

การพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือน ในภาคตะวันออกเฉียง
ประเทศไทย โดยการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่าปรับปรุงเทคนิค
การแยกส่วนประกอบและโฮสต์-วินเทอร์

ปรารถนา มินเสน^{*1}

ภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ เชียงใหม่ 50300

และ วรธา มินเสน²

ศูนย์วิจัยวิทยาการข้อมูล ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ เชียงใหม่ 50200

Received: 03 April 2024; Revised: 26 June 2024; Accepted: 09 July 2024

บทคัดย่อ

การศึกษานี้มีจุดประสงค์เพื่อประเมินประสิทธิภาพของตัวแบบ จากการผสมการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮสต์-วินเทอร์ (CS-HW) และค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบ (CS-D) ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือนในภาคตะวันออกเฉียงของประเทศไทยทั้งหมดจำนวน 6 เขื่อน เมื่อเทียบกับตัวแบบ ค้นหาแบบกริดของโฮสต์-วินเทอร์ (Grid-HW) และแยกส่วนประกอบแบบคลาสสิก (Classic-D) โดยใช้ชุดข้อมูลฝึกฝนจำนวน 66 เดือน และใช้เกณฑ์ค่าน้อยที่สุดของความคลาดเคลื่อนสมบูรณ์เฉลี่ย (MAE) เพื่อประเมินประสิทธิภาพของตัวแบบ ผลการศึกษาพบว่า CS-D และ CS-HW มีประสิทธิภาพสูงกว่า โดย CS-D แสดงค่า MAE ที่ต่ำกว่า Classic-D อย่างชัดเจน ในขณะที่ CS-HW มีค่า MAE ที่ต่ำกว่า Grid-HW อยู่เล็กน้อยในทุกเขื่อน

ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนล่องหน้ำในระยะยาว 24 เดือน จากชุดข้อมูลทดสอบ ใช้เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) MAE และร้อยละความคลาดเคลื่อนสมบูรณ์เฉลี่ยแบบสมมาตร (sMAPE) เป็นเครื่องมือในการประเมินประสิทธิภาพของตัวแบบ ผลการศึกษาพบว่า เขื่อนขุนด่านปราการชลเลือกตัวแบบค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮสต์-วินเทอร์รูปแบบบวก (CS-HW+) เขื่อนคลองสิียดเลือกตัวแบบค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮสต์-วินเทอร์รูปแบบคูณ (CS-HWx) เขื่อนนฤพดินทร์จินดาเลือกตัวแบบ Box-Jenkins เขื่อนบางพระเลือกตัวแบบค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบรูปแบบคูณ (CS-Dx) เขื่อนประแสร์เลือกตัวแบบค้นหาแบบกริดของโฮสต์-วินเทอร์รูปแบบคูณ (Grid-HWx) และหนองปลาไหลเลือกตัวแบบค้นหาแบบกริดของโฮสต์-วินเทอร์รูปแบบบวก (Grid-HW+) โดยการพยากรณ์ล่องหน้ำ 24 เดือน แสดงให้เห็นว่าปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนมีฤดูกาลชัดเจน

คำสำคัญ: การพยากรณ์, อ่างเก็บน้ำเขื่อน, ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่า, แยกส่วนประกอบ, โฮสต์-วินเทอร์

* Corresponding author. E-mail: pradthana_min@sc.cmru.ac.th

¹ ผู้ช่วยศาสตราจารย์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่

² ผู้ช่วยศาสตราจารย์ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่

Monthly Volumes of Water Inflow into the Large Dam Reservoirs in Eastern Thailand Forecasting by The Cuckoo Search Optimization Enhanced Decomposition and Holt-Winters Techniques

Pradthana Minsan^{*1}

Department of Mathematics and Statistics, Faculty of Science and Technology,
Chiang Mai Rajabhat University, Chiang Mai 50300

and Watha Minsan²

Data Science Research Center, Department of Statistics, Faculty of Science,
Chiang Mai University, Chiang Mai 50200

Received: 03 April 2024; Revised: 26 June 2024; Accepted: 09 July 2024

Abstract

This study aims to evaluate the efficiency of models through the integration of Cuckoo Search Optimization (CS) with Holt-Winters (CS-HW) and Decomposition (CS-D) for forecasting monthly inflow volumes into large dam reservoirs in Eastern Thailand, covering a total of 6 dams. This is compared with the Grid Search of Holt-Winters (Grid-HW) and the Classic Decomposition Model (Classic-D) using a training dataset spanning 66 months, and employing the Mean Absolute Error (MAE) as the criterion for the lowest MAE to assess model performance. The findings indicate that both CS-HW and CS-D models outperform traditional models, with CS-D demonstrating a significantly lower MAE than Classic-D, while CS-HW shows marginally lower MAE values than Grid-HW across all dams.

For the long-term forecasting of dam reservoir inflow volumes over a 24-month horizon using a test dataset, criteria including Root Mean Square Error (RMSE), MAE, and Symmetric Mean Absolute Percentage Error (sMAPE) were utilized to evaluate model performance. The results show that for different dams, specific models were chosen as best fitting: Khun Dan Prakan Chon Dam selected the CS with Additive Holt-Winters (CS-HW+), Khlong Siyat chose the CS with Multiplicative Holt-Winters (CS-HWx), Naruebodindrashinta Dam opted for the Box-Jenkins model, Bang Phra Dam for the CS with Multiplicative Decomposition (CS-Dx), Prasae Dam for the Grid Search of Multiplicative Holt-Winters (Grid-HWx), and Nong Pla Lai for the Grid Search of Additive Holt-Winters (Grid-HW+). The outcome of the 24-month forecasting demonstrates clear seasonal patterns in the reservoir inflow volumes to the dams.

Keywords: forecasting, dam reservoir, cuckoo search optimization, decomposition, Holt-Winters

* Corresponding author. E-mail: pradthana_min@g.cmru.ac.th

¹ Assistant Professor in Faculty of Science and Technology, Chiang Mai Rajabhat University

² Assistant Professor in Faculty of Science, Chiang Mai University

1. บทนำ

ช่วงเวลาที่ผ่านมาถือเป็นวิวัฒนาการที่สำคัญในการผสมผสานระหว่างการพยากรณ์อนุกรมเวลาและวิธีการเมตาฮีวิริสติกส์ ทั้งนี้เทคนิคการพยากรณ์อนุกรมเวลาได้รับการส่งเสริมอย่างต่อเนื่องจากการพัฒนาเมตาฮีวิริสติกส์ใหม่ๆ ในช่วง 30-40 ปีนี้ เมื่อพิจารณาขั้นตอนวิธีเมตาฮีวิริสติกส์ที่ได้รับแรงบันดาลใจจากธรรมชาติ (Nature-inspired meta-heuristics) ช่วยแก้ปัญหาด้วยการเลียนแบบปรากฏการณ์ทางชีวภาพหรือทางกายภาพในธรรมชาติ โดยทั่วไปแบ่งกลุ่มออกได้เป็น สามประเภทหลัก คือ อิงตามวิธีวิวัฒนาการ (Evolution-based) อิงตามวิธีฟิสิกส์ (Physics-based) และอิงตามวิธีแบบกลุ่ม (Swarm-based) เมื่อเฉพาะเจาะจงลงไปในกลุ่ม เมตาฮีวิริสติกส์อิงตามวิธีแบบกลุ่มที่เลียนแบบพฤติกรรมทางสังคมของกลุ่มสัตว์ เริ่มต้นด้วย พ.ศ. 2535 มีการนำเสนอ การหาค่าเหมาะที่สุดอาณานิคม (Ant colony optimization: ACO) ของ Dorigo [1] ที่ทำวิทยานิพนธ์ เลียนแบบพฤติกรรมของฝูงมด และนำมาพัฒนาตีพิมพ์เผยแพร่ร่วมกับ Dorigo et al. [2] นำเสนอในปี พ.ศ. 2549 ตามด้วย Kennedy & Eberhart [3] การหาค่าเหมาะที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization: PSO) นำเสนอในปี พ.ศ. 2538 ที่ได้ปูทางไปสู่ยุคความนิยมของขั้นตอนวิธีแบบกลุ่ม เพราะมีความก้าวหน้าในแนวทางนี้เพิ่มขึ้นมากมาย ผลงานที่โดดเด่น ได้แก่ การหาค่าเหมาะที่สุดสมรสในผึ้ง (Marriage in honey bees optimization) โดย Abbass [4] นำเสนอในปี พ.ศ. 2544 ขั้นตอนวิธีฝูงปลาเทียม (Artificial fish-swarm algorithm) โดย Li [5] นำเสนอในปี พ.ศ. 2546 ขั้นตอนวิธีปลวก (Termite algorithm) โดย Martin and Stephen [6] นำเสนอในปี พ.ศ. 2549 อาณานิคมผึ้งเทียม (Artificial Bee Colony: ABC) โดย Basturk and Karaboga [7] นำเสนอในปี พ.ศ. 2549 เป็นวิธีที่ได้รับความนิยมสูงในการนำไปประยุกต์ใช้

ในปี พ.ศ. 2550 มี 3 วิธีที่นำเสนอ คือ ขั้นตอนวิธีฝูงตัวต่อ (Wasp swarm algorithm) โดย Pinto et al. [8] การค้นหาลิง (Monkey search) โดย Mucherino & Seref [9] และขั้นตอนวิธีการค้นหาฝูงหมาป่า (Wolf pack search algorithm) โดย Yang et al. [10] หลังจากนั้น ในปี พ.ศ.

2551 ขั้นตอนวิธีการเก็บเกสรของผึ้ง (Bee collecting pollen algorithm) ก็ถูกนำเสนอโดย Lu & Zhou [11] การหาค่าเหมาะที่สุดพันธมิตรปลาโลมา (dolphin partner optimization) ถูกนำเสนอโดย Shiqin et al. [12] ในปี พ.ศ. 2552 และในปีเดียวกันนี้ Yang & Deb [13] แนะนำวิธีใหม่ การค้นหาค่าเหมาะที่สุดแบบนกกาเหว่า (Cuckoo search optimization: CS) ซึ่งเป็นวิธีที่นิยมใช้อย่างกว้างขวางโดยในเฉพาะบทความแรกที่นำเสนอวิธีการนี้ของ Yang and Deb มีการอ้างอิงที่ถูกระบุในเว็บไซต์ IEEE Xplore ไปแล้วกว่า 3,612 บทความ (สืบค้นเมื่อ 28 มีนาคม พ.ศ. 2567)

จากการพัฒนาเมตาฮีวิริสติกส์ที่หลากหลาย การผสมผสานวิธีการพยากรณ์และเมตาฮีวิริสติกส์จึงเพิ่มขึ้นด้วยเช่นเดียวกัน ในบรรดาวิธีเหล่านี้ วิธีการหาค่าเหมาะที่สุดการจับกลุ่มอนุภาคประพฤติกรรมแบบควอนตัม (Quantum-behaved particle swarm optimization: QPSO) ซึ่งนำโดย Sun et al. [14] นำเสนอในปี พ.ศ. 2547 ได้จุดประกายความสนใจเป็นพิเศษ วิธีนี้มีความยืดหยุ่นที่โดดเด่นจึงทำให้ถูกนำไปประยุกต์ใช้ในการพยากรณ์ที่ซับซ้อน Cheng et al. [15] ในปี พ.ศ. 2558 ใช้ QPSO เพื่อพัฒนาแบบจำลองการพยากรณ์ปริมาณน้ำไหลบ่าเข้าอ่างเก็บน้ำรายวันที่ผสมร่วมกับโครงข่ายประสาทเทียม (Artificial neural networks) Niu et al. [16] ในปี พ.ศ. 2561 ขยายขอบเขตการใช้ QPSO ควบคู่ไปกับ การเรียนรู้ของเครื่องสุดขีด (Extreme learning machine) เพื่อพยากรณ์ข้อมูลอนุกรมเวลาทางอุทกวิทยาสำหรับอ่างเก็บน้ำ ชินเฟิงเจียง ในประเทศจีน Feng et al. [17] ในปี พ.ศ. 2563 พยากรณ์ปริมาณน้ำไหลบ่ารายเดือน โดยการรวม QPSO เข้ากับการแยกส่วนประกอบโหมดการเปลี่ยนแปลง (Variational mode decomposition) และ ซัพพอร์ตเวกเตอร์แมชชีน (Support vector machines) นอกจากนี้ Hadavandi et al. [18] ในปี พ.ศ. 2553 ใช้ PSO เพื่อพัฒนาตัวแบบอนุกรมเวลาสำหรับการพยากรณ์ราคาทองคำ Kaewpaengjuntra et al. [19] ในปี พ.ศ. 2553 พยากรณ์ปริมาณการใช้ไฟฟ้ารายเดือนในประเทศไทยด้วยวิธีการทำให้เรียบเลขชี้กำลังของโฮลต์-วินเทอร์ (Holt-Winters: HW) ผสานกับวิธี ABC และ

