

เทคนิคการแยกส่วนประกอบ และ โฮลต์-วินเทอร์ ที่ได้รับการปรับปรุง ด้วยขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬ: กรณีศึกษาการพยากรณ์ PM2.5 ใน 8 จังหวัดภาคเหนือของประเทศไทย

Decomposition and Holt-Winters Techniques Enhanced by Whale Optimization Algorithm: Case Study of PM2.5 Forecasting in 8 Northern Provinces of Thailand

ปรารธนา มินเสน¹, วฐา มินเสน^{2,*}

¹ภาควิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏเชียงใหม่ เชียงใหม่ 50300

²ศูนย์วิจัยวิทยาการข้อมูล ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่ เชียงใหม่ 50200

Pradthana Minsan¹, Watha Minsan^{2,*}

¹Department of Mathematics and Statistics, Faculty of Science and Technology,

Chiang Mai Rajabhat University, Chiang Mai 50300

²Data Science Research Center, Department of Statistics, Faculty of Science,

Chiang Mai University, Chiang Mai 50200

Received 29 October 2023; Received in revised 2 July 2024; Accepted 8 July 2024

บทคัดย่อ

การศึกษานี้มีจุดประสงค์เพื่อประเมินประสิทธิภาพของตัวแบบ การผสมผสานขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาฬกับโฮลต์-วินเทอร์ (WOA-HW) และการแยกส่วนประกอบ (WOA-D) ในการพยากรณ์ความเข้มข้น PM2.5 รายสัปดาห์ใน 8 จังหวัดภาคเหนือของไทย เมื่อเทียบกับตัวแบบแยกส่วนประกอบแบบคลาสสิก (Classic-D) และ ค้นหาแบบกริดของโฮลต์-วินเทอร์ (Classic-HW) โดยใช้ชุดข้อมูลฝึกฝนจำนวน 130 สัปดาห์ ผลการศึกษาพบว่า WOA-HW และ WOA-D มีประสิทธิภาพสูงกว่าตัวแบบคลาสสิกโดย WOA-D แสดงค่ารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ที่ต่ำกว่า Classic-D อย่างชัดเจน ในขณะที่ WOA-HW มีค่า RMSE ที่ใกล้เคียงกับ Classic-HW แต่ใช้เวลาในการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดเร็วกว่า

ในการพยากรณ์ความเข้มข้นค่า PM2.5 ล่วงหน้าในระยะยาว 2 ปี โดยใช้ชุดข้อมูลทดสอบจำนวน 105 สัปดาห์ ใช้เกณฑ์ RMSE MAE และ MAPE เป็นเครื่องมือในการเปรียบเทียบ ผลลัพธ์แสดงว่าตัวแบบที่มีประสิทธิภาพมากที่สุดของแต่ละจังหวัดนั้นต่างกัน ตัวแบบ WOA-HW สำหรับจังหวัดลำปางและเชียงราย ตัวแบบ WOA-D สำหรับ

*ผู้รับผิดชอบบทความ: wathaminsan@gmail.com

doi: 10.14456/tstj.2024.43

จังหวัดแม่ฮ่องสอนและพะเยา ตัวแบบ Box-Jenkins สำหรับจังหวัดน่านและแพร่ ตัวแบบ Classic-HW สำหรับลำพูน และตัวแบบ Classic-D สำหรับจังหวัดเชียงใหม่ โดยการพยากรณ์ล่วงหน้า 2 ปีของทุกจังหวัดแสดงว่าความเข้มข้น PM2.5 มีฤดูกาลชัดเจนและสูงเกินค่าที่ส่งผลกระทบต่อสุขภาพในช่วงเดือนธันวาคมถึงเมษายน

คำสำคัญ: PM2.5; วิธีการหาค่าเหมาะที่สุดแบบวาท; แยกส่วนประกอบ; โฮลต์-วินเทอร์; บอกซ์-เจนกินส์; LSTM

Abstract

The objective of this study was to evaluate the effectiveness of two forecasting models: the hybrid Whale Optimization Algorithm with Holt-Winters (WOA-HW) and hybrid Whale Optimization Algorithm with Decomposition (WOA-D), in forecasting weekly PM2.5 concentrations in 8 provinces in Northern Thailand. These models were compared to classical decomposition (Classic-D) and grid search Holt-Winters (Classic-HW) models using a training dataset of 130 weeks. The results show that WOA-HW and WOA-D outperformed the classical models, with WOA-D exhibiting significantly lower RMSE than Classic-D. Although WOA-HW had RMSE values comparable to Classic-HW, it required less time to find the optimal parameters.

For long-term forecasts over two years, a test dataset of 105 weeks was used, with RMSE, MAE, and MAPE serving as evaluation metrics. The results indicated that the optimal model varied for each province: WOA-HW was best for Lampang and Chiang Rai, WOA-D for Mae Hong Son and Phayao, Box-Jenkins for Nan and Phrae, Classic-HW for Lamphun, and Classic-D for Chiang Mai. The two-year forecast for all provinces revealed a distinct seasonal pattern in PM2.5 concentrations, with levels exceeding health-impact thresholds from December to April.

Keywords: PM2.5; Whale Optimization Algorithm; Decomposition; Holt-Winters; Box-Jenkins; LSTM

1. บทนำ

การพยากรณ์อนุกรมเวลาเป็นกระบวนการในการคาดการณ์ค่าในอนาคตของอนุกรมเวลา วิธีการพยากรณ์อนุกรมเวลามีมากมายหลายวิธี หนึ่งในวิธีการพยากรณ์อนุกรมเวลาที่มีความนิยม คือ วิธีการโฮลต์-วินเทอร์ (Holt-Winters: HW) ซึ่งเป็นวิธีการพยากรณ์ที่มีประสิทธิภาพ อย่างไรก็ตามวิธีการ HW จำเป็นต้องกำหนดค่าพารามิเตอร์หลายตัว ซึ่งอาจทำให้การพยากรณ์ไม่แม่นยำถ้ากำหนดค่าพารามิเตอร์ไม่ดีเพียงพอ เพื่อเพิ่มประสิทธิภาพในการประมาณค่าพารามิเตอร์ของ HW ได้มีการศึกษาเกี่ยวกับการผสมรวมวิธีการ HW กับเมตาฮิวริสติกส์ (Metaheuristics) ซึ่งเป็นวิธีการค้นหาผลลัพธ์ที่เหมาะสมที่สุดจากพื้นที่ค้นหาขนาดใหญ่ เมตาฮิวริสติกส์มีหลายวิธี เช่น ขั้นตอนวิธีการหาค่าที่เหมาะสมแบบอาณานิคมมด (Ant Colony Optimization) ที่พัฒนาขึ้นโดย Dorigo [1] ในปี ค.ศ. 1992 ในวิทยานิพนธ์ระดับปริญญาเอกของเขา และนำมาพัฒนาต่อร่วมกับ Stützle [2] ในปี ค.ศ. 2004 ขั้นตอนวิธีอาณานิคมผึ้งเทียม (Artificial Bee Colony Algorithm) ที่พัฒนาโดย Karaboga ในปี ค.ศ. 2005 [3] ขั้นตอนวิธี Cuckoo Search (CS) ที่พัฒนาโดย Yang and Deb [4] ในปี ค.ศ. 2009 ขั้นตอนวิธีการหาค่าที่เหมาะสมแบบแมลงหวี่ (Fruit Fly Optimization) ซึ่งเป็นวิธีการที่นำเสนอโดย Pan [5] ในปี ค.ศ. 2011 และขั้นตอนวิธีการถ่ายละอองเรณูดอกไม้ (Flower Pollination Algorithm) ที่พัฒนาโดย Yang [6] ในปี ค.ศ. 2012

การศึกษาที่ผ่านมาพบว่า การผสมรวมวิธีการ HW กับเมตาฮิวริสติกส์สามารถปรับปรุงความแม่นยำของการพยากรณ์ได้ ตัวอย่างเช่น ในปี ค.ศ. 2010 Kaewpaengjuntra et al. [7] ได้ผสมรวม HW กับขั้นตอนวิธีอาณานิคมผึ้งเทียมเพื่อพยากรณ์การใช้ไฟฟ้าโดยรวมของประเทศไทย ในปี ค.ศ. 2013 Assis et al. [8] ได้ผสมรวม HW กับขั้นตอนวิธีการหาค่าที่เหมาะสมแบบอาณานิคมมดในการศึกษาลักษณะการรับส่งข้อมูล

ด้วยการใช้การวิเคราะห์การไหลแบบสองมิติเพื่อสร้างแบบจำลองพฤติกรรมรูปแบบการรับส่งข้อมูลในระบบเครือข่าย ในปี ค.ศ. 2018 Junta et al. [9] ได้ผสมรวม HW กับขั้นตอนวิธีการถ่ายละอองเรณูดอกไม้ เพื่อศึกษาการพยากรณ์ข้อมูลปริมาณการส่งออกสินค้าเกษตรรายเดือนจากเว็บไซต์ของสำนักงานเศรษฐกิจการเกษตร จำนวน 7 รายการ ในปี ค.ศ. 2020 Jiang et al. [10] ได้ผสมรวม HW กับขั้นตอนวิธีการหาค่าที่เหมาะสมแบบแมลงหวี่ ในการการคาดการณ์ปริมาณการใช้ไฟฟ้ารายเดือน และในปี ค.ศ. 2023 Mauricio and Ostia [11] ได้ใช้ขั้นตอนวิธี Cuckoo Search (CS) เพื่อเพิ่มประสิทธิภาพวิธีการ HW ในบริบทของการพยากรณ์โหลดหม้อแปลงไฟฟ้า

การนำเมตาฮิวริสติกส์มาผสมรวมกับการประมาณค่าพารามิเตอร์ HW นั้นทำให้ตัวแบบ HW สามารถสร้างตัวแบบที่มีความคลาดเคลื่อนไปจากข้อมูลจริงน้อยลง วิธีการเมตาฮิวริสติกส์เหล่านี้จึงถูกนำมาทดลองใช้กับ HW เมื่อมีการนำเสนอวิธีการเมตาฮิวริสติกส์วิธีการใหม่ๆ อยู่เสมอ ในปี ค.ศ. 2016 ขั้นตอนวิธีการหาค่าที่เหมาะสมที่สุดแบบวาฬ (Whale Optimization Algorithm: WOA) ที่ได้รับแรงบันดาลใจจากพฤติกรรมการล่าเหยื่อของวาฬหลังค่อม (Humpback Whale) ที่นำเสนอโดย Mirjalili and Lewis [12] วิธีนี้ได้รับความนิยมอย่างมากในฐานะขั้นตอนวิธีการหาค่าเหมาะสมที่ได้แรงบันดาลใจจากธรรมชาติที่สามารถประยุกต์ใช้ได้เป็นอย่างดีในการใช้งานด้านต่างๆ ในโลกแห่งความเป็นจริง จำนวนการอ้างอิง WOA แสดงให้เห็นถึงการเติบโตอย่างมาก คือ มีการอ้างอิง 37 ครั้งในปี 2016 และเพิ่มขึ้นเป็น 7,410 ครั้ง ในเดือนมีนาคม 2023 [13] และ Minsan et al. [14] ได้ใช้โซลเวอร์ (Solver) ของโปรแกรมเอ็กเซล (Excel) เวอร์ชัน 2019 เปรียบเทียบประสิทธิภาพกับ WOA ซึ่งผลลัพธ์ออกมาว่า WOA เป็นวิธีการหาผลลัพธ์ในฟังก์ชันทดสอบ 16 ฟังก์ชันได้ดีที่สุดเป็นส่วนใหญ่ ซึ่งสะท้อนให้เห็นถึงความนิยมและผลกระทบของ WOA ในการแก้ไขปัญหาการหาค่าที่เหมาะสมที่หลากหลาย

ในปี ค.ศ. 2023 Minsan and Minsan [15] ได้นำเสนอการผสมผสานกันระหว่าง WOA กับ เทคนิคการแยกส่วนประกอบรูปแบบบวกและ HW รูปแบบบวกโดยประมาณค่าพารามิเตอร์ใน HW จำนวน 3 ตัว และประมาณค่าพารามิเตอร์ในเทคนิคการแยกส่วนประกอบจำนวน 14 ตัว ใช้พยากรณ์รายได้รัฐบาลของประเทศไทย 4 ส่วน ซึ่งพบว่าวิธีการผสมผสาน WOA ร่วมกับเทคนิคการแยกส่วนประกอบ และวิธีการผสมผสาน WOA ร่วมกับ HW ได้ผลลัพธ์ที่ดีกว่าวิธีแยกส่วนประกอบแบบคลาสสิก (Classic Decomposition: Classic-D) และ Box-Jenkins และในปีต่อมา Minsan and Minsan [16] ได้ต่อยอดการผสมผสานกันระหว่างตัวแบบการแยกส่วนประกอบและ HW ตัวแบบรูปแบบบวกและรูปแบบคูณ ร่วมกับ WOA ในการพยากรณ์ปริมาณน้ำที่ไหลเข้าอ่างเก็บน้ำเขื่อนขนาดใหญ่รายเดือน ในภาคใต้ของประเทศไทย 4 แห่ง ซึ่งผลลัพธ์ในการผสมผสานนั้นก็ให้ผลลัพธ์ที่ดีเช่นเดียวกัน

