

**การพยากรณ์ปริมาณฝุ่นละออง PM2.5 ในจังหวัดนครสวรรค์
ด้วยแบบจำลองการเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก และแบบจำลองลูกผสมฐาน Prophet
Forecasting PM2.5 Concentrations in Nakhon Sawan Province
Using Machine Learning, Deep Learning, and Prophet-Based Hybrid Models**

ถิรภัทร มีสำราญ¹, ขม ปานตา², ภาสกร วรอาจ¹, วิฑูร สอนธิปักษ์^{1*}

Thiraphat Meesumrarn¹, Chom Panta², Phassakorn Worra-arj¹, Withoon Sonthipak^{1*}

¹สาขาวิชาวิทยาการคอมพิวเตอร์และเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครสวรรค์

¹Department of Computer Science and Information Technology, Faculty of Science and Technology,
Nakhon Sawan Rajabhat University

²สาขาวิชาคณิตศาสตร์และสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครสวรรค์

²Department of Mathematics and Statistics, Faculty of Science and Technology,
Nakhon Sawan Rajabhat University

บทคัดย่อ

ปัญหาฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) ในจังหวัดนครสวรรค์ เป็นปัญหาสำคัญทั้งด้านสิ่งแวดล้อมและสุขภาพ โดยปริมาณฝุ่นจะมีความเปลี่ยนแปลงตามฤดูกาล และได้รับผลจากปัจจัยด้านมลพิษทางอากาศและอุตุนิยมวิทยาหลายด้าน งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองพื้นฐานแบบจำลองการเรียนรู้ของเครื่อง แบบจำลองการเรียนรู้เชิงลึก และแบบจำลองลูกผสมฐาน Prophet สำหรับการพยากรณ์ปริมาณ PM2.5 รายวันในจังหวัดนครสวรรค์ โดยใช้ข้อมูลทุติยภูมิ ระหว่างเดือนมกราคม พ.ศ. 2563 ถึง ธันวาคม พ.ศ. 2568 โดยข้อมูลประกอบด้วย ปริมาณ PM2.5 และ ตัวแปรด้านมลพิษทางอากาศและอุตุนิยมวิทยา 10 ตัวแปร ซึ่งทำการแบ่งข้อมูลตามลำดับเวลาเป็น ชุดฝึกสอน ใช้ข้อมูลระหว่างปี พ.ศ. 2563–2566 ชุดตรวจสอบ ปี พ.ศ. 2567 และชุดทดสอบ ปี พ.ศ. 2568 การทดลองทำการประเมินผลการพยากรณ์ล่วงหน้า 1, 3 และ 7 วัน โดยเปรียบเทียบแบบจำลอง Persistence, Moving Average, Prophet, LSTM, GRU, XGBoost, Prophet-LSTM, Prophet-GRU และ Prophet-XGBoost ซึ่งพิจารณาจากค่า RMSE, MAE, MAPE และ R^2 รวมถึงการจำแนกวันที่ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร พบว่า GRU ให้ผลดีที่สุดในการพยากรณ์ล่วงหน้า 1 และ 3 วัน โดยมีค่า RMSE เท่ากับ 12.2476 และ 18.4001 ตามลำดับ ขณะที่ Prophet ให้ผลดีที่สุดในการพยากรณ์ล่วงหน้า 7 วัน โดยมีค่า RMSE เท่ากับ 20.5216 ผลการศึกษาแสดงให้เห็นว่าแบบจำลองที่เหมาะสมอาจแตกต่างกันตามระยะพยากรณ์ และการเปรียบเทียบหลายกลุ่มแบบจำลองช่วยให้เข้าใจข้อเด่นและข้อจำกัดของแต่ละวิธีได้ดีขึ้น สามารถนำไปใช้สนับสนุนการพัฒนาเครื่องมือพยากรณ์และระบบเฝ้าระวัง PM2.5 ในระดับพื้นที่ต่อไป

คำสำคัญ: ฝุ่นละออง PM2.5 การพยากรณ์อนุกรมเวลา การเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก
แบบจำลองลูกผสมฐาน Prophet

** Corresponding author: withoon@nsru.ac.th*

Abstract

Particulate matter with an aerodynamic diameter of less than 2.5 microns (PM_{2.5}) in Nakhon Sawan Province is an important environmental and public health issue. PM_{2.5} concentrations vary seasonally and are influenced by several air pollution and meteorological factors. This study aimed to compare the performance of baseline models, machine learning models, deep learning models, and Prophet-based hybrid models for daily PM_{2.5} forecasting in Nakhon Sawan Province. The study used secondary data collected from January 2020 to December 2025, consisting of PM_{2.5} concentrations and ten air pollution and meteorological variables. The data were divided chronologically into a training set from 2020 to 2023, a validation set from 2024, and a test set from 2025. Forecasting performance was evaluated for 1-, 3-, and 7-day-ahead horizons by comparing Persistence, Moving Average, Prophet, LSTM, GRU, XGBoost, Prophet-LSTM, Prophet-GRU, and Prophet-XGBoost models. The models were assessed using RMSE, MAE, MAPE, and R^2 , together with the classification of days when PM_{2.5} concentrations exceeded 50 $\mu\text{g}/\text{m}^3$. The results showed that GRU achieved the best performance for 1- and 3-day-ahead forecasting, with RMSE values of 12.2476 and 18.4001, respectively. In contrast, Prophet achieved the best performance for 7-day-ahead forecasting, with an RMSE of 20.5216. These findings indicate that the most suitable forecasting model may vary depending on the forecasting horizon. Comparing multiple groups of models provides a clearer understanding of the strengths and limitations of each approach. The findings can support the development of forecasting tools and local PM_{2.5} monitoring systems.

Keywords: PM_{2.5}, Time-Series Forecasting, Machine Learning, Deep Learning, Prophet-Based Hybrid Models

1. บทนำ

ปัญหามลพิษทางอากาศจากฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM_{2.5}) เป็นปัญหาด้านสิ่งแวดล้อมและสาธารณสุขที่สำคัญในหลายประเทศทั่วโลก เนื่องจากอนุภาคขนาดเล็กของ PM_{2.5} สามารถแทรกซึมเข้าสู่ระบบทางเดินหายใจและกระแสเลือด ก่อให้เกิดผลกระทบต่อระบบทางเดินหายใจ ระบบหัวใจและหลอดเลือด ตลอดจนเพิ่มความเสี่ยงต่อการเจ็บป่วยและการเสียชีวิตได้ องค์การอนามัยโลกจึงได้กำหนดแนวทางคุณภาพอากาศที่เข้มงวดขึ้นสำหรับ PM_{2.5} เพื่อคุ้มครองสุขภาพของประชาชน สะท้อนให้เห็นว่าปัญหาฝุ่นละอองขนาดเล็กเป็นสิ่งที่ควรได้รับการเฝ้าระวังและจัดการอย่างต่อเนื่อง (World Health Organization, 2021)

ในประเทศไทย โดยเฉพาะในพื้นที่ภาคเหนือตอนล่างและภาคกลางตอนบนอย่างจังหวัดนครสวรรค์ ซึ่งมีลักษณะภูมิประเทศเป็นที่ราบลุ่มและเป็นศูนย์กลางทางการเกษตร ปริมาณฝุ่นละอองจะมีความรุนแรงในช่วงฤดูแล้งและฤดูการเก็บเกี่ยว โดยมีที่มาจาก การเผาเศษวัสดุทางการเกษตร ประกอบกับสภาพอุตุนิยมวิทยาที่เอื้อต่อการสะสมของฝุ่นควัน การคาดการณ์แนวโน้มและปริมาณ PM2.5 ล่วงหน้าจึงมีความสำคัญต่อการบริหารจัดการและแจ้งเตือนประชาชน เพื่อลดผลกระทบทางสุขภาพที่อาจเกิดขึ้น