ในปี พ.ศ. 2556 Assis et al. [20] บูรณาการ HW กับ ขั้นตอนวิธี ACO

ในทำนองเดียวกัน Simoni et al. [21] ในปี พ.ศ. 2558 นำ PSO ผสานกับ HW สำหรับการเพิ่มประสิทธิภาพการพยากรณ์ในโรงไฟฟ้าพลังน้ำ ต่อมา Minsan & Minsan [22] ในปี พ.ศ. 2566 ได้นำเสนอแนวทางที่แสดงถึงการผสมผสานกันระหว่างตัวแบบการแยกส่วนประกอบรูปแบบบวกร่วมกับ ขั้นตอนวิธี การหาค่าเหมาะที่สุดของวาฬ (Whale Optimization Algorithm: WOA) และตัวแบบ HW รูปแบบบวกร่วมกับ WOA ซึ่งผลลัพธ์ในการผสมผสานนั้นได้ผลดีทั้งในช่วงการฝึกฝนตัวแบบ และการทดสอบตัวแบบ ในปีต่อมา Minsan & Minsan [23] ได้ต่อยอดการผสมผสานกันระหว่างตัวแบบการแยกส่วนประกอบ และ HW โดยจัดทำทั้งตัวแบบรูปแบบบวกและรูปแบบคูณ ร่วมกับ WOA ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือน ในภาคใต้ของประเทศไทย 4 แห่ง ซึ่งผลลัพธ์ในการผสมผสานนั้นได้ผลดีทั้งในช่วงการฝึกฝนตัวแบบ และการทดสอบตัวแบบเช่นกัน สุดท้าย Mauricio & Ostia [24] ในปี พ.ศ. 2566 ได้ใช้ CS อย่างมีประสิทธิภาพ เพื่อปรับปรุงวิธี HW โดยการปรับพารามิเตอร์ 3 ค่า ได้แก่ α , γ และ δ ในการพยากรณ์โหลดของหม้อแปลงไฟฟ้าระบบจำหน่าย

ในการศึกษานี้พวกเราใช้วิธีการ CS ในมาพัฒนาต่อยอดจากจาก Mauricio & Ostia [24] โดยนำเทคนิคในการผสมผสานกันจาก Minsan & Minsan [22-23] ที่ใช้ได้ผลดีทั้งในช่วงการฝึกฝนตัวแบบ และการทดสอบตัวแบบ เพื่อประมาณค่าพารามิเตอร์ในวิธีการ HW ที่มีจำนวนพารามิเตอร์ของตัวแบบที่ต้องประมาณจำนวน 3 ตัว และผสมผสานวิธีการ CS กับเทคนิคการแยกส่วนประกอบ ในการสร้างตัวแบบการพยากรณ์ด้วยจำนวนพารามิเตอร์ที่ต้องประมาณ 14 ตัว โดยในการศึกษานี้เราเลือกข้อมูลที่มีคุณสมบัติตามความต้องการเบื้องต้นของตัวแบบการพยากรณ์ HW และการแยกส่วนประกอบ คือข้อมูลปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่ในภาคตะวันออกเฉียงของประเทศไทยทั้งหมด มีจำนวน 6 เขื่อน โดยใช้ประโยชน์จากความสามารถของการเรียนแบบธรรมชาติของการวางไข่ของนกกาเหว่า ซึ่งเป็นวิธีการหาค่าที่เหมาะสมที่มีคุณภาพ ช่วยเพิ่มความแม่นยำและประสิทธิภาพของตัวแบบการพยากรณ์ในการ

วิเคราะห์หอนุกรมเวลา ในหัวข้อถัดไปเราจะกล่าวถึงการนำ CS ไปผสานกับ HW และการแยกส่วนประกอบ อย่างครอบคลุมทั้งขั้นตอนการดำเนินการ รหัสเทียม และสมการการคำนวณ

2. วิธีดำเนินการวิจัย

2.1 ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่า

เป็นเทคนิคการปรับแต่งที่เลียนแบบจากธรรมชาติพัฒนาโดย Yang & Deb [13] ในปี พ.ศ. 2552 ที่ซึ่งเลียนแบบพฤติกรรมกรวางไข่ของนกกาเหว่าบางชนิด ซึ่งนกเหล่านี้วางไข่ในรังของนกเจ้าบ้านตัวอื่นๆ โดยหวังว่าเจ้าของรังจะเลี้ยงลูกนกกาเหว่าเหมือนลูกนกของมันเอง หรือเมื่อนกที่เป็นเจ้าของรังพบไข่ที่ไม่ใช่ไข่ของตัวเอง มันอาจจะทิ้งไข่นั้นไป หรือทิ้งรังเดิมและสร้างรังใหม่ที่อื่น วิธีการดำรงสายพันธุ์แบบนี้เป็นวิธีการที่ได้ผลลัพธ์ที่ดี

วิธี CS ถูกนำไปประยุกต์ใช้มากมายและมีประสิทธิภาพในการแก้ปัญหาในขอบเขตที่หลากหลาย ตั้งแต่การออกแบบทางวิศวกรรม ไปจนถึงการประยุกต์ใช้ในการเรียนรู้ของเครื่อง จุดเด่นของ CS คือ ความเรียบง่ายและความสามารถในการหลีกเลี่ยงค่าไม่ใหติดอยู่ในค่าต่ำสุดเฉพาะที่ (Local optima) ทำให้เป็นเครื่องมือที่มีความยืดหยุ่นสูงสำหรับงานปรับแต่งค่าพารามิเตอร์ที่ต้องการหาค่าที่เหมาะสมที่เป็นปัญหาซับซ้อนได้ดี

เพื่อให้ง่ายต่อการเข้าใจ หลักการพื้นฐานของขั้นตอนวิธี CS แบบมาตรฐาน สามารถอธิบายได้จากกฎพื้นฐาน 3 ประการ

การวางไข่แบบสุ่มและการเลือกรัง นกกาเหว่าแต่ละตัววางไข่ 1 ฟอง ในรังที่เลือกแบบสุ่ม เพื่อความง่ายในการใช้งานจะกำหนดว่าจำนวนไข่ รัง และนกกาเหว่ามีจำนวนเท่ากัน นกกาเหว่าแต่ละตัวแทนคำตอบที่เป็นไปได้ วางไข่ 1 ฟองในรังที่เลือกแบบสุ่ม รังที่เลือกนั้นจะเป็นคำตอบใหม่ ดังนั้นรังเหล่านี้แทนคำตอบต่างๆ สำหรับปัญหาการหาค่าที่เหมาะสมที่สุด

การอยู่รอดของผู้ที่เหมาะสมที่สุด คือ รังที่ดีที่สุด รังที่มีไข่อุณหภูมิสูงที่สุดแทนผลลัพธ์ที่ดีที่สุด จะถูกเก็บไว้สำหรับรุ่นต่อไป กลไกการคัดเลือกนี้รับประกันว่าเฉพาะ

คำตอบที่มีแนวโน้มดีมากที่สุดเท่าที่นั้นที่จะถูกเก็บรักษาไว้ ซึ่งเลียนแบบหลักการวิวัฒนาการของการอยู่รอดของผู้ที่เหมาะสมที่สุด

ความน่าจะเป็นในการค้นพบ เนื่องจากจำนวนรังมีจำกัด จึงมีความน่าจะเป็นในการค้นพบไขของนกกาเหว่าแต่ละฟองจากเจ้าของรัง คือ $p_a \in (0,1)$ ความน่าจะเป็นนี้จะกำหนดว่านกเจ้าของรังจะทิ้งไขของนกกาเหว่าออก หรือทิ้งรังและสร้างรังใหม่ (มีความหมายเหมือนกันแล้วแต่จะเรียกว่าทิ้งไขของนกกาเหว่า หรือทิ้งรัง)

ขั้นตอนวิธี CS ใช้แนวคิดของการจำลองการบินแบบเลวี (Lévy flights) เพื่อจำลองพฤติกรรมการค้นหารังของนกกาเหว่าผ่านกระบวนการเดินสุ่ม (Random walk) การบินแบบเลวีเป็นรูปแบบเฉพาะของการเดินสุ่มที่มีระยะก้าว (Step length) ที่เป็นการแจกแจงหางหนา (Heavy-tailed distribution) กลไกการบินแบบเลวีนี้ ช่วยให้ขั้นตอนวิธีสามารถเดินสุ่มแบบเฉพาะที่ (Localized random walk) สลับกับการกระโดดไกล (Longer jumps) ซึ่งเป็นกลยุทธ์ที่มีประสิทธิภาพในการหลีกเลี่ยงค่าต่ำสุดเฉพาะที่ และช่วยให้สำรวจพื้นที่ค้นหาคำตอบได้อย่างครอบคลุมมากขึ้น

เวกเตอร์การเคลื่อนที่ของนกกาเหว่า X_i^{t+1} ถูกสร้างขึ้นโดยการบินแบบเลวี วิธีการนี้มีรายละเอียดใน Yang [25] ดังนี้

$$X_i^{t+1} = X_i^t + \alpha \text{Lévy}(s, \lambda) Z \quad (1)$$

โดยที่ X_i^t เป็นนกกาเหว่า i ในรอบที่ t และ $\text{Lévy}(s, \lambda) = s(X_i^t - X^*)$ และ $Z \sim N(0,1)$ ซึ่ง Z มีการแจกแจงปกติมาตรฐาน คำตอบที่ดีที่สุดในปัจจุบันคือ X^* ในขั้นตอนวิธีของ Mantegna ขนาดของการก้าว s จะคำนวณโดยใช้การแจกแจงปกติ U และการแจกแจงปกติ

มาตรฐาน V โดยผ่านการคำนวณ ตามที่อธิบายโดย Mantegna [26] ตามสมการที่ (2) ต่อไปนี้

$$s = \frac{U}{|V|^{1/\lambda}} \quad (2)$$

โดยที่ $U \sim N(0, \sigma^2), V \sim N(0,1)$

ในที่นี้ U มาจากการแจกแจงแบบปกติ ซึ่งมีค่าเฉลี่ยเป็น 0 และความแปรปรวนเป็น σ^2 โดยความแปรปรวนสามารถคำนวณได้ตามสมการที่ (3) ดังนี้

$$\sigma^2 = \left(\frac{\Gamma(1+\lambda)}{\lambda \Gamma((1+\lambda)/2)} \cdot \frac{\sin(\pi \lambda/2)}{2^{(\lambda-1)/2}} \right)^{1/\lambda} \quad (3)$$

โดยที่ Γ เป็นฟังก์ชันแกมมา และ Yang [25] กำหนดพารามิเตอร์เลวี $\lambda=1.5$ ดังนั้นค่า σ^2 จึงมีค่าเท่ากับ 0.6965745 และปัจจัยการปรับขนาดขั้นตอน $\alpha=0.01$

ในกรณีที่เกี่ยวข้องกับกระบวนการที่นกที่เป็นเจ้าของรังอาจจะทิ้งรัง (ทิ้งไข) ด้วยความน่าจะเป็น $p_a \in (0,1)$ ความน่าจะเป็นที่กำหนดเพื่อสร้างรังใหม่ จึงเริ่มจากตัวเลขสุ่ม $p \in (0,1)$ ถ้า $p < p_a$ แล้วเวกเตอร์ X_i^{t+1} จะถูกเลือกและแก้ไขการคำนวณตามสมการที่ (4) ในกรณีไม่ถูกเลือกก็จะไม่มีการเปลี่ยนแปลงค่า การคำนวณเวกเตอร์มีรายละเอียดดังนี้

$$X_i^{t+1} = X_i^t + Z(X_j^t - X_k^t) \quad (4)$$

โดยที่ X_j^t และ X_k^t เป็นเวกเตอร์ที่เลือกแบบสุ่มโดยการเรียงสับเปลี่ยน

Yang [25] แนะนำจำนวนนกกาเหว่า n เท่ากับ 15 ถึง 40 (โดยค่าเริ่มต้นคือ 25) และกำหนดนกที่เป็นเจ้าของรังอาจจะทิ้งรัง $p_a = 0.25$ ซึ่งเพียงพอสำหรับการนำไปใช้งานในปัญหาส่วนใหญ่

ขั้นตอนของ CS มีการสรุปไว้อย่างกระชับในรหัสเทียม (Pseudo code) ในรูปที่ 1

The number of bird host nests: n , the number of parameters: d , the maximum number of iterations: T_{\max} , the time limit: $MaxTime$, and the fitness value fails to improve after a specified number of iterations: $T_{improve}$.