ในการศึกษานี้ใช้วิธีการ WOA จาก Minsan and Minsan [15, 16] เพื่อประมาณค่าพารามิเตอร์ในวิธีการ HW ดังเช่นงานวิจัยที่ผ่านมา โดยมีจำนวนพารามิเตอร์ของตัวแบบที่ต้องประมาณจำนวน 3 ตัว และผสมผสานวิธีการ WOA กับ เทคนิคการแยกส่วนประกอบ (Decomposition: D) จำนวนพารามิเตอร์ที่ต้องประมาณจะเป็นไปตามลักษณะของข้อมูลที่ทำการศึกษา โดยการศึกษาเลือกข้อมูลความเข้มข้น PM2.5 ของ 8 จังหวัดภาคเหนือรายสัปดาห์ ที่ค่า PM2.5 เป็นปัญหาใหญ่ของภูมิภาคนี้มาโดยตลอดในช่วงทศวรรษนี้ เนื่องจากในช่วงประมาณเดือนมกราคมถึงเดือนเมษายนค่า PM2.5 จะสูงขึ้นจนก่อให้เกิดปัญหาสุขภาพกับประชาชน ดังนั้นจำนวนพารามิเตอร์ที่ต้องประมาณจำนวนมากถึง 54 ตัว ซึ่งจำนวนพารามิเตอร์ที่ต้องประมาณมากกว่า Minsan and Minsan [15, 16] เป็นการขยายขอบเขตของการประมาณค่าพารามิเตอร์ที่ยังคงใช้ประโยชน์จากความสามารถในการสำรวจและประเมินผลของ WOA ซึ่งเป็นวิธีการที่มีแนวโน้มว่าจะช่วยเพิ่มความแม่นยำและ

ประสิทธิภาพของตัวแบบการพยากรณ์ในการวิเคราะห์อนุกรมเวลา ในส่วนถัดไปจะกล่าวถึงการนำ WOA ไปผสมผสานกับ HW และ D อย่างครอบคลุมทั้งขั้นตอนการดำเนินการ รหัสเทียม และสูตรการคำนวณ

2. วิธีดำเนินการวิจัย

การศึกษานี้มีขั้นตอนวิธีการดำเนินการวิจัย 2.1 ถึง 2.4 ดังนี้

2.1 ขั้นตอนวิธีการค้นหาวาฬ

ขั้นตอนวิธีการค้นหาวาฬ [12, 14, 15, 16] ได้รับแรงบันดาลใจจากพฤติกรรมการล่าเหยื่อของวาฬหลังค่อม WOA ได้รับการยอมรับสำหรับประสิทธิภาพในการแก้ไขปัญหาที่ซับซ้อนในงานด้านต่างๆ วาฬหลังค่อมจะปล่อยฟองอากาศออกมาเพื่อต้อนให้ฝูงปลารวมกลุ่ม เรียกว่า การสร้างฟองอากาศในรูปเกลียวล้อมรอบเหยื่อไว้ หรือ Bubble-Net Feeding โดยวาฬหลังค่อมจะดำน้ำลงไปและเริ่มสร้างฟองอากาศในรูปเกลียวรอบตัวเหยื่อและว่ายน้ำขึ้นไปบนผิวน้ำเพื่อกินเหยื่อวิธี WOA จะนำหลักการหาอาหารของวาฬมาใช้ในการสร้างแบบจำลองทางคณิตศาสตร์เพื่อหาค่าที่เหมาะสมที่สุด มีข้อกำหนดเบื้องต้นดังนี้ N คือ จำนวนวาฬ และ m คือ จำนวนพารามิเตอร์ ตำแหน่งของวาฬแต่ละตัวจะแสดงเป็น $X_i = (x_i^1, x_i^2, \dots, x_i^m), i \in \{1, 2, \dots, N\}$ ในระหว่างกระบวนการการหาค่าที่เหมาะสมที่สุด วาฬจะดำเนินการเคลื่อนไหว 3 ประเภท ซึ่งในแต่ละเวลา วาฬจะปรับตำแหน่งตนเองโดยดำเนินการอย่างใดอย่างหนึ่งใน 3 การกระทำเหล่านี้

2.1.1 ล้อมรอบเหยื่อ (Encircling Prey)

วาฬหลังค่อมทราบตำแหน่งของเหยื่อและล้อมพวกมันไว้ โดยกำหนดว่าคำตอบที่ดีที่สุดเป็นตำแหน่งของเหยื่อที่เป็นเป้าหมายหรือจุดที่ใกล้เคียงกับค่าที่เหมาะสมที่สุดจากนั้นตัวแทนของคำตอบอื่นๆ จะปรับปรุงตำแหน่งของตัวเองโดยอ้างอิงกับตำแหน่งของเหยื่อ เปรียบได้กับวาฬหลังค่อมที่พุ่งเข้าไปล้อมเหยื่อ

ซึ่งพฤติกรรมดังกล่าว ดังสมการที่ (1)

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D}, \quad (1)$$

โดยที่ $\vec{X}(t+1)$ เป็นเวกเตอร์ตำแหน่งใหม่ของวาฬ เมื่อ $\vec{X}^*(t)$ คือเวกเตอร์ตำแหน่งที่ดีที่สุดที่วาฬพบจนถึงขณะนี้ (t) และ $\vec{A}$ คือ เวกเตอร์สัมประสิทธิ์แอมพลิจูด และ $\vec{D}$ คือ เวกเตอร์ที่สร้างขึ้นแบบสุ่ม การเคลื่อนไหวนี้ช่วยให้วาฬสำรวจพื้นที่ค้นหาได้อย่างมีประสิทธิภาพและไปสู่ผลลัพธ์ที่น่าพอใจขึ้นในเวลาถัดไป ($t+1$) เวกเตอร์ $\vec{A}$ และ $\vec{D}$ คำนวณดังนี้

$$\vec{A} = 2 \cdot \vec{a} \cdot \vec{r} - \vec{a},$$

$$\vec{D} = |\vec{C} \cdot \vec{X}^*(t) - \vec{X}(t)| \text{ ที่ } \vec{C} = 2 \cdot \vec{r},$$

โดยที่ $\vec{a}$ คือ สัมประสิทธิ์แอมพลิจูดที่ลดลงเชิงเส้นจาก 2 เป็น 0 ตลอดระยะเวลาของการทำซ้ำ เป็นการควบคุมการเคลื่อนที่ของวาฬในระยะเวลาสำรวจ (Exploration Phase) ในช่วงเริ่มต้นของกระบวนการค้นหา $\vec{a}$ จะมีค่าสูง ซึ่งช่วยให้วาฬสามารถสำรวจพื้นที่ค้นหาได้อย่างกว้างขวาง เมื่อกระบวนการค้นหาคืบหน้าไป $\vec{a}$ จะลดลง ซึ่งช่วยให้วาฬมุ่งเน้นไปที่พื้นที่ที่มีแนวโน้มว่าจะมีผลลัพธ์ที่ดี ส่วน $\vec{r}$ คือ เวกเตอร์แบบสุ่มใน $[0, 1]$ ที่ใช้ในการกำหนดทิศทางการเคลื่อนที่ของวาฬในระยะเวลาสำรวจ การเคลื่อนที่ของวาฬจะขึ้นอยู่กับทิศทางของเวกเตอร์ $\vec{r}$ และสัมประสิทธิ์แอมพลิจูด $\vec{a}$ ส่วน $\vec{C}$ คือ เวกเตอร์สัมประสิทธิ์ที่ใช้ในการควบคุมการเคลื่อนที่ของวาฬในระยะเวลาใช้ประโยชน์ (Exploitation Phase) การเคลื่อนที่ของวาฬจะขึ้นอยู่กับทิศทางของเวกเตอร์ $\vec{C}$ และสัมประสิทธิ์แอมพลิจูด $\vec{a}$

2.1.2 การโจมตีด้วยฟองอากาศแบบเกลียว (Bubble-net Attacking)

การโจมตีด้วยฟองอากาศแบบเกลียวเกิดขึ้นเมื่อวาฬหลังค่อมโอบล้อมเหยื่อไว้ภายในวงกลมที่หดตัวหรือเคลื่อนที่ตามเส้นทางรูปเกลียว วาฬหลังค่อมจะแสดงพฤติกรรมการว่ายน้ำรอบเหยื่อโดยค่อยๆ บีบวงล้อมรอบเหยื่อหรือการโจมตีด้วยฟองอากาศแบบเกลียวเข้าไปอย่างใดอย่างหนึ่ง ในการจำลองพฤติกรรมนี้ วิธี WOA จะกำหนดความน่าจะเป็น

ร้อยละ 50 ระหว่างการเกิดพฤติกรรมการบีบวงล้อมรอบเหยื่อดังสมการที่ (1)

$$\vec{X}(t+1) = \vec{X}^*(t) - \vec{A} \cdot \vec{D} \text{ ถ้า } p < 0.5,$$

และการโจมตีด้วยฟองอากาศแบบเกลียวดังสมการที่ (2) ดังนี้

$$\vec{X}(t+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(t) \text{ ถ้า } p \geq 0.5, \quad (2)$$

โดยที่ p คือ ค่าสุ่มใน $[0, 1]$, $\vec{D}' = |\vec{X}^*(t) - \vec{X}(t)|$ และบ่งชี้ถึงระยะทางของวาฬตัวที่ i^{th} ไปยังเหยื่อ (ผลลัพธ์ที่ดีที่สุดที่ได้มาจนถึงขณะนี้) b เป็นค่าคงตัวสำหรับการกำหนดรูปร่างของเกลียวลอการิทึม และ l คือ ค่าสุ่มใน $[-1, 1]$ นอกเหนือจากเทคนิคการโจมตีด้วยฟองอากาศแบบเกลียวแล้ว วาฬหลังค่อมยังดำเนินการค้นหาเหยื่อแบบสุ่มอีกด้วย แบบจำลองทางคณิตศาสตร์สำหรับกระบวนการค้นหาดังหวัข้อต่อไป

2.1.3 การค้นหาเหยื่อ (Search for Prey)

กลไกการสำรวจนี้ช่วยให้วาฬสามารถเข้าสู่พื้นที่ต่างๆ ของพื้นที่ค้นหา เพิ่มโอกาสในการค้นพบผลลัพธ์ที่ดีกว่า แบบจำลองทางคณิตศาสตร์สำหรับระยะเวลาสำรวจเกี่ยวข้องกับการปรับปรุงตำแหน่งของวาฬแบบสุ่มตามสมการต่อไปนี้

$$\vec{D} = |\vec{C} \cdot \vec{X}_{rand} - \vec{X}(t)|, \vec{X}(t+1) = \vec{X}_{rand} - \vec{A} \cdot \vec{D}, \quad (3)$$

โดยที่ $\vec{X}_{rand}$ เป็นเวกเตอร์ตำแหน่งแบบสุ่ม (วาฬแบบสุ่ม) ที่เลือกจากประชากรปัจจุบัน กลไกนี้ควบคู่กับการเน้นการสำรวจที่ $|\vec{A}| \geq 1$ เพิ่มความสามารถของขั้นตอนวิธีในการสำรวจผลลัพธ์ที่หลากหลายและป้องกันไม่ให้ติดอยู่ในค่าต่ำสุดเฉพาะที่ (Local Optima)

ถ้า $|\vec{A}| < 1$ จะดำเนินการตามสมการที่ (1) ที่วาฬจะทำการค้นหาลอยละเอียดยิ่งๆ คำตอบที่ดีที่สุด การเคลื่อนไหวทั้ง 3 แสดงไว้ในรหัสเทียม (Pseudocode) ที่ให้ไว้ใน Figure 1 ซึ่งอธิบายรายละเอียดเกี่ยวกับขั้นตอนเหล่านี้

```

Input: the number of whales:  $N$ , the number of parameters:  $m$ , maximum iterations:  $T_{\max}$ , time
limit:  $MaxTime$ , the fitness value fails to improve after a specified:  $T_{improve}$ , the bound of search area:
Range Initialize  $X_i = (x_i^1, x_i^2, \dots, x_i^m), X^*$ 

While ( $t < T_{\max}$  or time  $< MaxTime$  or the fitness value fails to improve after a specified  $T_{improve}$ )
  For  $i = 1$  to  $N$ 
    Check if any search agent goes beyond the search space and amend it
    For  $j = 1$  to  $m$ 
       $p = rand[0,1]$ 
      Update  $a, r, A, C, D, D', b, l, X_{rand}$ 
      If  $p \geq 0.5$  then
        #Exploitation Phase: Update  $x_i^j$  the position of the current search agent by the Eq. (2)
      Elseif  $p < 0.5$  and  $|A| < 1$ 
        #Encircling Prey: Update  $x_i^j$  the position of the current search agent by the Eq. (1)
      Elseif  $p < 0.5$  and  $|A| \geq 1$ 
        #Exploration Phase: Update  $x_i^j$  the position of the current search agent by the Eq. (3)
      Endif
    End for
  End for
  Calculate  $fitness(X_i)$  using HW/Decomposition
  Update  $X^*$  if there is a better solution
   $t = t + 1$ 
End while
Return  $X^*$ 

