

การประมาณค่าพารามิเตอร์ที่เหมาะสมที่สุดในวิธีโฮลต์-วินเทอร์และการแยกส่วนประกอบด้วยอัลกอริทึมการค้นหาแบบนกกาเหว่า : การพยากรณ์ปริมาณน้ำไหลรายเดือนเข้าสู่อ่างเก็บน้ำของเขื่อนขนาดใหญ่ในภาคกลางและภาคตะวันตกของประเทศไทย

Optimizing Parameter Estimation in Holt– Winters and Decomposition Methods Using the Cuckoo Search Algorithm : Forecasting Monthly Water Inflow into Large-Dam Reservoirs in Central and Western Thailand

กาญจนา ทองบุญนาค

Kanjana Thongboonnak

คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครราชสีมา

Faculty of Science and Technology, Nakhon Ratchasima Rajabhat University

วิระภรณ์ ไหมทอง*

Wiraporn Maithong*

คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่

Faculty of Science and Technology, Chiang Mai Rajabhat University

E-mail : kanjana.t@nrru.ac.th and wiraporn_mai@cmru.ac.th*

*Corresponding author

(Received: 18 February 2025, Revised: 29 September 2025, Accepted: 2 October 2025)

<https://doi.org/10.57260/stc.2025.1089>

บทคัดย่อ

การศึกษานี้มีจุดมุ่งหมายเพื่อประเมินประสิทธิภาพของตัวแบบ ซึ่งผสมผสานอัลกอริทึม การค้นหาแบบนกกาเหว่า (Cuckoo search: CS) เข้ากับวิธีโฮลต์-วินเทอร์ (CS-HW) และวิธีการแยกส่วนประกอบ (CS-D) สำหรับการพยากรณ์ปริมาณน้ำไหลรายเดือนเข้าสู่อ่างเก็บน้ำของเขื่อนขนาดใหญ่ในภาคกลางและภาคตะวันตกของประเทศไทยจำนวน 5 แห่ง โดยเปรียบเทียบกับโปรแกรมสำเร็จรูป ได้แก่ โปรแกรม Minitab (Minitab-D) และโปรแกรม Excel (ForecastSheet-HW) ในระยะชุดข้อมูลฝึกฝน พบว่า CS-HW และ CS-D สามารถให้ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute error: MAE) ต่ำกว่าวิธีโปรแกรมสำเร็จรูป แสดงถึงศักยภาพในการค้นหาค่าพารามิเตอร์ที่เหมาะสมยิ่งขึ้น

สำหรับระยะชุดข้อมูลทดสอบ ได้คัดเลือกตัวแบบสำหรับแต่ละอ่างเก็บน้ำ โดยใช้เกณฑ์ MAE ต่ำสุด ได้แก่ เชื่อนศรีนครินทร์ เลือก ForecastSheet-HW เชื่อนวชิราลงกรณ์ เชื่อนกระเสียว และเชื่อนทับเสลา เลือก CS-HW และเขื่อนป่าสักชลสิทธิ์ เลือก Minitab-D เมื่อใช้ตัวแบบที่ถูกคัดเลือกมาพยากรณ์ล่วงหน้า 24 เดือน พบว่า ปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อนทั้ง 5 แห่งมีลักษณะฤดูกาลชัดเจน โดยมีค่าสูงสุดในช่วงฤดูฝน (เดือนสิงหาคม–ตุลาคม) ผลการศึกษาชี้ให้เห็นว่าการผสานอัลกอริทึมเมตาฮิวริสติกส์อย่าง CS เข้ากับตัวแบบอนุกรมเวลาแบบดั้งเดิม สามารถช่วยเพิ่มความแม่นยำในการพยากรณ์ และเป็นประโยชน์ต่อการวางแผนบริหารจัดการทรัพยากรน้ำในอนาคต

คำสำคัญ: อนุกรมเวลา การพยากรณ์ อ่างเก็บน้ำเขื่อน ค้นหาค่าที่เหมาะสมที่สุดแบบนกกาเหว่า

Abstract

This study aims to evaluate the performance of models that integrate the Cuckoo Search (CS) algorithm with the Holt-Winters method (CS-HW) and the Decomposition method (CS-D) for forecasting the monthly water inflow into five large dam reservoirs located in the central and western regions of Thailand. The models were compared with two commonly used software packages, Minitab (Minitab-D) and Excel (ForecastSheet-HW). In the training phase, CS-HW and CS-D showed lower Mean Absolute Error (MAE) than the software-based approaches, indicating a greater capacity to optimize parameter estimation.

In the testing phase, the model with the lowest MAE was selected for each reservoir. Specifically, ForecastSheet- HW was chosen for the Srinagarind Dam, CS- HW for the Vajiralongkorn, Kra Siao, and Thap Salao Dams, and Minitab-D for the Pa Sak Cholasit Dam. When employing the selected models to forecast 24 months ahead, all five reservoirs exhibited a distinct seasonal pattern, with peak inflows occurring in the rainy season (August–October). The findings highlight that integrating a metaheuristic algorithm such as CS with traditional time series models can enhance forecasting accuracy, offering valuable support for future water resource management planning.

Keywords: Time series, Forecasting, Dam reservoir, Cuckoo search optimization

บทนำ

ในช่วงสามทศวรรษที่ผ่านมา มีความก้าวหน้าและการผสมผสานระหว่างการพยากรณ์อนุกรมเวลากับขั้นตอนวิธีเมตาฮีริสติกส์อย่างต่อเนื่อง แนวคิดหลักของเมตาฮีริสติกส์ที่ได้แรงบันดาลใจจากธรรมชาติ (Nature-inspired metaheuristics) เริ่มเป็นที่รู้จักตั้งแต่ ค.ศ. 1992 เมื่อ Dorigo (1992) นำเสนอวิธีการอาณานิคมมด (Ant colony optimization: ACO) (Dorigo et al., 2006) ตามมาด้วยการหาค่าเหมาะที่สุดแบบกลุ่มอนุภาค (Particle swarm optimization: PSO) ของ Kennedy & Eberhart (1995) ใน ค.ศ. 1995 และได้รับความนิยมเรื่อยมา จนถึงยุคที่มีการพัฒนาเมตาฮีริสติกส์หลากหลายรูปแบบ เช่น การค้นหาแบบฮาร์โมนี (Harmony search) (Geem et al., 2001) อาณานิคมผึ้งเทียม (Artificial bee colony: ABC) (Karaboga, 2005) ขั้นตอนวิธีหิ่งห้อย (Firefly algorithm) (Yang, 2009) วิธีการค้นหาแบบนกกาเหว่า (Cuckoo search: CS) (Yang & Deb, 2009) ขั้นตอนวิธีค้างคาว (Bat algorithm) (Yang, 2010) การหาค่าเหมาะที่สุดแบบแมลงหวี่ (Fruit fly optimization: FFO) (Pan, 2012) ขั้นตอนวิธีการถ่ายละอองเรณูดอกไม้ (Flower pollination algorithm) (Yang, 2012) ขั้นตอนวิธีฝูงกิ้งก่าย (Krill herd algorithm) (Gandomi & Alavi, 2012) การหาค่าเหมาะที่สุดหมาป่าสีเทา (Grey wolf optimization) (Mirjalili et al., 2014) ขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬ (Whale optimization algorithm: WOA) (Mirjalili & Lewis, 2016) ขั้นตอนวิธีแมลงปอ (Dragonfly algorithm) (Mirjalili, 2016) และ การหาค่าเหมาะที่สุดเหยี่ยวแฮร์ริส (Harris hawks optimization) (Heidari et al., 2019) เป็นต้น

ความพยายามในการบูรณาการขั้นตอนวิธีเมตาฮีริสติกส์เข้ากับการพยากรณ์อนุกรมเวลาส่งผลให้เกิดงานวิจัยที่หลากหลาย เช่น ประยุกต์ใช้เมตาฮีริสติกส์เพื่อเพิ่มประสิทธิภาพการประมาณค่าพารามิเตอร์เพื่อพยากรณ์ด้วยวิธีการทำให้เรียบเลขชี้กำลังของโฮลต์-วินเทอร์ (Holt-Winters: HW) เช่น การผสมผสาน HW กับ ABC (Kaewpaengjuntra et al., 2010) และ การผสมผสาน HW กับ FFO (Jiang et al., 2020) หรือการขยายงานวิจัยออกไปโดยประยุกต์ใช้เมตาฮีริสติกส์เพื่อเพิ่มประสิทธิภาพการประมาณค่าพารามิเตอร์เพื่อพยากรณ์ด้วยวิธีการแยกส่วนประกอบ (Decomposition) และ HW เช่น การผสมผสาน WOA กับการแยกส่วนประกอบ และ WOA กับ HW เพื่อค้นหาพารามิเตอร์ที่เหมาะสมในการพยากรณ์อนุกรมเวลารายเดือนรายได้รัฐบาลของประเทศไทย (Minsan & Minsan, 2023) และ การผสมผสาน CS กับการแยกส่วนประกอบ และ CS กับ HW เพื่อค้นหาพารามิเตอร์ที่เหมาะสมในการพยากรณ์อนุกรมเวลารายสัปดาห์ค่าความเข้มข้น PM2.5 ใน 8 จังหวัดภาคเหนือประเทศไทย (Minsan et al., 2024) และ การผสมผสาน WOA กับการแยกส่วนประกอบ และ WOA กับ HW เพื่อค้นหาพารามิเตอร์ที่เหมาะสมในการพยากรณ์อนุกรมเวลารายสัปดาห์ค่าความเข้มข้น PM2.5 ใน 8 จังหวัดภาคเหนือประเทศไทย (Minsan & Minsan, 2024a)

