขณะที่การเปรียบเทียบระหว่าง Grid-HW และ FOA-HW พบว่าทั้งสองวิธีสามารถปรับค่าพารามิเตอร์ได้อย่างเหมาะสม และให้ผลลัพธ์การพยากรณ์ที่มีความแม่นยำใกล้เคียงกัน โดยเกณฑ์การประเมิน RMSE ของทั้ง 2 วิธีมีความแตกต่างกันเพียงเล็กน้อย เมื่อพิจารณาค่า RMSE ของทั้ง 8 เขื่อน พบว่า Grid-HW ให้ค่า RMSE น้อยกว่า FOA-HW ใน 4 เขื่อน และ FOA-HW ให้ค่า RMSE น้อยกว่า Grid-HW ในอีก 4 เขื่อน ถึงแม้ว่าวิธี Grid-HW และ FOA-HW จะให้ผลลัพธ์ที่มีประสิทธิภาพใกล้เคียงกัน แต่ FOA-HW มีความโดดเด่นในเรื่องการปรับค่าพารามิเตอร์ให้เหมาะสมกับข้อมูลได้รวดเร็วกว่า

Grid-HW อย่างมาก ช่วยลดระยะเวลาในการประมวลผลได้อย่างเห็นได้ชัด และยังสามารถนำไปประยุกต์ใช้เพื่อเพิ่มความแม่นยำในการพยากรณ์ได้อย่างมีประสิทธิภาพ

2. เปรียบเทียบประสิทธิภาพในข้อมูลชุดทดสอบ

เปรียบเทียบประสิทธิภาพของตัวแบบพยากรณ์โดยใช้ข้อมูลชุดทดสอบทั้งหมด 8 เชื้อน ใช้เกณฑ์การประเมินคือ RMSE MAE และ MAPE โดยใช้เกณฑ์การคัดเลือกตัวแบบที่ดีที่สุด 2 ใน 3 ของเกณฑ์ดังกล่าว ผลการเปรียบเทียบแสดงดังตารางที่ 2 ถึงตารางที่ 4 จากการประเมิน พบว่าเชื้อนแต่ละแห่งมีตัวแบบที่ให้ผลลัพธ์ที่ดีที่สุดแตกต่างกัน โดยทำการเลือกตัวแบบที่มีประสิทธิภาพดีที่สุดตามเกณฑ์ที่กำหนด เพื่อใช้สำหรับการพยากรณ์ล่วงหน้าจำนวน 12 ค่า ซึ่งผลการคัดเลือกตัวแบบที่เหมาะสมของแต่ละเชื้อนมีดังนี้ เชื้อนแควน้อยบำรุงแดน พบว่าแม้วิธี FOA-CD จะให้ค่า MAPE ต่ำที่สุด ซึ่งหมายถึงผลการพยากรณ์มีความใกล้เคียงกับค่าจริงในแต่ละช่วงเวลาเมื่อพิจารณาเป็นเปอร์เซ็นต์ อย่างไรก็ตามเมื่อพิจารณาค่าความคลาดเคลื่อนโดยรวมจากค่า RMSE และ MAE กลับพบว่าวิธี FOA-HW ให้ผลดีกว่า ดังนั้นจึงเลือก FOA-HW เป็นตัวแบบที่เหมาะสมที่สุดสำหรับเชื้อนแควน้อยบำรุงแดน เชื้อนกัวคองมาเลือกใช้ตัวแบบ CD เชื้อนกัวลมเลือกใช้ตัวแบบ CD เชื้อนภูมิพลเลือกใช้ตัวแบบ CD เชื้อนสิริกิติ์เลือกใช้ตัวแบบ CD เชื้อนแม่กวางอุดมธราเลือกใช้ตัวแบบ FOA-HW เชื้อนแม่จัดสมบูรณ์ชลเลือกใช้ตัวแบบ FOA-HW และเชื้อนแม่มอกเลือกใช้ตัวแบบ FOA-HW ค่าพารามิเตอร์ของตัวแบบที่เลือกใช้ในแต่ละเชื้อนแสดงในตารางที่ 5 ซึ่งเป็นผลลัพธ์จากการปรับค่าพารามิเตอร์ให้เหมาะสมกับลักษณะของข้อมูลในแต่ละเชื้อน

ตารางที่ 2 เปรียบเทียบประสิทธิภาพวิธีการพยากรณ์ด้วยค่า RMSE จากการวิเคราะห์ปริมาณน้ำในเชื้อนของทั้ง 8 เชื้อน ในข้อมูลชุดทดสอบ