Objective function $f(X), X = (x_1, \dots, x_d)^T$.

Generate initial population of n host nests $X_i (i=1,2,\dots,n)$.

While ($t < T_{\max}$) or (time $< MaxTime$) or (the fitness value fails to improve after a specified $T_{improve}$)

For $i = 1$ to n

Get a cuckoo i by performing Lévy flights equation (1).

Calculate fitness of a cuckoo i .

Update a host nest X_i if there is a better solution.

```

End for
For  $i = 1$  to  $n$ 
    Random  $p$ 
    If ( $p < p_a$ ),
        A worse nest is abandoned and new one is built equation (4).
        Calculate fitness of a new nest  $i$ .
        Update a host nest  $X_i$  if there is a better solution.
    End if
End for
Rank the solutions and find the current best  $X^*$ , update  $t = t + 1$ .
End while
Return  $X^*$ .
    
```

รูปที่ 1 รหัสเทียมของ CS

2.2 การเตรียมข้อมูล

การศึกษานี้ใช้ข้อมูลทุติยภูมิจากกรมชลประทาน [27] ข้อมูลอนุกรมเวลารายวันตั้งแต่ 1 กรกฎาคม 2559 ถึง 31 ธันวาคม 2566 ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่ในภาคตะวันออกเฉียงของประเทศไทยจำนวนทั้งหมด ซึ่งมีด้วยกัน 6 แห่ง ได้แก่ ขุนด่านปราการชล คลองสิียด นฤบดินทร์จินดา บางพระ ประแสร์ และหนองปลาไหล โดยแต่ละแห่งมีจำนวน 2,740 ค่า ทำความสะอาดชุดข้อมูลโดยปรับค่านอกเกณฑ์ (Outlier) ที่มีปริมาณน้ำไหลเข้าอ่างผิดปกติ โดยการแก้ไข (Interpolation) ด้วยวิธีการหาค่าเฉลี่ยอย่างง่าย (Simple average) เป็นการปรับปรุงค่านอกเกณฑ์ โดยไม่มีผลกระทบต่อค่าเฉลี่ยทั่วไปของข้อมูล ซึ่งยังคงแสดงให้เห็นถึงลักษณะทางสถิติของชุดข้อมูลได้

สำหรับค่านอกเกณฑ์ ณ เวลา t หาค่าเฉลี่ยจากจุดข้อมูลก่อนหน้าและจุดถัดไปตามสมการที่ (5)

$$x_t = \frac{x_{t-1} + x_{t+1}}{2} \tag{5}$$

โดยค่านอกเกณฑ์ที่ตรวจสอบพบมีเพียง 4 ค่าจากข้อมูลทั้งหมด 6 ชุด จำนวน $2,740 \times 6 = 16,440$ ค่า ดังนี้

1 ค่าที่ ขุนด่านปราการชล วันที่ 24 มกราคม 2566

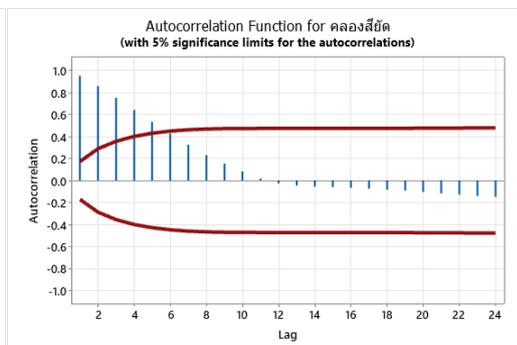
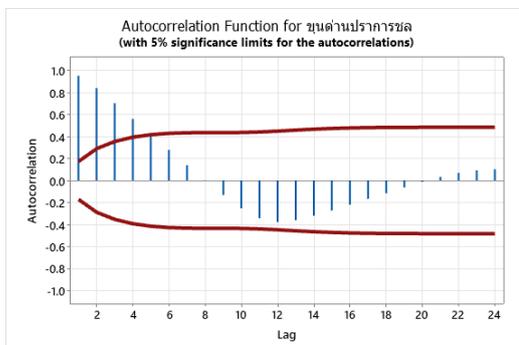
1 ค่าที่ นฤบดินทร์จินดา วันที่ 16 ตุลาคม 2563

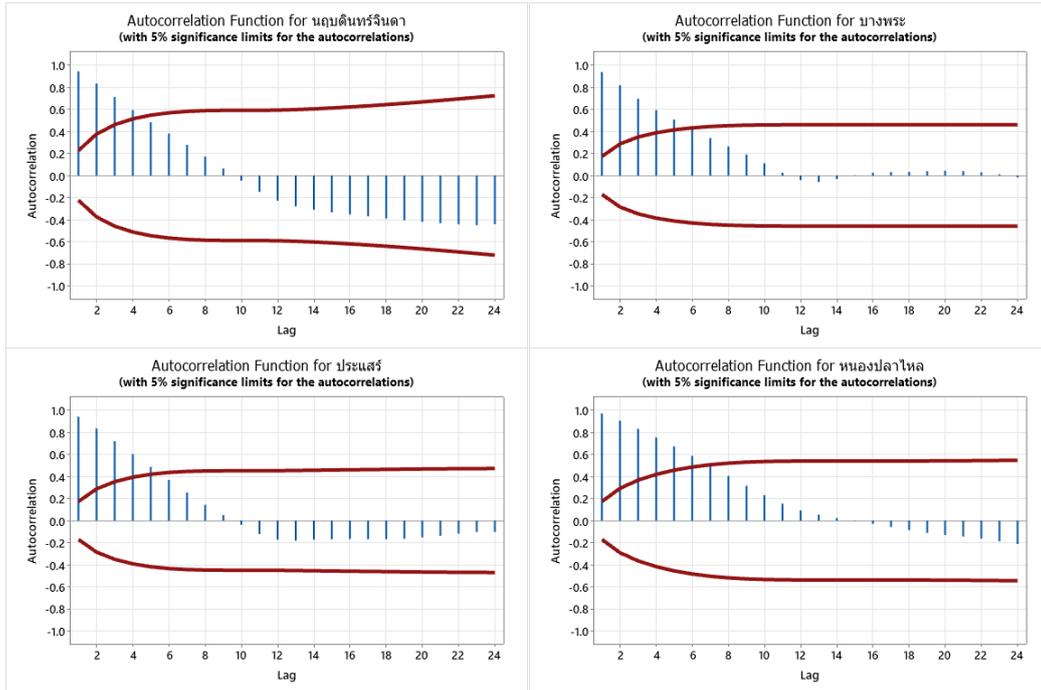
2 ค่าที่ หนองปลาไหล วันที่ 28 กันยายน 2562

และ 19 ธันวาคม 2563

หลังจากนั้นนำข้อมูลรายวันรวมเป็นข้อมูลรายเดือน ดังนั้นเดือนแต่ละแห่งมีจำนวน 90 เดือน

ชุดข้อมูลแสดงส่วนประกอบทั้งฤดูกาลและแนวโน้มโดยธรรมชาติ และสามารถวิเคราะห์โดยใช้ฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation: ACF) ที่ปรากฏในรูปที่ 2 ข้อมูลอนุกรมเวลาการปรับฤดูกาล





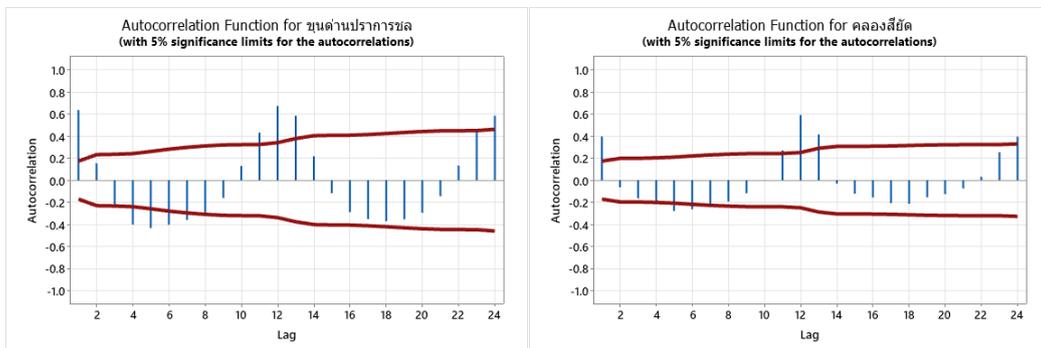
รูปที่ 2 ACF ของข้อมูลอนุกรมเวลาการปรับฤดูกาลของอ่างเก็บน้ำเขื่อน 6 แห่ง

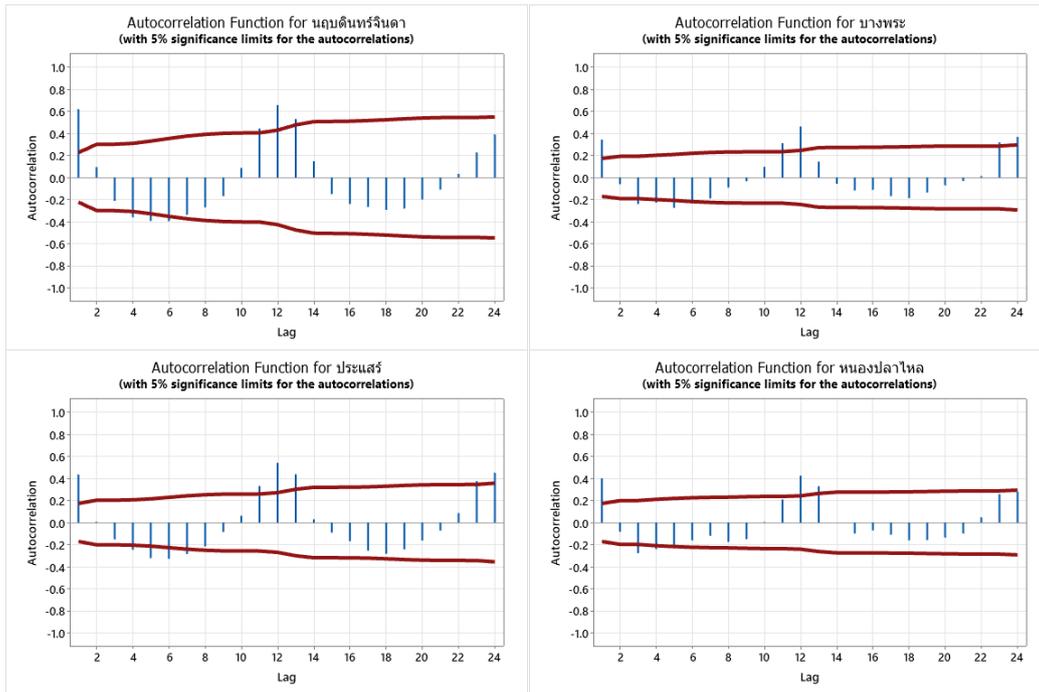
จากรูปที่ 2 ACF ของอ่างเก็บน้ำเขื่อนแต่ละแห่งมีค่ามากในช่วงเวลาที่ช้ากว่ากัน (Lag) 1 และค่อยๆ ลดลงอย่างช้าๆ เมื่อช่วงเวลาที่ช้ากว่ากันเพิ่มขึ้น แสดงถึงข้อมูลมีลักษณะแนวโน้ม

ACF ที่ปรากฏในรูปที่ 3 ข้อมูลอนุกรมเวลาการปรับแนวโน้ม ซึ่ง ACF ของอ่างเก็บน้ำเขื่อนแต่ละแห่งมีค่ามากที่สุดในช่วงเวลาที่ช้ากว่ากัน 12 แสดงถึงข้อมูลมีลักษณะ

ความแปรผันตามฤดูกาล ดังนั้นทั้ง 2 รูปจึงยืนยันส่วนประกอบโดยธรรมชาติของข้อมูล

ค่าจำกัดความอ่างเก็บน้ำขนาดใหญ่ หมายถึง อ่างเก็บน้ำมีปริมาตรเก็บกักเก็บน้ำได้มากกว่า 100 ล้านลูกบาศก์เมตร หรือมีพื้นที่อ่างเก็บน้ำตั้งแต่ 15 ตารางกิโลเมตร หรือมีพื้นที่ชลประทานมากกว่า 80,000 ไร่