ในด้านการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำมีการศึกษาที่โดดเด่น คือ Minsan & Minsan (2024b) ได้ผสมผสาน WOA กับการแยกส่วนประกอบ และ WOA กับ HW สำหรับการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำขนาดใหญ่ในภาคใต้ของประเทศไทย และ Minsan & Minsan (2024c) ได้ผสมผสาน CS กับการแยกส่วนประกอบ และ CS กับ HW เพื่อพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือนใน

ภาคตะวันออกเฉียงเหนือของประเทศไทย และ Vimolsutjarit et al. (2025) ได้การพยากรณ์ระดับน้ำในเขื่อนภาคเหนือประเทศไทย โดยใช้ตัวแบบการพยากรณ์การแยกส่วนประกอบและ HW ผสานกับ FFO และ Minsan & Minsan (2025a) การพยากรณ์ปริมาณน้ำฝนในลุ่มน้ำปิง วัง ยม และน่านของประเทศไทยโดยใช้วิธีการแยกส่วนประกอบและ HW ผสานกับ Solver GRG nonlinear ในโปรแกรม Excel เพิ่มประสิทธิภาพในการประมาณพารามิเตอร์ของตัวแบบ สามารถให้ความแม่นยำที่เทียบเคียงได้กับวิธีการที่ซับซ้อนของ WOA โดยไม่จำเป็นต้องมีการเขียนโค้ด ทำให้เป็นทางเลือกที่ใช้งานได้จริงในการพยากรณ์ โดยผู้สนใจสามารถดาวน์โหลดได้จาก Minsan & Minsan (2025b)

สำหรับขั้นตอนวิธีการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่าซึ่ง Yang & Deb (2009) พัฒนาขึ้น ได้รับความนิยมอย่างมากในสาขาต่างๆ เนื่องจากมีหลักการเลียนแบบพฤติกรรมกรวางไข่ของนกกาเหว่าในการแสวงหาจุดเหมาะที่สุด ทั้งในแง่ความแม่นยำและความรวดเร็วในการหาผลลัพธ์ ทั้งนี้งานวิจัยที่นำ CS ไปผสานกับตัวแบบ HW (Mauricio & Ostia, 2023; Minsan & Minsan, 2024c; Minsan et al., 2024) เพื่อปรับค่าพารามิเตอร์การทำให้เรียบ คือ องค์ประกอบเชิงระดับ (Level) เชิงแนวโน้ม (Trend) และเชิงฤดูกาล (Seasonal) หรือการผนวกกับตัวแบบการแยกส่วนประกอบ (Minsan & Minsan, 2024c; Minsan et al., 2024) ซึ่งเป็นเครื่องมือสำคัญในการแตกส่วนสัญญาณอนุกรมเวลาออกเป็นส่วนย่อย (แนวโน้ม ฤดูกาล และความสุ่ม) จึงช่วยให้การวิเคราะห์หรือการพยากรณ์มีประสิทธิภาพสูงขึ้น จากผลการศึกษาที่ผ่านมา บ่งบอกว่าการผสาน CS เข้ากับตัวแบบการพยากรณ์มีศักยภาพในการปรับปรุงความแม่นยำได้อย่างโดดเด่น ทั้งในช่วงการฝึกฝน (Training) และการทดสอบ (Testing) ในข้อมูลอนุกรมเวลา โดยเฉพาะกรณีศึกษาเกี่ยวกับข้อมูลทางอุทกวิทยาที่มีความผันแปรและความซับซ้อนหลากหลายที่มีลักษณะแนวโน้มและฤดูกาล การศึกษาครั้งนี้จึงมุ่งนำเสนอกระบวนการประมาณค่าพารามิเตอร์ของตัวแบบการแยกส่วนประกอบ และตัวแบบ HW ด้วยวิธี CS เรียกวิธีการเหล่านี้ว่า การค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮสต์-วินเทอร์ (CS-HW) และค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบ (CS-D) เพื่อใช้ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำขนาดใหญ่รายเดือนในภาคกลางและตะวันตกของประเทศไทย โดยคาดหวังว่าการผสมผสานระหว่างเทคนิคการค้นหาค่าเหมาะที่สุดที่มีประสิทธิภาพกับตัวแบบอนุกรมเวลาจะช่วยเพิ่มความแม่นยำ ลดข้อผิดพลาดในการพยากรณ์ และสามารถเป็นแนวทางสำหรับการบริหารจัดการทรัพยากรน้ำที่มีประสิทธิภาพยิ่งขึ้นในอนาคต


วัตถุประสงค์

1. นำเสนอเทคนิคการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่าสำหรับปรับค่าพารามิเตอร์ของตัวแบบการแยกส่วนประกอบ และตัวแบบโฮสต์-วินเทอร์โดยเรียกว่า CS-D และ CS-HW ตามลำดับ เพื่อเพิ่มความแม่นยำในการพยากรณ์
2. เพื่อประเมินประสิทธิภาพของ CS-D และ CS-HW ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำขนาดใหญ่รายเดือนในภาคกลางและภาคตะวันตกของประเทศไทย


ระเบียบวิธีวิจัย

1. การเตรียมข้อมูล


งานวิจัยนี้ใช้ข้อมูลทุติยภูมิจากกรมชลประทาน (<https://app.rid.go.th/reservoir/>) (กรมชลประทาน, 2568) ซึ่งเป็นอนุกรมเวลารายเดือนของปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่ในภาคกลางจำนวน 3 แห่ง ได้แก่ เขื่อนกระเสียวความจุ 299 ล้านลูกบาศก์เมตร เขื่อนทับเสลาความจุ 160 ล้านลูกบาศก์เมตร และเขื่อนป่าสักชลสิทธิ์ความจุ 960 ล้านลูกบาศก์เมตร และภาคตะวันตกจำนวน 2 แห่ง ได้แก่ เขื่อนศรีนครินทร์ความจุ 17,745 ล้านลูกบาศก์เมตร และเขื่อนวชิราลงกรณ์ความจุ 8,860 ล้านลูกบาศก์เมตร รวมจำนวน 5 แห่ง ช่วงเวลาเก็บข้อมูลตั้งแต่เดือนมกราคม ค.ศ. 2012 ถึงเดือนธันวาคม ค.ศ. 2023 รวมทั้งสิ้น 144 ค่า สำหรับแต่ละอ่างเก็บน้ำ



ภาพที่ 1 ข้อมูลอนุกรมเวลาปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนทั้ง 5



ภาพที่ 2 ACF ของข้อมูลอนุกรมเวลาการขจัดฤดูกาลของอ่างเก็บน้ำเขื่อนทั้ง 5



ภาพที่ 3 ACF ของข้อมูลอนุกรมเวลาการวัดแนวโน้มของอ่างเก็บน้ำเขื่อนทั้ง 5

จากการพิจารณาเบื้องต้นภาพที่ 1 พบว่า อนุกรมเวลามีส่วนประกอบทั้งแนวโน้มและฤดูกาล เนื่องจากกราฟอนุกรมเวลามีรูปแบบซ้ำๆ กันในคาบเวลาสม่ำเสมอ เมื่อขจัดฤดูกาลภาพที่ 2 แล้ววิเคราะห์ด้วยฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation function: ACF) พบว่า ACF ของอ่างเก็บน้ำแต่ละเขื่อนมีค่ามากในช่วงเวลาที่ช้ากว่ากัน 1 (Lag 1) และค่อย ๆ ลดลงเมื่อช่วงเวลาที่ช้ากว่ากันเพิ่มขึ้น แสดงลักษณะแนวโน้มของข้อมูล ส่วนการขจัดแนวโน้มภาพที่ 3 พบว่า ACF มีค่าด้านลบมากที่สุดในช่วงเวลาที่ช้ากว่ากัน 6 และ 18 (Lag 6 และ 18) และค่าด้านบวกมากที่สุดในช่วงเวลาที่ช้ากว่ากัน 12 และ 24 (Lag 12 และ 24) บ่งบอกถึงความผันผวนตามฤดูกาล จึงสรุปได้ว่าข้อมูลมีองค์ประกอบแนวโน้มและฤดูกาล