```

Figure 1 Pseudo-code of WOA

2.2 การเตรียมข้อมูล

วัตถุประสงค์ของการวิจัยครั้งนี้เพื่อนำเสนอการผสมผสานขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวฬกับไฮลด์-วินเทอร์ (Hybrid the Whale Optimization Algorithm with Holt-Winters: WOA-HW) และการแยกส่วนประกอบ (Hybrid the Whale Optimization Algorithm with Decomposition: WOA-D) การเลือกชุดข้อมูลที่น่าสนใจมาศึกษาควรเป็นชุดข้อมูลที่มีส่วนประกอบแนวโน้มและฤดูกาล ดังนั้นชุดข้อมูลสำหรับการศึกษานี้จึงเป็นข้อมูลความเข้มข้น

ของ PM2.5 ในภาคเหนือของประเทศไทย ที่โดยธรรมชาติมีลักษณะที่มีแนวโน้มและฤดูกาล

แหล่งของข้อมูลข้อมูลความเข้มข้นของ PM2.5 ได้จากกรมควบคุมมลพิษ กระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อมแห่งประเทศไทย [17] ข้อมูลนี้สามารถเข้าถึงได้จากเว็บไซต์อย่างเป็นทางการ Air4Thai ข้อมูลความเข้มข้นของ PM2.5 รายวันที่รวบรวมจาก 8 จังหวัดในภาคเหนือของประเทศไทย ได้แก่ เชียงใหม่ (CMI) ลำปาง (LPG) เชียงราย (CRI) แม่ฮ่องสอน (MSN) น่าน (NAN) ลำพูน (LPN) แพร่ (PRE) และพะเยา (PYO)

ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2562 ถึง 30 มิถุนายน พ.ศ. 2566 โดยแต่ละแห่งมีจำนวนข้อมูล 1,642 วัน ทำความสะอาดชุดข้อมูลโดยปรับค่าสูญหายที่เกิดขึ้นในบางวัน โดยการแก้ไข (Interpolation) ด้วยวิธีการหาค่าเฉลี่ยอย่างง่าย (Simple Average) เป็นการปรับปรุงค่าสูญหาย โดยไม่มีผลกระทบต่อค่าเฉลี่ยรายวันของข้อมูลก่อนการปรับ ซึ่งยังคงแสดงให้เห็นถึงลักษณะทางสถิติของชุดข้อมูลด้วยค่าเฉลี่ยรายวันค่าเดิม หลังจากนั้นข้อมูลถูกรวมเข้าด้วยกันเพื่อคำนวณค่าเฉลี่ยรายสัปดาห์ของความเข้มข้น PM2.5 ส่งผลให้มีข้อมูลทั้งหมด 235 สัปดาห์

สำหรับวัตถุประสงค์ของการวิจัยนี้แบ่งออกเป็น 2 ประเด็น คือ เปรียบเทียบวิธีการที่นำเสนอกับวิธีการแบบคลาสสิก(Classical: Classic) และศึกษาตัวแบบที่ดีที่สุดที่จะใช้ในการพยากรณ์ล่วงหน้า ดังนั้นชุดข้อมูลแบ่งออกเป็นสองกลุ่มย่อยที่แตกต่างกัน กลุ่มย่อยแรกกำหนดให้เป็นชุดข้อมูลฝึกฝน (Train Dataset) ประกอบด้วย 130 สัปดาห์ เรียกช่วงนี้ว่า ระยะเวลาข้อมูลฝึกฝน (Train Dataset Phase) และถูกใช้สำหรับพัฒนาตัวแบบสำหรับวิธีการพยากรณ์ต่างๆที่กำลังพิจารณา และเป็นช่วงทดสอบตัวแบบที่นำเสนอ เปรียบเทียบคู่กับตัวแบบที่สร้างขึ้นด้วยวิธีแบบคลาสสิก กลุ่มย่อยที่สองที่เรียกว่าชุดข้อมูลทดสอบ (Test Dataset) ประกอบด้วย 105 สัปดาห์ เรียกช่วงนี้ว่า ระยะเวลาข้อมูลทดสอบ (Test Dataset Phase) โดยทุกตัวแบบที่สร้างขึ้นในระยะเวลาข้อมูลการฝึกฝนจะนำมาพยากรณ์ระยะยาวจำนวน 105 สัปดาห์หรือจำนวน 2 ปี โดยมีเป้าหมายคือ การพิจารณาตัวแบบพยากรณ์ระยะยาวที่มีความคลาดเคลื่อนน้อยที่สุด ซึ่งจะนำตัวแบบนั้นใช้ในการพยากรณ์ล่วงหน้าจากวันสุดท้ายของชุดข้อมูลที่มีออกไปอีก 2 ปี คือ พยากรณ์ล่วงหน้ารายสัปดาห์ตั้งแต่ 1 กรกฎาคม พ.ศ. 2566 ถึง 30 มิถุนายน พ.ศ. 2568 เพื่อเป็นประโยชน์สำหรับการตัดสินใจทางนโยบายของรัฐบาลและผู้สนใจในการศึกษา PM2.5

ดังนั้นชุดข้อมูลทดสอบที่กำหนดนี้จึงการออกแบบโดยเจตนาให้ครอบคลุมระยะเวลาการพยากรณ์ 2 ปี สอดคล้องกับการพยากรณ์ล่วงหน้าระยะยาว

2.3 ตัวแบบพยากรณ์

การกำหนดสัญลักษณ์ในการศึกษา

Y_t คือ ค่าข้อมูลจริง ณ เวลา t

$\hat{Y}_t$ คือ ค่าพยากรณ์ ณ เวลา t

ε_t คือ ความคลาดเคลื่อนที่มีการแจกแจงปกติ และเป็นอิสระกัน มีค่าเฉลี่ยเท่ากับศูนย์ และความแปรปรวนคงที่ทุกช่วงเวลา

t คือ ช่วงเวลา มีค่าตั้งแต่ 1 ถึง n_1 หรือ n_2 หรือ n แล้วแต่กรณี

กรณีอยู่ในระยะข้อมูลฝึกฝน n_1 แทน จำนวนข้อมูลในอนุกรมเวลาชุดข้อมูลฝึกฝน ($n_1 = 130$)

กรณีอยู่ในระยะข้อมูลทดสอบ n_2 แทน จำนวนข้อมูลในอนุกรมเวลาชุดข้อมูลทดสอบ ($n_2 = 150$)

กรณีอยู่ในขั้นตอนการพยากรณ์ล่วงหน้า 1 กรกฎาคม 2566 ถึง 30 มิถุนายน 2568 n แทน จำนวนข้อมูลทั้งหมด ($n = 235$)

s คือ คาบของฤดูกาลมีค่าเท่ากับ 52 ($s = 52$)

2.3.1 วิธีแยกส่วนประกอบ (Decomposition Method)

วิธีที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่างๆ คือ แนวโน้ม (Trend) ฤดูกาล (Seasonal) วัฏจักร (Cycle) และส่วนประกอบไม่ปกติ (Irregular) โดยในการศึกษานี้เลือกศึกษาส่วนประกอบที่มีผลต่อการพยากรณ์ 2 ส่วนประกอบ คือ แนวโน้มและฤดูกาล รูปแบบบวก

แนวโน้มกำหนดให้มีตัวแบบแนวโน้มเส้นตรง (Linear Trend Model)

ตัวแบบและตัวแบบพยากรณ์แนวโน้มเส้นตรงดังสมการ (4) และ (5) ตามลำดับ ดังนี้

$$Y_t = \beta_0 + \beta_1 t + \varepsilon_t, \quad (4)$$

$$\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t, \quad (5)$$

เมื่อพารามิเตอร์ β_0, β_1 แทนระดับของข้อมูลและความชัน ตามลำดับ ส่วน $\hat{\beta}_0$ และ $\hat{\beta}_1$ เป็นตัวประมาณของ β_0 และ β_1 ตามลำดับ

เมื่อนำส่วนประกอบของข้อมูลอนุกรมเวลา มีแนวโน้มและฤดูกาลเข้ารวมกันจะกำหนดให้เป็นวิธีแยกส่วนประกอบรูปแบบบวก (Additive Decomposition) ที่เหมาะกับอนุกรมเวลาที่มีความแปรผันตามฤดูกาลคงที่

ตัวแบบแนวโน้มเส้นตรงฤดูกาลรูปแบบบวก ตัวแบบและตัวแบบพยากรณ์ดัง (6) และ (7) ตามลำดับ

$$Y_t = \beta_0 + \beta_1 t + S_t + \varepsilon_t, \quad (6)$$

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

เมื่อพารามิเตอร์ S_t แทนความแปรผันตามฤดูกาล ณ เวลา t และ $S_t = S_i$ สำหรับ $i = 1, 2, 3, \dots, s$ เมื่อ t เป็นเวลาในฤดูกาลที่ i มีค่า $\sum_{i=1}^s S_i = 0$ ส่วน $\hat{S}_t$ เป็นตัวประมาณของ S_t

ในการศึกษาการสร้างตัวแบบตามสมการที่ (7) จะดำเนินการตามขั้นตอนโดยจะเรียกว่า Classic-D [15, 16] เป็นเทคนิคการพยากรณ์อนุกรมเวลาที่แยกอนุกรมเวลาออกเป็นส่วนประกอบต่างๆ ได้แก่ ส่วนประกอบแนวโน้ม และฤดูกาล ขั้นตอนทั่วไปที่เกี่ยวข้องในการพยากรณ์ Classic-D มีดังต่อไปนี้

ขั้นที่ 1 การเตรียมข้อมูล รวบรวมข้อมูลอนุกรมเวลาในอดีตที่ต้องการใช้ในการพยากรณ์ ตรวจสอบให้แน่ใจว่าข้อมูลอยู่ในรูปแบบที่เหมาะสมและครอบคลุมช่วงเวลาเพียงพอ

ขั้นที่ 2 แสดงภาพอนุกรมเวลา สร้างกราฟข้อมูลอนุกรมเวลาเพื่อแสดงรูปแบบโดยรวม แนวโน้ม และความผันผวนตามฤดูกาล ขั้นตอนนี้ช่วยในการเข้าใจลักษณะของข้อมูลและตัดสินใจเลือกตัวแบบที่เหมาะสมกับลักษณะของข้อมูล โดยอาจจะใช้การทดสอบทางสถิติช่วยในการตัดสินใจ

ขั้นที่ 3 กำหนดช่วงฤดูกาล ระบุความยาวของรอบฤดูกาลในข้อมูล อาจเป็นรายวัน รายสัปดาห์ รายเดือน หรือรูปแบบอื่นใดที่วนซ้ำในช่วงเวลาที่กำหนด

ขั้นที่ 4 จัดแนวโน้มออกจากข้อมูล ลบส่วนประกอบแนวโน้มออกจากอนุกรมเวลาเพื่อให้เหลือเฉพาะส่วนประกอบฤดูกาล สามารถทำได้โดยใช้เทคนิคต่างๆ เช่น นำอนุกรมเวลาเดิมลบค่าเฉลี่ยเคลื่อนที่กลาง (สำหรับตัวแบบรูปแบบบวก)

ขั้นที่ 5 ประมาณค่าส่วนประกอบฤดูกาล คำนวณส่วนประกอบฤดูกาลโดยนำผลจากขั้นที่ 4 หาค่าเฉลี่ยของค่าแต่ละฤดูกาล ปรับปรุงส่วนประกอบฤดูกาลโดยนำแต่ละค่าเฉลี่ยฤดูกาลลบค่าเฉลี่ยโดยรวมของดัชนีฤดูกาล (สำหรับตัวแบบรูปแบบบวก)

ขั้นที่ 6 ลบส่วนประกอบฤดูกาลออก นำอนุกรมเวลาข้อมูลจริงลบผลจากขั้นที่ 5 (สำหรับตัวแบบรูปแบบบวก) เพื่อรับข้อมูลอนุกรมเวลาที่ไม่ฤดูกาล (การปรับการแปรผันตามฤดูกาล หรือ Adjustment of Seasonal Variation)

ขั้นที่ 7 ประมาณค่าส่วนประกอบแนวโน้ม คำนวณส่วนประกอบแนวโน้มโดยการถดถอยเชิงเส้น (Linear Regression) จากขั้นที่ 6

