

การพยากรณ์ PM2.5 รายวันแบบค่าสูงสุดด้วยแบบจำลอง FBProphet เพื่อสนับสนุนภารกิจ อากาศยานไร้คนขับ: กรณีศึกษาอำเภออรัญประเทศ จังหวัดสระแก้ว

ศรีชล ภิรมย์ลาภ¹, วิทมา ธรรมเจริญ², สมพล สกุลหลง³ และ สืบสกุล คุรุรัตน์^{3*}

¹สาขาวิชาเทคโนโลยีสารสนเทศและการสื่อสาร คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลตะวันออก

²ภาควิชาสถิติ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏรำไพพรรณี

³ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ ศรีราชา มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา

*suabsakul@eng.src.ku.ac.th

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองสำหรับการพยากรณ์ค่า PM2.5 รายวันในรูปแบบค่าสูงสุดในพื้นที่อำเภออรัญประเทศ จังหวัดสระแก้ว และเพื่อนำผลการพยากรณ์ดังกล่าวไปใช้สนับสนุนการวางแผนภารกิจของอากาศยานไร้คนขับ สำหรับการตรวจการณ์ในพื้นที่ชายแดน ข้อมูลที่ใช้ในการศึกษาประกอบด้วยค่าฝุ่น PM2.5 รายวันแบบค่าสูงสุด จากสถานีตรวจวัดคุณภาพอากาศ 71T (สวนกาญจนาภิเษก ร.9) ครอบคลุมระยะเวลา 6 ปี ตั้งแต่วันที่ 1 มกราคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2567 รวมทั้งสิ้น 2,192 ข้อมูล โดยได้ดำเนินการเตรียมข้อมูลผ่านกระบวนการจัดการค่าที่ขาดหายด้วยวิธี Forward Filling การตรวจจับค่าผิดปกติด้วยค่า Z-score และการลดสัญญาณรบกวนด้วยวิธี Rolling Median ระยะเวลา 7 วัน เพื่อคงไว้ซึ่งรูปแบบเชิงเวลาของข้อมูล แบบจำลอง FBProphet ถูกนำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา โดยมีการแบ่งข้อมูลออกเป็นชุดฝึกและชุดทดสอบในสัดส่วน 80:20 และปรับแต่งพารามิเตอร์ด้วยวิธี Manual Grid Search ผลการประเมินประสิทธิภาพของแบบจำลองพบว่า ชุดข้อมูลฝึกมีค่า R^2 เท่ากับ 0.636 และค่า RMSE เท่ากับ 7.54 $\mu\text{g}/\text{m}^3$ ขณะที่ชุดข้อมูลทดสอบมีค่า R^2 เท่ากับ 0.626 และค่า RMSE เท่ากับ 7.29 $\mu\text{g}/\text{m}^3$ แสดงให้เห็นถึงความสามารถในการพยากรณ์โดยไม่เกิดปัญหา overfitting ผลการพยากรณ์ยังแสดงให้เห็นรูปแบบเชิงฤดูกาลอย่างชัดเจน โดยค่าฝุ่น PM2.5 มีแนวโน้มสูงในช่วงฤดูหนาว และลดลงในช่วงฤดูฝน ผลการศึกษานี้แสดงให้เห็นว่า FBProphet เป็นเครื่องมือที่มีประสิทธิภาพ และสามารถตีความได้ง่าย สำหรับการพยากรณ์ค่าฝุ่น PM2.5 แบบค่าสูงสุดรายวันในบริบทของพื้นที่ที่มีข้อจำกัดด้านข้อมูล อีกทั้งการบูรณาการผลการพยากรณ์เข้ากับการวางแผนภารกิจของ UAV ยังเป็นแนวทางเชิงรุกในการสนับสนุนการตัดสินใจ ซึ่งช่วยเพิ่มความปลอดภัยในการบิน ยกระดับประสิทธิภาพในการตรวจการณ์ และเพิ่มประสิทธิภาพในการบริหารจัดการทรัพยากรด้านความมั่นคงในพื้นที่ชายแดนต่อไป

คำสำคัญ: การพยากรณ์ FBProphet PM2.5

Forecasting Daily Maximum PM2.5 Using FBProphet to Support Unmanned Aerial Vehicle Operations: A Case Study of Aranyaprathet District, Sa Kaeo

Srichol Phiromlap¹, Wittama Thumcharoen², Sompol Skullong³ and Suabsakul Gururatana^{3*}

¹Information and Communication Technology, Faculty of Science and Technology,
Rajamangala University of Technology Tawan-ok

²Department of Statistics, Faculty of Science and Technology, Rambhai Barni Rajabhat University

³ Department of Mechanical Engineering, Faculty of Engineering at Sriracha, Kasetsart University,
Sriracha Campus

*suabsakul@eng.src.ku.ac.th

Abstract

This study aims to develop a forecasting model for daily maximum PM2.5 concentrations in Aranyaprathet District, Sa Kaeo Province, Thailand, and to utilize the forecasting results to support mission planning of Unmanned Aerial Vehicles for border surveillance operations. The dataset consists of daily maximum PM2.5 values collected from air quality monitoring station 71T (King Rama IX Commemorative Park) over a six-year period from January 1, 2019 to December 31, 2024, totaling 2,192 observations. Data preprocessing included missing value handling using forward filling, anomaly detection via Z-score, and noise reduction using a 7-day rolling median to preserve temporal patterns. The FBProphet model was employed for time series forecasting, with the dataset split into Training and Testing sets at a ratio of 80:20. Hyperparameter tuning was conducted using Manual Grid Search to systematically identify optimal model configurations. Model performance evaluation shows that the Training set achieved an R^2 of 0.636 and an RMSE of $7.54 \mu\text{g}/\text{m}^3$, while the Testing set achieved an R^2 of 0.626 and an RMSE of $7.29 \mu\text{g}/\text{m}^3$, indicating reliable predictive capability without significant overfitting. The forecasting results reveal clear seasonal patterns, with elevated PM2.5 levels during the winter season and lower concentrations during the rainy season. The findings demonstrate that FBProphet is an effective and interpretable tool for forecasting daily maximum PM2.5 in data-limited environments. Furthermore, integrating PM2.5 forecasts into UAV mission planning provides a proactive decision-support approach to enhance flight safety, improve surveillance efficiency, and optimize resource allocation in border security operations.