การพยากรณ์ค่าความเข้มข้นของ PM2.5 จึงเป็นเครื่องมือสำคัญในการสนับสนุนการบริหารจัดการคุณภาพอากาศ การแจ้งเตือนความเสี่ยง และการตัดสินใจเชิงนโยบายในระดับพื้นที่ โดยเฉพาะเมื่อข้อมูล PM2.5 มีลักษณะเป็นอนุกรมเวลาที่ได้รับอิทธิพลจากแนวโน้มระยะยาว ความเป็นฤดูกาล และความสัมพันธ์แบบไม่เชิงเส้นกับตัวแปรด้านอุตุนิยมวิทยาและมลพิษร่วม งานวิจัยที่ผ่านมาได้ประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมากขึ้น เนื่องจากสามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนระหว่างค่าฝุ่นตัวแปรมลพิษ และตัวแปรอุตุนิยมวิทยาได้ดี เช่น งานวิจัยของ Lei et al. (2023) ได้ประยุกต์ใช้ ANN, XGBoost และวิธีการเรียนรู้ของเครื่องอื่น ๆ เพื่อพยากรณ์คุณภาพอากาศในมาเก๊า Karimian et al. (2019) พบว่าแบบจำลอง LSTM สามารถให้ผลการพยากรณ์ PM2.5 ได้ดีกว่าวิธีการอื่น เนื่องจากสามารถเรียนรู้การพึ่งพากันเชิงเวลาได้ดี Huang and Kuo (2018), Li et al. (2020) และ Bai et al. (2024) แสดงให้เห็นถึงศักยภาพของแบบจำลองเชิงลึกและแบบจำลองลูกผสม CNN-LSTM ในการพยากรณ์ค่าฝุ่น PM2.5 ขณะที่ Abuouelezz et al. (2025) เปรียบเทียบแบบจำลองหลายชนิดสำหรับ PM2.5 และ PM10 โดยพบว่าประสิทธิภาพของแบบจำลองอาจแตกต่างกันไปตามช่วงเวลาการพยากรณ์ บริบทของข้อมูล และแบบจำลองที่ให้ผลดีในระยะสั้นอาจไม่ใช่แบบจำลองที่เหมาะสมที่สุดในระยะยาว ในส่วนของแบบจำลอง Prophet ซึ่งพัฒนาโดย Taylor และ Letham ได้รับความสนใจอย่างมากในงานพยากรณ์อนุกรมเวลา เนื่องจากสามารถแยกองค์ประกอบของข้อมูลออกเป็นแนวโน้ม ฤดูกาล และอิทธิพลของเหตุการณ์พิเศษได้อย่างยืดหยุ่น อีกทั้งยังอธิบายผลได้ง่าย (Taylor & Letham, 2018) นอกจากนี้ Shen et al. (2020) ได้นำแบบจำลอง Prophet มาใช้พยากรณ์ค่าความเข้มข้นของมลพิษทางอากาศหลายชนิดในกรุงโซล ได้แก่ PM2.5, PM10, O₃, NO₂, SO₂ และ CO ซึ่งสะท้อนว่า Prophet สามารถประยุกต์ใช้กับข้อมูลคุณภาพอากาศที่มีองค์ประกอบเชิงเวลาและฤดูกาลได้ ต่อมาแบบจำลองลูกผสม Prophet-LSTM จึงได้รับการนำเสนอเพื่อผสานจุดแข็งของทั้งสองวิธีเข้าด้วยกัน โดย Prophet ทำหน้าที่อธิบายโครงสร้างเชิงแนวโน้มและฤดูกาลของอนุกรมเวลา ส่วน LSTM ช่วยเรียนรู้ความผันผวนและความสัมพันธ์แบบไม่เชิงเส้นที่เหลืออยู่จากข้อมูล งานของ Cáceres-Tello และ Galán-Hernández ซึ่งศึกษาการพยากรณ์ PM2.5 ในกรุงมาดริด รายงานว่าแบบจำลอง Prophet-LSTM สามารถสะท้อนทั้งรูปแบบฤดูกาลและช่วงที่ค่ามลพิษพุ่งสูงได้อย่างมีประสิทธิภาพ และมีศักยภาพสำหรับการประยุกต์ใช้ในการจัดการคุณภาพอากาศในเขตเมือง (Cáceres-Tello & Galán-Hernández, 2024) ในด้านแบบจำลองลูกผสมอื่น ๆ งานของ Chang et al. (2023) เสนอการพยากรณ์คุณภาพอากาศที่ผสมผสาน W-BiLSTM(PSO)-GRU และ XGBoost เพื่อเพิ่มความแม่นยำและความเสถียรของการพยากรณ์ ขณะที่ Lee et al. (2025) ชี้ให้เห็นว่าประสิทธิภาพของแบบจำลองพยากรณ์ PM2.5 อาจเปลี่ยนไปตามระยะพยากรณ์

และเงื่อนไขของช่วงค่าฝุ่นสูง ดังนั้นการประเมินผลในหลายระยะพยากรณ์และการพิจารณาเหตุการณ์ค่าฝุ่นสูง จึงมีความสำคัญต่อการนำแบบจำลองไปใช้จริง ทั้งนี้แบบจำลองพื้นฐาน เช่น Persistence และ Moving Average ก็มีความสำคัญในฐานะเกณฑ์เปรียบเทียบ เนื่องจากข้อมูล PM2.5 รายวันมีความต่อเนื่องเชิงเวลา หากแบบจำลองที่ซับซ้อนไม่สามารถให้ผลดีกว่าแบบจำลองพื้นฐานได้อย่างชัดเจน การนำไปใช้จริงย่อมต้องพิจารณาถึงความแม่นยำ ความซับซ้อน และความเหมาะสมต่อบริบทของข้อมูล ในส่วนงานวิจัยที่ผ่านมาในพื้นที่จังหวัดนครสวรรค์ จะมุ่งเน้นการประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่องพื้นฐานเป็นหลัก เช่น Linear Regression, Artificial Neural Network และ Random Forest โดยวิฑูร สนิธิปัญญ และคณะ (2567) พบว่า Random Forest ให้ผลดีที่สุดในการพยากรณ์ PM2.5 รายวัน ซึ่งยังขาดการเปรียบเทียบแบบจำลองหลายกลุ่มภายใต้ข้อมูลที่ครอบคลุมช่วงเวลาที่ยาวขึ้น รวมถึงการประเมินผลในหลายระยะพยากรณ์

งานวิจัยนี้จึงมุ่งเปรียบเทียบประสิทธิภาพของแบบจำลองพื้นฐาน แบบจำลองการเรียนรู้ของเครื่องแบบจำลองการเรียนรู้เชิงลึก และแบบจำลองลูกผสมฐาน Prophet สำหรับการพยากรณ์ปริมาณ PM2.5 รายวัน ในจังหวัดนครสวรรค์ โดยใช้ข้อมูล PM2.5 ร่วมกับตัวแปรด้านมลพิษทางอากาศและอุตุนิยมวิทยาจำนวน 10 ตัวแปร ระหว่างปี พ.ศ. 2563–2568 และประเมินผลการพยากรณ์ล่วงหน้า 1, 3 และ 7 วัน เพื่อให้เห็นข้อเด่นและข้อจำกัดของแต่ละแบบจำลองอย่างรอบด้าน และสนับสนุนการพัฒนาเครื่องมือพยากรณ์และระบบเฝ้าระวังคุณภาพอากาศในระดับพื้นที่ต่อไป

2. วัตถุประสงค์การวิจัย

2.1 เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองพื้นฐาน แบบจำลองการเรียนรู้ของเครื่องแบบจำลองการเรียนรู้เชิงลึก และแบบจำลองลูกผสมฐาน Prophet สำหรับการพยากรณ์ปริมาณ PM2.5 รายวัน ในจังหวัดนครสวรรค์

2.2 เพื่อประเมินความสามารถของแบบจำลองในการพยากรณ์ PM2.5 ล่วงหน้า 1, 3 และ 7 วัน และการจำแนกวันที่มีปริมาณ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร เพื่อพิจารณาความเหมาะสมของแบบจำลองต่อการประยุกต์ใช้ในการเฝ้าระวังคุณภาพอากาศในระดับพื้นที่

3. วิธีดำเนินการวิจัย

การวิจัยนี้ออกแบบมาเพื่อพัฒนาแบบจำลองสำหรับการพยากรณ์ปริมาณฝุ่นละออง PM2.5 และดำเนินการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง โดยมีขั้นตอนการดำเนินงานวิจัยดังต่อไปนี้

3.1 การรวบรวมและการเตรียมข้อมูล (Data Collection and Preprocessing)

ข้อมูลที่ใช้ในการวิจัยเป็นข้อมูลทุติยภูมิแบบรายวัน ที่เก็บรวบรวมโดยสถานีตรวจคุณภาพอากาศในพื้นที่โครงการชลประทานนครสวรรค์ และสถานีอุตุนิยมวิทยานครสวรรค์ ระหว่างวันที่ 1 มกราคม พ.ศ. 2563 ถึงวันที่ 31 ธันวาคม พ.ศ. 2568 โดยประกอบด้วยข้อมูลปริมาณฝุ่นละออง PM2.5 และตัวแปรด้านมลพิษ

ทางอากาศและอุตุนิยมวิทยาจำนวน 10 ตัวแปร ได้แก่ ปริมาณฝุ่นละออง PM10 ก๊าซคาร์บอนมอนอกไซด์ (CO) ไนโตรเจนไดออกไซด์ (NO₂) ก๊าซซัลเฟอร์ไดออกไซด์ (SO₂) ก๊าซโอโซน (O₃) ปริมาณฝน (RAIN) อุณหภูมิ (TEMPERATURE) ความชื้นสัมพัทธ์ (RH) ความกดอากาศเฉลี่ยที่ระดับผิวพื้น (SP) และ ความเร็วลม (SI)

ในการจัดเตรียมข้อมูล เริ่มจากการตรวจสอบรูปแบบวันที่ การเรียงลำดับข้อมูลตามเวลา และการตรวจสอบความครบถ้วนของข้อมูลรายวันตลอดช่วงเวลาที่ศึกษา จากนั้นจัดทำชุดข้อมูลให้อยู่ในรูปแบบรายวันต่อเนื่อง เพื่อให้เหมาะสมกับการวิเคราะห์อนุกรมเวลา กรณีพบข้อมูลสูญหาย ผู้วิจัยดำเนินการตามการจัดการข้อมูลสูญหาย โดยหากข้อมูลสูญหายเป็นช่องว่างระยะสั้น จะถูกเติมด้วยวิธีการประมาณค่าเชิงเส้น (linear interpolation) ส่วนช่องว่างระยะยาว จะถูกเติมด้วยค่ามัธยฐานรายเดือนจากข้อมูลย้อนหลัง เพื่อหลีกเลี่ยงการใช้ค่าก่อนหน้าหรือค่าถัดไปต่อเนื่องเป็นระยะเวลานาน

ภายหลังการทำความสะอาดข้อมูล ชุดข้อมูลจะถูกแบ่งออกตามลำดับเวลาเป็น 3 ส่วน ได้แก่ ชุดฝึกสอน (training set) ใช้ข้อมูลปี พ.ศ. 2563–2566 ชุดตรวจสอบ (validation set) ใช้ข้อมูลปี พ.ศ. 2567 และชุดทดสอบ (test set) ใช้ข้อมูลปี พ.ศ. 2568 การแบ่งข้อมูลตามลำดับเวลาดังกล่าว มีวัตถุประสงค์เพื่อให้สอดคล้องกับลักษณะของการพยากรณ์อนุกรมเวลาและลดความเสี่ยงจากการรั่วไหลของข้อมูลในอนาคตไปยังขั้นตอนการฝึกแบบจำลอง สำหรับแบบจำลองการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ข้อมูลนำเข้าถูกจัดให้อยู่ในรูปแบบหน้าต่างเวลา (sliding window) และปรับมาตรฐานของตัวแปรโดยใช้ค่าพารามิเตอร์ที่คำนวณจากชุดฝึกสอนเท่านั้น ก่อนนำไปใช้กับชุดตรวจสอบและชุดทดสอบ