รูปที่ 3 ACF ของข้อมูลอนุกรมเวลาการปรับแนวโน้มของอ่างเก็บน้ำเขื่อน 6 แห่ง

ข้อมูลจำนวน 90 เดือน แบ่งออกเป็น 2 ชุด ข้อมูลชุดแรกเป็นชุดข้อมูลฝึกฝน (Training data set) คือ ตั้งแต่เดือนกรกฎาคม พ.ศ. 2559 ถึงเดือนธันวาคม พ.ศ. 2564 จำนวน 66 เดือน เป็นชุดข้อมูลเพื่อสร้างตัวแบบพยากรณ์ ชุดข้อมูลชุดที่สองเป็นชุดข้อมูลทดสอบ (Test data set) คือ ตั้งแต่เดือนมกราคม พ.ศ. 2565 ถึงเดือนธันวาคม พ.ศ. 2566 จำนวน 24 เดือน เพื่อตรวจสอบความแม่นยำของตัวแบบพยากรณ์ และใช้โปรแกรม Minitab 18 และ Python เป็นเครื่องมือในการวิเคราะห์ข้อมูล

2.3 ตัวแบบพยากรณ์

ในการศึกษากำหนดสัญลักษณ์ไว้ดังนี้

Y_t คือ ค่าข้อมูลจริง ณ เวลา t

\hat{Y}_t คือ ค่าพยากรณ์ ณ เวลา t

ε_t คือ ความคลาดเคลื่อนที่มีการแจกแจงปกติและเป็นอิสระกัน มีค่าเฉลี่ยเท่ากับศูนย์ และความแปรปรวนคงที่ทุกช่วงเวลา

t คือ ช่วงเวลา โดย t มีค่าตั้งแต่ 1 ถึง $n_1 = 66$ ในชุดข้อมูลฝึกฝน และ t มีค่าตั้งแต่ 67 ถึง $n = 90$ ในชุดข้อมูลทดสอบ

กรณีอยู่ในขั้นตอนการพยากรณ์ล่วงหน้าเดือนมกราคม พ.ศ. 2567 ถึง ธันวาคม พ.ศ. 2568 การสร้างตัวแบบจะใช้ t มีค่าตั้งแต่ 1 ถึง $n = 90$ แทน จำนวนข้อมูลทั้งหมด

s คือ คาบของฤดูกาลมีค่าเท่ากับ 12

2.3.1 วิธีแยกส่วนประกอบ

วิธีที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่าง ๆ คือ แนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cycle) และส่วนประกอบไม่ปรกติ (Irregular) โดยในการศึกษานี้ เลือกศึกษาส่วนประกอบที่มีผลต่อการพยากรณ์ 2 ส่วนประกอบ คือ แนวโน้มและฤดูกาล

ต่อไปนี้เป็นขั้นตอนทั่วไปที่ใช้ในการพยากรณ์การวิเคราะห์แยกส่วนประกอบแบบคลาสสิก (Classical decomposition: Classical-D)

1. การเตรียมข้อมูล เริ่มต้นด้วยการรวบรวมข้อมูลอนุกรมเวลาให้เพียงพอสำหรับวัตถุประสงค์ในการพยากรณ์

2. การแสดงภาพ แสดงภาพข้อมูลผ่านพล็อตอนุกรมเวลา เพื่อศึกษารูปแบบของข้อมูล ส่วนประกอบต่างๆ เช่น แนวโน้ม และฤดูกาล

3. การระบุช่วงเวลาตามฤดูกาล กำหนดคาบของฤดูกาล คือ ช่วงเวลาของรอบที่เกิดซ้ำภายในข้อมูล

4. ปรับแนวโน้ม ขจัดองค์ประกอบแนวโน้มเพื่อมุ่งเน้นไปที่ฤดูกาล โดยทั่วไปจะใช้ใช้ค่าเฉลี่ยเคลื่อนที่กลางแล้วดำเนินการดังนี้

- ในตัวแบบรูปแบบบวกร นำอนุกรมเวลาเดิมลบค่าเฉลี่ยเคลื่อนที่กลาง

- ในตัวแบบรูปแบบคูณ นำอนุกรมเวลาเดิมหารค่าเฉลี่ยเคลื่อนที่กลาง

5. การประมาณค่าดัชนีฤดูกาล นำผลจากการปรับแนวโน้มมาคำนวณค่าเฉลี่ยสำหรับแต่ละฤดูกาล แล้วปรับปรุงค่าเหล่านั้นเพื่อกำหนดองค์ประกอบตามฤดูกาลตามรูปแบบดังนี้

- ในตัวแบบรูปแบบบวกร ให้ปรับปรุงดัชนีฤดูกาลโดยนำแต่ละค่าเฉลี่ยฤดูกาลลบค่าเฉลี่ยโดยรวมของดัชนีฤดูกาล

- ในตัวแบบรูปแบบคูณ ให้ปรับปรุงดัชนีฤดูกาลโดยนำแต่ละค่าเฉลี่ยฤดูกาลหารค่าเฉลี่ยโดยรวมของดัชนีฤดูกาล

จะได้ \hat{S}_t , ดัชนีฤดูกาล

6. การปรับการแปรผันตามฤดูกาล

- ในตัวแบบรูปแบบบวกร นำค่าอนุกรมเวลาเดิมลบกับค่าดัชนีฤดูกาล

- ในตัวแบบรูปแบบคูณ นำค่าอนุกรมเวลาเดิมหารกับค่าดัชนีฤดูกาล

7. การคำนวณแนวโน้ม ใช้การถดถอยเชิงเส้นกับค่าการปรับการแปรผันตามฤดูกาลเพื่อส่วนประกอบแนวโน้ม จะได้ $\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t$

8. การพยากรณ์ พยากรณ์โดยการรวมส่วนประกอบแนวโน้มและส่วนประกอบฤดูกาล ตัวแบบแนวโน้มเส้นตรงฤดูกาลรูปแบบบวกร และแบบคูณ ตัวแบบและตัวแบบพยากรณ์ดังสมการ (6) ถึง (9) ตามลำดับ

$$\text{ตัวแบบรูปแบบบวกร } Y_t = \beta_0 + \beta_1 t + S_t + \varepsilon_t \quad (6)$$

$$\text{พยากรณ์รูปแบบบวกร } \hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t + \hat{S}_t \quad (7)$$

$$\text{ตัวแบบรูปแบบคูณ } Y_t = (\beta_0 + \beta_1 t) \times S_t \times \varepsilon_t \quad (8)$$

$$\text{พยากรณ์รูปแบบคูณ } \hat{Y}_t = (\hat{\beta}_0 + \hat{\beta}_1 t) \times \hat{S}_t \quad (9)$$

เมื่อพารามิเตอร์ β_0, β_1 แทนระดับของข้อมูล และความชันตามลำดับ ส่วน $\hat{\beta}_0$ และ $\hat{\beta}_1$ เป็นตัวประมาณของ β_0 และ β_1 ตามลำดับ S_t แทนดัชนีฤดูกาล ณ เวลา t และ

$S_t = S_i$ สำหรับ $i=1,2,3,\dots,s$ เมื่อ t เป็นเวลาในฤดูกาลที่ i มีค่า โดยที่ $\sum_{i=1}^s S_i = 0$ เมื่อเป็นตัวแบบรูปแบบบวกร

และ $\sum_{i=1}^s S_i = s$ เมื่อเป็นตัวแบบรูปแบบคูณ ส่วน \hat{S}_t เป็นตัวประมาณของ S_t

9. การประเมินและการปรับแต่ง ประเมินการพยากรณ์เทียบกับข้อมูลจริงเพื่อวัดความแม่นยำและประสิทธิภาพของตัวแบบ

2.3.2 วิธีโฮลต์-วินเทอร์

วิธี HW ได้รับการยกย่องอย่างดีในด้านความสามารถในการปรับตัวในการจัดการการเปลี่ยนแปลงของการปรับระดับ แนวโน้มและฤดูกาลทั้งรูปแบบบวกรและแบบคูณตามข้อมูลอนุกรมเวลา แม้ว่าชุดข้อมูลการฝึกฝนจะมีจำนวนข้อมูลไม่มากก็สามารถใช้ในการสร้างตัวแบบได้ดี โดยเฉพาะเมื่อตัวแบบให้ความสำคัญกับค่าข้อมูลล่าสุดมากกว่าข้อมูลย้อนหลังในอดีต ในตัวแบบรูปแบบบวกรจะใช้สมการ (10) ถึง (13) ในตัวแบบรูปแบบคูณจะใช้สมการสมการ (14) ถึง (17)

พยากรณ์รูปแบบบวกร

$$\hat{Y}_{t+p} = \hat{T}_t + p\hat{\beta}_t + \hat{S}_{t-s+1+((p-1) \bmod s)} \quad \text{for } p = 1, 2, \dots \quad (10)$$

$$\hat{T}_t = \alpha(Y_t - \hat{S}_{t-s}) + (1-\alpha)(\hat{T}_{t-1} + \hat{\beta}_{t-1}) \quad (11)$$

$$\hat{\beta}_t = \gamma(\hat{T}_t - \hat{T}_{t-1}) + (1-\gamma)\hat{\beta}_{t-1} \quad (12)$$

$$\hat{S}_t = \delta(Y_t - \hat{T}_t) + (1-\delta)\hat{S}_{t-s} \quad (13)$$

พยากรณ์รูปแบบคูณ

$$\hat{Y}_{t+p} = (\hat{T}_t + p\hat{\beta}_t) \times \hat{S}_{t-s+1+((p-1) \bmod s)} \quad \text{for } p = 1, 2, \dots \quad (14)$$

$$\hat{T}_t = \alpha(Y_t / \hat{S}_{t-s}) + (1-\alpha)(\hat{T}_{t-1} + \hat{\beta}_{t-1}) \quad (15)$$

$$\hat{\beta}_t = \gamma(\hat{T}_t - \hat{T}_{t-1}) + (1-\gamma)\hat{\beta}_{t-1} \quad (16)$$

$$\hat{S}_t = \delta(Y_t / \hat{T}_t) + (1-\delta)\hat{S}_{t-s} \quad (17)$$

เมื่อ \hat{Y}_{t+p} คือ ค่าพยากรณ์ล่วงหน้า ณ เวลา $t+p$

p คือ จำนวนช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้า

\hat{T}_t คือ ระดับของอนุกรมเวลา ณ เวลา t

$\hat{\beta}_t$ คือ แนวโน้มของอนุกรมเวลา ณ เวลา t และ

\hat{S}_t คือ ฤดูกาลของอนุกรมเวลา ณ เวลา t

HW ใช้ค่าทำให้เรียบ 3 ค่าได้แก่ α, γ และ δ ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 สำหรับค่าระดับ α (Level parameter) ค่าที่ใกล้เคียงกับ 1 บ่งชี้ว่าตัวแบบปรับให้เข้า

กับการสังเกตล่าสุดอย่างมาก ในขณะที่ค่าที่ใกล้ 0 จะให้ความสำคัญกับการสังเกตในอดีตมากกว่า ค่าแนวโน้ม γ (Trend parameter) ค่าสูงช่วยให้ตัวแบบปรับตัวเข้ากับการเปลี่ยนแปลงของแนวโน้มได้อย่างรวดเร็วในค่าสังเกตล่าสุด ในขณะที่ค่าต่ำจะทำให้ตัวแบบตอบสนองต่อการเปลี่ยนแปลงของแนวโน้มล่าสุดน้อยลง และค่าฤดูกาล δ (Seasonal parameter) เป็นอิทธิพลของฤดูกาล ค่าที่สูงขึ้นส่งผลให้มีความไวต่อความผันผวนของฤดูกาลในคาบฤดูกาลล่าสุดมากขึ้น ในขณะที่ค่าที่ต่ำจะทำให้ตัวแบบมีความทนทานต่อการเปลี่ยนแปลงตามฤดูกาลในคาบฤดูกาลล่าสุด

โดยในงานวิจัยนี้พิจารณาพารามิเตอร์ทั้ง 3 ด้วยวิธีการค้นหาแบบกริด (Grid search) ที่เป็นเทคนิคหนึ่งในการเรียนรู้ของเครื่อง (Machine learning) โดยจะกำหนดการเปลี่ยนแปลงค่าพารามิเตอร์ในทศนิยม 2 ตำแหน่ง อัตราเพิ่มครั้งละ 0.01 เริ่มจาก 0.01 ถึง 0.99 ส่งผลให้มีการวนซ้ำทั้งหมด $99^3 = 970,299$ รอบ เรียกวิธีการศึกษาใหม่นี้ว่า Grid-HW [22] เมื่อการคำนวณสิ้นสุดจะเลือกพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าน้อยที่สุดของความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute error: MAE)

Objective Minimize $MAE(\alpha, \gamma, \delta)$,

$$\text{Variable range} \begin{cases} 0 < \alpha < 1 \\ 0 < \gamma < 1, \\ 0 < \delta < 1 \end{cases}$$

$$MAE = \frac{1}{n_t} \sum_{t=1}^{n_t} |Y_t - \hat{Y}_t| \quad (18)$$

เมื่อ \hat{Y}_t แทน ค่าพยากรณ์จาก Grid-HW

2.3.3 การผสมผสานการค้นหาค่าที่เหมาะสมแบบนกกาเหว่ากับโฮสต์-วินเทอร์

การใช้อัลกอริทึม CS เพื่อปรับพารามิเตอร์ให้เหมาะสมสำหรับตัวแบบ HW ขั้นตอนการคำนวณสำหรับ