Keywords: Forecasting, FBProphet, PM2.5

1. บทนำ

ในช่วงปี พ.ศ. 2568 สถานการณ์ความตึงเครียดและความขัดแย้งในบริเวณชายแดนระหว่างประเทศไทยและประเทศกัมพูชา ได้ส่งผลให้การกีดกันความมั่นคงมีความเข้มข้นมากยิ่งขึ้น โดยเฉพาะการตรวจการณ์ทางอากาศด้วยอากาศยานไร้คนขับ (Unmanned Aerial Vehicle, UAV) หรือ โดรน (Drone) ซึ่งถูกนำมาใช้เป็นเครื่องมือสำคัญในการเฝ้าระวังและติดตามสถานการณ์ตามแนวชายแดน อย่างไรก็ตาม ประสิทธิภาพของการปฏิบัติการของโดรน นั้นขึ้นอยู่กับสภาพแวดล้อมทางอากาศโดยตรง โดยเฉพาะทัศนวิสัยในการบินซึ่งอาจถูกรบกวนจากมลพิษทางอากาศ เช่น ฝุ่นละอองขนาดเล็ก PM2.5 ที่สามารถลดความชัดเจนของภาพจากกล้องตรวจการณ์ และส่งผลต่อความปลอดภัยในการบินได้ ดังนั้นปัญหาฝุ่น PM2.5 จึงไม่ได้เป็นเพียงประเด็นด้านสิ่งแวดล้อมหรือสุขภาพเท่านั้น แต่ยังมีความเชื่อมโยงโดยตรงกับการกีดกันความมั่นคง โดยเฉพาะในพื้นที่ชายแดนที่ต้องอาศัยการเฝ้าระวังอย่างต่อเนื่อง การพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้าจึงมีบทบาทสำคัญในการสนับสนุนการตัดสินใจวางแผนการบินของ UAV ให้มีประสิทธิภาพและปลอดภัยมากยิ่งขึ้น (PostToday [1])

ในช่วงหลายปีที่ผ่านมา การพัฒนาแบบจำลองเพื่อพยากรณ์ค่าฝุ่น PM2.5 ในประเทศไทยมีความก้าวหน้าอย่างต่อเนื่อง เนื่องจากปัญหามลพิษทางอากาศได้กลายเป็นประเด็นสำคัญที่ส่งผลกระทบต่อทั้งในด้านสิ่งแวดล้อม เศรษฐกิจ และสุขภาพของประชาชน โดยเฉพาะในช่วงฤดูหนาวหรือช่วงที่มีสภาวะอากาศนิ่งซึ่งเอื้อต่อการสะสมของฝุ่นละออง นักวิจัยได้พัฒนาแบบจำลองหลากหลายประเภท ทั้งแบบจำลองเชิงสถิติ เช่น ARIMA และแบบจำลองเชิงปัญญาประดิษฐ์ เช่น XGBoost, LSTM และ FBProphet ซึ่งมีความสามารถในการวิเคราะห์ข้อมูลอนุกรมเวลาและจับรูปแบบเชิงฤดูกาลได้อย่างมีประสิทธิภาพ โดยการประเมินประสิทธิภาพของแบบจำลองมักใช้ตัวชี้วัด เช่น Mean Absolute Error (MAE), Mean Squared Error (MSE) และ Root Mean Squared Error (RMSE)

ในพื้นที่กรุงเทพมหานคร Songpon Klerkkidakan [2] ได้ศึกษาและพัฒนาแบบจำลองผสมระหว่าง Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) โดยใช้ข้อมูลภาพถ่ายท้องฟ้าเป็นตัวแปรนำเข้า ซึ่งสามารถลดค่า RMSE ลงเหลือ 11.39 $\mu\text{g}/\text{m}^3$ เมื่อเทียบกับ CNN เพียงอย่างเดียวที่มีค่า RMSE สูงถึง 15.59 แสดงให้เห็นว่าการผสมข้อมูลเชิงเวลาเข้ามาช่วยเพิ่มความแม่นยำในการพยากรณ์ได้อย่างมีนัยสำคัญ นอกจากนี้งานวิจัยของ Sriruk Srithongchai [3] ได้ใช้แบบจำลอง LSTM ร่วมกับตัวแปรด้านมลพิษและอุตุนิยมวิทยาในกรุงเทพมหานคร พบว่าในพื้นที่ริมถนนสามารถให้ค่า RMSE ต่ำถึง 4.55 $\mu\text{g}/\text{m}^3$ ขณะที่พื้นที่ทั่วไปมีค่า RMSE อยู่ที่ 7.73 $\mu\text{g}/\text{m}^3$ ซึ่งสะท้อนถึงอิทธิพลของลักษณะพื้นที่ต่อความแม่นยำของแบบจำลอง

ในส่วนภูมิภาค งานวิจัยในพื้นที่จังหวัดอุดรธานีโดย Kittika Thipkumme et al. [4] พบว่าแบบจำลองโครงข่ายประสาทเทียมให้ผลดีที่สุด โดยมีค่า RMSE เท่ากับ 2.945 และค่า R^2 สูงถึง 0.948 ในขณะที่การเปรียบเทียบระหว่างแบบจำลอง SARIMA และ XGBoost ในกรุงเทพมหานคร พบว่า XGBoost มีความแม่นยำสูงกว่าอย่างชัดเจน โดยให้ค่า RMSE ต่ำสุดที่ 7.07 (Saranthon Maungmee and Pongpat Chaisiripan [5])

ในส่วนของแบบจำลอง FBProphet ซึ่งเป็นเทคนิคที่ได้รับความนิยมในการวิเคราะห์ข้อมูลอนุกรมเวลา งานวิจัยในมหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา พบว่าสามารถจับแนวโน้มตามฤดูกาลได้ดี แต่ยังมีข้อจำกัดในกรณีที่ค่าฝุ่นมีความผันผวนสูง โดยให้ค่า RMSE อยู่ที่ 22.05 อย่างไรก็ตามเมื่อมีการปรับแต่งพารามิเตอร์ร่วมกับเทคนิค Grid Search และ Cross-Validation ในพื้นที่จังหวัดระยอง พบว่าสามารถลดค่า RMSE ลงเหลือ 7.44 ซึ่งอยู่ในระดับที่สามารถนำไปใช้งานจริงได้ (Suabsakul Gururatana et al. [6], Panisa Puripanic [7])

จากงานวิจัยข้างต้นจะเห็นได้ว่า แม้จะมีการพัฒนาแบบจำลองที่มีความแม่นยำสูงในหลายพื้นที่ แต่การประยุกต์ใช้ในระบบของพื้นที่ชายแดน ซึ่งยังมีข้อจำกัดด้านข้อมูลและมีความต้องการเฉพาะด้านความมั่นคงยังมีอยู่อย่างจำกัด ดังนั้นงานวิจัยนี้จึงเลือกพื้นที่อำเภออรัญประเทศ จังหวัดสระแก้ว ซึ่งเป็นพื้นที่ชายแดนสำคัญของประเทศไทยที่มีบทบาททั้งด้านความมั่นคงและการค้าชายแดน เป็นกรณีศึกษาในการพัฒนาแบบจำลองพยากรณ์ค่าฝุ่น PM2.5 โดยมุ่งเน้นการนำผลการ