ขั้นที่ 8 สร้างตัวแบบการพยากรณ์ รวมส่วนประกอบแนวโน้มในขั้นที่ 7 ($\hat{Y}_t = \hat{\beta}_0 + \hat{\beta}_1 t$) และส่วนประกอบฤดูกาลขั้นที่ 5 ($\hat{S}_t$) ที่คำนวณไว้เพื่อตัวแบบการพยากรณ์แนวโน้มและฤดูกาลตามสมการที่ (7)

ขั้นที่ 9 ประเมินและปรับปรุง ประเมินความแม่นยำของตัวแบบการพยากรณ์โดยเปรียบเทียบกับค่าจริง หากจำเป็นให้ปรับปรุงตัวแบบการพยากรณ์

2.3.2 วิธีโฮลต์-วินเทอร์ (Holt-Winters Method: HW)

วิธี HW เป็นหนึ่งในวิธีการทำให้เรียบ (Smoothing) เป็นวิธีการสร้างสมการพยากรณ์จากค่าสังเกตในอนุกรมเวลาบางส่วนหรือทั้งหมดโดยให้น้ำหนักกับค่าสังเกตในอนุกรมเวลาแตกต่างกันแล้วแต่ส่วนประกอบของอนุกรมเวลา ในกรณีที่ส่วนประกอบของข้อมูลอนุกรมเวลาที่มีแนวโน้มและฤดูกาล จะสร้างตัวแบบพยากรณ์ด้วยวิธีการทำให้เรียบของ HW รูปแบบบวกหรือแบบคูณ HW ใช้ค่าทำให้เรียบ 3 ค่า

ได้แก่ α , γ และ δ ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 สำหรับค่าระดับ α (Level Parameter) ค่าที่ใกล้เคียงกับ 1 บ่งชี้ว่าตัวแบบปรับให้เข้ากับการสังเกตล่าสุดอย่างรวดเร็ว ในขณะที่ค่าที่ใกล้ 0 จะให้ความสำคัญกับการสังเกตในอดีตมากกว่า ค่าแนวโน้ม γ (Trend Parameter) ค่าสูงช่วยให้ตัวแบบปรับตัวเข้ากับการเปลี่ยนแปลงของแนวโน้มได้อย่างรวดเร็วในค่าสังเกตล่าสุด ในขณะที่ค่าต่ำจะทำให้ตัวแบบตอบสนองต่อการเปลี่ยนแปลงของแนวโน้มล่าสุดน้อยลง และค่าฤดูกาล δ (Seasonal Parameter) เป็นอิทธิพลของฤดูกาลหรือดัชนีฤดูกาล ค่าที่สูงขึ้นส่งผลให้มีความยืดหยุ่นและความไวต่อความผันผวนของฤดูกาลในคาบฤดูกาลล่าสุดมากขึ้น ในขณะที่ค่าที่ต่ำกว่าจะทำให้ตัวแบบมีความทนทานต่อการเปลี่ยนแปลงตามฤดูกาลในคาบฤดูกาลล่าสุด โดยในงานวิจัยนี้พิจารณาศึกษาแบบบวก และในการค้นหาค่าพารามิเตอร์ที่เหมาะสมจะใช้วิธีการค้นหาแบบกริด (Grid Search) ที่เป็นเทคนิคหนึ่งในการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเกี่ยวข้องกับการเปลี่ยนแปลงค่าพารามิเตอร์ในทศนิยม 3 ตำแหน่ง ในอัตราเพิ่มครั้งละ 0.005 เริ่มจาก 0 ถึง 1 ส่งผลให้มีการวนซ้ำทั้งหมด $201^3 = 8,120,601$ ครั้ง เรียกว่าวิธีการศึกษาที่ Classic-HW เมื่อการคำนวณสิ้นสุดจะเลือกพารามิเตอร์ที่ดีที่สุดที่พิจารณาจากค่าน้อยที่สุดของรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE)

รูปแบบบวก ตัวแบบและตัวแบบพยากรณ์ดัง (6)

และ (8) ตามลำดับ

$$\hat{Y}_{t+p} = \hat{T}_t + p\hat{\beta}_t + \hat{S}_{t-s+1+((p-1) \bmod s)}, \text{ สำหรับ } p=1,2,\dots, (8)$$

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

p จำนวนช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้า

$\hat{T}_t$ คือ ระดับของอนุกรมเวลา ณ เวลา t และ $\hat{\beta}_t$ คือ แนวโน้มของอนุกรมเวลา ณ เวลา t และ $\hat{S}_t$ คือ ส่วนประกอบฤดูกาลของอนุกรมเวลา ณ เวลา t คำนวณได้ดัง (9) (10) และ (11)

$$\hat{T}_t = \alpha(Y_t - \hat{S}_{t-s}) + (1-\alpha)(\hat{T}_{t-1} + \hat{\beta}_{t-1}), \quad (9)$$

$$\hat{\beta}_t = \gamma(\hat{T}_t - \hat{T}_{t-1}) + (1-\gamma)\hat{\beta}_{t-1}, \quad (10)$$

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

2.3.3 การผสานขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทกับโฮสต์-วินเทอร์

การเลือกพารามิเตอร์มีผลกระทบอย่างมากต่อประสิทธิภาพของตัวแบบ ดังนั้นการประยุกต์ WOA เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมของตัวแบบ HW [15, 16] จะต้องดำเนินการอย่างถูกต้อง มีขั้นตอนการดำเนินการดังนี้

ขั้นที่ 1 สร้างพารามิเตอร์เริ่มต้น ตำแหน่งของวาทแต่ละตัวแสดงถึงพารามิเตอร์สามตัว $\vec{X}_i = (\alpha_i, \gamma_i, \delta_i)$ ภายในขอบเขต $[0, 1]$

ขั้นที่ 2: เลือกการเคลื่อนไหว วาทแต่ละตัวเลือกการกระทำสำหรับการเคลื่อนไหวครั้งต่อไปโดยเลือกหนึ่งในสามการเคลื่อนไหว การเลือกนี้กำหนดว่าวาทจะเคลื่อนเข้าใกล้เหยื่อหรือขยายการค้นหาคาตามรัทัสเทียม Figure 1 โดยมีตัวแปรนำเข้าของ WOA คือ $N = 30$, $T_{\max} = 1,000$, $MaxTime = 180 \text{ sec.}$, $T_{\text{improve}} = 50$, และ $m = 3$.

ขั้นที่ 3 คำนวณความเหมาะสมของตัวแบบ ความเหมาะสมถูกคำนวณโดยประเมินจาก RMSE ของชุดข้อมูล โดยใช้ตำแหน่งของวาทแต่ละตัวในวิธี HW ดังนั้นค่าพารามิเตอร์ที่ให้ค่า RMSE ต่ำสุดในรอบนั้นจะสามารถตัดสินตำแหน่งที่ดีที่สุดได้และกำหนดเป็น $(\vec{X}^*)$

ขั้นที่ 4 กำหนดเกณฑ์การหยุด ขั้นตอน WOA จะสิ้นสุดลงเมื่อค่าความเหมาะสมไม่สามารถปรับปรุงได้หลังจากถึงจำนวนรอบที่กำหนด T_{improve} หรือถึงขีดจำกัดเวลา $MaxTime$ หรือถึงจำนวนรอบสูงสุด $T_{\max}$ ณ จุดนี้พารามิเตอร์ที่ดีที่สุดจะถูกส่งออกไปใช้

ขั้นที่ 5 การประเมินประสิทธิภาพ การประเมินประสิทธิภาพของ HW ด้วยพารามิเตอร์ที่ดีที่สุด เราประเมินความแม่นยำของการพยากรณ์โดยวัดความคลาดเคลื่อนระหว่างค่าพยากรณ์กับค่าข้อมูลจริง

ฟังก์ชันวัตถุประสงค์ของ WOA-HW เป็นสมการต่อไปนี้

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

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

ที่ซึ่ง $RMSE = \sqrt{\frac{1}{T} \sum_{i=1}^T (Y_i - \hat{Y}_i)^2}$ โดย T คือ จำนวนข้อมูล

ในอนุกรมเวลา Y_i คือ ค่าข้อมูลจริง $\hat{Y}_i$ คือ ค่าพยากรณ์ โดยวิธี WOA-HW ที่ได้ค่าพารามิเตอร์ที่ดีที่สุดจากขั้นที่ 4

จากขั้นที่ 1 ถึง 5 ใน WOA-HW นั้นใช้ขั้นตอนวิธี WOA ได้โดยตรงตาม Figure 1 รหัสเทียมของ WOA เนื่องจากว่าค่าพารามิเตอร์ของ HW มีช่วงเดียวกันกับขั้นตอนวิธี WOA คือ $[0, 1]$

2.3.4 การผสมขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทกับการแยกส่วนประกอบ

การเลือกพารามิเตอร์มีผลกระทบอย่างมากต่อประสิทธิภาพของตัวแบบ WOA-D [15, 16] ในการศึกษาขั้นตอนนี้ขั้นตอนวิธีการหาค่าเหมาะที่สุดแบบวาทถูกใช้เพื่อแก้ปัญหาค่าพารามิเตอร์ $\beta_0, \beta_1, \hat{S}_1, \hat{S}_2, \hat{S}_3, \hat{S}_4, \dots, \hat{S}_{52}$ ซึ่งมีจำนวนพารามิเตอร์ 54 ตัวของการแยกส่วนประกอบ มีขั้นตอนการดำเนินการดังนี้

ขั้นที่ 1 กำหนดข้อจำกัดของพารามิเตอร์ คำนวณส่วนประกอบแนวโน้มโดยใช้การถดถอยเชิงเส้น จะได้ $\hat{Y}_i = \beta_0' + \beta_1' t$ แนะนำให้ตั้งค่าขอบเขตบน (Upper Bound Constraints) และขอบเขตล่าง (Lower Bound Constraints) สำหรับพารามิเตอร์ β_0 และ β_1 ตามสมการต่อไปนี้

Upper Bound Constraints: $\beta_0 = 1.2\beta_0'$ และ $\beta_1 = 1.2\beta_1'$,
Lower Bound Constraints: $\beta_0 = 0.8\beta_0'$ และ $\beta_1 = 0.8\beta_1'$.

โดยข้อจำกัดเหล่านี้มีผลเมื่อพารามิเตอร์เป็นค่าบวก ในทางกลับกันหากพารามิเตอร์เป็นลบให้สลับขอบเขตบนและล่าง ค่าคงตัวที่กำหนด 0.8 และ 1.2 ใช้ในการควบคุมส่วนประกอบแนวโน้มให้อยู่ในช่วงที่เหมาะสมซึ่งสามารถปรับเปลี่ยนได้ โดยการลดค่าคงตัวเหล่านี้ลงจะทำให้ขอบเขตการค้นหาพารามิเตอร์ β_0 และ β_1 แคบลง ซึ่ง

ส่งผลให้กระบวนการค้นหาเร็วขึ้นแต่อาจส่งผลให้ผลลัพธ์สุดท้ายมีความแม่นยำน้อย และในทางกลับกันการเพิ่มค่าคงตัวเหล่านี้จะขยายขอบเขตการค้นหาพารามิเตอร์ β_0 และ β_1 ให้กว้างขึ้น ซึ่งอาจทำให้กระบวนการหาค่าที่เหมาะสมช้าลง แต่ส่งผลให้ผลลัพธ์สุดท้ายแม่นยำยิ่งขึ้น อย่างไรก็ตามในการศึกษานี้แนะนำค่า 0.8 และ 1.2 เนื่องจากได้ทำการทดสอบเบื้องต้นอย่างเพียงพอสำหรับการกำหนดค่าพารามิเตอร์เหล่านี้แล้ว

การกำหนดขอบเขตความแปรผันฤดูกาลให้ชัดเจนส่วนประกอบแนวโน้มออกจากอนุกรมเวลาโดยใช้การหาผลต่างลำดับ 1 จะได้ $\Delta Y_i = Y_i - Y_{i-1}$ กำหนดข้อจำกัดขอบเขตบนและล่างสำหรับพารามิเตอร์ฤดูกาล $\hat{S}_1, \hat{S}_2, \hat{S}_3, \dots, \hat{S}_{52}$ ดังนี้

Upper Bound Constraints (US) +[ค่าแอมพลิจูดสูงสุดของ ΔY_i]

Lower Bound Constraints (LS) -[ค่าแอมพลิจูดต่ำสุดของ ΔY_i]

แอมพลิจูด คือความสูงสูงสุดของคลื่น ซึ่งในกรณีนี้หมายถึง ความสูงสุดของความผันแปรฤดูกาลของอนุกรมเวลา

ขั้นที่ 2 สร้างพารามิเตอร์เริ่มต้น ตำแหน่งของแต่ละวาทแทนค่าพารามิเตอร์ 54 ตัว ซึ่งคือ $\bar{X}_i = (\beta_0, \beta_1, \hat{S}_1, \hat{S}_2, \hat{S}_3, \dots, \hat{S}_{52})$ ภายในขอบเขต $[0, 1]$ ให้สังเกตว่าในเบื้องต้นสามารถให้ WOA ค้นหาค่าพารามิเตอร์ภายในขอบเขต $[0, 1]$ ได้เลย โดยไม่ต้องปรับเปลี่ยนขั้นตอนวิธีของ WOA ใดๆ ส่วนค่าพารามิเตอร์เหล่านี้จะสามารถปรับเป็นหน่วยตามข้อมูลจริงในภายหลังก่อนคำนวณความเหมาะสมของตัวแบบ

ขั้นที่ 3 เลือกการเคลื่อนไหว วาทแต่ละตัวจะเลือกการกระทำสำหรับการเคลื่อนไหวครั้งต่อไปโดยเลือกหนึ่งในสามการเคลื่อนไหวตามขั้นตอนวิธีของ WOA การเลือกนี้กำหนดว่าวาทจะเคลื่อนเข้าใกล้เหยื่อหรือขยายการค้นหาตามรหัสเทียม Figure 1 โดยมีตัวแปรนำเข้าของ WOA คือ $N = 30$, $T_{\max} = 1,000$, $MaxTime = 180 \text{ sec.}$, $T_{\text{improve}} = 50$, และ $m = 54$

ขั้นที่ 4 การปรับหน่วยพารามิเตอร์ ตั้งค่าขั้นตอนวิธี WOA ให้ค้นหาพารามิเตอร์ภายในขอบเขต [0, 1] จากขั้นที่ 2 ดังนั้นจำเป็นต้องปรับหน่วยของพารามิเตอร์ก่อนคำนวณค่าความเหมาะสมของตัวแบบในขั้นที่ 5 โดยใช้สมการต่อไปนี้

Original Value = Scaled Value x (Upper Bound Constraint - Lower Bound Constraint) + Lower Bound Constraint.