การประเมินความเสถียรของความแปรปรวน ดำเนินการโดยใช้สถิติของเลวิน (Levene's Test) เพื่อตรวจสอบภาวะความแปรปรวนคงที่ (Homoscedasticity) ทั้งนี้ก่อนการทดสอบข้อมูลอนุกรมเวลาได้ถูกแปลงค่าเพื่อลดสหสัมพันธ์ในตัวเอง (Autocorrelation) ซึ่งเป็นการรับรองว่าค่าสังเกตต่างๆ มีความเป็นอิสระต่อกัน (Minsan & Minsan, 2023; Minsan et al., 2024; Minsan & Minsan, 2025a) หากผลทดสอบบ่งชี้ว่ามีความแปรปรวนคงที่ จะใช้รูปแบบบวก (Additive) ในการอธิบายความสัมพันธ์ระหว่างแนวโน้มและฤดูกาล แต่หากความแปรปรวนไม่คงที่ จะพิจารณารูปแบบคูณ (Multiplicative) จากตารางที่ 1 พบว่าค่าพี (P-value) มากกว่าระดับนัยสำคัญ 0.05 สำหรับทุกเขื่อน จึงสรุปได้ว่าข้อมูลอนุกรมเวลาของทั้ง 5 เขื่อนมีความแปรปรวนคงที่ และสามารถใช้รูปแบบบวกในการวิเคราะห์และพยากรณ์ต่อไป

ตารางที่ 1 การทดสอบของเลวิน แยกตามอ่างเก็บน้ำเขื่อนทั้ง 5

การทดสอบ ของเลวิน	อ่างเก็บน้ำเขื่อน				
	เขื่อน ศรีนครินทร์	เขื่อน วชิราลงกรณ์	เขื่อน กระเสียว	เขื่อน ทับเสลา	เขื่อน ป่าสักชลสิทธิ์
Test Statistic	0.71	0.10	0.80	0.16	0.09
P-value	0.400	0.758	0.374	0.687	0.771

2. การผสมการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับโฮสต์-วินเทอร์

วิธีโฮสต์-วินเทอร์ ได้รับการยอมรับอย่างกว้างขวางในด้านความสามารถในการปรับตัว เพื่อรองรับการเปลี่ยนแปลงของระดับ แนวโน้ม และฤดูกาล ทั้งในรูปแบบบวกและรูปแบบคูณตามลักษณะของข้อมูลอนุกรมเวลา แม้จะมีข้อมูลการฝึกฝนปริมาณไม่มากก็ตาม วิธีนี้ยังคงสามารถสร้างตัวแบบพยากรณ์ได้ดี ในกรณีรูปแบบบวกจะใช้สมการ (1) ถึง (4) สำหรับการพยากรณ์ตามวิธี HW อย่างเป็นขั้นตอนดังนี้

พยากรณ์รูปแบบบวก

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

$$\hat{T}_t = \alpha(Y_t - \hat{S}_{t-s}) + (1-\alpha)(\hat{T}_{t-1} + \hat{\beta}_{t-1}) \quad (2)$$

$$\hat{\beta}_t = \gamma(\hat{T}_t - \hat{T}_{t-1}) + (1-\gamma)\hat{\beta}_{t-1} \quad (3)$$

$$\hat{S}_t = \delta(Y_t - \hat{T}_t) + (1-\delta)\hat{S}_{t-s} \quad (4)$$

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

วิธี HW จะใช้พารามิเตอร์การทำให้เรียบ 3 ค่าหลัก ได้แก่ α, γ และ δ ซึ่งแต่ละค่ามีช่วงระหว่าง 0 ถึง 1 เพื่อนำมาปรับระดับ แนวโน้ม และฤดูกาล ของข้อมูลอนุกรมเวลา ในงานวิจัยนี้ได้ใช้อัลกอริทึม CS เพื่อค้นหาค่าพารามิเตอร์ทั้ง 3 ค่าที่เหมาะสมสำหรับตัวแบบ HW โดยมีขั้นตอนและรายละเอียดการคำนวณ แสดงไว้ในรหัสเทียม (Pseudo code) ในภาพที่ 4 หลังจากนั้นจึงประเมินประสิทธิภาพของตัวแบบ CS-HW ด้วยการวัดความแม่นยำในการพยากรณ์ตามฟังก์ชันวัตถุประสงค์ที่กำหนดในสมการ (5)

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

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

$$MAE = \frac{1}{n_1} \sum_{t=1}^{n_1} |Y_t - \hat{Y}_t| \quad (5)$$

เมื่อ n_1 หมายถึงความยาวของชุดข้อมูลฝึกฝนกำหนดที่ 120 ค่า และ

Y_t และ $\hat{Y}_t$ หมายถึงค่าจริงและค่าพยากรณ์จาก CS-HW ของชุดข้อมูลฝึกฝน

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

1. Get a cuckoo i by performing Lévy flights.

2. Calculate fitness using HW by equation (5) of a cuckoo i .

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

End for

For $i = 1$ to n

Random p

If ($p < p_a$),

1. Abandon a worse nest and build a new one.

2. Calculate fitness using HW by equation (5) of a new nest i .

3. 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.

ภาพที่ 4 รหัสเทียมของ CS-HW

(Minsan et al., 2024; Minsan & Minsan, 2024c)

3. การผสมผสานการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบ

การปรับพารามิเตอร์ของตัวแบบแยกส่วนประกอบด้วยอัลกอริทึม CS มีขั้นตอนการคำนวณตามรหัสเทียมในภาพที่ 5 ซึ่งสามารถสรุปประเด็นสำคัญได้ดังนี้

3.1 การปรับขนาดพารามิเตอร์ (Scaling parameters)

หลังจากกำหนดขอบเขตการค้นหา (search space) ของอัลกอริทึม CS ในช่วง $[0, 1]$ แล้ว นำค่าพารามิเตอร์ที่ได้จาก CS มาปรับขนาดให้สอดคล้องกับหน่วยข้อมูลจริง ก่อนคำนวณค่าความเหมาะสมของตัวแบบ โดยอาศัยสมการ (6)

$$\text{Original Value} = \text{Scaled Value} \times (\text{UB} - \text{LB}) + \text{LB} \quad (6)$$

Original Value คือ ค่าพารามิเตอร์ตามหน่วยข้อมูลจริง

Scaled Value คือ ค่าพารามิเตอร์ที่ได้จาก CS ในช่วง $[0, 1]$

UB และ LB คือ ค่าขอบเขตสูงสุด (Upper bound) และ ค่าขอบเขตต่ำสุด (Lower bound) ตามลำดับของหน่วยข้อมูลจริงที่ต้องการ การปรับขนาดพารามิเตอร์ด้วยสมการนี้ ทำให้การค้นหาค่าพารามิเตอร์ที่ได้จาก CS ในช่วง $[0, 1]$ สามารถแปลงกลับมาเป็นหน่วยจริงของข้อมูล เพื่อใช้ในการประเมินค่าความเหมาะสมของตัวแบบแยกส่วนประกอบได้อย่างถูกต้องและสอดคล้องกับบริบทของข้อมูลอนุกรมเวลาที่เราศึกษา

โดยค่าที่จำเป็นต้องหาเพิ่มเติมคือ UB และ LB ดังนี้

3.2 การคำนวณข้อจำกัดบนและล่างของ $\hat{\beta}_0$ และ $\hat{\beta}_1$

คำนวณส่วนประกอบแนวโน้มจากข้อมูลจริงโดยใช้การถดถอยเชิงเส้นจะได้ $\hat{Y}_t = \hat{\beta}_0' + \hat{\beta}_1't$ แล้ว

คำนวณ

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 & Minsan (2023)

3.3 การคำนวณข้อจำกัดบน (UB_s) และล่าง (LB_s) ของ $\hat{S}_i$ กรณีตัวแบบรูปแบบบวก

การกำหนดขอบเขตความแปรผันฤดูกาล ให้จำกัดส่วนประกอบแนวโน้มออกจากอนุกรมเวลาโดยใช้การหาผลต่างลำดับ 1 จะได้ $\Delta Y_t = Y_t - Y_{t-1}$ กำหนดข้อจำกัดขอบเขตบนและล่างสำหรับพารามิเตอร์ฤดูกาล $\hat{S}_1, \hat{S}_2, \hat{S}_3, \dots, \hat{S}_{12}$ ดังนี้

UB_s หาได้โดย $+[ค่าแอมพลิจูดสูงสุดของ ΔY_t]$

LB_s หาได้โดย $-[ค่าแอมพลิจูดต่ำสุดของ ΔY_t]$

แอมพลิจูด คือความสูงที่สุดของคลื่น ซึ่งในกรณีนี้หมายถึงความสูงที่สุดของความแปรผันฤดูกาลของอนุกรมเวลา

เมื่อได้ค่า Original value มาแล้วต้องปรับปรุงค่า $\hat{S}_i$ เพิ่มเติมก่อนนำไปประเมินผ่านความแม่นยำในการพยากรณ์ตามฟังก์ชันวัตถุประสงค์ สามารถคำนวณได้โดยใช้สมการที่ (7)

กรณีแยกส่วนประกอบรูปแบบบวก

$$\text{Adjust } \hat{S}_i = \hat{S}_i - \sum_{i=1}^{12} \hat{S}_i / 12, \text{ แล้ว } \sum_{i=1}^{12} \hat{S}_i = 0. \quad (7)$$

เมื่อการคำนวณสิ้นสุดจะเลือกพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าน้อยที่สุดของค่าน้อยที่สุดของความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ดังสมการที่ 8

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

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

$$\text{MAE} = \frac{1}{n_1} \sum_{t=1}^{n_1} |Y_t - \hat{Y}_t| \quad (8)$$

เมื่อ n_1 หมายถึงความยาวของชุดข้อมูลฝึกฝนกำหนดที่ 120 ค่า และ

Y_t และ $\hat{Y}_t$ หมายถึงค่าจริงและค่าพยากรณ์จาก CS-D ของชุดข้อมูลฝึกฝน

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: $\text{MaxTime} = 30$ sec., and the fitness value fails to improve after a specified number of iterations: $T_{\text{improve}} = 300$.