กระบวนการนี้มีรายละเอียดอยู่ในรหัสเทียมที่แสดงในรูปที่ 4 ประสิทธิภาพของตัวแบบ CS-HW ประเมินผ่านความแม่นยำในการพยากรณ์ตามฟังก์ชันวัตถุประสงค์ในสมการ (18)

2.3.4 การผสมผสานการค้นหาค่าที่เหมาะสมแบบนกกาเหว่ากับการแยกส่วนประกอบ

การใช้อัลกอริทึม CS เพื่อปรับพารามิเตอร์ให้เหมาะสมสำหรับตัวแบบ D ขั้นตอนการคำนวณสำหรับกระบวนการนี้มีรายละเอียดอยู่ในรหัสเทียมที่แสดงในรูปที่ 5 และอธิบายขั้นตอนที่สำคัญได้ดังนี้

การปรับขนาดพารามิเตอร์ (Scaling Parameters)

ตั้งค่าการค้นหาขั้นตอนวิธี CS ภายในขอบเขต [0, 1] จากขั้นที่ 2 แล้วนำค่าพารามิเตอร์ที่ได้รับจาก CS มาปรับขนาดพารามิเตอร์ให้เป็นไปตามหน่วยข้อมูลจริงก่อนคำนวณค่าความเหมาะสมของตัวแบบ โดยใช้สมการ (19) ต่อไปนี้ $Original\ Value = Scaled\ Value \times (UB - LB) + LB$ (19) Original Value คือ ค่าเดิมหรือค่าตามหน่วยข้อมูลจริง Scaled Value คือ ค่าพารามิเตอร์ที่ได้จาก CS ในช่วง [0, 1] สมการนี้จะช่วยแปลงค่าพารามิเตอร์ขั้นตอนวิธี CS ในช่วง [0, 1] ให้กลับไปอยู่ในหน่วยตามข้อมูลจริง

โดยค่าที่จำเป็นต้องหาเพิ่มเติมคือ Upper Bound Constraint (UB) และ Lower Bound Constraint (LB) ดังนี้

1. การคำนวณข้อจำกัดบนและล่างของ $\hat{\beta}_0$ และ $\hat{\beta}_1$

คำนวณส่วนประกอบแนวโน้มจากข้อมูลจริงโดยใช้การถดถอยเชิงเส้นจะได้ $\hat{Y}_t = \hat{\beta}'_0 + \hat{\beta}'_1 t$ แล้วคำนวณ UB ของ $\hat{\beta}'_0$ โดย $\hat{\beta}'_0 = 1.2\hat{\beta}'_0$ และ $\hat{\beta}'_1$ โดย $\hat{\beta}'_1 = 1.2\hat{\beta}'_1$ LB ของ $\hat{\beta}'_0$ โดย $\hat{\beta}'_0 = 0.8\hat{\beta}'_0$ และ $\hat{\beta}'_1$ โดย $\hat{\beta}'_1 = 0.8\hat{\beta}'_1$

โดยข้อจำกัดดำเนินการตามสูตรได้เมื่อพารามิเตอร์เป็นค่าบวก ในทางกลับกันหากพารามิเตอร์เป็นค่าลบให้สลับ UB และ LB ค่าคงตัวที่กำหนด 0.8 และ 1.2 กำหนดตาม Minsan and Minsan [22-23]

The number of bird host nests: $n = 25$, the number of parameters: $d = 3$, the maximum number of iterations: $T_{max} = 1,000$, the time limit: $MaxTime = 30$ sec., and the fitness value fails to improve after a specified number of iterations: $T_{improve} = 300$.

Objective function $f(X), X = (x_1, x_2, x_3)^T$.

Generate initial population of n host nests $X_i (i = 1, 2, \dots, n)$.

While ($t < T_{max}$) or ($time < MaxTime$) or (the fitness value fails to improve after a specified $T_{improve}$)

```

For  $i = 1$  to  $n$ 
    Get a cuckoo  $i$  by performing Lévy flights equation (1).
    Calculate fitness using HW by equation (18) of a cuckoo  $i$ .
    Update a host nest  $X_i$  if there is a better solution.
End for
For  $i = 1$  to  $n$ 
    Random  $p$ 
    If ( $p < p_a$ ),
        A worse nest is abandoned and new one is built equation (4).
        Calculate fitness using HW by equation (18) of a new nest  $i$ .
        Update a host nest  $X_i$  if there is a better solution.
    End if
End for
Rank the solutions and find the current best  $X^*$ , update  $t = t + 1$ .
End while
Return  $X^*$  # Objective Minimize  $MAE(\alpha^*, \gamma^*, \delta^*)$  where  $\alpha^*, \gamma^*, \delta^*$  are the optimized parameters.
    
```

รูปที่ 4 รหัสเทียมของ CS-HW

```

The number of bird host nests:  $n = 25$ , the number of parameters:  $d = 14$ , the maximum number of iterations:  $T_{max} = 1,000$ , the time limit:  $MaxTime = 30$  sec., and the fitness value fails to improve after a specified number of iterations:  $T_{improve} = 300$ .
Objective function  $f(X), X = (x_1, x_2, \dots, x_{14})^T$ .
Generate initial population of  $n$  host nests  $X_i (i = 1, 2, \dots, n)$ .
While ( $t < T_{max}$ ) or (time  $< MaxTime$ ) or (the fitness value fails to improve after a specified  $T_{improve}$ )
    For  $i = 1$  to  $n$ 
        Get a cuckoo  $i$  by performing Lévy flights equation (1).
        Scaling Parameters equation (19).
        Calculate fitness using decomposition by the equation (22) of a cuckoo  $i$ .
        Update a host nest  $X_i$  if there is a better solution.
    End for
    For  $i = 1$  to  $n$ 
        Random  $p$ 
        If ( $p < p_a$ ),
            A worse nest is abandoned and new one is built (4).
            Scaling Parameters equation (19).
            Calculate fitness using decomposition by the equation (22) of a new nest  $i$ .
            Update a host nest  $X_i$  if there is a better solution.
        End if
    End for
    Rank the solutions and find the current best  $X^*$ , update  $t = t + 1$ .
End while
Return  $X^*$  # Objective Minimize  $MAE(\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{S}_1^*, \hat{S}_2^*, \dots, \hat{S}_{12}^*)$  where  $\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{S}_1^*, \hat{S}_2^*, \dots, \hat{S}_{12}^*$  are the optimized parameters.
    
```

รูปที่ 5 รหัสเทียมของ CS-D

2. การคำนวณข้อจำกัดบน (UB_s) และล่าง (LB_s) ของ S_i
 การกำหนดขอบเขตความแปรผันฤดูกาล ให้จำกัด
 ส่วนประกอบแนวโน้มออกจากอนุกรมเวลาโดยใช้การหา

ผลต่างลำดับ 1 จะได้ $\Delta Y_t = Y_t - Y_{t-1}$ กำหนดข้อจำกัด
 ขอบเขตบนและล่างสำหรับพารามิเตอร์ฤดูกาล
 $\hat{S}_1, \hat{S}_2, \hat{S}_3, \dots, \hat{S}_{12}$ ดังนี้

UB_s หาได้โดย +[ค่าแอมพลิจูดสูงสุดของ ΔY_t]

LB_s หาได้โดย -[ค่าแอมพลิจูดต่ำสุดของ ΔY_t]

แอมพลิจูด คือความสูงที่สุดของคลื่น ซึ่งในกรณีนี้หมายถึงความสูงที่สุดของความแปรผันฤดูกาลของอนุกรมเวลา

เมื่อได้ค่า Original Value มาแล้วต้องปรับปรุงค่า \hat{S}_i ให้เพิ่มเติมก่อนนำไปประเมินผ่านความแม่นยำในการพยากรณ์ตามฟังก์ชันวัตถุประสงค์ สามารถคำนวณได้โดยใช้สมการที่ (20) และ (21)

กรณีแยกส่วนประกอบรูปแบบบวก

$$\text{Adjust } \hat{S}_i = \hat{S}_i - \sum_{i=1}^{12} \hat{S}_i / 12, \text{ แล้ว } \sum_{i=1}^{12} \hat{S}_i = 0. \quad (20)$$

กรณีแยกส่วนประกอบรูปแบบคูณ

$$\text{Adjust } \hat{S}_i = 12 \times \hat{S}_i / \sum_{i=1}^{12} \hat{S}_i, \text{ แล้ว } \sum_{i=1}^{12} \hat{S}_i = 12 \quad (21)$$

เมื่อการคำนวณสิ้นสุดจะเลือกพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าน้อยที่สุดของ MAE

Objective Minimize MAE($\hat{\beta}_0, \hat{\beta}_1, \hat{S}_1, \hat{S}_2, \dots, \hat{S}_{12}$)

$$\text{Variable range } \begin{cases} 0.8\hat{\beta}'_0 \leq \hat{\beta}_0 \leq 1.2\hat{\beta}'_0 \\ 0.8\hat{\beta}'_1 \leq \hat{\beta}_1 \leq 1.2\hat{\beta}'_1 \\ \text{LB}_s \leq \hat{S}_i \leq \text{UB}_s \end{cases} \text{ for } i = 1, 2, \dots, 12$$

$$\text{MAE} = \frac{1}{n_1} \sum_{t=1}^{n_1} |Y_t - \hat{Y}_t| \quad (22)$$

เมื่อ \hat{Y}_t แทน ค่าพยากรณ์จาก CS-D

2.3.5 การประเมินประสิทธิภาพ

การประเมินของการศึกษานี้แบ่งออกเป็นสองประเภทที่แตกต่างกัน

ประเภทแรกคือ “ระยะข้อมูลฝึกฝน” มีวัตถุประสงค์เพื่อระบุแนวทางการสร้างแบบจำลองที่ดีที่สุด โดยการประเมินประสิทธิภาพว่าแนวทางใดให้ค่า MAE ต่ำสุดในช่วงชุดข้อมูลฝึกฝน

$$\text{โดยที่ } \text{MAE} = \frac{1}{n_1} \sum_{t=1}^{n_1} |Y_t - \hat{Y}_t|$$

n_1 หมายถึงความยาวของชุดข้อมูลฝึกฝน และ Y_t และ \hat{Y}_t หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลฝึกฝนตามลำดับ

ผลของค่า MAE ในระยะข้อมูลฝึกฝนนี้จะได้ค่า MAE ทั้งหมด 8 วิธีคือ

- แยกส่วนประกอบแบบคลาสสิกรูปแบบบวก (Classic-D+)
- แยกส่วนประกอบแบบคลาสสิกรูปแบบคูณ (Classic-Dx)
- ค้นหาแบบกริดของโฮลต์-วินเทอร์รูปแบบบวก (Grid-HW+)
- ค้นหาแบบกริดของโฮลต์-วินเทอร์รูปแบบคูณ (Grid-HWx)
- ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบรูปแบบบวก (CS-D+)
- ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบรูปแบบคูณ (CS-Dx)
- ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮลต์-วินเทอร์รูปแบบบวก (CS-HW+)
- ค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮลต์-วินเทอร์รูปแบบคูณ (CS-HWx)

โดยจะเปรียบเทียบค่าที่ต่ำที่สุดของ MAE เป็นคู่เทียบกัน 4 คู่ คือ Classic-D+ เปรียบเทียบกับ CS-D+ Classic-Dx เปรียบเทียบกับ CS-Dx Grid-HW+ เปรียบเทียบกับ CS-HW+ และ Grid-HWx เปรียบเทียบกับ CS-HWx

ประเภทสองคือ “ระยะข้อมูลทดสอบ” มีวัตถุประสงค์เพื่อประเมินความสามารถในการพยากรณ์ล่วงหน้าของตัวแบบโดยให้ตัวแบบพยากรณ์ล่วงหน้า 2 ปี หรือ 24 เดือน ในระยะนี้ใช้ตัวชี้วัดสำคัญ 3 ตัว ประเมินประสิทธิภาพ ได้แก่ รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) MAE และ ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยแบบสมมาตร (Symmetric Mean Absolute Percentage Error: sMAPE) ในการประเมินมีสมการดัง (23) ถึง (25) ต่อไปนี้

$$\text{RMSE} = \sqrt{\frac{1}{24} \sum_{t=67}^n (Y_t - \hat{Y}_t)^2} \quad (23)$$

$$\text{MAE} = \frac{1}{24} \sum_{t=67}^n |Y_t - \hat{Y}_t| \quad (24)$$

$$\text{sMAPE} = 100 \times \frac{1}{24} \sum_{t=67}^n \frac{|Y_t - \hat{Y}_t|}{(Y_t + \hat{Y}_t)/2}, \quad [28] \quad (25)$$