Original Value คือ ค่าเดิมหรือค่าตามหน่วยข้อมูลจริง Scaled Value คือ ค่าพารามิเตอร์ที่ได้จาก WOA ในช่วง [0, 1] สมการนี้จะช่วยแปลงค่าพารามิเตอร์ขั้นตอนวิธี WOA ในช่วง [0, 1] ให้กลับไปอยู่ในหน่วยตามข้อมูลจริง

หากค่าเดิมเป็น $\hat{S}_i$ ต้องมีการปรับฤดูกาลเพิ่มเติมสามารถคำนวณได้โดยใช้สูตรต่อไปนี้

$$\text{Adjust } \hat{S}_i = \hat{S}_i - \sum_{i=1}^{52} \hat{S}_i / 52, \text{ แล้ว } \sum_{i=1}^{52} \hat{S}_i = 0$$

(หมายเหตุ: กรณีแยกส่วนประกอบรูปแบบคูณ Adjust $\hat{S}_i = 52 \times \hat{S}_i / \sum_{i=1}^{52} \hat{S}_i$, แล้ว $\sum_{i=1}^{52} \hat{S}_i = 52$)

จากขั้นที่ 1 ถึง 4 ใน WOA-D ที่แสดงข้างต้นนั้นใช้ขั้นตอนวิธี WOA ได้โดยตรงตาม Figure 1 รหัสเทียมของ WOA เพียงแต่ว่าก่อนขั้นตอนการคำนวณ "Calculate $fitness(X_i)$ " ให้ใช้ขั้นที่ 4 การปรับขนาดพารามิเตอร์ ซึ่งขั้นที่ 4 นั้นก็จะอ้างอิงขั้นที่ 1 ในการกำหนดข้อจำกัดของพารามิเตอร์ ดังนั้นอาจจะสรุปได้ว่าการประยุกต์ใช้ WOA กับวิธีแยกส่วนประกอบนั้น ขั้นที่ 1 และ 4 ที่กล่าวถึงในหัวข้อนี้เป็นส่วนที่สำคัญมากใน WOA-D

ขั้นที่ 5 คำนวณความเหมาะสมของตัวแบบ ความเหมาะสมถูกคำนวณโดยประเมินจาก RMSE ของชุดข้อมูล โดยใช้ตำแหน่งของวาฬแต่ละตัวในวิธีแยกส่วนประกอบ ดังนั้นค่าพารามิเตอร์ที่ให้ค่า RMSE ต่ำสุดในรอบนั้นจะสามารถตัดสินใจตำแหน่งที่ดีที่สุดได้และกำหนดเป็น $(\bar{X}^*)$

ขั้นที่ 6 และ 7 กำหนดเกณฑ์การหยุด และการประเมินประสิทธิภาพ เป็นดังเช่น WOA-HW

ฟังก์ชันวัตถุประสงค์ของ WOA-D เป็นสมการต่อไปนี้

$$\begin{aligned} \text{Objective Minimize } & \text{RMSE}(\hat{\beta}_0, \hat{\beta}_1, \hat{S}_1, \dots, \hat{S}_{52}), \\ \text{Variable range } & \begin{cases} 0.8\hat{\beta}'_0 \leq \hat{\beta}_0 \leq 1.2\hat{\beta}'_0 \\ 0.8\hat{\beta}'_1 \leq \hat{\beta}_1 \leq 1.2\hat{\beta}'_1 \\ \text{LS} \leq \hat{S}_i \leq \text{US} \text{ for } i=1,2,\dots,52 \end{cases}, \end{aligned}$$

ที่ซึ่ง $\text{RMSE} = \sqrt{\frac{1}{T} \sum_{i=1}^T (Y_i - \hat{Y}_i)^2}$ โดย T คือจำนวนข้อมูล

ในอนุกรมเวลา Y_i คือ ค่าข้อมูลจริง $\hat{Y}_i$ คือ ค่าพยากรณ์โดยวิธี WOA-D ที่ได้ค่าพารามิเตอร์ที่ดีที่สุดจากขั้นที่ 6

2.3.5 การประเมินประสิทธิภาพ

การประเมินของการศึกษานี้แบ่งออกเป็นสองประเภทที่แตกต่างกัน

ประเภทแรกคือ "ระยะข้อมูลฝึกฝน" มีวัตถุประสงค์เพื่อระบุแนวทางการสร้างตัวแบบที่ดีที่สุดโดยการประเมินประสิทธิภาพว่าแนวทางใดให้ค่า RMSE ต่ำสุดในช่วงชุดข้อมูลฝึกฝน โดยที่ $\text{RMSE} = \sqrt{\frac{1}{n_1} \sum_{i=1}^{n_1} (Y_i - \hat{Y}_i)^2}$, n_1

หมายถึงความยาวของชุดข้อมูลฝึกฝน และ Y_i และ $\hat{Y}_i$ หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลฝึกฝน ตามลำดับ

เนื่องจากในระยะข้อมูลฝึกฝนดำเนินการหาค่าเหมาะที่สุดอยู่บนฟังก์ชันวัตถุประสงค์ RMSE โดยสร้างตัวแบบให้มี RMSE ต่ำสุดจะเป็นตัวแบบที่ดีที่สุด ดังนั้นในระยะข้อมูลฝึกฝนจึงประเมินประสิทธิภาพด้วย RMSE โดยผลของค่า RMSE ในระยะข้อมูลฝึกฝนนี้จะได้ค่า RMSE ทั้งหมด 4 วิธีคือ RMSE ของ Classic-D Classic-HW WOA-D และ WOA-HW โดยจะเปรียบเทียบค่าที่ดีที่สุดของ RMSE เป็นคู่ๆกัน 2 คู่ คือ Classic-D เปรียบเทียบกับ WOA-D และ Classic-HW เปรียบเทียบกับ WOA-HW

ประเภทสองคือ “ระยะข้อมูลทดสอบ” มีวัตถุประสงค์เพื่อประเมินความสามารถในการพยากรณ์ล่วงหน้าของตัวแบบโดยให้ตัวแบบพยากรณ์ล่วงหน้าสองปีหรือ 105 สัปดาห์ เพื่อเปรียบเทียบประสิทธิภาพของ

ตัวแบบโดยละเอียด ในระยะนี้ใช้ตัวชี้วัดสำคัญ 3 ตัว ได้แก่ RMSE ความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) และ ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ในการประเมินมีสูตรดังต่อไปนี้

$$RMSE = \sqrt{\frac{1}{n_2} \sum_{i=1}^{n_2} (Y_i - \hat{Y}_i)^2}, \quad MAE = \frac{1}{n_2} \sum_{i=1}^{n_2} |Y_i - \hat{Y}_i|, \quad \text{และ} \quad MAPE = 100 \times \frac{1}{n_2} \sum_{i=1}^{n_2} |Y_i - \hat{Y}_i| / Y_i \quad \text{สำหรับ } Y_i > 0,$$

 n_2 หมายถึงความยาวของชุดข้อมูลทดสอบ และ Y_i และ $\hat{Y}_i$ หมายถึงค่าจริงและค่าพยากรณ์ของชุดข้อมูลทดสอบตามลำดับ

เนื่องจากการพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูลที่เกิดขึ้นได้ การแบ่งข้อมูลเป็นชุดข้อมูลฝึกฝนและทดสอบถ้าชุดข้อมูลทั้ง 2 มีลักษณะเดียวกันทุกประการ ความคลาดเคลื่อนที่ได้จากตัวแบบที่ดีที่สุด (ค่าความคลาดเคลื่อนต่ำสุด) จากชุดข้อมูลฝึกฝนก็จะตรงกันกับชุดข้อมูลทดสอบ แต่การพยากรณ์อนุกรมเวลาในข้อมูลจริงย่อมมีความแปรผันของข้อมูล ดังนั้นเพื่อเป็นประโยชน์ต่อการนำค่าพยากรณ์ล่วงหน้าไปใช้ การเพิ่มตัวแบบอื่นๆ ในการพยากรณ์จึงเป็นสิ่งสำคัญที่การศึกษานี้ในระยะข้อมูลทดสอบจึงเพิ่มวิธีการ Box-Jenkins [18] ซึ่งเป็นตัวแบบที่นิยมใช้กันอย่างแพร่หลาย การระบุพารามิเตอร์ของ Box-Jenkins ในการศึกษานี้ทำได้โดยใช้ขั้นตอนต่างๆ หลายขั้นตอนเพื่อระบุตัวแบบรวมการถดถอยในตัวกับการเฉลี่ยเคลื่อนที่แบบมีฤดูกาล (Seasonal Autoregressive Integrated Moving Average: SARIMA(p,d,q)(P,D,Q)₅₂) ดังนี้

1. การเตรียมข้อมูล (Data Preparation)

การวิเคราะห์ข้อมูลกราฟอนุกรมเวลา และ ACF ดัง Figure 2, 3 และ 4 และ ใช้การทดสอบ Dickey-Fuller (DF) โดยตั้งลำดับสูงสุดที่ 52 เพื่อพิจารณาฤดูกาลตามเงื่อนไขเกณฑ์สารสนเทศของอะไกเกะ (Akaike information criterion: AIC) เพื่อพิจารณาความเป็นอนุกรมเวลาแบบคงที่ ถ้าไม่เป็นอนุกรมเวลาแบบคงที่จะดำเนินการแปลงข้อมูลด้วยการหาลำดับที่ของการหาผล

ต่าง d และผลต่างฤดูกาลของอนุกรมเวลา D ของอนุกรมเวลา หรือการแปลงของบ็อกซ์-ค็อกซ์ (Box-Cox transformation) แก้ไขปัญหาเมื่อความแปรปรวนของอนุกรมเวลาไม่คงที่

2. การระบุตัวแบบ (Model Identification)

กำหนดขอบเขตค่า p, q ตั้งแต่ 0 ถึง 2 และ P, Q ตั้งแต่ 0 ถึง 1 ในการค้นหาพารามิเตอร์ที่เหมาะสมใช้วิธีการการค้นหากริดเป็นเทคนิคที่ใช้ในการเรียนรู้ของเครื่อง (Machine Learning) เพื่อค้นหาไฮเปอร์พารามิเตอร์ (Hyperparameters) ที่เหมาะสมที่สุดสำหรับตัวแบบที่กำหนด ไฮเปอร์พารามิเตอร์ คือ พารามิเตอร์ที่ตั้งค่าไว้ก่อนกระบวนการเรียนรู้จะเริ่มต้นในกรณีนี้ คือ ค่าพารามิเตอร์ที่สามารถกำหนดตัวแบบ SARIMA(p,d,q)(P,D,Q)₅₂ ดังนั้นชุดค่าผสมต่าง ๆ เกิดจากผลคูณคาร์ทีเซียน (Cartesian) ของค่าพารามิเตอร์อย่างเป็นระบบเพื่อระบุตัวแบบที่เหมาะสมที่สุดตามเกณฑ์ที่กำหนด

ขั้นตอนที่สำคัญของการค้นหากริดจึงอธิบายได้ดังนี้

2.1 กำหนดชุดของค่าที่เป็นไปได้สำหรับแต่ละพารามิเตอร์ p, q ตั้งแต่ 0 ถึง 2 และ P, Q ตั้งแต่ 0 ถึง 1