พยากรณ์ไปสนับสนุนการวางแผนภารกิจของอากาศยานไร้คนขับ (UAV) ในการตรวจการณ์ เพื่อเพิ่มประสิทธิภาพ ความปลอดภัย และความต่อเนื่องของการปฏิบัติงานในพื้นที่ที่มีความสำคัญเชิงยุทธศาสตร์

วัตถุประสงค์การวิจัย

1. เพื่อปรับแต่งพารามิเตอร์ของ FBProphet ให้เหมาะสมสำหรับการพยากรณ์ค่า PM2.5 ล่วงหน้า ในพื้นที่อำเภออรัญประเทศ จังหวัดสระแก้ว
2. เพื่อนำผลการพยากรณ์มาใช้ในการประกอบการวางแผนการบินของ UAV สำหรับภารกิจตรวจการณ์ตามแนวชายแดนอย่างมีประสิทธิภาพและปลอดภัย

2. ทฤษฎีที่เกี่ยวข้อง

2.1 โมเดล Facebook Prophet (FBProphet)

FBProphet เป็นแบบจำลองสำหรับการพยากรณ์ข้อมูลอนุกรมเวลา (time series forecasting) ที่ได้รับการพัฒนาโดยทีม Core Data Science ของ Facebook โดยถูกออกแบบมาเพื่อรองรับข้อมูลที่มีลักษณะซับซ้อน เช่น ข้อมูลที่มีแนวโน้มเปลี่ยนแปลงตามเวลา มีรูปแบบฤดูกาล (seasonality) หรือมีผลกระทบจากเหตุการณ์เฉพาะช่วงเวลา โมเดลนี้สามารถจัดอยู่ในกลุ่มของวิธีการแบบผสมผสานระหว่างแบบจำลองเชิงสถิติและแนวคิดของ Machine Learning เนื่องจากมีพื้นฐานจากหลักการทางสถิติในการอธิบายโครงสร้างของข้อมูล ขณะเดียวกันก็สามารถเรียนรู้รูปแบบและปรับค่าพารามิเตอร์จากข้อมูลได้โดยอัตโนมัติในลักษณะ data-driven แตกต่างจากแบบจำลอง Machine Learning ทั่วไปที่มักทำงานในลักษณะ black-box และต้องการข้อมูลจำนวนมากในการฝึกแบบจำลอง (Taylor and Letham [8])

แนวคิดสำคัญของ FBProphet คือการแยกองค์ประกอบของข้อมูลอนุกรมเวลาออกเป็นส่วนต่าง ๆ เพื่อช่วยให้สามารถอธิบายพฤติกรรมของข้อมูลได้อย่างชัดเจน โดยอาศัยแบบจำลองเชิงบวก (additive model) ซึ่งประกอบด้วยองค์ประกอบหลัก ได้แก่ แนวโน้มระยะยาวของข้อมูล (trend) รูปแบบฤดูกาล (seasonality) และผลกระทบจากเหตุการณ์พิเศษหรือวันสำคัญต่าง ๆ (holiday effects) การแยกองค์ประกอบดังกล่าวช่วยให้โมเดลสามารถวิเคราะห์ข้อมูลที่มีการเปลี่ยนแปลงตามเวลาได้อย่างยืดหยุ่น รวมถึงสามารถรองรับข้อมูลที่มีความไม่ต่อเนื่องหรือมีค่าบางช่วงเวลาหายไปได้ดี

นอกจากนี้ FBProphet ยังได้รับความนิยมอย่างมากในงานวิเคราะห์และพยากรณ์ข้อมูล เนื่องจากมีโครงสร้างของแบบจำลองที่เข้าใจง่าย สามารถตีความผลลัพธ์ได้ชัดเจน และใช้เวลาในการปรับแต่งพารามิเตอร์ค่อนข้างน้อยเมื่อเปรียบเทียบกับแบบจำลอง Machine Learning ขั้นสูงหลายประเภท อีกทั้งยังสามารถจัดการกับข้อมูลที่มีความผันผวนสูงหรือมีรูปแบบฤดูกาลหลายลักษณะในชุดข้อมูลเดียวกันได้อย่างมีประสิทธิภาพ ด้วยคุณสมบัติเหล่านี้ FBProphet จึงถูกนำไปประยุกต์ใช้ในหลากหลายสาขา เช่น การพยากรณ์ทางเศรษฐศาสตร์ การวิเคราะห์ข้อมูลพลังงาน การพยากรณ์คุณภาพอากาศ รวมถึงการติดตามแนวโน้มข้อมูลด้านสิ่งแวดล้อม

สำหรับ FBProphet นั้น ได้ถูกเผยแพร่ในรูปแบบซอฟต์แวร์โอเพนซอร์ส (open-source software) ทำให้นักวิจัย นักวิเคราะห์ข้อมูล และผู้ใช้งานทั่วไปสามารถเข้าถึงและนำไปประยุกต์ใช้ได้อย่างแพร่หลายผ่านไลบรารีในภาษาโปรแกรมต่าง ๆ เช่น Python และ R ส่งผลให้สามารถพัฒนาแบบจำลองการพยากรณ์ได้สะดวกและรวดเร็วมากขึ้น โดยโครงสร้างของแบบจำลองสามารถเขียนให้อยู่ในรูปสมการเชิงบวกขององค์ประกอบต่าง ๆ ดังแสดงในสมการที่ 1

$$y(t) = g(t) + s(t) + h(t) + \varepsilon(t) \quad (1)$$

โดยที่ $y(t)$ หรือ $\hat{y}$ คือค่าที่ต้องการพยากรณ์ ในขณะที่ $g(t)$ แทนองค์ประกอบของแนวโน้ม หรือ Trend ซึ่งสามารถกำหนดเป็นแบบเชิงเส้นหรือแบบลอจิสติกส์ เพื่ออธิบายพฤติกรรมที่ไม่เป็นคาบของข้อมูล ส่วน $s(t)$ แทนองค์ประกอบเชิงฤดูกาล ซึ่งสะท้อนรูปแบบที่เกิดขึ้นซ้ำ เช่น รายวัน รายสัปดาห์ หรือรายปี สำหรับ $h(t)$ เป็นผลกระทบจาก