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 $< \text{MaxTime}$) or (the fitness value fails to improve after a specified T_{improve})

For $i = 1$ to n

1. Get a cuckoo i by performing Lévy flights.
2. Scaling Parameters equation (6).
3. Calculate fitness using decomposition by the equation (8) of a cuckoo i .
4. Update a host nest X_i if there is a better solution.

End for

For $i = 1$ to n

Random p

If ($p < p_a$),

1. Abandon a worse nest and build a new one.
2. Scaling Parameters equation (6).
3. Calculate fitness using decomposition by the equation (8) of a new nest i .
4. 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 $\text{MAE}(\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{S}_1^*, \hat{S}_2^*, \dots, \hat{S}_{12}^*)$ where $\hat{\beta}_0^*, \hat{\beta}_1^*, \hat{S}_1^*, \hat{S}_2^*, \dots, \hat{S}_{12}^*$ are the optimized parameters.

ภาพที่ 5 รหัสเทียมของ CS-D

(Minsan et al., 2024; Minsan & Minsan, 2024c)

4. วิธีบอซ-เจนกินส์

บอซ-เจนกินส์ เป็นวิธีที่ให้ค่าพยากรณ์ที่มีความถูกต้องสูงกว่าค่าพยากรณ์จากวิธีการอื่นในการพยากรณ์ระยะสั้น การกำหนดตัวแบบพยากรณ์ทำได้โดยการตรวจสอบฟังก์ชันสหสัมพันธ์ในตัว และฟังก์ชันสหสัมพันธ์ในตัวอย่างบางส่วน (Partial autocorrelation function: PACF) ของอนุกรมเวลาแบบคงที่ (Stationary time series) หรืออนุกรมเวลาที่มีค่าเฉลี่ยของความแปรปรวนคงที่ ตัวแบบทั่วไปวิธี บอซ-เจนกินส์ คือ Seasonal autoregressive integrated moving average หรือ SARIMA(p,d,q)(P,D,Q)_L ดังที่แสดงใน (9) (วฐา, 2567)

$$\phi_p(B)\Phi_P(B^L)(1-B)^d(1-B^L)^D y_t = \delta + \theta_q(B)\Theta_Q(B^L)\varepsilon_t \quad (9)$$

โดยที่ $\delta = \phi_p(B)\Phi_P(B^L)\mu$; μ คือ ค่าเฉลี่ยของอนุกรมเวลาแบบคงที่

$(1-B)^d$ คือ อันดับของผลต่างแบบไม่มีฤดูกาล (Non-seasonal difference)

$(1-B^L)^D$ คือ อันดับของผลต่างแบบมีฤดูกาล (Seasonal difference)

$\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$ คือ การถดถอยในตัวแบบไม่มีฤดูกาลอันดับ p (Non-seasonal autoregressive operator of order p : AR(p))

$\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$ คือ ค่าเฉลี่ยเคลื่อนที่แบบไม่มีฤดูกาลอันดับ q (Non-seasonal moving average operator of order q : MA(q))

$\Phi_P(B^L) = (1 - \Phi_1 B^L - \Phi_2 B^{2L} - \dots - \Phi_P B^{PL})$ คือ การถดถอยในตัวแบบมีฤดูกาลอันดับ P (Seasonal autoregressive operator of order P : SAR(P))

$\Theta_Q(B^L) = (1 - \Theta_1 B^L - \Theta_2 B^{2L} - \dots - \Theta_Q B^{QL})$ คือ แทนค่าเฉลี่ยเคลื่อนที่แบบมีฤดูกาลอันดับ Q (Seasonal moving average operator of order Q : SMA(Q))

B คือ ตัวดำเนินการถดถอยหลัง (Backward operator) โดยที่ $B^p y_t = y_{t-p}$

d และ D คือ ลำดับที่ของการหาผลต่างและผลต่างฤดูกาลของอนุกรมเวลา ตามลำดับ

L คือ คาบของฤดูกาล

สรุปการสร้างตัวแบบพยากรณ์โดยวิธี บอซ-เจนกินส์ มีขั้นตอนดังนี้

4.1. ตรวจสอบความคงที่ของอนุกรมเวลา

พิจารณารกราฟอนุกรมเวลา ตลอดจนกราฟ ACF และ PACF เพื่อวิเคราะห์ว่าอนุกรมเวลาที่มีความคงที่ (Stationary) หรือไม่ หากพบว่าอนุกรมเวลาไม่คงที่ (Non-stationary) ต้องดำเนินการทำให้อนุกรมเวลาดังกล่าวคงที่ก่อนจึงจะเข้าสู่ขั้นตอนถัดไป

4.2. การแปลงผลต่าง (Regular difference)

หากกราฟ ACF และ PACF บ่งชี้ว่าอนุกรมเวลาที่มีแนวโน้มอย่างชัดเจน (Trend) อาจกำหนดค่า d (ระดับการหาผลต่าง) เป็น 1 หรือ 2 เพื่อขจัดแนวโน้มหรือทำให้อนุกรมเวลาที่มีความคงที่

4.3. การแปลงผลต่างตามฤดูกาล (Seasonal difference)

ในกรณีที่กราฟ ACF และ PACF แสดงลักษณะของฤดูกาล (Seasonality) จะต้องหาผลต่างตามฤดูกาล โดยกำหนดค่า D เป็น 1 หรือ 2 ขึ้นอยู่กับคาบฤดูกาลของข้อมูล

4.4. การแปลงข้อมูล (Data transformation)

หากพบว่าอนุกรมเวลาที่มีความแปรปรวนที่ไม่คงที่ อาจใช้เทคนิคการแปลง เช่น การแปลงแบบบ็อกซ์-ค็อกซ์ (Box-Cox transformation) เพื่อลดความแปรปรวนให้คงที่ เช่น การแปลงข้อมูล y_t เป็น $\ln(y_t)$ หรือ y_t^λ โดยที่ λ อาจอยู่ในช่วง -5 ถึง 5 เป็นต้น

4.5. การกำหนดตัวแบบเบื้องต้น (Model identification)

เมื่อได้อนุกรมเวลาใหม่ที่มีความคงที่แล้ว ให้ระบุโครงสร้างตัวแบบเบื้องต้น โดยพิจารณาค่าพารามิเตอร์ p, q, P และ Q

4.6. การประมาณค่าพารามิเตอร์ (Parameter estimation)

ทำการประมาณค่าพารามิเตอร์ของตัวแบบด้วยวิธีที่เหมาะสม เช่น วิธีกำลังสองน้อยที่สุด (Ordinary least squares: OLS)

4.7. การตรวจสอบความเหมาะสมของตัวแบบ (Model diagnostics)

4.7.1 ทดสอบนัยสำคัญของพารามิเตอร์ ใช้สถิติการทดสอบที (t-test) เพื่อพิจารณาว่าตัวประมาณแต่ละตัวมีนัยสำคัญทางสถิติหรือไม่

4.7.2 ตรวจสอบความเป็นอิสระของความคลาดเคลื่อน ใช้สถิติ Ljung-Box โดยกำหนด lag ที่เหมาะสม (เช่น 36) เพื่อตรวจสอบว่าความคลาดเคลื่อนมีการกระจายตัวเป็นอิสระหรือไม่

4.7.3 ตรวจสอบการแจกแจงปกติ ใช้สถิติ Kolmogorov-Smirnov (KS test) เพื่อดูว่าความคลาดเคลื่อนมีรูปแบบการแจกแจงใกล้เคียงปกติหรือไม่

4.7.4 ตรวจสอบค่าเฉลี่ยของความคลาดเคลื่อนเท่ากับศูนย์ ใช้สถิติการทดสอบที (t-test)

4.7.5 ตรวจสอบความแปรปรวนคงที่ ใช้สถิติการทดสอบของเลวิน (Levene's test) เพื่อดูว่าความคลาดเคลื่อนมีความแปรปรวนสม่ำเสมอตลอดช่วงเวลากำหนดหรือไม่

หากตัวแบบไม่ผ่านเงื่อนไขใด ๆ ในขั้นตอนการตรวจสอบนี้ ควรปรับแก้หรือเลือกตัวแบบใหม่ โดยย้อนกลับไปทำซ้ำในขั้นตอนที่ 4.5 ถึง 4.7 จนกว่าจะได้ตัวแบบที่เหมาะสม

4.8. การพยากรณ์ (Forecasting)