2.2 สร้างกริดโดยใช้ผลคูณคาร์ทีเซียนของค่าที่เป็นไปได้สำหรับแต่ละพารามิเตอร์

2.3 สำหรับแต่ละจุดในกริด สร้างตัวแบบ SARIMA(p,d,q)(P,D,Q)₅₂ ตามพารามิเตอร์ในกริดที่กำหนดนั้น

2.4 คำนวณค่าประเมินความเหมาะสมของตัวแบบ โดยในงานวิจัยนี้ใช้ค่า AIC เป็นเกณฑ์ที่กำหนด

2.5 ทำซ้ำขั้นตอนที่ 3 และ 4 ทุกจุดของกริด

2.6 เรียงลำดับตัวแบบเหมาะสมตามค่า AIC จากน้อยไปมาก ดังนั้นจะได้ค่าพารามิเตอร์ของ p, q, P และ Q และ AIC ทุกตัวแบบที่เป็นไปตามแต่ละจุดในกริด

3. การตรวจสอบความเหมาะสมของตัวแบบ (Model Validation)

เลือกตัวแบบที่มีค่า AIC ต่ำที่สุดและดำเนินการขั้นตอนต่อไปจนกว่าตัวแบบจะผ่านการวิเคราะห์ค่าความคลาดเคลื่อนทั้งหมด ($e = Y - \hat{Y}$) ถ้าผ่านขั้นตอนเหล่านี้ทั้งหมด ตัวแบบนั้นจะเป็นตัวแบบที่เหมาะสมในการพยากรณ์

ขั้นตอนการวิเคราะห์ค่าความคลาดเคลื่อน

3.1 ค่าความคลาดเคลื่อนมีการแจกแจงปกติ โดยสถิติการทดสอบคอลโมโกรอฟ-สมิธรอนฟ

3.2 ค่าความคลาดเคลื่อนเป็นอิสระกัน โดยสถิติการทดสอบ Ljung-Box

3.3 ค่าความคลาดเคลื่อนมีค่าเฉลี่ยเท่ากับศูนย์ โดยสถิติการทดสอบที

3.4 ค่าความคลาดเคลื่อนมีความแปรปรวนคงที่ทุกช่วงเวลา โดยสถิติการทดสอบของเลวิน

โดยผลลัพธ์ตามขั้นตอนการดำเนินการของวิธีการ Box-Jenkins นี้ เป็นไปตามการศึกษาของ Minsan et. al. [19] และเพิ่มวิธีหน่วยความจำระยะสั้นแบบยาว (Long Short-term Memory: LSTM) [20] ที่เป็นวิธีการเรียนรู้ของเครื่องที่กำลังเป็นที่นิยมในการศึกษาดูด้วย ประกอบกับ Singhaworawong [21] ได้ใช้ LSTM ในการพยากรณ์ PM2.5 รายชั่วโมงของจังหวัดเชียงใหม่ ซึ่งได้ผลลัพธ์ที่ดี จึงนำมาใช้เป็นแนวคิดเพื่อประยุกต์ใช้ในงานวิจัย โดยกำหนดค่าของไฮเปอร์พารามิเตอร์ ดังนี้

ฟังก์ชันความสูญเสีย (Loss Function) เป็นวิธีคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error) ตัวเพิ่มประสิทธิภาพ (Optimizer) เป็นวิธี nadam ทำการฝึกสอน (Epoch) จำนวน 100 ครั้ง โดยการตั้งค่านี้เป็นการสมดุระหว่างการเรียนรู้ที่เพียงพอที่จะเรียนรู้รูปแบบที่ซ่อนอยู่ในข้อมูลอนุกรมเวลา ได้คำตอบที่เหมาะสมโดยไม่ใช้เวลาในการวนซ้ำมากเกินไป และไม่เกิดปัญหาฟิตมากเกินไป (Overfitting)

จำนวนเซลล์ประสาทเทียม (Neurons) ในเลเยอร์ เท่ากับ 25 50 และ 75 เลือกเพื่อสำรวจระดับความซับซ้อนของตัวแบบที่แตกต่างกัน จำนวนที่ต่ำกว่า เช่น 25 และ 50 ช่วยให้ตัวแบบเรียนรู้แบบไม่ซับซ้อน ในขณะที่จำนวนที่สูงกว่า เช่น 75 ช่วยให้ตัวแบบสามารถตรวจสอบความสัมพันธ์ที่ซับซ้อนมากขึ้นในข้อมูล โดยค่าที่กำหนดนี้ให้ความสมดุลที่ระหว่างประสิทธิภาพของตัวแบบและประสิทธิภาพในการคำนวณ ทำให้แบบตัวแบบสามารถจับรูปแบบที่จำเป็นโดยไม่ต้องคำนวณมากเกินไป

จำนวนข้อมูลย้อนหลัง (Look Back) เท่ากับ 26 52 และ 104 กำหนดแบบสอดคล้องกับข้อมูลรายสัปดาห์ โดยตรวจสอบรูปแบบตามฤดูกาลที่สำคัญ คือ กำหนด 26 สัปดาห์ครอบคลุมครึ่งปี กำหนด 52 สัปดาห์ครอบคลุมหนึ่งปีเต็ม และ 104 สัปดาห์ครอบคลุมสองปี ตัวเลือกนี้ช่วยให้แน่ใจว่าตัวแบบจะตรวจสอบการเปลี่ยนแปลงตามฤดูกาลทั้งระยะสั้นและระยะยาวได้

ผลของค่า RMSE MAE และ MAPE ในระยะข้อมูลทดสอบนี้จะได้ค่าแต่ละค่าทั้งหมด 6 วิธีคือ Classic-D Classic-HW WOA-D WOA-HW Box-Jenkins และ LSTM โดยจะเปรียบเทียบค่าที่ต่ำที่สุดของ RMSE MAE และ MAPE ใน 6 วิธีเหล่านั้น เพื่อใช้ในการตัดสินใจตัวแบบที่ดีที่สุดในการพยากรณ์ล่วงหน้า

การทดลองดำเนินการในสภาพแวดล้อม Google Colab [22] ซึ่งให้สิทธิ์เข้าถึงความสามารถในการเขียนโปรแกรม Python โดยอัตโนมัติ คอมพิวเตอร์

CPU Intel(R) Core(TM) i5-9400 @ 2.90GHz, RAM 16GB, ทำงานบนระบบปฏิบัติการ Windows 11




Figure 2 Weekly PM2.5 actual data of 8 northern provinces




Figure 3 ACF of the deseasonalization time series data of 8 northern provinces




Figure 4 ACF of the detrended time series data of 8 northern provinces

3. การทดลองและการวิเคราะห์

3.1 ผลลัพธ์ของการวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลา

การวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลาโดยวิธีการวิเคราะห์เบื้องต้นจากกราฟอนุกรมเวลาของข้อมูลตาม Figure 2 ได้ผลดังนี้ ค่า PM2.5 ในทุกจังหวัดภาคเหนือตอนบนปรากฏเห็นความแปรผันตามฤดูกาลชัดเจน โดยคาบของฤดูกาลเป็นช่วงเวลา 1 ปี ดังนั้น ในชุดข้อมูลรายสัปดาห์จึงตัดสินใจคาบเวลาของฤดูกาลคือ 52 สัปดาห์ ในการตัดสินใจเกี่ยวกับแนวโน้ม ถ้าทดลองแบ่งส่วนข้อมูล 2.5 ปี ตามกำหนดข้อมูลชุดฝึกฝนคือตั้งแต่ พ.ศ. 2562 ถึง พ.ศ. 2564 พบว่า ค่า PM2.5 มีแนวโน้มลดลงเล็กน้อย แต่ถ้าทดลองแบ่งส่วนข้อมูล 3.5 ปี ตั้งแต่ปี พ.ศ. 2562 ถึง พ.ศ. 2565 พบว่า ค่ามีแนวโน้มลดลงมากกว่าพิจารณา 2.5 ปี และถ้าไม่แบ่งข้อมูลเลยใช้ข้อมูล 4.5 ปี พบว่า ข้อมูลส่วนใหญ่มียังมีแนวโน้มลดลงแต่ลดลงน้อยกว่าการทดลองแบ่งส่วนข้อมูล 3.5 ปี และมี 3 จังหวัดที่มีแนวโน้มเพิ่มขึ้นคือ จังหวัดลำปาง น่าน และพะเยา สาเหตุเพราะค่า PM2.5 ในปี พ.ศ. 2566 รุนแรงจาก 4 ปีก่อนหน้าอย่างมาก จากข้อมูลลักษณะการเคลื่อนไหวของอนุกรมเวลาเบื้องต้นนี้ การคาดการณ์แนวโน้มในอนาคตจึงอาจจะเป็นเรื่องยากพอสมควร ในการศึกษาครั้งนี้จึงตัดสินใจว่า ข้อมูลมีแนวโน้ม โดยแนวโน้มกับฤดูกาลมีความสัมพันธ์แบบบวก เนื่องจากถ้าตัดสินใจจากเฉพาะชุดข้อมูลฝึกฝน แนวโน้มกับฤดูกาลจะมีความสัมพันธ์แบบคูณถ้าใช้ตัวแบบคุณนี้แนวโน้มที่ลดลงในช่วงชุดข้อมูลฝึกฝนจะทำให้ขนาดความแปรผันตามฤดูกาลลดลงด้วยซึ่งจะทำให้การคาดการณ์ล่วงหน้าคลาดเคลื่อนมาก โดยเฉพาะเมื่อนำผลการพยากรณ์ล่วงหน้าไปทดสอบกับชุดข้อมูลการทดสอบในปี พ.ศ. 2566 (ปีที่ 4.5) เพราะปีนี้มีความรุนแรง PM2.5 มาก นี่เป็นสาเหตุในการศึกษาครั้งนี้ใช้ตัวแบบรูปแบบบวก ในการศึกษาทั้ง HW และวิธีแยกส่วนประกอบ

การตัดสินใจเกี่ยวกับแนวโน้มและฤดูกาลสามารถใช้ฟังก์ชันสหสัมพันธ์ในตัว (Autocorrelation Function: ACF) ช่วยพิจารณาได้ดัง Figure 3 และ 4 โดย Figure 3 เป็น ACF ของข้อมูลแต่ละจังหวัดที่จัดฤดูกาล และ Figure 4 เป็น ACF ของข้อมูลแต่ละจังหวัดที่จัดแนวโน้ม โดยทั้ง 2 รูปนี้ยังเป็นตัวใช้ในการสร้างตัวแบบ Box-Jenkins อีกด้วย ทั้งนี้การตัดสินใจที่สอดคล้องกับการตัดสินใจด้วยการวิเคราะห์ลักษณะการเคลื่อนไหวของอนุกรมเวลา

3.2 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในระยะชุดข้อมูลฝึกฝน

เพื่อประเมินประสิทธิภาพของตัวแบบ WOA-HW และ WOA-D ในการพยากรณ์ความเข้มข้นของ PM2.5 การศึกษาได้ดำเนินการวิเคราะห์เปรียบเทียบกับตัวแบบการพยากรณ์แบบคลาสสิกสองแบบ ได้แก่ Classic-D และ Classic-HW เมื่อนำไปใช้กับชุดข้อมูลเดียวกัน คือ ข้อมูลอนุกรมเวลาความเข้มข้นค่า PM2.5 รายสัปดาห์ 8 จังหวัดภาคเหนือในชุดข้อมูลฝึกฝนได้ผลตาม Table ที่ 1

ความสามารถในการปรับแต่งพารามิเตอร์ของขั้นตอนวิธี WOA สามารถผสานเข้ากับตัวแบบ HW และการแยกส่วนประกอบได้อย่างมีประสิทธิภาพ ส่งผลให้ค่า RMSE ต่ำลงเมื่อเทียบกับวิธีการแบบคลาสสิก แสดงให้เห็นว่าการผสาน WOA ช่วยทำให้ฟังก์ชันวัตถุประสงค์ RMSE ต่ำลงมากกว่าใช้วิธีการแบบคลาสสิก

ในการเปรียบเทียบแบบคู่ โดยคู่แรกระหว่างตัวแบบ WOA-D และ Classic-D ตัวแบบ WOA-D แสดงให้เห็นค่า RMSE ที่ต่ำกว่าอย่างมากเมื่อเทียบกับ Classic-D ซึ่งบ่งชี้ว่าความสามารถในการหาค่าเหมาะที่สุดของพารามิเตอร์ WOA ให้ผลที่ดีเหนือกว่าวิธีการแบบคลาสสิกในทุกชุดข้อมูล

ในการเปรียบเทียบคู่ที่สอง WOA-HW และ Classic-HW ค่า RMSE มีค่าใกล้เคียงกันมากจะแตกต่างกันที่ระดับทศนิยม 1 ตำแหน่งเป็นต้นไป จากชุดข้อมูลอนุกรมเวลา 8 จังหวัด พบว่า ค่าต่ำสุดของ RMSE ในทั้งสองวิธีนั้นเท่ากันคือ WOA-HW ชนะ 4 ชุดข้อมูล คือ ลำปาง เชียงราย ลำพูน และพะเยา ส่วน Classic-HW