เหตุการณ์พิเศษ เช่น วันหยุด ที่อาจทำให้ข้อมูลเกิดความผันผวน และ $\varepsilon(t)$ คือค่าความคลาดเคลื่อน (Error Term) ที่เกิดจากปัจจัยสุ่มหรือสิ่งรบกวน

ในกระบวนการเรียนรู้ของแบบจำลอง FBProphet มีการประมาณค่าพารามิเตอร์โดยอาศัยแนวคิดแบบ Bayesian ซึ่งเป็นแนวทางที่สามารถรวมข้อมูลเชิงสถิติและความไม่แน่นอนของข้อมูลเข้าด้วยกันได้อย่างมีประสิทธิภาพ โดยทั่วไปแบบจำลองสามารถเลือกใช้ในการประมาณค่าพารามิเตอร์ในรูปแบบ Maximum a Posteriori (MAP) ซึ่งเป็นวิธีที่ใช้ในการค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดภายใต้เงื่อนไขของข้อมูลที่มีอยู่ ผ่านอัลกอริทึม L-BFGS ซึ่งเป็นเทคนิค optimization ที่ช่วยให้การคำนวณทำได้รวดเร็วและมีเสถียรภาพ นอกจากนี้ FBProphet ยังรองรับการประมาณค่าแบบ Full Bayesian Inference ซึ่งเป็นแนวทางที่นำความไม่แน่นอนของพารามิเตอร์เข้ามาพิจารณาาร่วมในกระบวนการเรียนรู้ของโมเดล ทำให้แบบจำลองสามารถสร้างช่วงความเชื่อมั่นหรือช่วงความไม่แน่นอนของผลการพยากรณ์ได้อย่างเหมาะสม ส่งผลให้ผู้ใช้งานสามารถตีความความน่าเชื่อถือของผลการพยากรณ์ได้ชัดเจนมากยิ่งขึ้น

อีกหนึ่งจุดเด่นสำคัญของ FBProphet คือความสามารถในการปรับแต่งพารามิเตอร์ของแบบจำลองให้เหมาะสมกับลักษณะเฉพาะของข้อมูลอนุกรมเวลา ผู้ใช้งานสามารถกำหนดจำนวนจุดเปลี่ยนแนวโน้มของข้อมูล (changepoints) เพื่อให้โมเดลสามารถตรวจจับการเปลี่ยนแปลงของแนวโน้มในช่วงเวลาต่าง ๆ ได้ดีขึ้น รวมถึงสามารถเลือกประเภทของฤดูกาล (seasonality mode) ได้ทั้งแบบ additive และ multiplicative ตามลักษณะการเปลี่ยนแปลงของข้อมูล นอกจากนี้ยังสามารถกำหนดน้ำหนักหรืออิทธิพลของวันหยุดและเหตุการณ์พิเศษต่าง ๆ เพื่อสะท้อนผลกระทบที่เกิดขึ้นต่อข้อมูลในช่วงเวลานั้นได้อย่างเหมาะสม ความยืดหยุ่นดังกล่าวช่วยให้ FBProphet สามารถประยุกต์ใช้กับข้อมูลที่มีรูปแบบซับซ้อน มีความผันผวนสูง หรือมีพฤติกรรมเปลี่ยนแปลงตามช่วงเวลาได้อย่างมีประสิทธิภาพ

ด้วยคุณสมบัติในการจัดการข้อมูลอนุกรมเวลาที่มีความไม่แน่นอนและโครงสร้างข้อมูลที่ซับซ้อน FBProphet จึงได้รับความนิยมอย่างแพร่หลายในงานด้านการพยากรณ์หลากหลายประเภท ทั้งในด้านสิ่งแวดล้อม เศรษฐศาสตร์ พลังงาน และการบริหารจัดการข้อมูลเชิงธุรกิจ ตัวอย่างการประยุกต์ใช้งาน ได้แก่ การพยากรณ์ค่าฝุ่นละออง PM2.5 และดัชนีคุณภาพอากาศ การคาดการณ์ปริมาณการใช้พลังงานไฟฟ้า การวิเคราะห์ปริมาณการจราจร การคาดการณ์ยอดขายสินค้า ตลอดจนการติดตามแนวโน้มข้อมูลในระดับเมืองหรือระดับประเทศ ซึ่งสะท้อนให้เห็นถึงศักยภาพของ FBProphet ในการเป็นเครื่องมือสำคัญสำหรับการวิเคราะห์และพยากรณ์ข้อมูลอนุกรมเวลาในยุคปัจจุบัน

2.2 การประเมินประสิทธิภาพแบบจำลอง

ในการประเมินประสิทธิภาพของแบบจำลองสำหรับการพยากรณ์ข้อมูล มักนิยมใช้ตัวชี้วัดทางสถิติ (Evaluation Metrics) เพื่อวัดระดับความแม่นยำและความสามารถของแบบจำลองในการพยากรณ์ค่าที่ใกล้เคียงกับข้อมูลจริง สำหรับการวัดความแม่นยำของผลลัพธ์การพยากรณ์นั้นนิยมใช้ตัวชี้วัดหลัก 4 ค่าได้แก่ ค่าสัมประสิทธิ์การตัดสินใจ (R^2), ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) และค่าความคลาดเคลื่อนเฉลี่ยแบบร้อยละ (MAPE)

ค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination) ถูกแสดงในสมการที่ 3 ใช้สำหรับวัดสัดส่วนของความแปรปรวนของข้อมูลจริงที่สามารถอธิบายได้ด้วยแบบจำลอง โดยมีค่าอยู่ในช่วง 0 ถึง 1 ซึ่งค่าที่เข้าใกล้ 1 แสดงถึงความสามารถของแบบจำลองในการอธิบายข้อมูลได้ดี

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (2)$$

โดย N คือ จำนวนตัวอย่างทั้งหมด, Y_i คือ ค่าจริงของตัวแปรเป้าหมายในลำดับที่ i , $\hat{Y}_i$ คือ ค่าที่แบบจำลองพยากรณ์ได้ในลำดับที่ i และ $\bar{Y}$ คือ ค่าเฉลี่ยของข้อมูลจริงทั้งหมด