Y_t และ \hat{Y}_t หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลทดสอบ ตามลำดับ

เนื่องจากการพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูลที่เกิดขึ้นได้ การแบ่งข้อมูลเป็นชุดข้อมูลฝึกฝนและทดสอบถ้าชุดข้อมูลทั้ง 2 มีลักษณะเดียวกันทุกประการ ความคลาดเคลื่อนที่ได้จากตัวแบบที่ดีที่สุด (ค่าความคลาดเคลื่อนต่ำสุด) จากชุดข้อมูลฝึกฝนก็จะตรงกันกับชุดข้อมูลทดสอบ แต่การพยากรณ์อนุกรมเวลาในข้อมูลจริงมีความแปรผันของข้อมูล ความแตกต่างเล็กน้อยที่อาจเกิดขึ้นในชุดข้อมูลฝึกฝนกับชุดข้อมูลทดสอบเกิดขึ้นได้เสมอ ดังนั้นเพื่อเป็นประโยชน์ต่อการนำค่าพยากรณ์ล่วงหน้าไปใช้ การเพิ่มตัวแบบอื่นๆ ในการพยากรณ์จึงเป็นสิ่งสำคัญที่การศึกษา

ในระยะข้อมูลทดสอบจึงเพิ่มวิธีการ Box-Jenkins [29] ซึ่งเป็นตัวแบบที่นิยมใช้กันอย่างแพร่หลาย และเพิ่มวิธีแบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-term Memory: LSTM) [30] ที่เป็นวิธีการเรียนรู้ของเครื่องที่กำลังเป็นที่นิยมในการศึกษาด้วย

การระบุพารามิเตอร์ของ Box-Jenkins ในการศึกษาทำได้โดยใช้ขั้นตอนต่างๆ หลายขั้นตอน ซึ่งรวมถึงการวิเคราะห์ข้อมูลพล็อตอนุกรมเวลา ACF และ PACF ดังรูปที่ 2 และ 3 ใช้การทดสอบ Dickey-Fuller (DF) โดยตั้งลำดับสูงสุดช่วงเวลาที่ช้ากว่ากันที่ 12 ตามเงื่อนไขเกณฑ์สารสนเทศของอะกะอิเกะ (Akaike information criterion: AIC) ในการเลือกตัวแบบ และตัวแบบที่ถูกเลือกต้องเป็นตัวแบบที่ได้ค่าความคลาดเคลื่อน ($e_t = Y_t - \hat{Y}_t$) ผ่านการทดสอบการแจกแจงปกติ เป็นอิสระกัน มีค่าเฉลี่ยเท่ากับศูนย์ และความแปรปรวนคงที่ทุกช่วงเวลา

การดำเนินการของ LSTM กำหนดค่าของไฮเปอร์พารามิเตอร์ ดังนี้ ฟังก์ชันความสูญเสีย (Loss function) เป็นวิธี MAE ตัวเพิ่มประสิทธิภาพ (Optimizer) เป็นวิธี adam ทำการฝึกสอน (Epoch) จำนวน 100 ครั้ง จำนวนเซลล์ประสาทเทียม (Neurons) ในเลเยอร์ เท่ากับ 50 และจำนวนข้อมูลย้อนหลัง (Look back) เท่ากับ 12 และ 24

ผลของค่า RMSE MAE และ sMAPE ในระยะข้อมูลทดสอบนี้จะได้ค่าแต่ละค่าทั้งหมด 10 วิธีคือ Classic-D+ Classic-Dx Grid-HW+ Grid-HWx CS-D+ CS-Dx CS-HW+ CS-HWx Box-Jenkins และ LSTM โดยจะเปรียบเทียบหาว่าค่าที่ต่ำที่สุดของ RMSE MAE และ sMAPE

ใน 10 วิธีเหล่านั้น เพื่อใช้ในการตัดสินใจตัวแบบที่ดีที่สุดในการพยากรณ์ล่วงหน้า 24 เดือน

การทดลองดำเนินการในสภาพแวดล้อม Google Colab [31] ซึ่งให้สิทธิ์เข้าถึงความสามารถในการเขียนโปรแกรม Python โดยอัตโนมัติ คอมพิวเตอร์ CPU Intel(R) Core(TM) i5-9400 @ 2.90GHz, RAM 16GB, ทำงานบนระบบปฏิบัติการ Windows 11

3. การทดลองและการวิเคราะห์

3.1 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในระยะชุดข้อมูลฝึกฝน

เพื่อประเมินประสิทธิภาพของตัวแบบ CS-HW และ CS-D ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อน การศึกษาได้ดำเนินการวิเคราะห์เปรียบเทียบกับตัวแบบการพยากรณ์แบบเดิมสองแบบ ได้แก่ Classic-D และ Grid-HW เมื่อนำไปใช้กับชุดข้อมูลเดียวกันคือ ข้อมูลอนุกรมปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนรายเดือน ในชุดข้อมูลฝึกฝนได้ผลตามตารางที่ 1 โดยการประมวลผลตัวแบบ CS-HW และ CS-D ทุกชุดข้อมูลหยุดในการหาคำตอบที่การจำนวน 1,000 รอบ เวลาเฉลี่ยในการประมวลผล 18.54 วินาที

จะเห็นว่าการผสมผสาน CS เข้ากับตัวแบบ HW และการแยกส่วนประกอบ สามารถทำให้คุณภาพในการพยากรณ์เพิ่มมากขึ้น ค่าพยากรณ์มีค่าใกล้เคียงกับค่าจริงมากกว่าวิธีเดิมทั้งสองแบบ (ค่า MAE ต่ำ) ไม่ว่าจะเป็นตัวแบบรูปแบบบวก หรือแบบคูณ ในทุกอ่างเก็บน้ำเขื่อนทั้ง 6 เขื่อน

ดังนั้นจึงสรุปในระยะชุดข้อมูลฝึกฝนได้ว่า

- CS-D+ ได้ค่า MAE ต่ำกว่า Classic-D+
- CS-Dx ได้ค่า MAE ต่ำกว่า Classic-Dx
- CS-HW+ ได้ค่า MAE ต่ำกว่า Grid-D+ และ
- CS-HWx ได้ค่า MAE ต่ำกว่า Grid-Dx

3.2 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในระยะชุดข้อมูลทดสอบ

การสรุปตัวแบบที่มีประสิทธิภาพของแต่ละอ่างเก็บน้ำเขื่อนในชุดข้อมูลทดสอบ เพื่อเลือกตัวแบบที่มีประสิทธิภาพดีที่สุดในพยากรณ์ล่วงหน้า พิจารณาจากตาราง

- ที่ 2, 3 และ 4 แสดงค่า RMSE MAE และ sMAPE โดยจะเลือกตัวแบบที่มีค่าต่ำสุดในเกณฑ์ทั้ง 3 มากที่สุดถือเป็นตัวแบบที่มีประสิทธิภาพดีที่สุด
- ชุดข้อมูลปราการชล เลือกตัวแบบ CS-HW+ โดยมีค่าต่ำสุด RMSE และ MAE
 - คลองสีียด เลือกตัวแบบ CS-HWx โดยมีค่าต่ำสุด RMSE และ MAE
 - นฤปดินทร์จินดา เลือกตัวแบบ Box-Jenkins โดยมีค่าต่ำสุด RMSE MAE และ sMAPE
 - บางพระ เลือกตัวแบบ CS-Dx โดยมีค่าต่ำสุด MAE และ sMAPE
 - ประแสร์ เลือกตัวแบบ Grid-HWx โดยมีค่าต่ำสุด RMSE MAE และ sMAPE และ
 - หนองปลาไหล เลือกตัวแบบ Grid-HW+ โดยมีค่าต่ำสุด RMSE MAE และ sMAPE

ตารางที่ 1 MAE ของชุดข้อมูลฝักฝนในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ			อ่างเก็บน้ำเขื่อน					
			ขุนด่าน ปราการชล	คลองสีียด	นฤปดินทร์ จินดา	บางพระ	ประแสร์	หนองปลา ไหล
แยก ส่วนประกอบ	รูปแบบบวก	Classic-D+	11.5375	13.7844	14.9803	3.5043	8.4433	10.5343
		CS-D+	10.3638	12.0919	12.9626	3.1395	7.3334	9.8216
	รูปแบบคูณ	Classic-Dx	11.2483	13.7163	13.8682	3.6592	10.0939	10.0441
		CS-Dx	9.6461	12.1326	12.7933	3.1564	7.4321	9.0497
โพลต์-วินเทอร์	รูปแบบบวก	Grid-HW+	13.7838	17.4135	18.1630	4.3327	9.9975	12.6653
		CS-HW+	13.4842	16.5732	17.1675	4.3253	9.9109	12.5604
	รูปแบบคูณ	Grid-HWx	13.6355	20.1507	14.2889	4.7496	12.2709	13.2358
		CS-HWx	13.2772	17.4437	14.2209	4.4687	10.0412	12.4710

หมายเหตุ: มีการเน้นค่า MAE ต่ำสุดด้วยสี ระหว่าง Classic-D และ CS-D และระหว่าง Grid-HW และ CS-HW

ตารางที่ 2 RMSE ของชุดข้อมูลทดสอบในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ			อ่างเก็บน้ำเขื่อน					
			ขุนด่าน ปราการชล	คลองสีียด	นฤปดินทร์ จินดา	บางพระ	ประแสร์	หนองปลา ไหล
แยก ส่วนประกอบ	รูปแบบบวก	Classic-D+	13.9	23.8	19.2	5.3	19.1	19.6
		CS-D+	14.1	24.0	16.1	5.5	20.0	17.7
	รูปแบบคูณ	Classic-Dx	16.1	24.4	17.4	5.5	27.7	21.6
		CS-Dx	16.2	24.3	21.6	5.0	21.1	21.1
โพลต์-วินเทอร์	รูปแบบบวก	Grid-HW+	12.3	22.4	15.9	5.0	18.9	13.0
		CS-HW+	11.5	23.4	44.1	5.0	19.2	16.2
	รูปแบบคูณ	Grid-HWx	15.3	23.6	82.2	5.2	16.4	16.5
		CS-HWx	18.1	22.2	87.0	5.1	19.0	15.0
Box-Jenkins			24.2	39.8	14.6	6.2	27.8	18.8
LSTM			38.8	34.8	43.0	6.2	22.2	19.0

หมายเหตุ: มีการเน้นค่า RMSE ต่ำสุดด้วยสี สำหรับอ่างเก็บน้ำเขื่อนแต่ละแห่ง

ตารางที่ 3 MAE ของชุดข้อมูลทดสอบในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ			อ่างเก็บน้ำเขื่อน					
			ขุนด่าน ปราการชล	คลองสิียด	นฤบดีนทร์ จินดา	บางพระ	ประแสร์	หนองปลา ไหล
แยก ส่วนประกอบ	รูปแบบบวก	Classic-D+	10.4	14.3	12.0	2.9	12.1	17.9
		CS-D+	8.5	13.7	9.6	3.2	12.1	14.5
	รูปแบบคูณ	Classic-Dx	8.7	13.3	11.2	2.9	15.5	17.0
		CS-Dx	9.9	13.7	13.3	2.8	12.4	15.2
ไฮลด์-วินเทอร์	รูปแบบบวก	Grid-HW+	6.3	12.8	9.5	3.3	11.4	10.7
		CS-HW+	5.9	13.8	37.7	3.3	11.5	11.6
	รูปแบบคูณ	Grid-HWx	10.3	14.1	52.1	3.5	10.4	12.6
		CS-HWx	12.3	12.8	54.9	3.3	12.0	11.4
Box-Jenkins			12.8	21.3	8.3	3.4	16.1	12.2
LSTM			24.6	21.0	25.8	3.4	14.2	13.2

หมายเหตุ: มีการเน้นค่า MAE ต่ำสุดด้วยสี สำหรับอ่างเก็บน้ำเขื่อนแต่ละแห่ง

ตารางที่ 4 sMAPE ของชุดข้อมูลทดสอบในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ			อ่างเก็บน้ำเขื่อน					
			ขุนด่าน ปราการชล	คลองสิียด	นฤบดีนทร์ จินดา	บางพระ	ประแสร์	หนองปลา ไหล
แยก ส่วนประกอบ	รูปแบบบวก	Classic-D+	93.2	90.0	74.1	46.2	84.3	75.1
		CS-D+	78.3	113.3	93.9	56.6	115.1	64.0
	รูปแบบคูณ	Classic-Dx	51.5	68.9	67.3	48.5	94.9	66.4
		CS-Dx	56.0	79.9	66.1	46.1	83.7	60.0
ไฮลด์-วินเทอร์	รูปแบบบวก	Grid-HW+	57.5	109.8	60.0	51.1	93.5	52.8
		CS-HW+	55.5	121.6	124.2	51.1	102.5	62.0
	รูปแบบคูณ	Grid-HWx	68.0	87.5	109.4	52.8	70.6	55.9
		CS-HWx	70.9	80.0	110.4	51.8	74.9	53.3
Box-Jenkins			78.2	132.8	58.1	55.1	109.7	72.2
LSTM			111.9	149.1	136.6	51.1	121.3	72.8