3.2 แบบจำลองที่ใช้ในการวิจัย (Models Used in the Study)

การวิจัยนี้เปรียบเทียบแบบจำลองหลายกลุ่มสำหรับการพยากรณ์ปริมาณ PM2.5 รายวันในจังหวัดนครสวรรค์ เพื่อให้เห็นความแตกต่างของประสิทธิภาพระหว่างแบบจำลองที่มีระดับความซับซ้อนต่างกัน โดยแบบจำลองที่ใช้ในการทดลองประกอบด้วย 4 กลุ่ม ได้แก่ แบบจำลองพื้นฐาน แบบจำลองการเรียนรู้ของเครื่อง แบบจำลองการเรียนรู้เชิงลึก และแบบจำลองลูกผสมฐาน Prophet

3.2.1 แบบจำลองพื้นฐาน (Baseline)

แบบจำลองพื้นฐานที่ใช้ในงานวิจัยนี้ ประกอบด้วย

แบบจำลองความคงทน (Persistence Model) แนวคิดหลักของแบบจำลองนี้คือ การพยากรณ์ว่าเหตุการณ์หรือค่าในอนาคตจะมีค่าเท่ากับค่าล่าสุด ณ ขณะปัจจุบันเสมอ โดยสมมติว่าสภาวะแวดล้อมจะไม่เปลี่ยนแปลงไปจากเดิม ซึ่งในงานวิจัยนี้ใช้ค่าล่าสุดของ PM2.5 เป็นค่าพยากรณ์สำหรับอนาคต เหมาะสำหรับใช้เป็นเกณฑ์เปรียบเทียบเบื้องต้น เนื่องจากข้อมูล PM2.5 รายวันมักมีความต่อเนื่องเชิงเวลา

ค่าเฉลี่ยเคลื่อนที่ (Moving Average) เครื่องมือทางสถิติที่ใช้ในการวิเคราะห์ข้อมูลอนุกรมเวลา (Time Series) โดยนำข้อมูลในอดีตมาหาค่าเฉลี่ยเพื่อปรับระดับข้อมูลให้เรียบขึ้น ลดความผันผวน ใช้ทำนายข้อมูลในอนาคต เช่น การพยากรณ์ยอดขาย ปริมาณความต้องการสินค้าคงคลัง หรือสภาพอากาศ จัดเป็นแบบจำลองพื้นฐานที่ใช้เปรียบเทียบกับแบบจำลองที่ซับซ้อนกว่า

3.2.2 แบบจำลองการเรียนรู้ของเครื่อง (Machine Learning Models)

แบบจำลอง Extreme Gradient Boosting (XGBoost) เป็นอัลกอริทึมการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูง พัฒนาขึ้นโดย Tianqi Chen ในปี 2016 XGBoost เป็นการพัฒนาต่อยอดจากเทคนิค Gradient Boosting โดยเพิ่มประสิทธิภาพในด้านความเร็วและความแม่นยำ แนวคิดหลักของ XGBoost คือการสร้างชุดของแบบจำลองอ่อนแอ (weak learners) ซึ่งส่วนใหญ่เป็นต้นไม้ตัดสินใจ (decision trees) แบบตื้น แล้วรวมผลการทำนายของแบบจำลองเหล่านี้เข้าด้วยกันเพื่อสร้างแบบจำลองที่แข็งแกร่ง โดยในแต่ละรอบของการเรียนรู้ XGBoost จะสร้างต้นไม้ใหม่เพื่อทำนายค่าความคลาดเคลื่อน (residuals) ของแบบจำลองในรอบก่อนหน้า (Chen & Guestrin, 2016) ในงานวิจัยนี้ แบบจำลอง XGBoost ใช้ข้อมูล PM2.5 ย้อนหลังร่วมกับตัวแปรด้านมลพิษทางอากาศและอุตุนิยมวิทยา เพื่อพยากรณ์ค่าความเข้มข้นของ PM2.5 ในระยะล่วงหน้าที่กำหนด

3.2.3 แบบจำลองการเรียนรู้เชิงลึก (Deep Learning Models)

แบบจำลองหน่วยความจำระยะสั้นแบบยาว หรือ Long Short-Term Memory (LSTM) เป็นโครงข่ายประสาทเทียมแบบเวียนกลับ (Recurrent Neural Network: RNN) ที่ถูกพัฒนาขึ้นเพื่อแก้ปัญหาการเรียนรู้ข้อมูลลำดับเวลาที่มีความสัมพันธ์ต่อเนื่องกันในระยะยาว โดย LSTM มีความสามารถในการจดจำข้อมูลสำคัญและลดผลกระทบจากปัญหาการเลือนหายของกราเดียนต์ จึงเหมาะสำหรับการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลา เช่น ข้อมูล PM2.5 ซึ่งมีความผันผวนตามเวลาและได้รับอิทธิพลจากหลายปัจจัยร่วมกัน โครงสร้างการทำงานของ LSTM ประกอบด้วยหน่วยควบคุมสำคัญ ได้แก่ ประตูรับข้อมูลเข้า (input gate) ประตูลืมข้อมูล (forget gate) และประตูส่งออก (output gate) ซึ่งทำหน้าที่ควบคุมการเก็บรักษา การปรับปรุง และการส่งต่อข้อมูลภายในหน่วยความจำของโครงข่าย โดยกระบวนการคำนวณของ LSTM สามารถอธิบายได้ดังสมการต่อไปนี้ (Hochreiter & Schmidhuber, 1997)

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$

โดยที่	x_t	คือ ข้อมูลนำเข้า ณ เวลา t
	h_{t-1}	คือ สถานะซ่อนของช่วงเวลาก่อนหน้า
	C_t	คือ สถานะเซลล์ ณ เวลา t
	f_t	คือ ประตูลืมข้อมูล (forget gate)
	i_t	คือ ประตูรับข้อมูลเข้า (input gate)
	o_t	คือ ประตูส่งออก (output gate)
	$\tilde{C}_t$	คือ ค่าผู้สมัครของสถานะเซลล์

- W คือ ค่าน้ำหนัก
 b คือ ค่าคงที่ของแบบจำลอง
 σ คือ ฟังก์ชันกระตุ้นแบบซิกมอยด์

ในการสร้างแบบจำลอง LSTM สำหรับงานวิจัยนี้ ผู้วิจัยกำหนดให้ข้อมูลลำดับเวลาก่อนหน้าและตัวแปรร่วมทั้ง 10 ตัวแปรเป็นข้อมูลนำเข้า เพื่อให้แบบจำลองสามารถเรียนรู้ผลกระทบของปัจจัยด้านมลพิษทางอากาศและอุตุนิยมวิทยาที่มีต่อการเปลี่ยนแปลงของ PM2.5 ได้อย่างมีประสิทธิภาพ

แบบจำลองโครงข่ายประตูกกกลับ (Gated Recurrent Unit: GRU) เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบเวียนกลับ (RNN) เสนอโดย Cho et al. (2014) ที่ออกแบบมาสำหรับข้อมูลแบบลำดับเวลา (Sequential Data) เช่น การแปลภาษา หรือการพยากรณ์ ช่วยลดปัญหาการเลือนหายของกราเดียนต์ จุดเด่นของแบบจำลอง GRU คือมีโครงสร้างที่เล็กกว่าและมีจำนวนพารามิเตอร์น้อยกว่าแบบจำลอง LSTM ส่งผลให้ใช้เวลาในการฝึกฝนข้อมูลจากตัวอย่างเร็วกว่าแบบจำลอง LSTM โดยมีหลักการคำนวณคล้ายกับแบบจำลอง LSTM คือการใช้ประตูในการถ่วงน้ำหนักการส่งสัญญาณ

3.2.4 แบบจำลอง Prophet และแบบจำลองลูกผสมฐาน Prophet

แบบจำลอง Prophet เป็นแบบจำลองอนุกรมเวลาที่พัฒนาเพื่อใช้กับข้อมูลที่มีองค์ประกอบของแนวโน้ม (trend) และฤดูกาล (seasonality) เหมาะสำหรับข้อมูลที่มีรูปแบบการเปลี่ยนแปลงตามเวลาอย่างต่อเนื่องและอาจมีความผันผวนในบางช่วง แบบจำลองสามารถเขียนได้ในลักษณะทั่วไปดังนี้ (Taylor & Letham, 2018)

$$y(t) = g(t) + s(t) + \varepsilon_t \quad (7)$$

โดยที่ $y(t)$ คือ ค่าความเข้มข้นของ PM2.5 ณ เวลา t

$g(t)$ คือ องค์ประกอบแนวโน้มของข้อมูล

$s(t)$ คือ องค์ประกอบฤดูกาล

ε_t คือ ค่าความคลาดเคลื่อนที่เหลือจากแบบจำลอง

งานวิจัยนี้แบบจำลอง Prophet ใช้เพื่อเรียนรู้องค์ประกอบเชิงแนวโน้มและฤดูกาลของอนุกรมเวลา PM2.5 จากนั้นจึงพัฒนาแบบจำลองลูกผสม ได้แก่ Prophet-LSTM, Prophet-GRU และ Prophet-XGBoost โดยให้ Prophet สร้างค่าพยากรณ์พื้นฐานก่อน แล้วคำนวณค่าคลาดเคลื่อนคงเหลือระหว่างค่าจริงกับค่าพยากรณ์จาก Prophet จากนั้นนำค่าคลาดเคลื่อนดังกล่าวไปให้ LSTM, GRU หรือ XGBoost เรียนรู้เพิ่มเติม เพื่อให้แบบจำลองลูกผสมสามารถอธิบายส่วนที่ Prophet ยังไม่สามารถจับได้อย่างสมบูรณ์ หลักการของแบบจำลองลูกผสมสามารถเขียนได้โดยสรุปดังนี้