ถัดมาค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error, MSE) ดังสมการที่ 4 เป็นตัวชี้วัดที่แสดงค่าเฉลี่ยของผลต่างกำลังสองระหว่างค่าที่พยากรณ์ได้กับค่าจริงของข้อมูลทั้งหมด โดยค่า MSE ที่ต่ำบ่งบอกถึงความคลาดเคลื่อนที่น้อยและแบบจำลองมีความแม่นยำสูง

$$MSE = \frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2 \quad (3)$$

ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error, RMSE) เป็นการนำค่า MSE มาหารค่ารากที่สอง เพื่อให้มีหน่วยเดียวกับข้อมูลจริง ทำให้สามารถตีความผลลัพธ์ได้ง่ายขึ้น โดยค่า RMSE ที่ต่ำแสดงถึงประสิทธิภาพของแบบจำลองที่ดีดังสมการที่ 4

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad (4)$$

ต่อมาความคลาดเคลื่อนเฉลี่ยแบบร้อยละ (Mean Absolute Percentage Error, MAPE) ดังสมการที่ 5 ถูกใช้ในการประเมินความแม่นยำของแบบจำลอง โดยพิจารณาความคลาดเคลื่อนสัมพัทธ์ระหว่างค่าจริงและค่าที่พยากรณ์ในแต่ละจุดข้อมูล จากนั้นนำมาหาค่าเฉลี่ยและแสดงผลในรูปแบบร้อยละ ซึ่งช่วยให้สามารถตีความความแม่นยำของแบบจำลองได้อย่างชัดเจน

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100 \quad (5)$$

3. วิธีดำเนินการวิจัย

3.1 การเตรียมข้อมูล

ข้อมูล PM2.5 รายวัน (หน่วย: ไมโครกรัมต่อลูกบาศก์เมตร หรือ $\mu\text{g}/\text{m}^3$) ถูกดึงมาจากสถานีตรวจวัดคุณภาพอากาศหมายเลข 71T ซึ่งตั้งอยู่ที่สวนกาญจนาภิเษก ร.9 ผ่านระบบโดยช่วงเวลาของข้อมูลที่ใช้คือระหว่างวันที่ 1 มกราคม 2562 ถึงวันที่ 31 ธันวาคม 2567 รวมเป็นข้อมูลรายวันตลอดระยะเวลา 6 ปี (Pollution Control Department [9])

ข้อมูลดังกล่าวเปิดเผยผ่านระบบฐานข้อมูลคุณภาพอากาศของกรมควบคุมมลพิษ ซึ่งรวบรวมข้อมูลจากสถานีตรวจวัดคุณภาพอากาศทั่วประเทศแบบต่อเนื่อง สถานี 71T ถูกเลือกใช้ในการศึกษานี้เนื่องจากเป็นสถานีตรวจวัดที่ตั้งอยู่ในอำเภออรัญประเทศ และใกล้กับชายแดนในพื้นที่การบมมากที่สุด ในบรรดาสถานีที่มีข้อมูลย้อนหลังครบถ้วน

สำหรับชุดข้อมูลที่ใช้ในการวิจัยประกอบด้วยข้อมูลค่าฝุ่นละออง PM2.5 รายวันแบบค่าสูงสุด จำนวนทั้งสิ้น 2,192 ตัวอย่าง ครอบคลุมช่วงเวลา 6 ปี นั้นข้อมูลดังกล่าวมีลักษณะเป็นข้อมูลอนุกรมเวลาต่อเนื่องและครอบคลุมรูปแบบการเปลี่ยนแปลงตามฤดูกาลครบทั้ง 6 รอบปี จึงมีความเพียงพอสำหรับการพัฒนาแบบจำลองพยากรณ์ เนื่องจากสามารถแสดงทั้งแนวโน้ม และรูปแบบเชิงฤดูกาลของข้อมูลได้อย่างครบถ้วน นอกจากนี้ FBProphet ยังได้รับการออกแบบให้เหมาะสมกับข้อมูลอนุกรมเวลาที่มีการเปลี่ยนแปลงตามฤดูกาลและแนวโน้มในระยะยาว โดยอาศัยข้อมูลย้อนหลังหลายรอบของฤดูกาลในการประมาณค่าพารามิเตอร์ของแบบจำลอง ดังนั้นชุดข้อมูลจำนวน 2,192 ตัวอย่างจึงมีความเหมาะสมและเพียงพอสำหรับการเรียนรู้รูปแบบของข้อมูล

ในส่วนงานวิจัยนี้มีวัตถุประสงค์หลักเพื่อศึกษาการประยุกต์ใช้ FBProphet สำหรับการพยากรณ์ค่า PM2.5 และการประเมินความเหมาะสมของพารามิเตอร์ของแบบจำลอง จึงได้มุ่งเน้นการเปรียบเทียบกับแบบจำลองพื้นฐานหรือแบบจำลองชนิดอื่น อย่างไรก็ตามผู้วิจัยเสนอให้การเปรียบเทียบกับแบบจำลองพื้นฐาน เช่น Naïve Forecast, ARIMA หรือ SARIMA เป็นแนวทางสำหรับการศึกษาในอนาคตต่อไป

3.2 การทำความสะอาดข้อมูล (Data Cleaning)

ก่อนการสร้างแบบจำลองนั้นข้อมูลค่าฝุ่นละออง PM_{2.5} รายวันได้ผ่านกระบวนการตรวจสอบคุณภาพข้อมูล (Data Quality Assessment) และการทำความสะอาดข้อมูล (Data Cleaning) เพื่อให้ชุดข้อมูลมีความสมบูรณ์และเหมาะสมสำหรับการวิเคราะห์ โดยเริ่มจากการตรวจสอบค่าที่ขาดหาย (Missing Values) พบว่ามีข้อมูลสูญหายจำนวน 23 ค่า คิดเป็นร้อยละ 1.05 ของข้อมูลทั้งหมด ซึ่งได้ดำเนินการแทนค่าด้วยวิธี Forward Fill เพื่อรักษาความต่อเนื่องของข้อมูลอนุกรมเวลา จากนั้นจึงทำการตรวจจับข้อมูลผิดปกติ (Outlier Detection) โดยใช้ค่า Z-score และกำหนดเกณฑ์การพิจารณาที่ $|Z| > 3$ ผลการตรวจสอบพบข้อมูลผิดปกติจำนวน 44 จุด หรือคิดเป็นร้อยละ 2.01 ของข้อมูลทั้งหมด หลังจากนั้นได้ลดผลกระทบของสัญญาณรบกวนในข้อมูลด้วยเทคนิค Rolling Median โดยใช้หน้าต่างการคำนวณ (Window Size) เท่ากับ 7 วัน เพื่อคงไว้ซึ่งแนวโน้มและรูปแบบเชิงฤดูกาลของข้อมูล พร้อมทั้งลดความผันผวนระยะสั้นที่อาจเกิดจากค่าผิดปกติหรือความคลาดเคลื่อนในการตรวจวัด เมื่อข้อมูลผ่านกระบวนการทำความสะอาดเรียบร้อยแล้ว จึงได้แปลงโครงสร้างข้อมูลให้อยู่ในรูปแบบที่สอดคล้องกับข้อกำหนดของแบบจำลอง FBProphet โดยกำหนดคอลัมน์วันที่เป็น ds และค่าความเข้มข้นของ PM_{2.5} เป็น y จากนั้นจึงจัดเรียงข้อมูลตามลำดับเวลา (Ascending Timestamp) เพื่อให้ข้อมูลมีความต่อเนื่องก่อนนำไปใช้ในการฝึกและประเมินแบบจำลองพยากรณ์ต่อไป