หมายเหตุ: มีการเน้นค่า sMAPE ต่ำสุดด้วยสี สำหรับอ่างเก็บน้ำเขื่อนแต่ละแห่ง

3.3 การพยากรณ์ล่วงหน้า 2 ปี

การพยากรณ์ค่าปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อน ทั้ง 6 เขื่อน ตามตัวแบบที่มีประสิทธิภาพมากที่สุดในหัวข้อ 3.2 ได้ผลการพล็อตอนุกรมเวลาค่าจริงและค่าพยากรณ์ดังตารางที่ 5 และรูปที่ 4 จะเห็นว่าปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนทุกเขื่อนนั้นมีฤดูกาลชัดเจน และใน 5 เขื่อนจะมีช่วงเวลาน้ำไหลเข้าเขื่อนมากที่สุดเหมือนกันคือช่วงฤดูฝนในเดือน กันยายน ประกอบไปด้วยเขื่อน ขุนด่าน

ปราการชล คลองสิียด นฤบดีนทร์จินดา บางพระ และประแสร์ ส่วนเขื่อน หนองปลาไหล จะมีช่วงช่วงเวลาน้ำไหลเข้าเขื่อนมากที่สุดเป็นช่วงปลายฤดูร้อนในเดือน พฤษภาคม

ในเขื่อนนฤบดีนทร์จินดาตัวแบบ Box-Jenkins เป็นตัวแบบที่เหมาะสม โดยได้ตัวแบบเป็น SARIMA(3,1,0)(0,1,1)₁₂ โดยต้องใช้ Ln เพื่อแปลงค่าของข้อมูลอนุกรมเวลา และผ่านการตรวจสอบคุณลักษณะของความคลาดเคลื่อนจากการพยากรณ์ ดังนี้ ความคลาดเคลื่อนมีการแจกแจงปรกติจากสถิติทดสอบ Anderson-Darling

(AD = 0.246, p-value = 0.749) ส่วนการทดสอบค่าเฉลี่ย ความคลาดเคลื่อนเท่ากับศูนย์ ($t = 0.40$, p-value = 0.688) และมีความแปรปรวนคงที่ทุกช่วงเวลาโดยสถิติทดสอบ Levene (Levene = 1.55, p-value = 0.217) ความคลาดเคลื่อนเป็นอิสระกัน (Ljung-Box Lag 48 (Chi-square) = 53.02, p-value = 0.165)

4. สรุปและวิจารณ์ผล

การใช้ CS ผสานกับ HW ในการประมาณค่าพารามิเตอร์จำนวน 3 ตัว คือ α, γ และ δ และ CS ผสานกับการแยกส่วนประกอบ ในการประมาณค่าพารามิเตอร์จำนวน 14 ตัว คือ $\beta_0, \beta_1, \hat{S}_1, \hat{S}_2, \dots$ และ \hat{S}_{12} ได้ผลลัพธ์ที่ดีกว่าการประมาณค่าพารามิเตอร์ด้วยวิธีเดิม ซึ่งสอดคล้องกับงานวิจัย Minsan & Minsan [23] ที่แสดงให้เห็นว่า การใช้วิธี WOA ผสานกับ HW และวิธี WOA ผสานกับการแยกส่วนประกอบใช้งานได้ดี เมื่อเทียบกับวิธี Classic-D Grid-HW LSTM และ Box-Jenkins โดยงานวิจัยนี้ผลการทดลองกับข้อมูลปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่ในภาคตะวันออกเฉียงเหนือของประเทศไทยทั้งหมดจำนวน 6 เขื่อน ได้ผลการทดลองดีในการทดลองชุดข้อมูลฝึกฝน และได้ผลการทดลองดีในการทดลองชุดข้อมูลทดสอบ

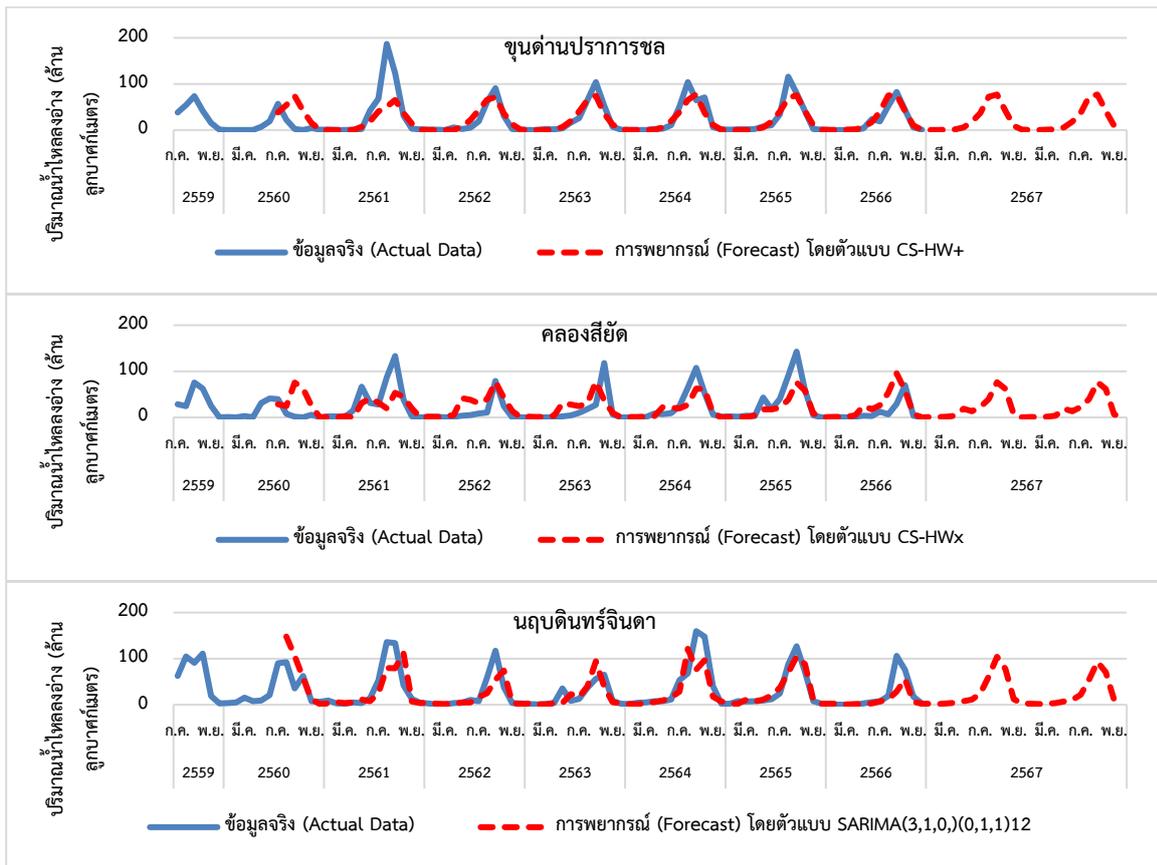
การนำเมตาฮีริสติกส์มาผสมผสานกับการประมาณค่าพารามิเตอร์ของตัวแบบพยากรณ์อนุกรมเวลาเป็นวิธีการที่ดี โดยสามารถนำวิธีการเมตาฮีริสติกส์ต่างๆ มาใช้ร่วมกันกับตัวแบบอนุกรมเวลา โดยหลักการคือเลือกวิธีการเมตาฮีริสติกส์ที่สนใจหรือวิธีการใหม่ๆ มาทำตามขั้นตอนของ Minsan & Minsan [22-23] หรือทำตามงานวิจัยนี้ก็จะสามารถผสมผสานทั้งสองส่วนคือ วิธีการเมตาฮีริสติกส์กับเทคนิคการพยากรณ์อนุกรมเวลาได้เป็นอย่างดี โดยที่ Minsan & Minsan [22-23] ที่ใช้วิธีการเมตาฮีริสติกส์ WOA และงานวิจัยนี้การใช้ CS สามารถหาค่าพารามิเตอร์ที่เหมาะสมโดยการประมวลผลเพียงครั้งเดียวก็ได้คำตอบที่ดีโดยไม่ต้องประมวลผลซ้ำหลายครั้ง เนื่องจากผลลัพธ์ของค่าต่ำสุดในฟังก์ชันวัตถุประสงค์ที่ได้มีความแกร่ง จากตารางที่ 6 ซึ่งแสดงค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของฟังก์ชันวัตถุประสงค์ ในการประมวลผลจำนวน 10 ครั้งของเขื่อนขุนด่านปราการชล จะเห็นว่าตัวแบบทั้ง 4 ที่ใช้ CS นั้นมีส่วนเบี่ยงเบนมาตรฐานที่มีค่าต่ำอยู่ในหลักทศนิยมตำแหน่งที่ 2 เป็นต้นไป แสดงว่าคำตอบที่ได้ในแต่ละครั้งที่ประมวลผลใกล้เคียงกัน ดังนั้นผู้ที่สนใจศึกษาแนวทางนี้อาจจะนำไปประยุกต์ใช้กับเทคนิคการพยากรณ์อนุกรมเวลาอื่นๆ ก็จะเป็นงานวิจัยที่น่าสนใจเป็นอย่างมาก

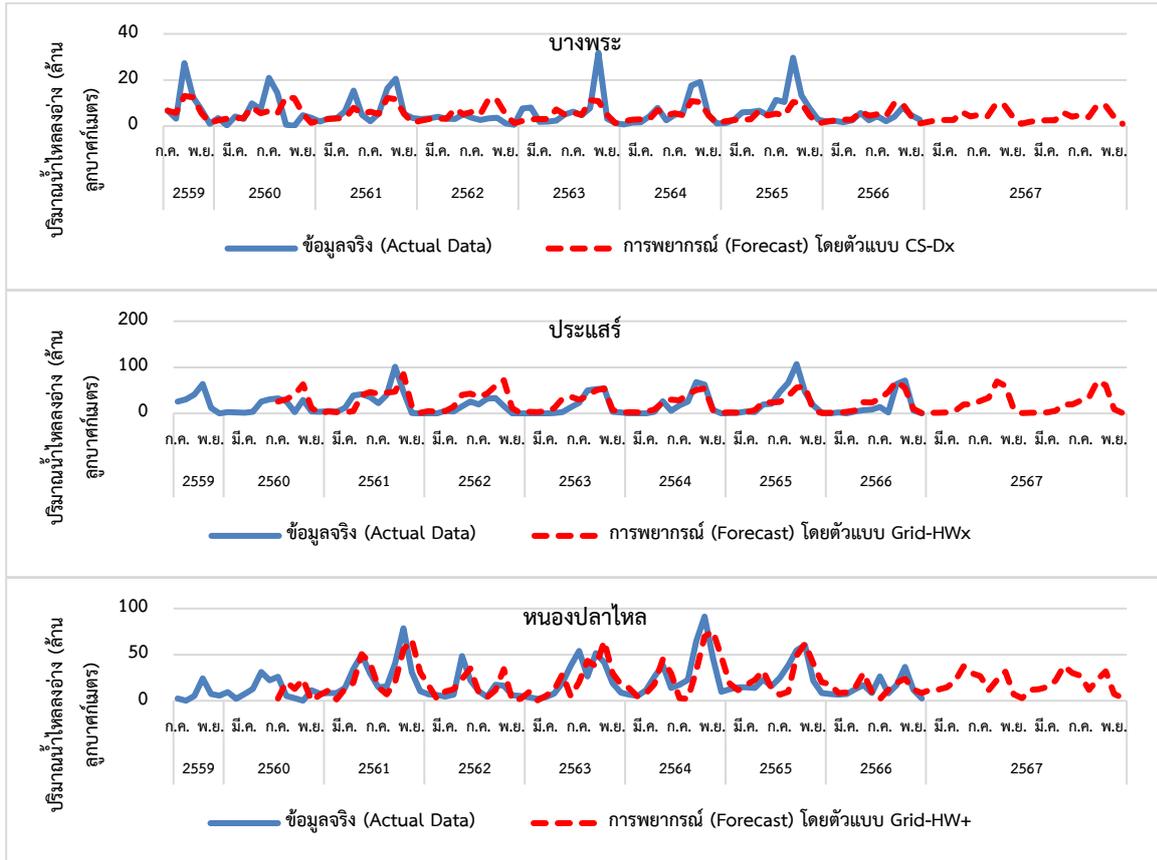
ตารางที่ 5 การพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อน (ล้านลูกบาศก์เมตร) มกราคม 2567 - ธันวาคม 2568