ตัวแบบ	แควน้อยบำรุงแดน	กัวคองมา	กัวลม	ภูมิพล	สิริกิติ์	แม่กวาง	แม่จัด	แม่มอก
FOA-CD	127.667	31.054	13.427	2,319.26	374.492	90.958	87.897	15.109
CD	126.04	27.246*	11.572*	1,836.969*	334.039*	65.745	61.423	13.708
FOA-HW	124.737*	44.887	15.294	6,067.00	641.95	39.241*	9.481*	13.170*
Grid-HW	208.971	46.199	18.415	2,725.60	811.241	55.321	36.96	19.783

หมายเหตุ * คือค่า RMSE ที่มีค่าต่ำที่สุดของแต่ละเชื้อน

ตารางที่ 3 เปรียบเทียบประสิทธิภาพวิธีการพยากรณ์ด้วยค่า MAE จากการวิเคราะห์ปริมาณน้ำในเชื้อนของทั้ง 8 เชื้อน ในข้อมูลชุดทดสอบ

ตัวแบบ	แควน้อยบำรุงแดน	กัวคองมา	กัวลม	ภูมิพล	สิริกิติ์	แม่กวาง	แม่จัด	แม่มอก
FOA-CD	101.621	26.178	10.625	2,013.36	307.01	89.382	87.26	11.547
CD	97.143	22.034*	9.147*	1,566.865*	279.126*	63.42	61.025	11.27
FOA-HW	78.828*	39.564	14.085	4,966.28	519.787	30.589*	8.040*	10.312*
Grid-HW	163.29	42.408	16.38	2,255.74	704.795	46.638	30.866	18.338

หมายเหตุ * คือค่า MAE ที่มีค่าต่ำที่สุดของแต่ละเชื้อน

ตารางที่ 4 เปรียบเทียบประสิทธิภาพวิธีการพยากรณ์ด้วยค่า MAPE จากการวิเคราะห์ปริมาณน้ำในเขื่อนของทั้ง 8 เขื่อน ในข้อมูลชุดทดสอบ

ตัวแบบ	แควน้อยบำรุงแดน	ก๊วกอหมา	ก๊วลม	ภูมิพล	สิริกิติ์	แม่กวาง	แม่จัต	แม่มอก
FOA-CD	31.617*	20.515	12.71	21.97	6.071	49.454	39.936	17.156
CD	32.466	17.947*	11.389*	17.193*	5.474*	35.152	28.406	18.763
FOA-HW	33.096	44.459	20.49	63.72	10.723	17.505*	3.576*	17.046*
Grid-HW	68.944	48.87	25.911	31.45	15.06	27.898	16.271	39.92


หมายเหตุ* คือค่า MAPE ที่มีค่าต่ำที่สุดของแต่ละเขื่อน

ตารางที่ 5 ค่าพารามิเตอร์ที่เหมาะสมที่สุดของตัวแบบ FOA-CD CD FOA-HW และ Grid-HW จากการวิเคราะห์ปริมาณน้ำในเขื่อนของทั้ง 8 เขื่อน ในข้อมูลชุดทดสอบ

ตัวแบบ	พารามิเตอร์	แควน้อยบำรุงแดน	ก๊วกอหมา	ก๊วลม	ภูมิพล	สิริกิติ์	แม่กวาง	แม่จัต	แม่มอก
FOA-CD	β_0	436.342	103.847	62.489	6215.324	5395.230	77.151	140.290	43.133
	β_1	0.441	0.006	0.031	2.19	-4.133	0.106	-0.029	0.098
CD	β_0	419.504	101.580	60.974	5906.892	5318.207	63.879	126.912	40.393
	β_1	0.661	0.065	0.062	8.568	-2.806	0.389	0.257	0.137
FOA-HW	α	0.846	0.784	0.884	0.413	0.607	0.587	0.722	0.814
	β	0.000	0.000	0.000	0.370	0.000	0.000	0.000	0.000
	γ	1.000	1.000	1.000	1.000	1.000	1.000	1.000	1.000
	δ	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Grid-HW	α	0.840	0.830	0.870	0.540	0.680	0.560	0.730	0.820
	β	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
	γ	1.000	0.853	1.000	1.000	1.000	1.000	1.000	1.000

3. พยากรณ์ล่วงหน้า 12 เดือน

จากการประเมินประสิทธิภาพของการพยากรณ์ในข้อมูลชุดทดสอบ ผู้วิจัยได้นำแต่ละวิธีพยากรณ์ที่มีความเหมาะสมของแต่ละเขื่อนมาทำพยากรณ์ล่วงหน้า 12 ค่า ได้ดังรูปที่ 4