เพื่อป้องกันปัญหา Data Leakage กระบวนการแบ่งข้อมูลออกเป็นชุดฝึก (Training Set) และชุดทดสอบ (Testing Set) ถูกดำเนินการตามลำดับเวลาก่อนการประเมินแบบจำลอง โดยข้อมูลในชุดทดสอบไม่ได้ถูกนำมาใช้ในการปรับแต่งพารามิเตอร์หรือประเมินกระบวนการเรียนรู้ของแบบจำลอง ทำให้ผลการประเมินสะท้อนสมรรถนะของแบบจำลองต่อข้อมูลที่ไม่เคยพบมาก่อนอย่างเหมาะสม

3.3 การปรับแต่งแบบจำลอง (Hyperparameter Tuning)

หลังจากดำเนินการทำความสะอาดข้อมูลและจัดเตรียมข้อมูลให้อยู่ในรูปแบบที่เหมาะสมแล้ว ข้อมูลทั้งหมดถูกแบ่งออกเป็น ชุดฝึกและ ชุดทดสอบ ตามลำดับเวลาของข้อมูลในสัดส่วน 80:20 เพื่อรักษาความต่อเนื่องของข้อมูลอนุกรมเวลา และป้องกันการรั่วไหลของข้อมูล (Data Leakage) โดยชุดฝึกประกอบด้วยข้อมูลจำนวน 1,753 ตัวอย่าง สำหรับใช้ในการสร้างแบบจำลองและปรับแต่งพารามิเตอร์ ส่วนชุดทดสอบประกอบด้วยข้อมูลจำนวน 439 ตัวอย่าง ซึ่งใช้สำหรับประเมินประสิทธิภาพของแบบจำลองกับข้อมูลที่ไม่เคยใช้ในการฝึกมาก่อน

การปรับแต่งพารามิเตอร์ของแบบจำลอง FBProphet ดำเนินการด้วยวิธี Manual Grid Search โดยมุ่งเน้นการปรับค่า changepoint_prior_scale ซึ่งเป็นพารามิเตอร์ที่มีผลต่อความยืดหยุ่นของแนวโน้มของข้อมูล เนื่องจากเป็นพารามิเตอร์ที่มีอิทธิพลต่อประสิทธิภาพของแบบจำลองมากที่สุดในการศึกษานี้ โดยกำหนดค่าที่ใช้ในการทดลอง ได้แก่ 0.05, 0.10 และ 0.30 จากนั้นประเมินประสิทธิภาพของแต่ละแบบจำลองด้วยค่า Mean Absolute Error และเลือกค่าที่ให้ความคลาดเคลื่อนต่ำที่สุดเป็นค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองขั้นสุดท้าย

3.4 การพยากรณ์ล่วงหน้า

เมื่อได้แบบจำลอง FBProphet ที่ผ่านการปรับแต่งพารามิเตอร์แล้ว จึงนำแบบจำลองดังกล่าวมาใช้ในการพยากรณ์ค่าฝุ่นละออง PM_{2.5} รายวันแบบค่าสูงสุดล่วงหน้าเป็นระยะเวลา 365 วัน โดยอาศัยข้อมูลย้อนหลังที่ผ่านการทำความสะอาดและผ่านกระบวนการเรียนรู้ของแบบจำลองแล้ว ผลการพยากรณ์ประกอบด้วยค่าที่คาดการณ์ได้ในแต่ละวัน พร้อมทั้งช่วงความเชื่อมั่น (Prediction Interval) ซึ่งช่วยแสดงระดับความไม่แน่นอนของผลการพยากรณ์ การพยากรณ์ดังกล่าวมีวัตถุประสงค์เพื่อศึกษารูปแบบแนวโน้มและการเปลี่ยนแปลงตามฤดูกาลของค่าฝุ่น PM_{2.5} รวมทั้งประเมินศักยภาพของแบบจำลองในการนำไปประยุกต์ใช้เพื่อสนับสนุนการวางแผนภารกิจของอากาศยานไร้คนขับต่อไป

3.5 การวิเคราะห์ผล

ผลการพยากรณ์ที่ได้จากแบบจำลอง FBProphet ถูกนำมาประเมินประสิทธิภาพโดยเปรียบเทียบค่าที่พยากรณ์กับค่าที่ตรวจวัดจริง ทั้งในชุดฝึกและชุดทดสอบ โดยใช้ตัวชี้วัดทางสถิติ ได้แก่ Coefficient of Determination , Mean Squared Error , Root Mean Squared Error และ Mean Absolute Percentage Error เพื่อประเมินความสามารถของแบบจำลองในการอธิบายข้อมูลและความแม่นยำของการพยากรณ์ นอกจากนี้ ยังทำการวิเคราะห์แนวโน้มและรูปแบบเชิงฤดูกาลของค่าฝุ่น PM2.5 ที่ได้จากแบบจำลอง เพื่อพิจารณาความเหมาะสมของผลการพยากรณ์สำหรับการนำไปใช้สนับสนุนการวางแผนการปฏิบัติงาน การบริหารจัดการความเสี่ยงด้านคุณภาพอากาศ และการกำหนดช่วงเวลาที่เหมาะสมสำหรับการปฏิบัติการกิจของอากาศยานไร้คนขับในพื้นที่ศึกษาต่อไป


4. ผลการศึกษา

4.1 ผลการทำความสะอาดข้อมูล

หลังจากรวบรวมข้อมูลค่าฝุ่น PM2.5 รายวันจากสถานีตรวจวัด 71T สวนกาญจนาภิเษก ร.9 จังหวัดสระแก้ว ดำเนินการทำความสะอาดข้อมูลเพื่อให้พร้อมสำหรับการพยากรณ์ โดยชุดข้อมูลครอบคลุมระยะเวลาดังแต่วันที่ 1 มกราคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2567 รวมเป็นเวลา 6 ปี มีข้อมูลทั้งหมด 2,192 รายการ