ค่าคลาดเคลื่อนคงเหลือคำนวณจาก

$$r_t = y_t - \hat{y}_t^{Prophet} \quad (8)$$

และค่าพยากรณ์สุดท้ายของแบบจำลองลูกผสมคำนวณจาก

$$\hat{y}_t^{Hybrid} = \hat{y}_t^{Prophet} + \hat{r}_t^{Model} \quad (9)$$

โดยที่ y_t คือ ค่าจริงของ PM2.5

$\hat{y}_t^{Prophet}$ คือ ค่าที่พยากรณ์ได้จากแบบจำลอง Prophet

r_t คือ ค่าคลาดเคลื่อนคงเหลือ ณ เวลา t

$\hat{r}_t^{Model}$ คือ ค่าคลาดเคลื่อนที่พยากรณ์ได้จาก LSTM, GRU หรือ XGBoost
ตามชนิดของแบบจำลองลูกผสม

เพื่อให้การทดลองสามารถตรวจสอบและทำซ้ำได้ งานวิจัยนี้กำหนดค่าพารามิเตอร์เริ่มต้นของแบบจำลอง ดังแสดงในตารางที่ 1

ตารางที่ 1 ค่าพารามิเตอร์เริ่มต้นของแบบจำลองที่ใช้ในการทดลอง

แบบจำลอง	ค่าพารามิเตอร์เริ่มต้นที่ใช้ในการทดลอง
Persistence	ใช้ค่าล่าสุดของ PM2.5 เป็นค่าพยากรณ์ในระยะล่วงหน้าที่กำหนด ไม่มีการกำหนดพารามิเตอร์เพิ่มเติม
Moving Average	ใช้ค่าเฉลี่ยของ PM2.5 ย้อนหลังตามขนาดหน้าต่างเวลา (sliding window) ที่กำหนด ไม่มีการฝึกพารามิเตอร์
Prophet	changepoint prior scale = 0.05, seasonality prior scale = 10.0, seasonality mode = additive, daily seasonality = False, weekly seasonality = True, yearly seasonality = True
LSTM	hidden units = 64, dropout = 0.20, optimizer = Adam, learning rate = 0.001, loss function = MSE, batch size = 32, maximum epochs = 200, early stopping patience = 20
GRU	hidden units = 64, dropout = 0.20, optimizer = Adam, learning rate = 0.001, loss function = MSE, batch size = 32, maximum epochs = 200, early stopping patience = 20
XGBoost	objective = reg: squared error, n estimators = 600, learning rate = 0.03, max depth = 3, subsample = 0.90, col sample by tree = 0.90
Prophet-LSTM	ใช้ Prophet สร้างค่าพยากรณ์พื้นฐานก่อน จากนั้นคำนวณ residual และใช้ LSTM เรียนรู้ residual โดยใช้ค่าพารามิเตอร์ของ Prophet และ LSTM ตามที่ระบุข้างต้น

ตารางที่ 1 ค่าพารามิเตอร์เริ่มต้นของแบบจำลองที่ใช้ในการทดลอง (ต่อ)

แบบจำลอง	ค่าพารามิเตอร์เริ่มต้นที่ใช้ในการทดลอง
Prophet-GRU	ใช้ Prophet สร้างค่าพยากรณ์พื้นฐานก่อน จากนั้นคำนวณ residual และใช้ GRU เรียนรู้ residual โดยใช้ค่าพารามิเตอร์ของ Prophet และ GRU ตามที่ระบุข้างต้น
Prophet-XGBoost	ใช้ Prophet สร้างค่าพยากรณ์พื้นฐานก่อน จากนั้นคำนวณ residual และใช้ XGBoost เรียนรู้ residual โดยใช้ค่าพารามิเตอร์ของ Prophet และ XGBoost ตามที่ระบุข้างต้น
Sliding window	ทดสอบขนาดหน้าต่างข้อมูลย้อนหลัง 3, 5, 7 และ 14 วัน และเลือกค่าที่ให้ RMSE ต่ำที่สุดบนชุดตรวจสอบ
การพยากรณ์ด้วย Prophet บนชุดทดสอบ	ใช้วิธี rolling prediction โดยฝึก Prophet ตามข้อมูลที่มีถึงวันต้นทางของการพยากรณ์
การทดลองซ้ำ	แบบจำลองที่มีองค์ประกอบเชิงสุ่มทดลองซ้ำ 30 ครั้ง และรายงานผลเป็นค่าเฉลี่ย $\pm$ ส่วนเบี่ยงเบนมาตรฐาน

3.3 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลองในการวิจัยนี้ ใช้ชุดทดสอบปี พ.ศ. 2568 โดยพิจารณาการพยากรณ์ล่วงหน้า 3 ระยะ ได้แก่ 1 วัน 3 วัน และ 7 วัน เพื่อเปรียบเทียบความสามารถของแบบจำลองภายใต้ระยะพยากรณ์ที่แตกต่างกัน การประเมินผลแบ่งออกเป็นสองส่วนหลัก ได้แก่ การประเมินความแม่นยำของค่าพยากรณ์ PM2.5 แบบต่อเนื่อง และการประเมินความสามารถในการจำแนกวันที่มีปริมาณ PM2.5 เกินเกณฑ์ที่กำหนด โดยใช้เกณฑ์ในการประเมินประกอบด้วย 4 ค่า ได้แก่ ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) และค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R^2) โดย RMSE, MAE และ MAPE ที่มีค่าต่ำแสดงถึงความสามารถของแบบจำลองที่น้อยกว่า ส่วนค่า R^2 ที่สูงกว่าแสดงถึงความสามารถของแบบจำลองในการอธิบายความแปรปรวนของข้อมูลได้ดีกว่า โดยสามารถคำนวณได้จากสมการดังนี้

$$RMSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (10)$$

ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) สามารถคำนวณได้จากสมการดังนี้

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (11)$$

ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) สามารถคำนวณได้จากสมการดังนี้

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100}{n} \quad (12)$$

ค่าสัมประสิทธิ์การตัดสินใจ (R^2) สามารถคำนวณได้จากสมการดังนี้

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (13)$$

โดยที่	y_i	คือ ค่าจริงของ PM2.5
	$\hat{y}_i$	คือ ค่าที่พยากรณ์ได้จากแบบจำลอง
	$\bar{y}$	คือ ค่าเฉลี่ยของค่าจริง
	n	คือ จำนวนข้อมูลในชุดทดสอบ

นอกจากการประเมินค่าพยากรณ์แบบต่อเนื่องแล้ว งานวิจัยนี้ยังประเมินความสามารถของแบบจำลองในการจำแนกวันที่มีปริมาณ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร ซึ่งจะมีคุณภาพอากาศที่เริ่มมีผลกระทบต่อสุขภาพของมนุษย์ ตามเกณฑ์ปริมาณฝุ่น PM 2.5 ของประเทศไทย ที่กำหนดมาตรฐานดัชนีคุณภาพอากาศ (AQI) ไว้ว่า หาก ค่า AQI 101 ถึง 200 หรือ ปริมาณฝุ่น 51 ถึง 75 ไมโครกรัมต่อลูกบาศก์เมตร จะถูกกำหนดสีสัญลักษณ์ เป็น สีส้ม คุณภาพอากาศ เริ่มมีผลกระทบต่อสุขภาพ ประชาชนทั่วไปควรลดเวลากลางแจ้ง โดยดำเนินการแปลงค่าจริงและค่าพยากรณ์ให้อยู่ในรูปกลุ่มสองประเภท ได้แก่ วันที่ไม่เกินเกณฑ์และวันที่เกินเกณฑ์ จากนั้นประเมินด้วยค่า Precision, Recall และ F1-score เพื่อสะท้อนความเหมาะสมของแบบจำลองต่อการประยุกต์ใช้ในบริบทของการเฝ้าระวังคุณภาพอากาศ โดยคำนวณได้ดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1-score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (16)$$

โดยที่	TP	คือ จำนวนวันที่แบบจำลองพยากรณ์ว่าเกินเกณฑ์และค่าจริงเกินเกณฑ์
	FP	คือ จำนวนวันที่แบบจำลองพยากรณ์ว่าเกินเกณฑ์แต่ค่าจริงไม่เกินเกณฑ์
	FN	คือ จำนวนวันที่แบบจำลองพยากรณ์ว่าไม่เกินเกณฑ์แต่ค่าจริงเกินเกณฑ์

เพื่อเพิ่มความน่าเชื่อถือของผลการทดลอง แบบจำลองที่มีองค์ประกอบเชิงซ้อน เช่น LSTM, GRU และแบบจำลองลูกผสมที่เกี่ยวข้อง ถูกทดลองซ้ำจำนวน 30 ครั้ง และรายงานผลในรูปค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน นอกจากนี้ยังใช้การทดสอบ Diebold-Mariano เพื่อเปรียบเทียบความแตกต่างของความแม่นยำระหว่างแบบจำลอง โดยพิจารณาจากค่าความคลาดเคลื่อนกำลังสองของแบบจำลองที่นำมาเปรียบเทียบ