รูปที่ 4 พยากรณ์ล่วงหน้า 12 เดือน

สรุปผลการวิจัย

การศึกษาในครั้งนี้ได้นำเสนอวิธีการคัดเลือกตัวแบบพยากรณ์ที่มีความเหมาะสมกับข้อมูลปริมาณน้ำเฉลี่ยรายเดือนในเขื่อนภาคเหนือของประเทศไทยจำนวน 8 เขื่อน ซึ่งได้แก่ เขื่อนแควน้อยบำรุงแดน เขื่อนก๊วกลม เขื่อนก๊วกคองหมา เขื่อนภูมิพล เขื่อนสิริกิติ์ เขื่อนแม่วงอุดมธารา เขื่อนแม่งัดสมบูรณ์ชล และเขื่อนแม่มอก จากเว็บไซต์กรมชลประทาน ตั้งแต่ปี พ.ศ. 2552 ถึงปี พ.ศ. 2566 จำนวน 144 ชุดข้อมูล สำหรับการสร้างตัวแบบพยากรณ์ทั้งหมด 4 วิธี ได้แก่ วิธี FOA-CD วิธี FOA-HW วิธี CD และวิธี HW ในการศึกษาครั้งนี้ได้ประยุกต์ใช้วิธี FOA ซึ่งเป็นการนำเมตาฮิวริสติกส์มาผสมผสานกับวิธีการพยากรณ์อนุกรมเวลาในการหาค่าพารามิเตอร์ที่เหมาะสมที่สุดในการพยากรณ์ ซึ่งให้ผลลัพธ์ที่ดีกว่าวิธีเดิมในข้อมูลชุดฝึกฝน ซึ่งสอดคล้องกับงานวิจัย ปราณและวสุธา (2567a, 2567b) Minsan and Minsan (2023, 2024) และ Minsan *et al.* (2024) ที่แสดงให้เห็นว่าการใช้วิธีผสมผสานระหว่างการพยากรณ์อนุกรมเวลากับเมตาฮิวริสติกส์ดีกว่าวิธีเดิม

ในการเปรียบเทียบประสิทธิภาพในชุดทดสอบในตารางที่ 2 ถึงตารางที่ 4 โดยใช้เกณฑ์การประเมิน RMSE MAE และ MAPE โดยพิจารณาค่าที่ดีที่สุด 2 ใน 3 พบว่า ตัวแบบ FOA-HW ให้ผลลัพธ์ที่แม่นยำที่สุดใน 4 เขื่อน ได้แก่ เขื่อนแควน้อยบำรุงแดน เขื่อนแม่วงอุดมธารา เขื่อนแม่งัดสมบูรณ์ชล และเขื่อนแม่มอก ขณะที่ตัวแบบ CD ให้ผลลัพธ์ที่ดีที่สุดในอีก

4 เชื้อน ได้แก่ เชื้อนแก้วคอกหมา เชื้อนแก้วลม เชื้อนภูมิพล และเชื้อนสิริกิติ์ แสดงให้เห็นว่าประสิทธิภาพของตัวแบบขึ้นอยู่กับลักษณะของข้อมูลของแต่ละเชื้อนโดยหากข้อมูลมีความไม่แน่นอนหรือเปลี่ยนแปลงตามเวลาตัวแบบ FOA-HW จะเหมาะสมกว่า ในขณะที่ข้อมูลที่มีความคงที่และรูปแบบสม่ำเสมอจะเหมาะสมกับการใช้ตัวแบบ CD มากกว่า