เดือน/ปี	อ่างเก็บน้ำเขื่อน					
	ขุนด่านปราการชล	คลองสิียด	นฤปดินทร์จินดา	บางพระ	ประแสร์	หนองปลาไหล
	CS-HW+	CS-HWx	SARIMA(3,1,0),(0,1,1) ₁₂	CS-Dx Model	Grid-HWx	Grid-HW+
ม.ค. 2567	0.4	0.8	2.4	1.9	1.2	11.7
ก.พ. 2567	0.3	0.7	1.7	2.5	1.6	12.2
มี.ค. 2567	0.5	1.3	2.9	2.6	2.3	14.6
เม.ย. 2567	1.3	3.4	4.0	2.6	5.6	21.5
พ.ค. 2567	5.7	18.7	7.9	6.2	19.2	37.5
มิ.ย. 2567	18.2	13.2	11.2	4.2	19.3	29.9
ก.ค. 2567	37.1	22.5	24.3	4.9	27.0	26.8
ส.ค. 2567	72.3	39.6	61.0	4.1	34.2	11.6
ก.ย. 2567	77.0	76.0	103.8	9.5	69.0	22.7
ต.ค. 2567	41.5	62.0	77.9	9.1	59.7	31.6
พ.ย. 2567	9.2	6.1	11.8	4.1	9.1	6.9
ธ.ค. 2567	1.0	0.3	2.6	1.0	0.8	2.9

เดือน/ปี	อ่างเก็บน้ำเขื่อน					
	ขุนด่านปราการชล	คลองสิียด	นฤปดินทร์จินดา	บางพระ	ประแสร์	หนองปลาไหล
	CS-HW+	CS-HWx	SARIMA(3,1,0),(0,1,1) ₁₂	CS-Dx Model	Grid-HWx	Grid-HW+
ม.ค. 2568	0.4	0.8	2.3	1.8	1.2	12.0
ก.พ. 2568	0.3	0.7	1.7	2.4	1.6	12.5
มี.ค. 2568	0.5	1.3	2.5	2.5	2.3	14.9
เม.ย. 2568	1.3	3.4	3.5	2.5	5.7	21.8
พ.ค. 2568	5.7	18.7	7.1	5.9	19.5	37.8
มิ.ย. 2568	18.2	13.2	10.4	4.0	19.6	30.2
ก.ค. 2568	37.1	22.5	21.8	4.7	27.5	27.1
ส.ค. 2568	72.3	39.6	54.3	4.0	34.8	11.9
ก.ย. 2568	77.0	76.0	93.0	9.1	70.2	23.0
ต.ค. 2568	41.5	62.0	70.5	8.7	60.8	31.8
พ.ย. 2568	9.2	6.1	10.7	3.9	9.2	7.2
ธ.ค. 2568	1.0	0.3	2.3	1.0	0.8	3.2

หมายเหตุ: ปริมาณน้ำน้อย  ปริมาณน้ำมาก ในแต่ละปี





รูปที่ 5 ค่าจริงและค่าพยากรณ์ของอ่างเก็บน้ำเขื่อนทั้ง 6 เขื่อน โดยใช้วิธีการพยากรณ์ที่เหมาะสมที่สุด

ตารางที่ 6 ค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐานของ MAE ของชุดข้อมูลฝึกฝนในแต่ละอ่างเก็บน้ำเขื่อนขุนด่านปราการชล

ตัวแบบ	ขุนด่านปราการชล	
	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน
CS-D+	10.3737	0.0165
CS-Dx	9.6478	0.0036
CS-HW+	13.4842	0.0000
CS-HW-	13.2879	0.0401

อย่างไรก็ตามในการพยากรณ์ล่วงหน้านั้นไม่สามารถเฉพาะเจาะจงได้อย่างมั่นใจว่าวิธีการพยากรณ์ใดให้ผลลัพธ์ในการพยากรณ์ล่วงหน้าดีที่สุด ความผันผวนของข้อมูลอนุกรมเวลาในชุดที่ทำการศึกษามีผลต่อความแม่นยำในการพยากรณ์ล่วงหน้า ถ้าชุดข้อมูลฝึกฝนมีรูปแบบเช่นเดียวกันกับในชุดข้อมูลทดสอบ ตัวแบบที่ดีในชุดข้อมูลฝึกฝนก็จะมีแนวโน้มให้ผลลัพธ์ที่ดีในช่วงชุดข้อมูลทดสอบ

ด้วย อย่างไรก็ตามต้องตระหนักไว้ด้วยว่า ความผันผวนของข้อมูลอนุกรมเวลามีขึ้นได้เสมอ ชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบอาจมีความแตกต่างกันบ้าง ดังนั้นจึงขอแนะนำว่าในการพยากรณ์ล่วงหน้าควรสร้างตัวแบบหลายตัวแบบเพื่อนำมาเปรียบเทียบกับกันตามเกณฑ์การตัดสินใจ ไม่ควรใช้ตัวแบบใดตัวแบบหนึ่งเพียงตัวแบบเดียว

5. กิตติกรรมประกาศ

การศึกษานี้ได้รับการสนับสนุนจากภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ ประเทศไทย

6. เอกสารอ้างอิง

[1] M. Dorigo, "Optimization, learning and natural algorithms," Ph.D. thesis, Politecnico di Milano, Italy, 1992.

- [2] M. Dorigo, M. Birattari and T. Stutzle, "Ant colony optimization," *IEEE Comput Intell.*, vol. 1, no. 4, pp. 28–39, 2006.
- [3] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," in *Proceedings of the 1995 IEEE International Conference on Neural Networks*, Perth, WA, Australia, pp. 1942–1948, 1995.
- [4] H. A. Abbass, "MBO: Marriage in Honey Bees Optimization – a Haplometrosis Polygynous Swarming Approach," in *Proceedings of The 2001 Congress on Evolutionary Computation*, Seoul, Korea (South), pp. 207–214, 2001.
- [5] X. Li, "A new intelligent optimization-artificial fish swarm algorithm," PhD thesis, Zhejiang University of Zhejiang, China, 2003.
- [6] R. Martin and W. Stephen, "Termite: A Swarm Intelligent Routing Algorithm for Mobilewireless Ad-Hoc Networks," in *Stigmergic Optimization*, Studies in Computational Intelligence, Springer, Berlin, Heidelberg, 2006, pp. 155–184.
- [7] B. Basturk and D. Karaboga, "An Artificial Bee Colony (ABC) Algorithm for Numeric Function Optimization," in *Proceedings of the IEEE Swarm Intelligence Symposium*, Indianapolis, USA, pp. 12–14, 2006.
- [8] P. C. Pinto, T. A. Runkler and J.M. Sousa, "Wasp Swarm Algorithm for Dynamic MAXSAT problems," in *Adaptive and Natural Computing Algorithms*, Springer, Berlin, Heidelberg, 2007, pp. 350–357.
- [9] A. Mucherino and O. Seref, "Monkey Search: A Novel Metaheuristic Search for Global Optimization," in *AIP Conference on Data Mining, Systems Analysis and Optimization in Biomedicine*, Gainesville, 2007.
- [10] C. Yang, X. Tu and J. Chen, Algorithm of Marriage in Honey Bees Optimization Based on The Wolf Pack Search, in *Proceedings of The 2007 International Conference on Intelligent Pervasive Computing (IPC 2007)*, Jeju, Korea (South), pp. 462–467, 2007.
- [11] X. Lu and Y. Zhou, "A Novel Global Convergence Algorithm: Bee Collecting Pollen Algorithm, in *Advanced Intelligent Computing Theories and Applications With Aspects of Artificial Intelligence*, Springer, Berlin, Heidelberg, 2008, pp. 518–525.
- [12] Y. Shiqin, J. Jianjun and Y. Guangxing, "A Dolphin Partner Optimization," in *Proceedings Of The WRI Global Congress on Intelligent Systems*, Xiamen, China, pp. 124–128, 2009.
- [13] X. S. Yang and S. Deb, "Cuckoo Search Via Lévy Flights," in *Proceedings of The World Congress on Nature & Biologically Inspired Computing (NaBIC)*, Coimbatore, India, pp. 210–214, 2009.
- [14] J. Sun, B. Feng and W. Xu, "Particle Swarm Optimization With Particles Having Quantum Behavior," in *Proceedings of the 2004 Congress on Evolutionary Computation (IEEE Cat. No.04TH8753)*, Portland, OR, USA. pp. 325-331, 2004.
- [15] C. T. Cheng, W. J. Niu, Z. K. Feng, J. J. Shen and K. W. Chau, "Daily reservoir runoff forecasting method using artificial neural network based on quantum-behaved particle swarm optimization," *Water.*, vol. 7, no. 8, pp. 4232-4246, 2015.
- [16] W. J. Niu, Z. K. Feng, C. T. Cheng and J. Z. Zhou, "Forecasting daily runoff by extreme learning machine based on quantum-behaved particle swarm optimization," *Journal of Hydrologic Engineering.*, vol. 23, no. 3, pp. 04018002, 2018.

- [17] Z. K. Feng, W. J. Niu, Z. Y. Tang, Z. Q. Jiang, Y. Xu, Y. Liu and H. R. Zhang, "Monthly runoff time series prediction by variational mode decomposition and support vector machine based on quantum-behaved particle swarm optimization," *Journal of Hydrology.*, vol. 583, no. 6, pp. 1-12, 2020.
- [18] E. Hadavandi, A. Ghanbari and S. Abbasian-Nagheh, "Developing a Time Series Model Based on Particle Swarm Optimization for Gold Price Forecasting," in *Third International Conference on Business Intelligence and Financial Engineering*, Hong Kong, China. pp. 337-340, 2010.
- [19] S. Kaewpaengjuntra, S. Somhom and L. Saenchan, "Electricity consumption forecasting model using hybrid Holt-Winters exponential smoothing and artificial bee colony algorithm," *Information Technology Journal.*, vol. 6, no. 1, pp. 12-17, 2010.
- [20] M. V. O. Assis, L. F. Carvalho, J. J. P. C. Rodrigues and M.L. Provençal, "Holt-Winters Statistical Forecasting and ACO Metaheuristic for Traffic Characterization," in *Proceeding of 2013 IEEE International Conference on Communications (ICC)*, Budapest, Hungary, pp. 2524-2528. 2013.
- [21] A. Simoni, E. D. Gjika and L. Puka, "Evolutionary Algorithm PSO and Holt-Winters Method Applied in Hydro Power Plants Optimization," in *Proceeding of the SPNA - Statistics Probability and Numerical Analysis*, Tirana, Albania, pp. 7-20, 2015.
- [22] W. Minsan and P. Minsan, "Incorporating decomposition and the Holt-Winters method into the whale optimization algorithm for forecasting monthly government revenue in Thailand," *Science & Technology Asia.*, vol. 28, no. 4, pp. 38-53, 2023.
- [23] W. Minsan and P. Minsan, "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.*, vol. 14, no. 2, pp. 1-16, 2024.
- [24] C. C. Mauricio and C. F. Ostia, "Cuckoo Search Algorithm Optimization of Holt-Winter Method for Distribution Transformer Load Forecasting," in *Proceeding of the 2023 9th International Conference on Control, Automation and Robotics (ICCAR)*, Beijing, China, pp. 36-42, 2023.
- [25] X. S. Yang, *Nature-Inspired Optimization Algorithms*, London: Elsevier, 2014.
- [26] R. N. Mantegna, "Fast, accurate algorithm for numerical simulation of Lévy stable stochastic process," *Physical Review E.*, vol. 49, no. 5, pp. 4677-4683, 1994.
- [27] Royal Irrigation Department, Ministry of Agriculture and Cooperatives, "Reservoirs Nationwide," [Online]. Available: <https://app.rid.go.th/reservoir/rsvmiddle>. [Accessed 26 January 2024].
- [28] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *International Journal of Forecasting.*, vol. 22, no. 4, pp. 679-688, 2006.
- [29] G. E. P. Box, G. M. Jenkins, G. C. Reinsel and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed., Oxford, England: John Wiley & Sons, 2015.

- [30] S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation.*, vol. 9, no. 8, pp. 1735-1780, 1997.
- [31] "Google Colab, Overview of Colaboratory Features," [Online]. Available: <https://colab.research.google.com/notebooks/intro.ipynb>. [Accessed 1 February 2024].