นำตัวแบบที่ผ่านการตรวจสอบแล้วมาใช้พยากรณ์อนุกรมเวลาตามช่วงที่ต้องการ โดยคาดหวังให้ผลการพยากรณ์มีความน่าเชื่อถือและสอดคล้องกับพฤติกรรมของข้อมูลจริง

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_t หมายถึงความยาวของชุดข้อมูลฝึกฝนกำหนดที่ 120 ค่า และ Y_t และ $\hat{Y}_t$ หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลฝึกฝน ตามลำดับ

ผลของค่า MAE ในระยะข้อมูลฝึกฝนนี้จะได้ค่า MAE ทั้งหมด 4 วิธีคือ

- แยกส่วนประกอบโดยโปรแกรมสำเร็จรูป Minitab คำสั่ง Decomposition (Minitab-D) ซึ่งโปรแกรมจะทำการประมาณค่าพารามิเตอร์ที่เหมาะสม $\hat{\beta}_0, \hat{\beta}_1, \hat{S}_1, \hat{S}_2, \dots, \hat{S}_{12}$ โดยอัตโนมัติ
- เทคนิคการทำให้เรียบเลขชี้กำลังโฮลต์-วินเทอร์ โดยโปรแกรมสำเร็จรูป Excel คำสั่ง Forecast Sheet (ForecastSheet-HW) ซึ่งโปรแกรมจะทำการประมาณค่าพารามิเตอร์ที่เหมาะสม α, γ และ δ โดยอัตโนมัติ
- ค้นหาค่าที่เหมาะสมที่สุดแบบนกกาเหว่ากับการแยกส่วนประกอบ (CS-D) และ
- ค้นหาค่าที่เหมาะสมที่สุดแบบนกกาเหว่ากับโฮลต์-วินเทอร์ (CS-HW)

โดยจะเปรียบเทียบค่าที่ต่ำที่สุดของ MAE เป็นคู่ๆกัน 2 คู่ คือ Minitab-D เปรียบเทียบกับ CS-D และ ForecastSheet-HW เปรียบเทียบกับ CS-HW เพื่อพิจารณาว่าเทคนิคใดที่ประมาณค่าพารามิเตอร์ได้เหมาะสมที่สุด

ประเภทสองคือ “ระยะข้อมูลทดสอบ” มีวัตถุประสงค์เพื่อประเมินความสามารถในการพยากรณ์ล่วงหน้าของตัวแบบโดยให้ตัวแบบพยากรณ์ล่วงหน้า 2 ปีหรือ 24 เดือน ในระยะนี้ใช้ตัวชี้วัด MAE ในการประเมิน

$$MAE = \frac{1}{24} \sum_{t=121}^n |Y_t - \hat{Y}_t|$$

Y_t และ $\hat{Y}_t$ หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลทดสอบ ตามลำดับ

n หมายถึงความยาวของชุดข้อมูลกำหนดที่ 144 ค่า โดยที่ t เริ่มต้นที่ 121 จนถึง 144

โดยจะเปรียบเทียบค่าที่ต่ำที่สุดของ MAE 5 วิธี คือ Minitab-D, CS-D, ForecastSheet-HW, CS-HW และวิธีบ็อกซ์-เจนกินส์ เพื่อพิจารณาว่าเทคนิคใดที่ประมาณค่าพารามิเตอร์ได้เหมาะสมที่สุด

ผลการวิจัย

1. การวิเคราะห์ประสิทธิภาพในระยะชุดข้อมูลฝึกฝน

การวิจัยครั้งนี้ได้เปรียบเทียบประสิทธิภาพของตัวแบบ CS-HW และ CS-D กับโปรแกรมสำเร็จรูป 2 วิธี ได้แก่ Minitab-D และ ForecastSheet-HW โดยใช้ชุดข้อมูลอนุกรมเวลารายเดือนเกี่ยวกับปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนในภาคกลางและภาคตะวันตกของประเทศไทย (Training set) ผลสรุปค่าความคลาดเคลื่อนเฉลี่ยแบบ MAE แสดงไว้ในตารางที่ 2

ในการรันตัวแบบ CS-HW และ CS-D กำหนดจำนวนรอบ (Iterations) ในการค้นหาคำตอบไว้ที่ 1,000 รอบ โดยใช้ Python Google Colab ซึ่งมีค่าเฉลี่ยเวลาประมวลผลประมาณ 20 วินาทีต่อชุดข้อมูล ผลการวิเคราะห์ตารางที่ 2 ชี้ให้เห็นว่า การผสมผสานอัลกอริทึม CS เข้ากับตัวแบบ HW และการแยกส่วนประกอบ

ช่วยเพิ่มคุณภาพการพยากรณ์ให้ใกล้เคียงค่าจริงมากขึ้น เมื่อเปรียบเทียบกับการใช้โปรแกรมสำเร็จรูป Minitab-D และ ForecastSheet-HW สังเกตได้จากค่า MAE ที่ต่ำกว่าในทุกอ่างเก็บน้ำเขื่อนทั้ง 5 แห่ง

ดังนั้น สำหรับระยะชุดข้อมูลฝึกฝน สามารถสรุปได้ว่า

- CS-D ให้ค่า MAE ต่ำกว่าวิธี แยกส่วนประกอบแบบ Minitab-D
- CS-HW ให้ค่า MAE ต่ำกว่าวิธี HW ที่ได้จากโปรแกรมสำเร็จรูป ForecastSheet-HW

ผลดังกล่าวแสดงให้เห็นถึงศักยภาพของการประยุกต์อัลกอริทึม CS ในการปรับพารามิเตอร์ของตัวแบบทั้ง HW และแยกส่วนประกอบ ซึ่งสามารถนำไปใช้ต่อยอดในการพยากรณ์อนุกรมเวลาประเภทอื่น ๆ ได้อย่างมีประสิทธิภาพยิ่งขึ้นในอนาคต

ตาราง 2 MAE ของชุดข้อมูลฝึกฝนในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ		อ่างเก็บน้ำเขื่อน				
		เขื่อน	เขื่อน	เขื่อน	เขื่อน	เขื่อน
		ศรีนครินทร์	วชิราลงกรณ์	กระเสียว	ทับเสลา	ป่าสักชลสิทธิ์
แยก	Minitab-D	160.0198	213.5383	14.6219	9.4960	109.1045
ส่วนประกอบ	CS-D	151.8844	167.4885	13.5084	8.4132	98.3076
ไฮลด์-วินเทอร์	ForecastSheet-HW	210.7096	249.4301	17.9591	11.3919	160.0426
	CS-HW	162.6741	217.0941	14.5921	7.8170	105.1020

หมายเหตุ: ตัวทึบคือ MAE ต่ำสุด Minitab-D และ CS-D และระหว่าง ForecastSheet-HW และ CS-HW

2. การวิเคราะห์ประสิทธิภาพในระยะชุดข้อมูลทดสอบ

ในระยะชุดข้อมูลทดสอบนี้ได้มีการใช้ตัวแบบบ็อกซ์-เจนกินส์ มาร่วมในการสร้างตัวแบบตามที่ Minsan & Minsan (2024c) ได้กล่าวไว้ว่า การพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูลที่เกิดขึ้นได้ การแบ่งข้อมูลเป็นชุดข้อมูลฝึกฝนและทดสอบถ้าชุดข้อมูลทั้ง 2 มีลักษณะเดียวกันทุกประการ ความคลาดเคลื่อนที่ได้จากตัวแบบที่ดีที่สุด (ค่าความคลาดเคลื่อนต่ำสุด) จากชุดข้อมูลฝึกฝนก็จะตรงกันกับชุดข้อมูลทดสอบ แต่การพยากรณ์อนุกรมเวลาในข้อมูลจริงมีความแปรผันของข้อมูล ความแตกต่างเล็กน้อยที่อาจเกิดขึ้นในชุดข้อมูลฝึกฝนกับชุดข้อมูลทดสอบเกิดขึ้นได้เสมอ ดังนั้นเพื่อเป็นประโยชน์ต่อการนำค่าพยากรณ์ล่วงหน้าไปใช้ การเพิ่มตัวแบบอื่นๆ ในการพยากรณ์จึงเป็นสิ่งสำคัญที่การศึกษานี้ ดังนั้นในการศึกษานี้จึงเพิ่มการสร้างตัวแบบบ็อกซ์-เจนกินส์ได้ผลดังนี้

เขื่อนศรีนครินทร์ ตัวแบบ $SARIMA(0,1,2)(0,1,1)_{12}$ มีสมการพยากรณ์คือ

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + 0.3527e_{t-1} + 0.2357e_{t-2} + 0.8163e_{t-12} + 0.2879e_{t-13} + 0.1924e_{t-14}$$

เขื่อนวชิราลงกรณ์ ตัวแบบ $SARIMA(0,1,1)(0,1,1)_{12}$ มีสมการพยากรณ์คือ

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + 0.7046e_{t-1} + 0.8084e_{t-12} + 0.5696e_{t-13}$$