4. ผลการวิจัย

ผลการวิจัยแบ่งออกเป็น 4 ส่วน ได้แก่ ผลการวิเคราะห์ข้อมูลเบื้องต้น ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองในการพยากรณ์ปริมาณ PM2.5 ผลการจำแนกวันที่มีปริมาณ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร และผลการทดสอบความแตกต่างของความแม่นยำระหว่างแบบจำลอง โดยประเมินผลบนชุดทดสอบปี พ.ศ. 2568 ภายใต้ระยะพยากรณ์ล่วงหน้า 1, 3 และ 7 วัน


4.1 ผลการวิเคราะห์ข้อมูลเบื้องต้น

ข้อมูลรายวันของปริมาณฝุ่นละออง PM2.5 ในจังหวัดนครสวรรค์ และตัวแปรร่วมด้านมลพิษทางอากาศและอุตุนิยมวิทยาจำนวน 10 ตัวแปร จากการตรวจสอบลักษณะทั่วไปของข้อมูลพบว่า ข้อมูล PM2.5 มีการเปลี่ยนแปลงตามช่วงเวลาอย่างชัดเจน และมีความผันผวนในแต่ละวันค่อนข้างสูง โดยในบางช่วงเวลาปรากฏค่าที่เพิ่มสูงขึ้นอย่างเด่นชัด สะท้อนให้เห็นว่าข้อมูลดังกล่าวมีลักษณะเป็นอนุกรมเวลาที่ไม่คงที่ และอาจได้รับอิทธิพลจากทั้งปัจจัยเชิงฤดูกาลและปัจจัยแวดล้อมอื่นร่วมกัน เมื่อพิจารณาแนวโน้มของข้อมูลตลอดช่วงเวลาศึกษา พบว่าค่าความเข้มข้นของ PM2.5 มีลักษณะขึ้นลงเป็นช่วง ๆ และมีแนวโน้มเกิดค่าสูงในบางฤดูกาลมากกว่าช่วงอื่น ซึ่งเป็นตามลักษณะของปัญหามลพิษทางอากาศในประเทศไทยที่จะมีความรุนแรงขึ้นในช่วงฤดูแล้งและช่วงที่สภาพบรรยากาศเอื้อต่อการสะสมของฝุ่นละออง โดยข้อมูลเบื้องต้นแสดงในตารางที่ 2

ตารางที่ 2 ค่าสถิติเบื้องต้นของตัวแปรที่ใช้ในการวิจัย

ตัวแปร	ค่าเฉลี่ย	ค่าสูงสุด	ค่าต่ำสุด	ส่วนเบี่ยงเบนมาตรฐาน
PM2.5	70.89	167	10	33.19
PM10	47.25	284	1.12	25.55
ก๊าซคาร์บอนมอนอกไซด์ (CO)	0.99	2.54	0.2	0.28
ไนโตรเจนไดออกไซด์ (NO ₂)	6.44	40	1	4.28
ก๊าซซัลเฟอร์ไดออกไซด์ (SO ₂)	1.22	14	0	0.77
ก๊าซโอโซน (O ₃)	16.07	61	1	5.39
ปริมาณฝน (RAIN)	3.47	109	0	10.76
อุณหภูมิ (TEMPERATURE)	28.65	36	19	2.73
ความชื้นสัมพัทธ์ (RH)	73.59	98	48	9.88
ความกดอากาศเฉลี่ยที่ระดับผิวพื้น (SP)	1005.39	1016.2	997.3	3.45
ความเร็วลม (SI)	5.51	25	0.86	4.03

เมื่อพิจารณารูปแบบอนุกรมเวลา พบว่าค่าความเข้มข้นของ PM2.5 มีรูปแบบการแกว่งตัวขึ้นลงต่อเนื่อง และมีช่วงที่เกิดค่าสูงผิดปกติบางระยะ ซึ่งเป็นลักษณะที่บ่งชี้ว่าข้อมูลมีทั้งองค์ประกอบของแนวโน้ม ฤดูกาล และความผันผวนระยะสั้น แสดงในภาพที่ 1



ภาพที่ 1 อนุกรมเวลาของค่าความเข้มข้น PM2.5 รายวันในจังหวัดนครสวรรค์

4.2 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองในการพยากรณ์ PM2.5

ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 9 วิธี ได้แก่ Persistence, Moving Average, Prophet, LSTM, GRU, XGBoost, Prophet-LSTM, Prophet-GRU และ Prophet-XGBoost แสดงให้เห็นว่าแบบจำลองที่ให้ผลดีที่สุดแตกต่างกันตามระยะพยากรณ์ล่วงหน้า โดยการพยากรณ์ล่วงหน้า 1 วัน แบบจำลอง GRU ให้ค่า RMSE ต่ำที่สุดเท่ากับ 12.2476 ± 0.3372 ค่า MAE เท่ากับ 9.0176 ± 0.2833 ค่า MAPE เท่ากับ 17.5351 ± 0.7005 และค่า R^2 เท่ากับ 0.8629 ± 0.0076 รองลงมาคือแบบจำลอง Persistence ซึ่งมีค่า RMSE เท่ากับ 12.3949 และค่า R^2 เท่ากับ 0.8597 แสดงให้เห็นว่า GRU สามารถเรียนรู้รูปแบบการเปลี่ยนแปลงระยะสั้นของ PM2.5 ได้ดี ขณะเดียวกันแบบจำลองพื้นฐานอย่าง Persistence ยังคงให้ผลที่ใกล้เคียงมาก เนื่องจากข้อมูล PM2.5 รายวันมีความต่อเนื่องเชิงเวลา ดังแสดงในตารางที่ 3

ตารางที่ 3 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองในการพยากรณ์ PM2.5 บนชุดทดสอบปี พ.ศ. 2568 ระยะพยากรณ์ล่วงหน้า 1 วัน

Model	RMSE	MAE	MAPE	R^2
GRU	12.2476 ± 0.3372	9.0176 ± 0.2833	17.5351 ± 0.7005	0.8629 ± 0.0076
LSTM	12.6661 ± 0.3792	9.5133 ± 0.3184	18.7838 ± 0.8027	0.8534 ± 0.0089
Moving Average	15.1226 ± 0.0000	10.6142 ± 0.0000	18.6953 ± 0.0000	0.7912 ± 0.0000
Persistence	12.3949 ± 0.0000	8.6685 ± 0.0000	15.8620 ± 0.0000	0.8597 ± 0.0000
Prophet	19.6419 ± 0.0000	14.3206 ± 0.0000	26.7970 ± 0.0000	0.6477 ± 0.0000
Prophet-GRU	16.5676 ± 0.4159	12.2736 ± 0.3020	22.7544 ± 0.6596	0.7492 ± 0.0126
Prophet-LSTM	16.4704 ± 0.2704	12.1451 ± 0.2152	22.5683 ± 0.4669	0.7522 ± 0.0082
Prophet-XGBoost	16.5489 ± 0.0811	12.3140 ± 0.0656	22.7738 ± 0.1313	0.7499 ± 0.0025
XGBoost	13.2157 ± 0.0950	9.8191 ± 0.0756	18.6711 ± 0.1689	0.8405 ± 0.0023

การพยากรณ์ล่วงหน้า 3 วัน แบบจำลอง GRU ให้ผลดีที่สุด โดยมีค่า RMSE เท่ากับ 18.4001 ± 0.5077 ค่า MAE เท่ากับ 13.7304 ± 0.4899 ค่า MAPE เท่ากับ 27.5691 ± 1.4027 และค่า R^2 เท่ากับ 0.6906 ± 0.0172 รองลงมาคือแบบจำลอง LSTM ซึ่งมีค่า RMSE เท่ากับ 18.5919 ± 0.5494 และค่า R^2 เท่ากับ 0.6841 ± 0.0189 แสดงให้เห็นว่าแบบจำลองการเรียนรู้เชิงลึกที่ออกแบบมาสำหรับข้อมูลลำดับเวลา โดยเฉพาะ GRU และ LSTM มีความเหมาะสมกับการพยากรณ์ PM2.5 ในระยะสั้นถึงระยะกลาง ดังแสดงในตารางที่ 4

ตารางที่ 4 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองในการพยากรณ์ PM2.5 บนชุดทดสอบปี พ.ศ. 2568
ระยะพยากรณ์ล่วงหน้า 3 วัน

Model	RMSE	MAE	MAPE	R^2
GRU	18.4001 ± 0.5077	13.7304 ± 0.4899	27.5691 ± 1.4027	0.6906 ± 0.0172
LSTM	18.5919 ± 0.5494	13.9059 ± 0.5439	28.1375 ± 1.3793	0.6841 ± 0.0189
Moving Average	20.1420 ± 0.0000	14.3785 ± 0.0000	24.8422 ± 0.0000	0.6295 ± 0.0000
Persistence	20.7080 ± 0.0000	14.6342 ± 0.0000	25.5844 ± 0.0000	0.6084 ± 0.0000
Prophet	20.0806 ± 0.0000	14.6526 ± 0.0000	27.4027 ± 0.0000	0.6318 ± 0.0000
Prophet-GRU	20.3053 ± 0.2738	14.6417 ± 0.1980	27.2611 ± 0.5502	0.6234 ± 0.0102
Prophet-LSTM	20.4511 ± 0.1600	14.7827 ± 0.1370	27.5563 ± 0.3740	0.6181 ± 0.0060
Prophet-XGBoost	21.4453 ± 0.0911	15.7499 ± 0.0791	28.4664 ± 0.1648	0.5800 ± 0.0036
XGBoost	20.3815 ± 0.1317	15.3027 ± 0.1089	30.1461 ± 0.2602	0.6207 ± 0.0049