ในการตรวจสอบพบว่าข้อมูลบางช่วงมีค่าที่ขาดหายทั้งหมด 23 ค่า หรือคิดเป็นประมาณร้อยละ 1.05 ของข้อมูลทั้งหมด ซึ่งถือว่าอยู่ในระดับที่สามารถบริหารจัดการได้โดยไม่กระทบต่อความแม่นยำของแบบจำลอง จากนั้นจึงมีการจัดเรียงข้อมูลตามลำดับเวลา และดำเนินการเติมค่าที่ขาดไปด้วยวิธีการแทนค่าด้วยข้อมูลก่อนหน้า (Forward Fill) เพื่อคงลักษณะต่อเนื่องของชุดข้อมูลไว้ให้สมบูรณ์ที่สุด

หลังจากผ่านกระบวนการทำความสะอาดข้อมูลเรียบร้อยแล้ว จึงสามารถนำข้อมูลที่ได้รับการปรับปรุงนี้ไปวิเคราะห์และแสดงภาพแนวโน้มการเปลี่ยนแปลงของค่าฝุ่น PM2.5 รายวันได้ โดยจากการแสดงผลแบบ Time Series พบว่าค่าฝุ่นในพื้นที่ดังกล่าวมีแนวโน้มสูงขึ้นในช่วงฤดูหนาวของแต่ละปี โดยเฉพาะในช่วงต้นปี ซึ่งบางช่วงเวลาค่าฝุ่นสูงเกินกว่าค่ามาตรฐานของประเทศไทยที่กำหนดไว้ที่ 37.5 ไมโครกรัมต่อลูกบาศก์เมตรอย่างชัดเจนดังภาพที่ 1




ภาพที่ 1 ข้อมูลค่าฝุ่น PM2.5 รายวันจากสถานีตรวจวัด 71T สวนกาญจนาภิเษก ร.9 จังหวัดสระแก้ว

ในการวิเคราะห์ข้อมูลฝุ่น PM2.5 จากสถานี 71T ใช้ค่า Z-score เพื่อคัดกรองค่าที่เบี่ยงเบนจากค่าเฉลี่ยอย่างรุนแรง โดยพิจารณาค่า Z ที่มากกว่า 3 ซึ่งหมายถึงข้อมูลที่อยู่ไกลจากค่าเฉลี่ยมากกว่า 3 เท่าของส่วนเบี่ยงเบนมาตรฐาน การใช้เกณฑ์นี้ช่วยระบุข้อมูลที่มีความผิดปกติ ได้อย่างแม่นยำ โดยจุดวงกลมในภาพ 2 แสดงค่าที่ผิดปกติซึ่งอาจมีสาเหตุจากเหตุการณ์พิเศษหรือความคลาดเคลื่อนในการวัด พบว่ามีข้อมูลผิดปกติจำนวน 44 จุด คิดเป็น 2.01% ของข้อมูลทั้งหมด



ภาพที่ 2 ค่าผิดปกติในข้อมูลค่าฝุ่น PM2.5 รายวันจากสถานีตรวจวัด 71T สวนกาญจนาภิเษก ร.9 จังหวัดสระแก้ว

ข้อมูล PM2.5 รายวันจากสถานี 71T หลังจากตรวจพบข้อมูลที่มีความผิดปกติแล้ว ได้รับการทำความสะอาดข้อมูล และจากจัดการกับข้อมูลผิดปกติแล้วได้ถูกแสดงในภาพที่ 3 ข้อมูลที่เหลือถูกปรับให้เรียบขึ้นด้วยเทคนิค Rolling Median แบบ 7 วัน ของ Stone [10] เพื่อลดความผันผวนระยะสั้นโดยไม่กระทบต่อแนวโน้มหลักของข้อมูล การใช้ค่ามัธยฐานมีความเหมาะสมสำหรับการจัดการข้อมูลที่มีค่า outlier และสัญญาณรบกวนลักษณะพุ่งสูง (Spiky Noise) ซึ่งพบได้บ่อยในข้อมูลอนุกรมเวลาด้านสิ่งแวดล้อม เทคนิคดังกล่าวช่วยลดผลกระทบของค่าผิดปกติ และช่วยแยกความผันผวนที่ไม่ต้องการออกจากแนวโน้มที่แท้จริงของข้อมูลได้อย่างมีประสิทธิภาพ โดยยังคงลักษณะสำคัญของข้อมูลไว้ แม้ในกรณีที่ไม่สามารถระบุรูปแบบของสัญญาณรบกวนได้อย่างชัดเจน




ภาพที่ 3 ข้อมูลค่าฝุ่น PM2.5 รายวันจากสถานีตรวจวัด 71T ที่ได้รับการทำความสะอาดแล้ว

4.2 ผลการวิเคราะห์ข้อมูลเชิงสำรวจ (Exploratory Data Analysis, EDA)


หลังจากที่ได้ข้อมูลค่าฝุ่น PM2.5 รายวันที่ได้รับการทำความสะอาดแล้วนั้น ต่อมาได้ทำการวิเคราะห์ข้อมูลเชิงสำรวจ ซึ่งเป็นขั้นตอนสำคัญในการทำความเข้าใจลักษณะและแนวโน้มของค่าฝุ่น PM2.5 รายวันในพื้นที่ศึกษา ก่อนเข้าสู่กระบวนการสร้างแบบจำลองพยากรณ์ ในการวิเคราะห์ค่าฝุ่น PM2.5 นั้นได้ใช้แผนภาพกล่อง (Boxplot) เพื่อแสดงการกระจายของข้อมูลในสองมิติ ได้แก่ ตามวันในสัปดาห์ และตามเดือนในรอบปี ซึ่งช่วยให้เห็นลักษณะเชิงเวลา (Temporal Pattern) และการแปรปรวนของค่าฝุ่นในระดับต่าง อย่างชัดเจน

เริ่มจากการวิเคราะห์การกระจายค่าฝุ่น PM2.5 ตามวันในสัปดาห์ดังภาพที่ 4 พบว่าค่าฝุ่นมีลักษณะกระจายคล้ายกันตลอดทั้งสัปดาห์ โดยค่ามัธยฐานของแต่ละวันอยู่ในช่วงประมาณ 10–15 $\mu\text{g}/\text{m}^3$ ซึ่งต่ำกว่าค่ามาตรฐานของประเทศไทย (37.5 $\mu\text{g}/\text{m}^3$) อย่างไรก็ตาม ในทุกวันยังคงพบค่าฝุ่นที่พุ่งสูงผิดปกติอยู่เป็นระยะ แสดงให้เห็นถึงความผันผวนในระดับรายวันของมลพิษทางอากาศ แม้จะไม่มี ความแตกต่างที่ชัดเจนระหว่างวันธรรมดาและวันหยุดสุดสัปดาห์ แต่ลักษณะของข้อมูลแสดงให้เห็นว่าทุกวันมีโอกาสเกิดค่าฝุ่นสูงกว่าปกติได้ จึงควรมีการเฝ้าระวังอย่างต่อเนื่องโดยไม่จำกัดเฉพาะบางวัน