เขื่อนกระเสียว ตัวแบบ $SARIMA(3,1,0)(0,1,1)_{12}$ มีสมการพยากรณ์คือ

$$Y_t = 0.5977Y_{t-1} + 0.1724Y_{t-2} - 0.1537Y_{t-3} + 0.3836Y_{t-4} \\ + Y_{t-12} - 0.5977Y_{t-13} - 0.1724Y_{t-14} + 0.1537Y_{t-15} - 0.3836Y_{t-16} + 0.8371e_{t-12}$$

เชื่อนทับเสลา ตัวแบบ SARIMA (0,1,2)(0,1,1)₁₂ มีสมการพยากรณ์คือ

$$Y_t = Y_{t-1} + Y_{t-12} - Y_{t-13} + 0.4415e_{t-1} + 0.2069e_{t-2} + 0.8653e_{t-12} + 0.3820e_{t-13} + 0.1792e_{t-14}$$

เชื่อนป่าสักชลสิทธิ์ ตัวแบบ SARIMA (1,1,1)(1,2,1)₁₂ มีสมการพยากรณ์คือ

$$Y_t = 1.406Y_{t-1} - 0.406Y_{t-2} + 1.4195Y_{t-12} - 1.996Y_{t-13} \\ + 0.5764Y_{t-14} + 0.161Y_{t-24} - 0.2262Y_{t-25} + 0.0652Y_{t-26} \\ - 0.5805Y_{t-36} + 0.8161Y_{t-37} - 0.2356Y_{t-38} + 0.806e_{t-1} + 0.8604e_{t-12} + 0.6932e_{t-13}$$

โดยตัวแบบทั้งหมดผ่านการตรวจสอบความเหมาะสมของตัวแบบแยกตามอ่างเก็บน้ำเชื่อน ดังตารางที่ 3

ตารางที่ 3 ตัวแบบบอกซ์-เจนกินส์ และการตรวจสอบความเหมาะสมของตัวแบบแยกตามอ่างเก็บน้ำเชื่อน

อ่างเก็บน้ำเชื่อน	Box-Jenkins SARIMA (p, d, q)(P, D, Q) ₁₂	t-test (P-value)	Levene (P-value)	KS (P-value)	LB Lag 36 (P-value)
เชื่อนศรีนครินทร์	SARIMA (0,1,2)(0,1,1) ₁₂	0.22 (0.824)	1.25 (0.267)	0.051 (>0.150)	43.53 (0.104)
เชื่อนวชิราลงกรณ์	SARIMA (0,1,1)(0,1,1) ₁₂	-0.10 (0.917)	4.63 (0.054)	0.082 (0.074)	47.99 (0.056)
เชื่อนกระเสียว	SARIMA (3,1,0)(0,1,1) ₁₂	0.50 (0.618)	0.02 (0.875)	0.076 (0.129)	41.71 (0.117)
เชื่อนทับเสลา	SARIMA (0,1,2)(0,1,1) ₁₂	0.05 (0.964)	3.70 (0.057)	0.062 (>0.150)	37.61 (0.266)
เชื่อนป่าสักชลสิทธิ์	SARIMA (1,1,1)(1,2,1) ₁₂	-0.38 (0.703)	1.05 (0.309)	0.088 (0.067)	43.44 (0.085)

หมายเหตุ * ปฏิเสธสมมติฐานว่างที่ระดับนัยสำคัญ 0.05
A ทุกตัวแบบใช้การแปลง Box-Cox โดยการใช LN

เพื่อสรุปและคัดเลือกตัวแบบที่มีประสิทธิภาพสูงสุดสำหรับแต่ละอ่างเก็บน้ำเชื่อนในช่วงชุดข้อมูลทดสอบ นำค่า MAE จากตารางที่ 4 มาเปรียบเทียบ โดยตัวแบบที่มีค่า MAE ต่ำที่สุดจะถือเป็นตัวแบบที่เหมาะสมที่สุด สำหรับการพยากรณ์ล่วงหน้า 24 เดือน ผลการวิเคราะห์สรุปได้ดังนี้

เชื่อนศรีนครินทร์ วิธี ForecastSheet-HW มีค่า MAE = 117.1537 ต่ำที่สุดเมื่อเทียบกับวิธีอื่น จึงเลือก ForecastSheet-HW เป็นตัวแบบที่เหมาะสมที่สุด

เชื่อนวชิราลงกรณ์ วิธี CS-HW มีค่า MAE = 134.5742 ต่ำที่สุดในบรรดาวิธีที่เปรียบเทียบ จึงเลือก CS-HW เป็นตัวแบบที่เหมาะสมที่สุด

เชื่อนกระเสียว วิธี CS-HW มีค่า MAE = 16.5608 ต่ำที่สุด จึงเลือก CS-HW เป็นตัวแบบที่เหมาะสมที่สุด

เชื่อนทับเสลา วิธี CS-HW มีค่า MAE = 12.5736 ต่ำที่สุด จึงเลือก CS-HW เป็นตัวแบบที่เหมาะสมที่สุด

เชื่อมป่าสักชลสิทธิ์ วิธี Minitab-D มีค่า MAE = 146.7654 ต่ำที่สุด จึงเลือก Minitab-D เป็นตัวแบบที่เหมาะสมที่สุด

โดยสรุป วิธีการประเมินประสิทธิภาพในชุดข้อมูลทดสอบ พิจารณาจากค่า MAE ต่ำที่สุดในแต่ละอ่างเก็บน้ำเขื่อน เพื่อคัดเลือกตัวแบบที่เหมาะสม ก่อนนำไปใช้ในการพยากรณ์ล่วงหน้า 24 เดือนต่อไป ซึ่งผลจากตารางที่ 4 ชี้ให้เห็นว่า CS-HW ให้ผลลัพธ์ที่ดีที่สุดใน 3 อ่างเก็บน้ำเขื่อน คือ วชิราลงกรณ์ กระเสียว และทับเสลา ขณะที่ ForecastSheet-HW เหมาะสำหรับเขื่อนศรีนครินทร์ และ Minitab-D เหมาะสำหรับเชื่อมป่าสักชลสิทธิ์

ตาราง 4 MAE ของชุดข้อมูลทดสอบในแต่ละอ่างเก็บน้ำเขื่อน

ตัวแบบ		อ่างเก็บน้ำเขื่อน				
		เขื่อนศรีนครินทร์	เขื่อนวชิราลงกรณ์	เขื่อนกระเสียว	เขื่อนทับเสลา	เขื่อนป่าสักชลสิทธิ์
แยก	Minitab-D	162.7047	214.9490	18.8629	14.7376	146.7654
ส่วนประกอบ	CS-D	210.7895	213.1062	20.3763	13.4046	179.2700
ไฮลด์-วินเทอร์	ForecastSheet-HW	117.1537	163.8233	17.1654	14.6953	181.0408
	CS-HW	118.0851	134.5742	16.5608	12.5736	170.9831
Box-Jenkins		323.5661	193.8779	59.0792	40.3133	278.4647

หมายเหตุ: ตัวทึบคือ MAE ต่ำสุดสำหรับอ่างเก็บน้ำเขื่อนแต่ละแห่ง

3. การพยากรณ์ล่วงหน้า 24 เดือน

จากตารางที่ 5 ซึ่งแสดงปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อนรายเดือน (ล้านลูกบาศก์เมตร: ลบ.ม.) ทั้ง 5 แห่ง ได้แก่ เขื่อนศรีนครินทร์ เขื่อนวชิราลงกรณ์ เขื่อนกระเสียว เขื่อนทับเสลา และเขื่อนป่าสักชลสิทธิ์ พบว่ามีลักษณะการไหลเข้ามากที่สุดในช่วงฤดูฝน ประมาณเดือน สิงหาคม – ตุลาคม สอดคล้องกับฤดูกาลของประเทศไทย โดยตัวอย่างข้อมูลเด่น ๆ มีดังนี้

เขื่อนศรีนครินทร์ คาดการณ์ว่าปริมาณน้ำไหลเข้าสูงสุดในช่วงเดือนตุลาคม เช่น ตุลาคม พ.ศ. 2567 = 1,301 ลบ.ม. และ ตุลาคม พ.ศ. 2568 = 1,307 ลบ.ม.

เขื่อนวชิราลงกรณ์ แสดงปริมาณน้ำไหลเข้าจำนวนมากช่วงเดือน สิงหาคม – ตุลาคม เช่น สิงหาคม พ.ศ. 2567 และ 2568 = 1,572 ลบ.ม.

เขื่อนกระเสียว แม้ตัวเลขจะน้อยกว่าเขื่อนขนาดใหญ่แห่งอื่น แต่ยังพบสภาวะน้ำไหลสูงสุด (Peak) ในช่วงเวลาเดียวกัน เช่น ตุลาคม พ.ศ. 2567 และ 2568 = 101 ลบ.ม.


เขื่อนทับเสลา ปริมาณน้ำไหลเข้ามีการเพิ่มขึ้นชัดเจนช่วงปลายฤดูฝน โดยเดือน กันยายน และ ตุลาคม พ.ศ. 2567 และ 2568 อาจเพิ่มขึ้นถึง 41 – 66 ล้าน ลบ.ม.