การพยากรณ์ล่วงหน้า 7 วัน แบบจำลอง Prophet ให้ค่า RMSE ต่ำที่สุดเท่ากับ 20.5216 ค่า MAE เท่ากับ 14.9815 ค่า MAPE เท่ากับ 28.0974 และค่า R^2 เท่ากับ 0.6154 รองลงมาคือ GRU และ LSTM โดยมีค่า RMSE เท่ากับ 21.2340 ± 0.4968 และ 21.3556 ± 0.4114 ตามลำดับ ผลดังกล่าวชี้ให้เห็นว่า เมื่อระยะพยากรณ์ยาวขึ้น แบบจำลอง Prophet ซึ่งเน้นการอธิบายแนวโน้มและฤดูกาลของอนุกรมเวลา สามารถให้ผลที่เหมาะสมกว่าแบบจำลองอื่น ดังแสดงในตารางที่ 5

ตารางที่ 5 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองในการพยากรณ์ PM_{2.5} บนชุดทดสอบปี พ.ศ. 2568
ระยะพยากรณ์ล่วงหน้า 7 วัน

Model	RMSE	MAE	MAPE	R^2
GRU	21.2340 ± 0.4968	16.6394 ± 0.7174	33.6929 ± 2.0954	0.5881 ± 0.0194
LSTM	21.3556 ± 0.4114	16.5193 ± 0.5840	33.0285 ± 1.6674	0.5834 ± 0.0160
Moving Average	23.5394 ± 0.0000	16.7055 ± 0.0000	28.0147 ± 0.0000	0.4940 ± 0.0000
Persistence	24.1772 ± 0.0000	17.0562 ± 0.0000	28.7352 ± 0.0000	0.4662 ± 0.0000
Prophet	20.5216 ± 0.0000	14.9815 ± 0.0000	28.0974 ± 0.0000	0.6154 ± 0.0000
Prophet-GRU	21.4530 ± 0.2689	15.6439 ± 0.2380	29.5231 ± 0.7158	0.5797 ± 0.0106
Prophet-LSTM	21.4255 ± 0.2449	15.5929 ± 0.1731	29.2745 ± 0.4995	0.5808 ± 0.0096
Prophet-XGBoost	22.2340 ± 0.1167	16.4052 ± 0.0844	30.4888 ± 0.1529	0.5486 ± 0.0047
XGBoost	22.4313 ± 0.1200	17.5072 ± 0.1091	35.7828 ± 0.2719	0.5405 ± 0.0049

สรุปได้ว่าไม่มีแบบจำลองใดให้ผลดีที่สุดในทุกระยะพยากรณ์ แบบจำลอง GRU เหมาะสมกับการพยากรณ์ล่วงหน้า 1 และ 3 วัน ขณะที่ Prophet เหมาะสมกับการพยากรณ์ล่วงหน้า 7 วัน ส่วนแบบจำลองลูกผสมฐาน Prophet ให้ผลอยู่ในระดับใกล้เคียงกับแบบจำลองอื่นในบางกรณี แต่ไม่ได้ให้ค่า RMSE ต่ำที่สุดเมื่อเทียบกับแบบจำลองเดี่ยว


เมื่อพิจารณากราฟเปรียบเทียบค่าจริงและค่าพยากรณ์ของแบบจำลอง 3 อันดับแรกที่คัดเลือกจากค่า RMSE ต่ำที่สุด โดยภาพที่ 2 แสดงผลการพยากรณ์ล่วงหน้า 1 วัน ซึ่งประกอบด้วยแบบจำลอง GRU, Persistence และ LSTM



ภาพที่ 2 ค่าจริงและค่าพยากรณ์ PM_{2.5} ของแบบจำลอง 3 อันดับแรกในระยะพยากรณ์ล่วงหน้า 1 วัน

จากภาพที่ 2 พบว่าแบบจำลองทั้งสามสามารถติดตามแนวโน้มของค่า PM2.5 รายวันได้ดี โดยเฉพาะในช่วงที่ค่าฝุ่นมีการเปลี่ยนแปลงต่อเนื่อง อย่างไรก็ตาม ในช่วงที่เกิดค่าสูงเฉียบพลัน แบบจำลองยังมีแนวโน้มประเมินค่าต่ำกว่าค่าจริงบางช่วง ผลดังกล่าวสอดคล้องกับค่าตัวชี้วัดในตารางที่ 3 ซึ่งแสดงว่า GRU ให้ค่า RMSE ต่ำที่สุดในการพยากรณ์ล่วงหน้า 1 วัน ขณะที่ Persistence และ LSTM ให้ผลใกล้เคียงกัน


ภาพที่ 3 แสดงค่าจริงและค่าพยากรณ์ของแบบจำลอง 3 อันดับแรกในระยะพยากรณ์ล่วงหน้า 3 วัน ได้แก่ GRU, LSTM และ Prophet เพื่อพิจารณาความสามารถของแบบจำลองในการติดตามแนวโน้มของ PM2.5 เมื่อระยะพยากรณ์เพิ่มขึ้นจาก 1 วันเป็น 3 วัน



ภาพที่ 3 ค่าจริงและค่าพยากรณ์ PM2.5 ของแบบจำลอง 3 อันดับแรกในระยะพยากรณ์ล่วงหน้า 3 วัน

จากภาพที่ 3 จะเห็นได้ว่าเมื่อระยะพยากรณ์เพิ่มขึ้นเป็น 3 วัน ความคลาดเคลื่อนของแบบจำลองเพิ่มขึ้นเมื่อเทียบกับการพยากรณ์ล่วงหน้า 1 วัน โดยเฉพาะในช่วงที่ค่า PM2.5 เปลี่ยนแปลงรวดเร็ว แบบจำลอง GRU และ LSTM ยังคงสามารถสะท้อนแนวโน้มโดยรวมของข้อมูลได้ดี ส่วน Prophet ให้ค่าพยากรณ์ที่เรียกว่า

ภาพที่ 4 แสดงผลการพยากรณ์ล่วงหน้า 7 วันของแบบจำลอง 3 อันดับแรก ได้แก่ Prophet, GRU และ LSTM ซึ่งเป็นระยะพยากรณ์ที่ยาวที่สุดในการศึกษา



ภาพที่ 4 ค่าจริงและค่าพยากรณ์ PM2.5 ของแบบจำลอง 3 อันดับแรกในระยะพยากรณ์ล่วงหน้า 7 วัน

จากภาพที่ 4 พบว่าเส้นพยากรณ์ของแบบจำลอง Prophet มีลักษณะเรียบกว่าแบบจำลองการเรียนรู้เชิงลึก และสามารถสะท้อนแนวโน้มโดยรวมของ PM2.5 ได้ดีในระยะพยากรณ์ล่วงหน้า 7 วัน ผลนี้สอดคล้องกับตารางที่ 5 ซึ่ง Prophet ให้ค่า RMSE ต่ำที่สุดในระยะพยากรณ์ดังกล่าว ขณะที่ GRU และ LSTM ยังคงให้ผลใกล้เคียงกัน แต่มีความผันผวนของค่าพยากรณ์มากกว่า

4.3 ผลการจำแนกวันที่ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร

การจำแนกวันที่มีปริมาณ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร โดยพิจารณาจากค่า Precision, Recall และ F1-score ผลการประเมินแสดงให้เห็นว่าแบบจำลองที่เหมาะสมสำหรับการจำแนกวันเกินเกณฑ์อาจแตกต่างจากแบบจำลองที่ให้ค่า RMSE ต่ำที่สุด ดังแสดงในตารางที่ 6

การพยากรณ์ล่วงหน้า 1 วัน แบบจำลอง Prophet-GRU ให้ค่า F1-score สูงที่สุดเท่ากับ 0.9377 ใกล้เคียงกับ Prophet-LSTM ซึ่งมีค่า F1-score เท่ากับ 0.9376 และ Persistence ซึ่งมีค่า F1-score เท่ากับ 0.9360 แสดงให้เห็นว่าแม้แบบจำลองลูกผสมฐาน Prophet จะไม่ใช่แบบจำลองที่ดีที่สุดในเรื่อง RMSE แต่ยังมีประสิทธิภาพที่ดีในการจำแนกวันที่ PM2.5 เกินเกณฑ์ โดยเฉพาะในระยะพยากรณ์ 1 วัน สำหรับการพยากรณ์ล่วงหน้า 3 วัน แบบจำลอง Moving Average ให้ค่า F1-score สูงที่สุดเท่ากับ 0.9017 รองลงมาคือ Persistence มีค่า F1-score เท่ากับ 0.8895 และ Prophet-GRU มีค่า F1-score เท่ากับ 0.8871 ส่วนการพยากรณ์ล่วงหน้า 7 วัน แบบจำลอง Moving Average ยังคงให้ค่า F1-score สูงที่สุดเท่ากับ 0.8902 รองลงมาคือ Persistence มีค่า F1-score เท่ากับ 0.8779 และ Prophet-XGBoost มีค่า F1-score เท่ากับ 0.8754

ผลการจำแนกวันเกินเกณฑ์แสดงให้เห็นว่าแบบจำลองพื้นฐานมีประโยชน์ในเชิงการเฝ้าระวังคุณภาพอากาศ โดยเมื่อพิจารณาในรูปของการจำแนกเหตุการณ์เกินเกณฑ์มากกว่าการพยากรณ์ค่าต่อเนื่อง ขณะเดียวกันแบบจำลองลูกผสมฐาน Prophet มีบทบาทเด่นในการจำแนกระยะสั้น โดยเฉพาะ Prophet-GRU และ Prophet-LSTM ในการพยากรณ์ล่วงหน้า 1 วัน

ตารางที่ 6 ผลการจำแนกวันที่ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร

Horizon	Model	Precision	Recall	F1
1	GRU	0.8871	0.9684	0.9259
1	LSTM	0.8781	0.9663	0.9200
1	Moving Average	0.9138	0.9244	0.9191
1	Persistence	0.9360	0.9360	0.9360
1	Prophet	0.8010	0.9593	0.8730
1	Prophet-GRU	0.9262	0.9496	0.9377
1	Prophet-LSTM	0.9250	0.9506	0.9376
1	Prophet-XGBoost	0.9074	0.9512	0.9288
1	XGBoost	0.8559	0.9700	0.9094