ขณะที่ชุดข้อมูล เชียงใหม่ แม่ฮ่องสอน น่าน และแพร่ อย่างไรก็ตาม ต้นทุนด้านเวลาคำนวณอาจเป็นปัจจัยที่จะต้องนำมาพิจารณา เนื่องจากว่า ในการทดลองของการศึกษานี้ การค้นหาแบบกริด ซึ่งเกี่ยวข้องกับการเปลี่ยนแปลงค่าพารามิเตอร์ 3 ค่าได้แก่ α, γ และ δ ในระดับทศนิยม 3 ตำแหน่ง ที่อัตราเพิ่มแต่ละค่าครั้งละ 0.005 เริ่มจาก 0 ถึง 1 ส่งผลให้มีการวนซ้ำทั้งหมด 8,120,601 ครั้ง ที่เป็นการค้นหาค่าพารามิเตอร์ที่เหมาะสมกับฟังก์ชันวัตถุประสงค์ที่ละเอียดมาก ด้วยความละเอียดระดับนี้ทำให้การทดลองด้วยไพทอน (Python) บนกูเกิลคอลลาบ (Google Colab) ใช้เวลาเฉลี่ย

1 ชั่วโมง ส่วนเบี่ยงเบนมาตรฐาน 2 นาที ต่อ 1 จังหวัด ในการประมวลผลของฟังก์ชันวัตถุประสงค์ ส่วนการประมวลผล WOA-HW ด้วยไพทอนใช้เวลาเฉลี่ย 48 วินาที ส่วนเบี่ยงเบนมาตรฐาน 2 วินาที ต่อ 1 จังหวัดในการประมวลผลของฟังก์ชันวัตถุประสงค์ (โดยที่ Minsan and Minsan [15, 16] และงานวิจัยนี้สามารถหาค่าพารามิเตอร์ที่เหมาะสมโดยการประมวลผลตามขั้นตอนวิธีที่นำเสนอเพียงครั้งเดียวก็ได้คำตอบที่ดีโดยไม่ต้องทำซ้ำ) สรุปได้ว่าการนำ WOA มาใช้กับวิธีการ HW และการแยกส่วนประกอบ ช่วยให้สามารถปรับแต่งตัวแบบได้แม่นยำและมีเวลาในการค้นหาที่เหมาะสม

Table 1 Training Dataset RMSE by Province

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	9.63899	10.97138	14.63914	16.35235	10.79831	10.01703	10.98414	11.22043
Classic-D	10.73072	13.84824	17.18191	20.45834	12.59933	12.43616	14.16146	15.05965
WOA-HW	13.98683	17.19809	21.47516	26.30601	16.40176	15.10299	17.04539	16.72952
Classic-HW	13.97959	17.19810	21.47518	26.30559	16.04056	15.10300	17.04403	16.72953

Note: The lowest RMSE value between WOA-D and Classic-D, and between WOA-HW and Classic-HW is bolded

3.3 การวิเคราะห์ประสิทธิภาพการเปรียบเทียบในระยะชุดข้อมูลทดสอบ

การสรุปตัวแบบที่มีประสิทธิภาพของแต่ละจังหวัดในชุดข้อมูลทดสอบเพื่อเลือกตัวแบบที่มีประสิทธิภาพดีที่สุดในพยากรณ์ล่วงหน้า พิจารณาจาก Table ที่ 2 3 และ 4 แสดงค่า RMSE MAE และ MAPE ตามลำดับ โดยจะเลือกตัวแบบที่มีค่าต่ำสุดในเกณฑ์ทั้ง 3 มากที่สุดถือเป็นตัวแบบที่มีประสิทธิภาพดีที่สุด

- จังหวัดเชียงใหม่เลือกตัวแบบ Classic-D เพราะมีค่า RMSE และ MAPE ต่ำสุด
- จังหวัดลำปางเลือกตัวแบบใดก็ได้ใน 3 ตัวแบบนี้คือ WOA-HW มีค่า RMSE ต่ำที่สุด Classic-HW มีค่า MAE ต่ำที่สุด และ Classic-D มีค่า MAPE ต่ำที่สุดในงานวิจัยนี้เลือก WOA-HW ในการพยากรณ์ล่วงหน้า
- จังหวัดเชียงรายเลือกตัวแบบ WOA-HW เพราะมีค่า MAE และ MAPE ต่ำสุด

- จังหวัดแม่ฮ่องสอนเลือกตัวแบบใดก็ได้ใน 3 ตัวแบบนี้คือ WOA-D มีค่า RMSE ต่ำที่สุด LSTM มีค่า MAE ต่ำที่สุด และ Box-Jenkins มีค่า MAPE ต่ำที่สุดในงานวิจัยนี้เลือก WOA-D ในการพยากรณ์ล่วงหน้า
- จังหวัดน่านเลือกตัวแบบ Box-Jenkins เพราะมีค่า RMSE MAE และ MAPE ต่ำสุด ใช้ Ln ในการแปลงข้อมูลและได้ตัวแบบ SARIMA (2,1,0)(0,1,1)₅₂
- จังหวัดลำพูนเลือกตัวแบบ Classic-HW เพราะมีค่า RMSE MAE และ MAPE ต่ำสุด
- จังหวัดแพร่เลือกตัวแบบ Box-Jenkins เพราะมีค่า MAE และ MAPE ต่ำสุด ใช้ Ln ในการแปลงข้อมูลและได้ตัวแบบ SARIMA (1,1,1)(0,1,0)₅₂
- จังหวัดพะเยาเลือกตัวแบบ WOA-D เพราะมีค่า RMSE และ MAE ต่ำสุด

Table 2 RMSE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	23.1066	24.0376	29.7050	25.3191	25.8858	22.2615	19.7992	22.5871
WOA-HW	22.4704	20.5950	28.0672	27.7104	31.7598	16.2253	16.4673	23.3082
Classic-D	21.8446	24.9215	31.0733	30.6131	25.1791	21.7060	21.5414	24.9190
Classic-HW	22.0666	20.5951	28.0641	27.7424	23.8451	16.2212	16.4660	23.3035
Box-Jenkins	24.0092	24.2997	35.3172	28.8855	22.5499	17.4173	16.8644	23.5297
LSTM	24.6521	28.6177	43.9556	26.7570	23.9249	18.3271	18.7947	26.2028

Note: The lowest value for each province is bolded

Table 3 MAE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	14.4982	16.9714	17.7679	13.6246	19.0599	14.7432	13.9808	12.5994
WOA-HW	12.6768	13.1074	15.4342	13.4418	23.1809	10.6340	10.6631	12.6384
Classic-D	14.3271	16.8168	18.6476	15.1466	18.3419	13.8492	14.8273	15.1587
Classic-HW	12.1324	13.1065	15.4371	13.5613	15.2835	10.6305	10.6631	12.6358
Box-Jenkins	12.8686	15.1068	21.8719	13.4957	13.5623	11.4518	10.4930	13.1559
LSTM	12.7400	19.8306	24.5086	12.6958	14.8416	11.7020	13.6729	13.8013

Note: The lowest value for each province is bolded

Table 4 MAPE Metrics for Each Province's Testing Dataset

	CMI	LPG	CRI	MSN	NAN	LPN	PRE	PYO
WOA-D	61.4543	62.3862	69.0285	57.5336	61.7411	55.7308	56.4822	43.9754
WOA-HW	49.6047	45.8028	63.1640	44.7999	72.4274	51.6015	40.4787	42.7960
Classic-D	40.7040	44.0149	74.3722	57.6796	60.6864	52.9528	59.4778	56.3023
Classic-HW	45.7530	45.7961	63.2067	46.5667	44.5442	51.5791	40.5051	42.7963
Box-Jenkins	43.2071	46.6772	97.2940	39.8519	39.3229	52.2111	39.5831	42.4107
LSTM	43.3844	72.3414	86.3939	56.0160	43.2336	62.8611	59.3373	40.7605

Note: The lowest value for each province is bolded

3.4 การพยากรณ์ล่วงหน้า 2 ปี

การพยากรณ์ค่าความเข้มข้น PM2.5 ทั้ง 8 จังหวัดตามตัวแบบที่มีประสิทธิภาพมากที่สุดในหัวข้อ 3.3 ได้ผลกราฟเส้นค่าจริงและค่าพยากรณ์ดัง Figure 5 และ 6 จะเห็นว่า PM2.5 ทุกจังหวัดนั้นมีฤดูกาลชัดเจน คือจะมีช่วงที่ค่า PM2.5 สูงเกิน 37.5 ไมโครกรัมต่อลูกบาศก์เมตร เริ่มประมาณเดือนธันวาคมเป็นต้นไป

จนถึงประมาณเดือนพฤษภาคม และจะมีช่วงค่าสูงเกิน 75.1 ไมโครกรัมต่อลูกบาศก์เมตรขึ้นไปซึ่งถือว่าเป็นช่วงที่ค่า PM2.5 นั้นมีผลกระทบต่อสุขภาพมากอยู่ในช่วงเดือนมีนาคมและเมษายน มีเพียงจังหวัดแพร่ที่ค่า PM2.5 นั้นสูงเกิน 75.1 ไมโครกรัมต่อลูกบาศก์เมตรเร็วกว่าจังหวัดอื่นๆ คือตั้งแต่ประมาณเดือนมกราคมเป็นต้นไป




Figure 5 Comparison of actual and forecasted weekly PM2.5 values for each province using the appropriate forecasting method

Month Year	Weekly	Chiang Mai	Lampang	Chiang Rai	Mae Hong Son	Nan	Lamphun	Phrae	Phayao
July-23	27	7	14	4	6	15	5	11	12
July-23	28	6	15	3	10	16	7	11	12
July-23	29	9	14	3	7	16	5	11	11
July-23	30	11	17	2	2	19	5	22	12
July-23	31	9	14	1	5	18	4	12	5
August-23	32	10	12	1	1	19	3	12	10
August-23	33	11	14	1	4	17	5	13	10
August-23	34	10	13	1	5	18	4	13	11
August-23	35	15	12	1	9	21	6	17	22
September-23	36	10	15	4	9	19	5	14	13
September-23	37	8	11	1	21	19	1	10	9
September-23	38	12	16	1	5	17	4	12	13
September-23	39	10	23	8	9	19	13	13	14
October-23	40	9	26	10	6	20	20	14	10
October-23	41	9	25	9	4	18	24	19	16
October-23	42	14	25	6	15	23	21	36	20
October-23	43	14	24	8	7	22	19	36	17
October-23	44	18	25	7	11	27	17	36	17
November-23	45	20	30	7	15	31	18	40	16
November-23	46	18	32	12	18	27	22	23	22
November-23	47	19	31	11	9	26	23	22	22
November-23	48	22	30	11	14	36	25	29	29
December-23	49	30	35	23	34	46	27	29	30
December-23	50	27	43	25	15	42	38	48	31
December-23	51	33	41	19	13	48	28	49	42
December-23	52	25	56	19	8	37	39	43	29
January-24	1	35	43	13	12	45	35	38	33
January-24	2	41	50	19	12	52	39	51	35
January-24	3	37	58	15	16	57	33	62	47
January-24	4	42	63	20	22	68	36	75	55
January-24	5	39	62	21	25	73	40	94	55
February-24	6	28	49	21	37	75	36	78	44
February-24	7	41	30	20	63	74	29	94	59
February-24	8	51	53	35	65	79	51	116	56
February-24	9	56	79	41	104	98	56	163	68
March-24	10	89	68	50	141	108	54	123	89
March-24	11	71	77	91	97	87	74	74	58
March-24	12	55	71	78	129	86	59	103	72
March-24	13	93	70	91	145	98	61	120	88
April-24	14	49	100	139	90	107	87	146	70
April-24	15	46	53	50	65	88	59	115	60
April-24	16	37	50	51	41	64	50	100	43
April-24	17	14	56	50	32	56	55	51	28
April-24	18	18	32	50	16	50	30	64	34
May-24	19	19	38	54	13	35	37	30	20
May-24	20	20	34	47	8	37	31	48	33
May-24	21	14	34	48	8	35	28	42	21
May-24	22	17	23	24	6	27	19	29	16
June-24	23	11	22	19	8	21	16	22	14
June-24	24	9	14	9	5	19	7	19	15
June-24	25	13	14	5	3	19	6	14	11
June-24	26	8	16	7	1	15	7	16	8
July-24	27	7	14	4	5	17	5	16	13
July-24	28	6	15	3	9	20	7	16	13
July-24	29	8	14	3	6	19	5	17	12
July-24	30	10	17	2	1	23	5	31	13
July-24	31	8	14	1	4	22	4	17	6
August-24	32	10	12	1	0	23	3	17	11
August-24	33	11	14	1	3	20	5	19	11
August-24	34	10	13	1	4	22	4	19	12
August-24	35	14	12	1	8	25	6	25	23
September-24	36	9	15	4	8	23	5	21	14
September-24	37	7	11	1	20	22	1	15	10
September-24	38	12	16	1	4	21	4	17	13
September-24	39	10	23	8	8	23	13	19	14
September-24	40	8	26	10	5	25	20	21	11
October-24	41	9	25	9	3	22	24	27	17
October-24	42	14	25	6	14	27	21	52	20
October-24	43	14	24	8	6	26	19	52	18
October-24	44	17	25	7	10	32	17	52	18
November-24	45	19	30	7	14	37	18	59	17
November-24	46	18	32	12	17	33	22	33	23
November-24	47	19	31	11	8	31	23	31	23
November-24	48	21	30	11	13	44	25	42	29
December-24	49	29	35	23	33	55	27	42	31
December-24	50	26	43	25	14	51	38	69	32
December-24	51	32	41	19	12	58	28	71	43
December-24	52	25	56	19	7	44	39	63	29
December-24/ January-25	53/1	35	43	13	11	54	35	54	34
January-25	2	41	50	19	11	63	39	73	35
January-25	3	37	58	15	15	68	33	90	48
January-25	4	42	63	20	21	82	36	109	56
January-25	5	39	62	21	24	88	40	136	56
February-25	6	27	49	21	36	90	36	113	45
February-25	7	41	30	20	62	89	29	136	60
February-25	8	51	53	35	64	96	51	167	57
February-25	9	55	79	41	103	118	56	236	68
March-25	10	89	68	50	140	130	54	178	89
March-25	11	70	77	91	96	105	74	107	59
March-25	12	54	71	78	128	104	59	148	72
March-25	13	92	70	91	144	118	61	173	89
March-25	14	48	100	139	89	129	87	211	71
April-25	15	45	53	50	64	106	59	161	61
April-25	16	36	50	51	40	78	50	144	43
April-25	17	14	56	50	31	68	55	73	29
April-25	18	18	32	50	15	60	30	92	35
May-25	19	18	38	54	12	42	37	44	20
May-25	20	20	34	47	7	45	31	69	33
May-25	21	13	35	48	7	42	28	61	22
May-25	22	16	23	24	5	33	19	42	17
June-25	23	10	22	19	7	26	16	31	15
June-25	24	8	14	9	4	23	7	27	15
June-25	25	12	14	5	2	23	6	21	12
June-25	26	7	16	7	1	18	7	23	9