เขื่อนป่าสักชลสิทธิ์ มีแนวโน้มคล้ายคลึงกัน คือสภาวะน้ำไหลสูงสุดในช่วงฤดูฝน เช่น กันยายน พ.ศ. 2567 = 717 ล้าน ลบ.ม. และ กันยายน พ.ศ. 2568 = 726 ล้าน ลบ.ม.

ภาพรวมทั้งหมดแสดงให้เห็นถึง ลักษณะฤดูกาลอย่างชัดเจน ของการไหลเข้าอ่างเก็บน้ำเขื่อนทั้ง 5 แห่ง โดยเฉพาะในเดือน สิงหาคม – ตุลาคม ซึ่งเป็นช่วงฤดูฝน ส่งผลให้ปริมาณน้ำไหลเข้าเพิ่มขึ้นอย่างมีนัยสำคัญ ผลการพยากรณ์ดังกล่าวสามารถสนับสนุนการวางแผนบริหารจัดการน้ำอย่างเหมาะสมตลอดระยะเวลา 2 ปีข้างหน้า ทั้งในด้านการรักษาระดับน้ำในเขื่อน การเตรียมพร้อมรับปริมาณน้ำในช่วงฤดูฝน และการจัดสรรน้ำสำหรับพื้นที่ตอนล่างในช่วงฤดูแล้งต่อไป

ตาราง 5 การพยากรณ์ล่วงหน้าปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อน (ล้านลูกบาศก์เมตร) มกราคม 2567 - ธันวาคม 2568

เดือน/ปี ค.ศ.	อ่างเก็บน้ำเขื่อน				
	เขื่อน ศรีนครินทร์	เขื่อน วชิราลงกรณ์	เขื่อน กระเสียว	เขื่อน ทับเสลา	เขื่อน ป่าสักชลสิทธิ์
Jan-24	105	45	0	1	124
Feb-24	101	38	6	3	126
Mar-24	101	29	3	3	103
Apr-24	118	31	11	2	77
May-24	201	134	38	5	111
Jun-24	217	230	19	5	102
Jul-24	507	788	24	4	161
Aug-24	981	1,572	28	5	239
Sep-24	1,165	1,211	76	41	717
Oct-24	1,301	947	101	66	490
Nov-24	402	205	21	11	166
Dec-24	185	81	1	2	120
Jan-25	111	44	0	1	133
Feb-25	107	37	6	3	135
Mar-25	107	28	3	3	112
Apr-25	124	31	11	2	86
May-25	207	133	38	5	120
Jun-25	223	229	19	5	111
Jul-25	513	788	24	4	170
Aug-25	987	1,572	28	5	247
Sep-25	1,171	1,210	76	41	726
Oct-25	1,307	946	101	66	498
Nov-25	408	204	21	11	175
Dec-25	191	81	1	2	129



ภาพที่ 6 ค่าจริงและค่าพยากรณ์ของอ่างเก็บน้ำเขื่อนทั้ง 5 เขื่อน โดยใช้วิธีการพยากรณ์ที่เหมาะสมที่สุด

การอภิปรายผล

1. การนำเสนอเทคนิคการค้นหาค่าที่เหมาะสมที่สุดแบบนกกาเหว่า (CS) สำหรับปรับค่าพารามิเตอร์ของตัวแบบการแยกส่วนประกอบ (CS-D) และตัวแบบโฮลต์-วินเทอร์ (CS-HW)

ผลของงานวิจัยสอดคล้องกับงานวิจัยที่ใช้อัลกอริทึมเมตาฮีวิริสติกส์เพื่อปรับค่าพารามิเตอร์ของตัวแบบอนุกรมเวลา เช่น การใช้ CS เพื่อเพิ่มความแม่นยำของ HW (Mauricio & Ostia, 2023) การบูรณาการ HW กับ ABC (Kaewpaengjuntra et al., 2010) และ FFO (Jiang et al., 2020) ตลอดจนงานที่ผสานเมตาฮีวิริสติกส์กับ Decomposition และ HW ในบริบทข้อมูลอนุกรมเวลาของประเทศไทย (เช่น Minsan & Minsan, 2023; 2025a) ข้อสังเกตดังกล่าวช่วยยืนยันว่าแนวทาง CS-D/CS-HW มีฐานเชิงประจักษ์รองรับและสามารถประยุกต์ใช้ได้กว้างขวางในชุดข้อมูลที่มีแนวโน้มและฤดูกาลเด่นชัด

ผลการพัฒนาตัวแบบ CS-D และ CS-HW พบว่าสามารถปรับค่าพารามิเตอร์ให้อยู่ในช่วงที่เหมาะสม สอดคล้องกับข้อมูลอนุกรมเวลามีแนวโน้ม และฤดูกาลได้ดี อัลกอริทึม CS ช่วยค้นหาพารามิเตอร์ภายในขอบเขตที่กำหนดให้เกิดค่าความคลาดเคลื่อนต่ำโดยอัตโนมัติ

การใช้เทคนิคการปรับขนาดพารามิเตอร์ที่นำเสนอโดย Minsan & Minsan (2023) เพื่อเปลี่ยนค่าที่ได้จากอัลกอริทึม CS ซึ่งอยู่ในช่วง $[0, 1]$ ให้กลับมาอยู่ในหน่วยข้อมูลจริง ช่วยให้วิธีการประมาณค่าพารามิเตอร์สอดคล้องกับบริบทของข้อมูลปริมาณน้ำในเขื่อนได้อย่างเป็นรูปธรรม

การนำโครงสร้างการคำนวณจากรหัสเทียมที่ออกแบบใหม่สำหรับ CS-D และ CS-HW ทำให้สะดวกต่อการปรับแต่ง และสามารถประยุกต์ใช้ร่วมกับอนุกรมเวลาอื่น ๆ ที่มีแนวโน้มและฤดูกาลได้ในอนาคต

2. การประเมินประสิทธิภาพของ CS-D และ CS-HW ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำขนาดใหญ่รายเดือนในภาคกลางและภาคตะวันตกของประเทศไทย

เมื่อเปรียบเทียบผลการพยากรณ์กับวิธีมาตรฐานหรือโปรแกรมสำเร็จรูปอื่น ๆ เช่น Minitab-D, ForecastSheet-HW และ Box-Jenkins พบว่า CS-HW ให้ค่า MAE ต่ำกว่าวิธี HW ในโปรแกรมสำเร็จรูปอย่างชัดเจนในหลายอ่างเก็บน้ำเขื่อน ขณะที่ CS-D มีความแม่นยำเพิ่มขึ้นเหนือกว่าวิธีแยกส่วนประกอบในโปรแกรมสำเร็จรูปในบางกรณีเช่นกัน

ในการประเมินทั้งช่วงข้อมูลฝึกฝน และข้อมูลทดสอบ กลุ่มตัวแบบ CS-HW และ CS-D แสดงให้เห็นถึงแนวโน้มค่าพยากรณ์ที่สอดคล้องกับฤดูกาลและแนวโน้มของข้อมูลจริงมากยิ่งขึ้น โดยเฉพาะอย่างยิ่งกรณีที่ข้อมูลมีความผันผวนสูงในช่วงฤดูฝน จากผลการวิเคราะห์ สามารถเลือกตัวแบบที่เหมาะสมที่สุดในแต่ละอ่างเก็บน้ำเขื่อนสำหรับการพยากรณ์ล่วงหน้า ช่วยลดค่าความคลาดเคลื่อนในอ่างเก็บน้ำเขื่อนที่ลักษณะข้อมูลมีการเปลี่ยนแปลงแนวโน้มและฤดูกาลอย่างชัดเจนเช่นกัน

ข้อค้นพบสำคัญคือ การผสานอัลกอริทึมเมตาฮีริสติกส์อย่าง CS เข้ากับตัวแบบอนุกรมเวลาที่มีฤดูกาลและแนวโน้ม (HW และ แยกส่วนประกอบ) ช่วยเพิ่มความแม่นยำในการพยากรณ์ปริมาณน้ำไหลเข้าอ่างเก็บน้ำเขื่อน ซึ่งเป็นข้อมูลสำคัญต่อการวางแผนและบริหารจัดการทรัพยากรน้ำในพื้นที่ภาคกลางและภาคตะวันตกของประเทศไทย

บทสรุปและข้อเสนอแนะ

การวิจัยนี้มุ่งนำเสนอเทคนิคการค้นหาค่าเหมาะที่สุดแบบนกกาเหว่า เพื่อปรับค่าพารามิเตอร์ของตัวแบบการแยกส่วนประกอบ และโฮลต์-วินเทอร์ ซึ่งเรียกว่า CS-D และ CS-HW ตามลำดับ เพื่อนำมาใช้ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำขนาดใหญ่รายเดือนในภาคกลางและภาคตะวันตกของประเทศไทย ปัญหาหลักที่พบคือ วิธีดั้งเดิมที่ใช้กันทั่วไปในโปรแกรมสำเร็จรูปหรือเรียกว่าวิธีแบบดั้งเดิม เช่น ค้นหาแบบกริดของโฮลต์-วินเทอร์ และ แยกส่วนประกอบแบบคลาสสิก ตามที่ได้กล่าวไว้ใน Minsan & Minsan (2024c) มักมีข้อจำกัดในการค้นหาค่าพารามิเตอร์ที่เหมาะสม ทำให้ความแม่นยำในการพยากรณ์ลดลงเมื่อข้อมูลมี