ตารางที่ 6 ผลการจำแนกวันที่ PM2.5 เกิน 50 ไมโครกรัมต่อลูกบาศก์เมตร (ต่อ)

Horizon	Model	Precision	Recall	F1
3	GRU	0.7937	0.9589	0.8681
3	LSTM	0.7974	0.9595	0.8707
3	Moving Average	0.8966	0.9070	0.9017
3	Persistence	0.8895	0.8895	0.8895
3	Prophet	0.7971	0.9593	0.8707
3	Prophet-GRU	0.8303	0.9523	0.8871
3	Prophet-LSTM	0.8161	0.9568	0.8808
3	Prophet-XGBoost	0.8397	0.9316	0.8833
3	XGBoost	0.7428	0.9643	0.8391
7	GRU	0.7150	0.9692	0.8220
7	LSTM	0.7363	0.9643	0.8346
7	Moving Average	0.8851	0.8953	0.8902
7	Persistence	0.8779	0.8779	0.8779
7	Prophet	0.7971	0.9593	0.8707
7	Prophet-GRU	0.8007	0.9595	0.8729
7	Prophet-LSTM	0.7983	0.9593	0.8714
7	Prophet-XGBoost	0.8057	0.9583	0.8754
7	XGBoost	0.7100	0.9767	0.8223

4.4 ผลการทดสอบความแตกต่างของความแม่นยำระหว่างแบบจำลอง

งานวิจัยนี้ใช้การทดสอบ Diebold-Mariano โดยเปรียบเทียบแบบจำลองแต่ละตัวกับแบบจำลองที่ให้ค่า RMSE ต่ำที่สุดในแต่ละระยะพยากรณ์ พบว่า การพยากรณ์ล่วงหน้า 1 วัน แบบจำลอง GRU เป็นแบบจำลองที่ให้ค่า RMSE ต่ำที่สุด เมื่อเปรียบเทียบกับแบบจำลองอื่น พบว่า GRU ให้ผลดีกว่า Moving Average, Prophet, LSTM, XGBoost, Prophet-LSTM, Prophet-GRU และ Prophet-XGBoost อย่างมีนัยสำคัญทางสถิติที่ระดับ 0.05 อย่างไรก็ตาม เมื่อเปรียบเทียบกับ Persistence พบว่าค่า p-value เท่ากับ 0.5108 ซึ่งมากกว่า 0.05 แสดงว่าแม้ GRU จะมีค่า RMSE ต่ำกว่า Persistence แต่ไม่แตกต่างกันอย่างมีนัยสำคัญ

การพยากรณ์ล่วงหน้า 3 วัน GRU เป็นแบบจำลองที่ให้ค่า RMSE ต่ำที่สุดเช่นเดียวกัน ผลการทดสอบพบว่า GRU ให้ผลดีกว่า Persistence, XGBoost, Prophet-LSTM, Prophet-GRU และ Prophet-XGBoost อย่างมีนัยสำคัญทางสถิติ แต่เมื่อเทียบกับ Moving Average, Prophet และ LSTM ค่า p-value มากกว่า 0.05 แสดงให้เห็นว่าความแตกต่างระหว่าง GRU กับแบบจำลองบางตัวในระยะพยากรณ์ 3 วันไม่แตกต่างกัน

การพยากรณ์ล่วงหน้า 7 วัน Prophet เป็นแบบจำลองที่ให้ค่า RMSE ต่ำที่สุด ผลการทดสอบพบว่า Prophet ให้ผลดีกว่า Persistence, Moving Average, XGBoost และ Prophet-XGBoost อย่างมีนัยสำคัญทางสถิติ ขณะที่ความแตกต่างระหว่าง Prophet กับ LSTM, GRU, Prophet-LSTM และ Prophet-GRU ไม่มีนัยสำคัญทางสถิติที่ระดับ 0.05 ผลดังกล่าวแสดงให้เห็นว่า แม้ Prophet จะมีค่า RMSE ต่ำที่สุดในการพยากรณ์ล่วงหน้า 7 วัน แต่แบบจำลองการเรียนรู้เชิงลึกและแบบจำลองลูกผสมบางตัวให้ผลไม่แตกต่างกัน

ตารางที่ 7 ผลการทดสอบ Diebold-Mariano เปรียบเทียบกับแบบจำลองที่ดีที่สุดในแต่ละระยะพยากรณ์

Horizon	Best model by RMSE	Comparison	DM statistic	p-value
1	GRU	Persistence vs GRU	0.6583	0.5108
1	GRU	Moving Average vs GRU	4.2790	0.0000
1	GRU	Prophet vs GRU	6.8623	0.0000
1	GRU	LSTM vs GRU	4.3044	0.0000
1	GRU	XGBoost vs GRU	3.0510	0.0024
1	GRU	Prophet-LSTM vs GRU	6.0704	0.0000
1	GRU	Prophet-GRU vs GRU	6.3267	0.0000
1	GRU	Prophet-XGBoost vs GRU	6.3004	0.0000
3	GRU	Persistence vs GRU	2.2399	0.0257
3	GRU	Moving Average vs GRU	1.8553	0.0644
3	GRU	Prophet vs GRU	1.7798	0.0759
3	GRU	LSTM vs GRU	1.9227	0.0553
3	GRU	XGBoost vs GRU	3.4056	0.0007
3	GRU	Prophet-LSTM vs GRU	2.3807	0.0178
3	GRU	Prophet-GRU vs GRU	2.3575	0.0189
3	GRU	Prophet-XGBoost vs GRU	3.2823	0.0011
7	Prophet	Persistence vs Prophet	2.3039	0.0218
7	Prophet	Moving Average vs Prophet	2.0540	0.0407
7	Prophet	LSTM vs Prophet	0.8817	0.3785
7	Prophet	GRU vs Prophet	0.6015	0.5479
7	Prophet	XGBoost vs Prophet	2.0869	0.0376
7	Prophet	Prophet-LSTM vs Prophet	1.5874	0.1133
7	Prophet	Prophet-GRU vs Prophet	1.6817	0.0935
7	Prophet	Prophet-XGBoost vs Prophet	2.1123	0.0353

5. อภิปรายผลการวิจัยและข้อเสนอแนะ

การวิจัยนี้แสดงให้เห็นว่า การเลือกแบบจำลองสำหรับการพยากรณ์ PM2.5 ไม่ควรพิจารณาจากความซับซ้อนของแบบจำลองเพียงอย่างเดียว ควรพิจารณาควบคู่กับระยะพยากรณ์และวัตถุประสงค์ของการใช้ผลของการพยากรณ์ จากผลการวิจัยพบว่า แบบจำลองที่เหมาะสมแตกต่างกันตามระยะพยากรณ์ล่วงหน้า กล่าวคือ แบบจำลองการเรียนรู้เชิงลึก โดยเฉพาะแบบจำลอง GRU มีความเหมาะสมกับการพยากรณ์ระยะสั้นถึงระยะกลาง ขณะที่แบบจำลอง Prophet มีความเหมาะสมมากขึ้นเมื่อระยะพยากรณ์ยาวขึ้นเป็น 7 วัน ผลดังกล่าวอธิบายได้จากลักษณะของข้อมูล PM2.5 รายวัน ซึ่งมีทั้งความต่อเนื่องเชิงเวลา ความผันผวนรายวัน และรูปแบบเชิงฤดูกาลร่วมกัน

ในกรณีการพยากรณ์ล่วงหน้า 1 และ 3 วัน แบบจำลอง GRU ให้ผลที่โดดเด่นกว่าแบบจำลองส่วนใหญ่ เนื่องจาก GRU เป็นโครงข่ายประสาทเทียมแบบเวียนกลับที่ออกแบบมาเพื่อเรียนรู้ข้อมูลลำดับเวลา และมีโครงสร้างที่กระชับกว่า LSTM ทำให้สามารถเรียนรู้รูปแบบการเปลี่ยนแปลงระยะสั้นของ PM2.5 ได้ดี โดยเฉพาะช่วงเวลาที่ค่าฝุ่นมีการเปลี่ยนแปลงต่อเนื่อง อย่างไรก็ตาม ผลการทดสอบทางสถิติชี้ให้เห็นว่า บางกรณี GRU ไม่ได้แตกต่างจากแบบจำลองพื้นฐานหรือแบบจำลองเชิงลำดับเวลาอย่างชัดเจนทั้งหมด แสดงให้เห็นว่า แบบจำลองการเรียนรู้เชิงลึกจะให้ผลดี แต่การนำไปใช้จริงควรเปรียบเทียบกับแบบจำลองพื้นฐานเสมอ เพื่อให้มั่นใจว่าความซับซ้อนที่เพิ่มขึ้นให้ประโยชน์เพียงพอต่อการใช้งานจริง ผลที่แบบจำลอง Persistence ให้ผลใกล้เคียงกับแบบจำลองที่ดีที่สุดในการพยากรณ์ล่วงหน้า 1 วัน เป็นสิ่งที่ต้องสนใจและให้ความสำคัญในเชิงปฏิบัติ เนื่องจากแสดงให้เห็นว่าค่า PM2.5 รายวันในพื้นที่ศึกษามีความต่อเนื่องจากวันก่อนหน้าในระดับสูง ดังนั้น แบบจำลองพื้นฐานที่ใช้ค่าล่าสุดเป็นค่าพยากรณ์จึงเป็นเกณฑ์เปรียบเทียบที่ดี ทำให้เห็นว่าการพัฒนาแบบจำลองพยากรณ์ PM2.5 ควรมีการเปรียบเทียบกับ baseline ที่เหมาะสมทุกครั้ง เพื่อประเมินคุณค่าที่แท้จริงของแบบจำลองขั้นสูง