Note: The yellow category, which has health impacts, ranges from 37.5 to 75.09 micrograms per cubic meter. The red category, indicating severe health impacts, starts at 75.1 micrograms per cubic meter and above.

Figure 6 Two-Year Ahead Forecasted Values for All Provinces

4. วิจารณ์ผล

WOA เพื่อประมาณค่าพารามิเตอร์ในวิธีการ HW จำนวน 3 ตัว และ เทคนิคการแยกส่วนประกอบ จำนวนมากถึง 54 ตัว ได้ผลลัพธ์ที่ดีกว่าการประมาณค่าพารามิเตอร์ด้วยวิธีคลาสสิกเป็นส่วนใหญ่ ซึ่งสอดคล้องกับงานวิจัย Minsan and Minsan [15, 16] ดังนั้นจากสรุปผลงานวิจัยนี้และงานวิจัย Minsan and Minsan [15, 16] ทำให้มีความเชื่อมั่นได้ว่าการใช้ WOA-HW และ WOA-D นั้นให้ผลลัพธ์ในการสร้างตัวแบบที่มีความคลาดเคลื่อนจากข้อมูลจริงต่ำ แม้ว่าค่าพารามิเตอร์จะมีจำนวนมาก WOA ก็ยังสามารถใช้งานได้ดี

5. สรุป

จาก Table 5 สรุปได้ว่าในระยะชุดข้อมูลฝึกฝน WOA-D ได้ค่าต่ำสุดฟังก์ชันวัตถุประสงค์ทั้ง 8 จังหวัด ส่วน WOA-HW ได้ค่าต่ำสุดฟังก์ชันวัตถุประสงค์ 4 จังหวัด ทำให้เชื่อได้ว่าการนำเมตาฮิวริสติกส์มาผสานกับการประมาณค่าพารามิเตอร์ของตัวแบบพยากรณ์อนุกรมเวลาเป็นวิธีการที่ดี โดยสามารถนำวิธีการเมตาฮิวริสติกส์ต่างๆ มาใช้ร่วมกันกับตัวแบบอนุกรมเวลาได้ดังผลการวิจัยที่ผ่านมาของ Minsan and Minsan [15, 16] ที่ประมาณค่าพารามิเตอร์มากที่สุด 14 ตัว และผลการศึกษานี้ที่ประมาณค่าพารามิเตอร์ได้มากขึ้น คือ 54 ตัว โดยหลักการคือเลือกวิธีการเมตาฮิวริสติกส์ที่สนใจหรือวิธีการใหม่ๆ มาทำตามขั้นตอนของงานวิจัยนี้ก็จะสามารถผสมผสานทั้งสองส่วน คือ วิธีการเมตาฮิวริสติกส์กับเทคนิคการพยากรณ์อนุกรมเวลาได้อย่างดี

นอกจากใช้เมตาฮิวริสติกส์อื่นๆ อาจจะพิจารณาเทคนิคการสร้างตัวแบบพยากรณ์ที่นอกเหนือจากงานวิจัยนี้คือ เทคนิคการแยกส่วนประกอบ และเทคนิค HW โดยผู้ที่สนใจศึกษาแนวทางนี้อาจจะนำ WOA ไปประยุกต์ใช้กับเทคนิคการพยากรณ์อนุกรมเวลาอื่นๆ ก็จะเป็นงานวิจัยที่น่าสนใจเป็นอย่างมาก ทั้งนี้ผลสรุปของงานวิจัยแสดงให้เห็นแล้วว่าการประมาณค่าพารามิเตอร์จำนวนมาก เช่น 54 ตัว วิธีการเมตาฮิวริสติกส์ WOA ก็สามารถประมาณค่าพารามิเตอร์ได้

Table 5 Summary of the best-fit model of objective function RMSE for each province in the train dataset phase

Train Dataset Phase	
WOA-D	CMI, LPG, CRI, MSN, NAN, LPN, PRE, PYO
Classic-D	-
WOA-HW	LPG, CRI, LPN, PYO
Classic-HW	CMI, MSN, NAN, PRE

จากตารางที่ 6 แสดงให้เห็นว่าไม่สามารถระบุวิธีการพยากรณ์ล่วงหน้าแบบใดที่ให้ผลลัพธ์ที่ดีที่สุดอย่างแน่ชัด เนื่องจากความผันผวนของข้อมูลอนุกรมเวลาส่งผลต่อความแม่นยำในการพยากรณ์ล่วงหน้า โดยทั่วไปแล้ว หากชุดข้อมูลฝึกอบรมมีรูปแบบคล้ายคลึงกับชุดข้อมูลทดสอบ โมเดลที่ดีในชุดข้อมูลฝึกอบรมก็มีแนวโน้มที่จะให้ผลลัพธ์ที่ดีในชุดข้อมูลทดสอบด้วยเช่นกัน อย่างไรก็ตาม สิ่งสำคัญคือต้องตระหนักว่าความผันผวนของข้อมูลอนุกรมเวลานั้นเกิดขึ้นได้เสมอ ชุดข้อมูลฝึกอบรมและชุดข้อมูลทดสอบอาจมีความแตกต่างกัน แนวทางปฏิบัติที่แนะนำ คือ ในการพยากรณ์ล่วงหน้าควรสร้างตัวแบบหลายตัวแบบเพื่อนำมาเปรียบเทียบกับตามเกณฑ์การตัดสินใจ

Table 6 Summary of the most suitable model for each province in the test dataset phase

Test Dataset Phase			
	RMSE	MAE	MAPE
WOA-D	MSN, PYO	PYO	-
Classic-D	CMI	-	CMI, LPG
WOA-HW	LPG	CRI	CRI
Classic-HW	CRI, LPN, PRE	CMI, LPG, LPN	LPN
Box-Jenkins	NAN	NAN, PRE	MSN, NAN, PRE
LSTM	-	MSN	PYO

6. References

- [1] Dorigo, M., 1992, Optimization, Learning and Natural Algorithms, Ph.D. Thesis, Politecnico di Milano, Italy, 140 p.
- [2] Dorigo, M. and Stützle, T., 2004, Ant Colony Optimization, MIT Press, Cambridge, MA, USA, 305 p.
- [3] Karaboga, D., 2005, An Idea Based on Honey Bee Swarm for Numerical Optimization, Technical Report-TR06, Engineering Faculty, Computer Engineering Department, Erciyes University, 10 p.
- [4] Yang, X.S., and Deb, S., 2009, Cuckoo Search Via Lévy Flights, Proceedings of World Congress on Nature & Biologically Inspired Computing (NaBIC), pp. 210-214.
- [5] Pan, W.T., 2011, A New Evolutionary Computation Approach: Fruit Fly Optimization Algorithm, Proceedings of the Conference of Digital Technology and Innovation Management, Taipei, Taiwan, pp. 382-391.
- [6] Yang, X.S., 2012, Flower pollination algorithm for global optimization, Unconventional Computation and Natural Computation, Lecture Notes in Computer Science. 7445: 240-249.
- [7] Kaewpaengjuntra, S., Somhom, S. and 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. (in Thai)
- [8] Assis, M.V.O., Carvalho, L.F., Rodrigues, J.J.P.C. and Provençal, M.L., 2013, Holt-Winters statistical forecasting and ACO metaheuristic for traffic characterization. Proceeding of 2013 IEEE International Conference on Communications (ICC), Budapest, Hungary, pp. 2524-2528.
- [9] Janta, S., Thaninpong, P. and Minsan.W., 2018, Holt-Winters Exponential Smoothing Forecasting using Flower Pollination Algorithm based Parameter Estimation, Proceeding of The 6th Academic Science and Technology Conference 2018, Bang Phli, Samut Prakan, pp. BS-40-46. (in Thai) Available Source: https://drive.google.com/file/d/1zVBvqbNqfTqrZYUmiY8wS2uN1amtOy/view?usp=drive_link, July 1, 2023. (in Thai)
- [10] Jiang, W., Wu, X., Gong, Y., Yu, W. and Zhong, X., 2020, Holt-Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption, Energy. 193: 116779.
- [11] Mauricio, C.C. and Ostia, C.F., 2023, Cuckoo search algorithm optimization of Holt-Winter method for distribution transformer load forecasting. Proceeding of the 2023 9th International Conference on Control, Automation and Robotics (ICCAR), Beijing, China, pp. 36-42.
- [12] Mirjalili, S. and Lewis, A., 2016, The whale optimization algorithm, Advances in Engineering Software. 95: 51-67.

- [13] Nadimi-Shahraki M.H., Zamani, H., Varzaneh Z.A. and Mirjalili, S., 2023, A systematic review of the whale optimization algorithm: theoretical foundation improvements and hybridizations, *Archives of Computational Methods in Engineering*. 30: 4113-4159.
- [14] Minsan, W., Saengngammuang, N., Taninpong, P. and Thumronglaohapun, S., 2021, Comparing Methods of Optimization in Solver of Excel 2019 and Whale Optimization Algorithm, *UTK Research Journal*. 15(2): 106-120. (in Thai)
- [15] Minsan, W. and Minsan, P., 2023, Incorporating Decomposition and the Holt-Winters Method into the Whale Optimization Algorithm for Forecasting Monthly Government Revenue in Thailand, *Science & Technology Asia*. 28(4): 38-53.
- [16] Minsan, W. and Minsan, P., 2024, Decomposition and Holt-Winters Enhanced by the Whale Optimization Algorithm for Forecasting the Amount of Water Inflow into the Large Dam Reservoirs in Southern Thailand, *Journal of Current Science and Technology*. 14(2): 1-16.
- [17] Ministry of Natural Resources and Environment, Pollution Control Department, Available Source: <http://air4thai.pcd.go.th/webV2/history/#> , July 30, 2023. (in Thai)
- [18] Box, G.E.P., Jenkins, G.M., Reinsel, G.C. and Ljung G.M., 2015, *Time Series Analysis: Forecasting and Control*, 5th ed., Wiley, 712 p.
- [19] Minsan, W. and Minsan, P. and Panichkit osolkul, W., 2024, Enhancing Decomposition and Holt-Winters Weekly Forecasting of PM 2.5 Concentrations in Thailand's Eight Northern Provinces Using the Cuckoo Search Algorithm, *Thailand Statistician*. 22(4) : 963-935.
- [20] Hochreiter, S. and Schmidhuber, J., 1997, Long short-term memory, *Neural Computation*. 9(8): 1735-1780.
- [21] Singhaworawong, P., (2020), *Forecasting PM2.5 in Chiang Mai using long short-term memory models*, Master Thesis, Srinakharinwirot University, Bangkok, 76 p. (in Thai)
- [22] Google Colab, Overview of Colaboratory Features, Available Source: <https://colab.research.google.com/notebooks/intro.ipynb> , May 1, 2023.