ความผันผวนสูงหรือมีฤดูกาลชัดเจน การนำอัลกอริทึม CS มาใช้ช่วยเพิ่มประสิทธิภาพการค้นหา ค่าพารามิเตอร์อย่างเป็นระบบและครอบคลุมยิ่งขึ้น ส่งผลให้ตัวแบบสามารถจับลักษณะเชิงแนวโน้มและ ฤดูกาลได้ดีขึ้น

CS-D และ CS-HW สามารถลดค่าความคลาดเคลื่อนเฉลี่ย (MAE) ได้ดีให้ค่าพยากรณ์ที่ใกล้เคียงกับ ปริมาณน้ำไหลเข้าจริง นับเป็นแนวทางที่มีศักยภาพสำหรับการบริหารจัดการทรัพยากรน้ำอย่างเป็นระบบ อย่างไรก็ตาม ควรมีการศึกษาลักษณะข้อมูลเฉพาะพื้นที่ในเชิงลึก และปรับค่าเริ่มต้นของอัลกอริทึมให้ เหมาะสม เพื่อให้การประมวลผลรวดเร็วและรองรับข้อมูลที่มีความผันแปรสูงในอนาคตได้ดียิ่งขึ้น นอกจากนี้ ยังควรบูรณาการแนวทางการพยากรณ์เข้ากับปัจจัยทางกายภาพอื่น ๆ เช่น ปริมาณฝนที่ตกตามพื้นที่ลุ่มน้ำ งานวิจัยของ Minsan & Minsan (2025a, 2025b) เป็นต้น เพื่อเพิ่มประสิทธิภาพและรองรับการตัดสินใจเชิง นโยบายได้ดียิ่งขึ้นในระยะยาว

ดังนั้นการศึกษานี้มีข้อจำกัดสำคัญคือ (1) ใช้ข้อมูลเวลารายเดือนของอ่างเก็บน้ำ 5 แห่งในช่วงปี 2012–2023 ซึ่งอาจไม่ครอบคลุมความแปรปรวนทุกรูปแบบ (2) ไม่ได้ผนวกตัวแปรภายนอก เช่น ปริมาณฝน พื้นที่รับน้ำ หรือสภาพภูมิอากาศ จึงประเมินเฉพาะพลวัตภายในของอนุกรมเวลา (3) เกณฑ์คัดเลือกตัวแบบอิง ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) เป็นหลัก

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณคณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครราชสีมาและคณะ วิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่เป็นอย่างยิ่ง ที่ได้กรุณาเอื้อเฟื้อสถานที่และ โปรแกรมสำเร็จรูป รวมถึงสนับสนุนรหัสภาษา Python สำหรับการประมวลผลเชิงวิเคราะห์ ซึ่งเป็นประโยชน์ อย่างยิ่งต่อการดำเนินงานวิจัยและช่วยให้ผลลัพธ์มีความเที่ยงตรงและสมบูรณ์ยิ่งขึ้น

เอกสารอ้างอิง

กรมชลประทาน. (2568). *ระบบฐานข้อมูลน้ำในอ่างเก็บน้ำ กรมชลประทาน*.

<https://app.rid.go.th/reservoir/>

วฐา มินเสน. (2567). *เอกสารคำสอนการวิเคราะห์อนุกรมเวลา*. คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่.

Dorigo, M. (1992). *Optimization, Learning and Natural Algorithms*. Ph.D. thesis, Politecnico di Milano, Italy.

Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. *IEEE Comput Intell*, 1(4), 28–39. <https://doi.org/10.1109/MCI.2006.329691>

Gandomi, A. H., & Alavi, A. H. (2012). Krill herd: a new bio-inspired optimization algorithm.

Communications in Nonlinear Science and Numerical Simulation, 17(12), 4831-4845.

<https://doi.org/10.1016/j.cnsns.2012.05.010>

- Geem, Z. W., Kim, J. H., & Loganathan, G. V. (2001). A new heuristic optimization algorithm: harmony search. *Simulation*, 76(2), 60-68.
<https://doi.org/10.1177/003754970107600201>
- Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019). Harris hawks optimization: Algorithm and applications. *Future Generation Computer Systems*, 97, 849-872. <https://doi.org/10.1016/j.future.2019.02.028>
- Jiang, W., Wu, X., Gong, Y., Yu, W., & Zhong, X. (2020). Holt–Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption. *Energy*, 193, 116779. <https://doi.org/10.1016/j.energy.2019.116779>
- Kaewpaengjuntra, S., Somhom, S., & Saenchan, L. (2010). Electricity consumption forecasting model using hybrid Holt-Winters exponential smoothing and artificial bee colony algorithm. *Information Technology Journal*, 6(1), 12-17. https://ph01.tci-thaijo.org/index.php/IT_Journal/article/view/73218
- Karaboga, D. (2005). *An Idea Based on Honey Bee Swarm for Numerical Optimization (Technical Report No. TR06)*. Erciyes University, Engineering Faculty, Computer Engineering Department. https://abc.erciyes.edu.tr/pub/tr06_2005.pdf
- Kennedy, J., & Eberhart, R. (1995). *Particle Swarm Optimization*. In 1995 IEEE International Conference on Neural Networks (ICNN'95) (pp. 1942–1948). IEEE.
<https://doi.org/10.1109/ICNN.1995.488968>
- Mauricio, C. C., & Ostia, C. F. (2023). *Cuckoo search algorithm optimization of holt-winter method for distribution transformer load forecasting*. In 9th International Conference on Control, Automation and Robotics (ICCAR) (pp. 36-42), Beijing, China. <https://doi.org/10.1109/ICCAR57134.2023.10151700>
- Minsan, W., & 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. <https://ph02.tci-thaijo.org/index.php/SciTechAsia/article/view/250335>
- Minsan, P., & Minsan, W. (2024a). Decomposition and Holt-Winters techniques enhanced by whale optimization algorithm: case study of pm2.5 forecasting in 8 northern provinces of Thailand. *Thai Science and Technology Journal*, 32(6), 12-34.
<https://li01.tci-thaijo.org/index.php/tstj/article/view/261071>

- Minsan, W., & Minsan, P. (2024b). 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), article 38. <https://doi.org/10.59796/jcst.V14N2.2024.38>
- Minsan, P., & Minsan, W. (2024c). 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. *Thai Journal of Operations Research*, 12(2), 69-89. <https://ph02.tci-thaijo.org/index.php/TJOR/article/view/253542>
- Minsan, W., Minsan, P., & 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. <https://ph02.tci-thaijo.org/index.php/thaistat/article/view/256084>
- Minsan, P., & Minsan, W. (2025a). Forecasting rainfall in the Ping, Wang, Yom, and Nan River Basins of Thailand using decomposition and holt-winters methods enhanced by GRG nonlinear optimization. *ASEAN J Sci Tech Report*, 28(5), e259297. <https://doi.org/10.55164/ajstr.v28i5.259297>
- Minsan, W., & Minsan, P. (2025b). *GRG-HW and GRG-D optimization models for rainfall forecasting in the Yom river basin*. figshare. Dataset. <https://doi.org/10.6084/m9.figshare.28953389.v2>
- Mirjalili, S. (2016). Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. *Neural Computing and Applications*, 27, 1053-1073. <https://doi.org/10.1007/s00521-015-1920-1>
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in Engineering Software*, 95, 51-67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>
- Pan, W. T. (2012). A new fruit fly optimization algorithm: taking the financial distress model as an example. *Knowledge-Based Systems*, 26, 69-74. <https://doi.org/10.1016/j.knosys.2011.07.001>

- Vimolsutjarit, N., Minsan,W., Taninpong, P., & Thumronglaohapun, S. (2025). Forecasting Water Volume of Dam Reservoirs in Northern Thailand Using a Classical Decomposition and Holt-Winters Enhanced by Fruit Fly Optimization Algorithm. *KKU Science Journal*, 53(2), 205–218. <https://ph01.tci-thaijo.org/index.php/KKUSciJ>
- Yang, X. S. (2009). *Firefly Algorithms for Multimodal Optimization*. In proceedings of 5th international symposium, SAGA 2009 Sapporo, Japan. https://doi.org/10.1007/978-3-642-04944-6_14
- Yang, X. S. (2010). *A New Metaheuristic Bat-Inspired Algorithm*. In proceedings of nature inspired cooperative strategies for optimization (NICSO 2010). Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-12538-6_6
- Yang, X. S. (2012). *Flower Pollination Algorithm for Global Optimization*. In proceedings of unconventional computation and natural computation, Lecture notes in computer science. (pp. 240-249). https://doi.org/10.1007/978-3-642-32894-7_27
- Yang, X. S., Deb, & S. (2009). *Cuckoo Search Via Lévy Flights*. In 2009 World Congress on Nature & Biologically Inspired Computing (NaBIC) (pp. 210–214). IEEE. <https://doi.org/10.1109/NABIC.2009.5393690>