การพยากรณ์ล่วงหน้า 7 วัน แบบจำลอง Prophet ให้ผลเหมาะสมที่สุดในเชิงค่าความคลาดเคลื่อนโดยรวม ซึ่งสอดคล้องกับลักษณะของ Prophet ที่เน้นการอธิบายองค์ประกอบของแนวโน้มและฤดูกาลของอนุกรมเวลา เมื่อระยะพยากรณ์ยาวขึ้น ดังนั้น แบบจำลองที่สามารถตรวจจับโครงสร้างระยะยาวของข้อมูลได้ดี จึงมีความได้เปรียบ แต่ผลการทดสอบ Diebold-Mariano แสดงให้เห็นว่า Prophet ไม่ได้แตกต่างจาก LSTM, GRU และแบบจำลองลูกผสมฐาน Prophet บางตัวอย่างมีนัยสำคัญในระยะ 7 วัน จึงสรุปได้ว่า Prophet เป็นแบบจำลองที่ให้ผลดีที่สุดในเชิงตัวเลขของการทดลองนี้ แต่ไม่ได้เหนือกว่าแบบจำลองอื่นทุกตัวอย่างมีนัยสำคัญทางสถิติ

เมื่อพิจารณาแบบจำลองลูกผสมฐาน Prophet พบว่า แบบจำลองกลุ่มนี้ไม่ได้ให้ค่า RMSE ต่ำที่สุดในการพยากรณ์ค่าต่อเนื่อง แต่มีผลการทดลองที่ดีในการจำแนกวันที่ PM2.5 เกินเกณฑ์ โดยเฉพาะในระยะพยากรณ์ล่วงหน้า 1 วัน แสดงให้เห็นว่าแบบจำลองที่เหมาะสมสำหรับการพยากรณ์ค่าตัวเลขต่อเนื่องอาจไม่ใช่แบบจำลองเดียวกับที่เหมาะสมที่สุดสำหรับการจำแนกเหตุการณ์เกินเกณฑ์ ในการเฝ้าระวังคุณภาพอากาศ การจำแนกวันที่ค่าฝุ่นเกินระดับที่เริ่มส่งผลกระทบต่อสุขภาพมีความสำคัญไม่น้อยไปกว่าการพยากรณ์ปริมาณ

ดังนั้นการเลือกใช้แบบจำลองจึงควรพิจารณาวัตถุประสงค์เป็นหลัก สิ่งที่ต้องคำนึงถึงอีกอย่างหนึ่ง คือ ความสามารถของแบบจำลองในการติดตามค่าสูงเฉียบพลันลดลงอย่างเห็นได้ชัด จากกราฟค่าจริงและค่าพยากรณ์ โดยเฉพาะช่วงที่ PM2.5 มีการเพิ่มขึ้นอย่างรวดเร็ว ลักษณะดังกล่าวเป็นข้อจำกัดทั่วไปของการพยากรณ์มลพิษทางอากาศรายวัน เนื่องจากค่าฝุ่นอาจได้รับผลจากปัจจัยเฉพาะเหตุการณ์ เช่น การเผาในที่โล่ง การเปลี่ยนแปลงของสภาพลม หรือสภาพอุตุนิยมวิทยาเฉพาะช่วง ซึ่งทำให้ไม่สามารถสะท้อนได้ครบถ้วนจากตัวแปรที่ใช้ในแบบจำลอง ดังนั้น แม้แบบจำลองจะให้ผลดีในภาพรวม แต่การพยากรณ์ช่วงค่าสูงยังเป็นประเด็นที่ควรพัฒนาเพิ่มเติม

ข้อเสนอแนะสำหรับการนำไปใช้ในเชิงปฏิบัติ คือ หากต้องการพยากรณ์ PM2.5 ล่วงหน้าในระยะสั้น เช่น 1 ถึง 3 วัน แบบจำลอง GRU เป็นทางเลือกที่เหมาะสม เนื่องจากให้ผลดีในการติดตามการเปลี่ยนแปลงของข้อมูลรายวัน แต่หากต้องการพยากรณ์ในระยะ 7 วัน แบบจำลอง Prophet เป็นทางเลือกที่น่าสนใจ เนื่องจากสามารถสะท้อนแนวโน้มโดยรวมของข้อมูลได้ดีและมีความซับซ้อนไม่สูงมาก ส่วนกรณีที่ต้องการนำไปใช้ในการเฝ้าระวังหรือแจ้งเตือนวันที่ PM2.5 เกินเกณฑ์ ควรพิจารณาค่า Precision, Recall และ F1-score ร่วมกับ RMSE เพราะการประเมินจากค่าความคลาดเคลื่อนเพียงอย่างเดียวอาจไม่เพียงพอต่อการตัดสินใจในงานด้านสุขภาพและสิ่งแวดล้อม

ข้อเสนอแนะในการวิจัยครั้งต่อไป การขยายการศึกษาไปสู่ข้อมูลจากหลายสถานีหรือหลายพื้นที่ เพื่อประเมินว่าแบบจำลองที่ให้ผลดีในจังหวัดนครสวรรค์ยังคงให้ผลดีในพื้นที่อื่นหรือไม่ หรือการพิจารณาเพิ่มตัวแปรที่เกี่ยวข้องกับแหล่งกำเนิดฝุ่นและสภาพแวดล้อมเฉพาะเหตุการณ์ เช่น ข้อมูลจุดความร้อน ทิศทางลม ความเร็วลมในระดับต่าง ๆ หรือข้อมูลกิจกรรมการเผาในพื้นที่ อีกทั้งศึกษาแนวทางปรับปรุงการพยากรณ์ในช่วงที่เกิดค่าฝุ่นสูงเฉียบพลัน เนื่องจากเป็นช่วงที่มีความสำคัญต่อการแจ้งเตือนประชาชนมากที่สุด

6. เอกสารอ้างอิง

- วิฑูร สนิธิปักษ์, ขม ปานตา, ภาสกร วรอาจ, และ ธิรภัทร มีสำราญ. (2567). การพยากรณ์ปริมาณฝุ่นละออง PM2.5 ในจังหวัดนครสวรรค์ ด้วยเทคนิคการเรียนรู้ของเครื่อง. *วารสารวิชาการวิทยาศาสตร์และเทคโนโลยี 8(16)*, 25-31. <https://ph03.tci-thaijo.org/index.php/ajsas/article/view/3464/2625>
- Abuouelezz, W., Ali, N., Aung, Z., Altunaiji, A., Shah, S. B., & Gliddon, D. (2025). Exploring PM2.5 and PM10 ML forecasting models: A comparative study in the UAE. *Scientific Reports*, 15(1), 9797. <https://doi.org/10.1038/s41598-025-94013-1>
- Bai, X., Zhang, N., Cao, X., & Chen, W. (2024). Prediction of PM2.5 concentration based on a CNN-LSTM neural network algorithm. *PeerJ*, 12, e17811. <https://doi.org/10.7717/peerj.17811>
- Cáceres-Tello, J., & Galán-Hernández, J. J. (2024). Analysis and prediction of PM2.5 pollution in Madrid: The use of Prophet–Long Short-Term Memory hybrid models. *AppliedMath*, 4(4), 1428–1452. <https://doi.org/10.3390/appliedmath4040076>

- Chang, W., Chen, X., He, Z., & Zhou, S. (2023). A prediction hybrid framework for air quality integrated with W-BiLSTM(PSO)-GRU and XGBoost methods. *Sustainability*, 15(22), 16064. <https://doi.org/10.3390/su152216064>
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining* (pp. 785-794). <https://doi.org/10.1145/2939672.2939785>
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder–decoder for statistical machine translation. *arXiv*. <https://doi.org/10.48550/arXiv.1406.1078>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, C.-J., & Kuo, P.-H. (2018). A deep CNN-LSTM model for particulate matter (PM_{2.5}) forecasting in smart cities. *Sensors*, 18(7), 2220. <https://doi.org/10.3390/s18072220>
- Karimian, H., Li, Q., Wu, C., Qi, Y., Mo, Y., Chen, G., Zhang, X., & Sachdeva, S. (2019). Evaluation of different machine learning approaches to forecasting PM_{2.5} mass concentrations. *Aerosol and Air Quality Research*, 19(6), 1400–1410. <https://doi.org/10.4209/aaqr.2018.12.0450>
- Lee, C.-Y., Lee, J.-Y., Han, S.-H., Kang, J.-G., Lee, J.-B., & Choi, D.-R. (2025). Performance evaluation of PM_{2.5} forecasting using SARIMAX and LSTM in the Korean Peninsula. *Atmosphere*, 16(5), 524. <https://doi.org/10.3390/atmos16050524>
- Lei, T. M. T., Ng, S. C. W., & Siu, S. W. I. (2023). Application of ANN, XGBoost, and Other ML Methods to Forecast Air Quality in Macau. *Sustainability*, 15(6), 5341. <https://doi.org/10.3390/su15065341>
- Li, T., Hua, M., & Wu, X. (2020). A hybrid CNN-LSTM model for forecasting particulate matter (PM_{2.5}). *IEEE Access*, 8, 26933-26940. <https://doi.org/10.1109/ACCESS.2020.2971348>
- Shen, J., Valagolam, D., & McCalla, S. (2020). Prophet forecasting model: A machine learning approach to predict the concentration of air pollutants (PM_{2.5}, PM₁₀, O₃, NO₂, SO₂, CO) in Seoul, South Korea. *PeerJ*, 8, e9961. <https://doi.org/10.7717/peerj.9961>
- Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37–45. <https://doi.org/10.1080/00031305.2017.1380080>
- World Health Organization. (2021). *WHO global air quality guidelines: Particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide*. <https://www.who.int/publications/i/item/9789240034228>