เอกสารอ้างอิง

- ทรงศิริ แด่สมบัติ. (2539). เทคนิคการพยากรณ์เชิงปริมาณ. พิมพ์ครั้งที่ 1. กรุงเทพฯ: สำนักพิมพ์ฟิสิกส์เซ็นเตอร์. 337 หน้า.
- รอยล จิตรดอน. (2564). 'วิกฤติน้ำ' ปี 64 แล้งหนัก-น้ำเค็มรุก. กรุงเทพธุรกิจ. แหล่งข้อมูล: <https://www.bangkokbiznews.com/social/925562>. ค้นเมื่อวันที่ 5 ธันวาคม 2567.
- ศานิกานต์ เสนิงค์. (2565). เราได้อะไรมา และเสียอะไรไปจากการสร้างเขื่อน. สถาบันส่งเสริมการสอนวิทยาศาสตร์และเทคโนโลยี (สสวท.). แหล่งข้อมูล: <https://www.ipst.ac.th/knowledge/knowledge-article/article-primary-science/31776/damp.html>. ค้นเมื่อวันที่ 25 ธันวาคม 2567.
- ศูนย์ประมวลวิเคราะห์สถานการณ์น้ำ กรมชลประทาน. (2567). ตารางสรุปข้อมูลอ่างขนาดใหญ่ทั่วประเทศ. แหล่งข้อมูล: https://water.rid.go.th/flood/flood/res_table.htm. ค้นเมื่อวันที่ 20 มกราคม 2567.
- ปรารธนา มินเสน และวรา มินเสน (2567a). การพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือน ในภาคตะวันออกเฉียงเหนือของประเทศไทย โดยการค้นหาค่าเหมาะที่สุดแบบนกเขาว่าปรับปรุงเทคนิค การแยกส่วนประกอบและโพลต์-วินเทอร์. วารสารไทยการวิจัยดำเนินงาน 12(2): 69 - 89.
- ปรารธนา มินเสน และวรา มินเสน (2567b). เทคนิคการแยกส่วนประกอบ และ โพลต์-วินเทอร์ ที่ได้รับการปรับปรุงด้วยขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬ: กรณีศึกษาการพยากรณ์ PM2.5 ใน 8 จังหวัดภาคเหนือของประเทศไทย. วารสารวิทยาศาสตร์และเทคโนโลยี 32(6): 12 - 34.
- Belton, V. and Stewart, T.J. (2002). Multiple Criteria Decision Analysis: An Integrated Approach. Springer.
- Dorigo, M., Birattari, M. and Stutzle, T. (2006). Ant colony optimization. IEEE Computational Intelligence Magazine 1(4): 28 – 39. doi: 10.1109/MCI.2006.329691.
- Goldberg, D.E. and Holland, J.H. (1988). Genetic Algorithms and Machine Learning. Machine Learning 3: 95 – 99. doi: 10.1023/a:1022602019183.
- Jiang, W., Wu, X., Gong, Y., Yu, W. and Zhong, X. (2020). Holt-Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption. Energy 193: 116779. doi: 10.1016/j.energy.2019.116779.
- Kennedy, J. and Eberhart, R. (1995). Particle Swarm Optimization. In: the IEEE International Conference on Neural Networks. Proceedings of ICNN'95 - International Conference on Neural Networks. Perth, Australia 4: 1942 - 1948. doi: 10.1109/ICNN.1995.488968.
- Khairalla, M. (2022). Meta-Heuristic Search Optimization and its application to Time Series Forecasting Model. Intelligent Systems with Applications 16: 200142. doi: 10.1016/j.iswa.2022.200142.
- Mirjalili, S. and Lewis, A. (2016). The Whale Optimization Algorithm. Advances in Engineering Software 95: 51 - 67. doi: 10.1016/j.advengsoft.2016.01.008.
- Minsan, W. and Minsan, P. (2023). Incorporating Decomposition and the Holt-Winters Method into the Whale Optimization Algorithm for Forecasting Monthly Government Revenue in Thailand. Science & Technology Asia 28(4): 38 - 53.

- Minsan, W. and Minsan, P. (2024). Decomposition and Holt-Winters Enhanced by the Whale Optimization Algorithm for Forecasting the Amount of Water Inflow into the Large Dam Reservoirs in Southern Thailand. *Journal of Current Science and Technology* 14(2): 38
- Minsan, W., Minsan, P. and Panichkitkosolkul, W. (2024). Enhancing Decomposition and Holt-Winters Weekly Forecasting of PM2.5 Concentrations in Thailand's Eight Northern Provinces Using the Cuckoo Search Algorithm. *Thailand Statistician* 22(4): 963 - 985.
- Pan, W.T. (2012). A new Fruit Fly Optimization Algorithm: Taking the financial distress model as an example. *Knowledge-Based Systems* 26: 69 - 74. doi: 10.1016/j.knosys.2011.07.001.
- Wang, L., Shi, Y. and Liu, S. (2015). An improved fruit fly optimization algorithm and its application to joint replenishment problems. *Expert Systems with Applications* 42(9): 4310 - 4323.
- Winters, P.R. (1960). Forecasting Sales by Exponentially Weighted Moving Averages. *Management Science* 6(3): 324 - 342.
- Yang, X.S. (2009). Firefly Algorithms for Multimodal Optimization. In: *Stochastic Algorithms: Foundations and Applications*. Watanabe, O. and Zeugmann, T. (Eds.), Lecture Notes in Computer Science. Springer, Berlin. 169 – 178.
- Yang, X.S., and Deb, S. (2009). Cuckoo Search via Lévy flights. In: *World Congress on Nature & Biologically Inspired Computing (NaBIC 2009)*. IEEE Publications, Coimbatore, India. 201 - 214. doi: 10.1109/NaBIC.2009.5393690.