ต่อมาเมื่อพิจารณาการกระจายของค่าฝุ่น PM2.5 รายเดือนดังภาพที่ 5 พบว่ามีลักษณะตามฤดูกาลอย่างชัดเจน โดยในช่วงฤดูหนาวและต้นปี เช่น เดือนมกราคม กุมภาพันธ์ และมีนาคม ค่าฝุ่น PM2.5 มีแนวโน้มสูงกว่าช่วงอื่นอย่างเห็นได้ชัด โดยเฉพาะเดือนมกราคมซึ่งพบค่ามัธยฐานสูงที่สุด และมีการกระจายของข้อมูลในช่วงบนกว้าง แสดงถึงความรุนแรงของสถานการณ์ฝุ่นในช่วงเวลาดังกล่าว ในทางกลับกัน ช่วงกลางปีซึ่งตรงกับฤดูฝน ได้แก่ เดือนมิถุนายน กรกฎาคม และสิงหาคม ค่าฝุ่นเฉลี่ยลดลงอย่างชัดเจน โดยส่วนใหญ่มีค่าต่ำกว่า 15 $\mu\text{g}/\text{m}^3$ และมี outlier ค่อนข้างน้อย แสดงถึงผลของสภาพอากาศที่มีฝนตกช่วยชะล้างมลพิษในบรรยากาศได้อย่างมีประสิทธิภาพ ส่วนในช่วงปลายปี เช่น ตุลาคมถึงธันวาคม ค่าฝุ่นเริ่มสูงขึ้นอีกครั้ง ซึ่งเป็นสัญญาณเตือนถึงการเข้าสู่ฤดูฝุ่นอีกครั้งตามลำดับ ภาพรวมจากการวิเคราะห์ EDA นี้ชี้ให้เห็นว่า ปัจจัยทางฤดูกาลมีอิทธิพลอย่างมีนัยสำคัญต่อค่าฝุ่น PM2.5 โดยเฉพาะในช่วงฤดูหนาวที่มีความเสี่ยงสูงต่อการเกิดวิกฤตมลพิษ



ภาพที่ 4 รูปแบบการกระจายค่าฝุ่น PM2.5 ตามวันในสัปดาห์



ภาพที่ 5 รูปแบบกระจายของค่าฝุ่น PM2.5 รายเดือน

4.3 ผลการปรับแต่ง Hyperparameter สำหรับ FBProphet

เพื่อให้ได้แบบจำลองการพยากรณ์ค่า PM2.5 ที่มีความแม่นยำและสอดคล้องกับลักษณะข้อมูลสิ่งแวดล้อมในพื้นที่ชายแดน จึงได้ดำเนินการปรับแต่งพารามิเตอร์ของโมเดล FBProphet โดยใช้แนวทางแบบ Manual Grid Search โดยเฉพาะในส่วนของ changepoint_prior_scale ซึ่งควบคุมความยืดหยุ่นของแนวโน้ม (trend flexibility) ได้ทดสอบหลายค่าระหว่าง 0.05, 0.1 และ 0.3 โดยใช้ Mean Absolute Error เป็นตัวชี้วัดประสิทธิภาพ พบว่าค่าที่เหมาะสมที่สุดคือ 0.3 ซึ่งให้ค่า MAE ต่ำที่สุด จึงเลือกใช้ในการสร้างแบบจำลองสุดท้าย ทั้งนี้ โมเดลถูกฝึกด้วยชุดข้อมูลที่แบ่งออกเป็น ชุดฝึกจำนวน 1,753 ตัวอย่าง ในช่วงวันที่ 1 มกราคม 2019 ถึง 19 ตุลาคม 2023 และ ชุดทดสอบ จำนวน 439 ตัวอย่าง ครอบคลุมช่วงวันที่ 20 ตุลาคม 2023 ถึง 31 ธันวาคม 2024

เพื่อให้โมเดลแสดงลักษณะเชิงฤดูกาลของข้อมูล PM2.5 ได้เหมาะสมได้เพิ่ม seasonality แบบกำหนดเอง ได้แก่ รายเดือน (30.5 วัน) และรายปีแบบ long-term (365.25 วัน) ขณะเดียวกันยังมีการกำหนดพารามิเตอร์สำคัญอื่นๆ ให้เหมาะสมกับลักษณะของข้อมูลและวัตถุประสงค์ในการใช้งานเชิงพื้นที่ ดังสรุปในตาราง 1 ด้านล่างนี้

ตารางที่ 1 พารามิเตอร์ที่ใช้ในการสร้างแบบจำลอง FBProphet


พารามิเตอร์	ค่า	คำอธิบาย
changepoint_prior_scale	0.3	ควบคุมความยืดหยุ่นของการเปลี่ยนแปลงแนวโน้ม (Trend) ของแบบจำลอง โดยค่าที่สูงขึ้นทำให้แบบจำลองสามารถตอบสนองต่อการเปลี่ยนแปลงของข้อมูลได้มากขึ้น
changepoint_range	0.8	กำหนดสัดส่วนของข้อมูลย้อนหลังที่ใช้ในการตรวจหาจุดเปลี่ยนแนวโน้ม (Changepoints) ของข้อมูลอนุกรมเวลา
n_changepoints	25	กำหนดจำนวนจุดเปลี่ยนแนวโน้มสูงสุดที่แบบจำลองสามารถประมาณได้จากข้อมูล
seasonality_mode	additive	กำหนดรูปแบบการรวมองค์ประกอบเชิงฤดูกาลเข้ากับแนวโน้มของข้อมูล โดยใช้แบบเชิงบวก (Additive Model)
seasonality_prior_scale	10	ควบคุมความยืดหยุ่นขององค์ประกอบเชิงฤดูกาล (Seasonality) ในการประมาณแบบจำลอง
interval_width	0.8	กำหนดระดับช่วงความเชื่อมั่น (Prediction Interval) ของผลการพยากรณ์ที่ร้อยละ 80
mcmc_samples	0	กำหนดให้ประมาณค่าพารามิเตอร์ด้วยวิธี Maximum a Posteriori (MAP)

จากตารางที่ 1 แสดงพารามิเตอร์ที่ใช้ในการสร้างแบบจำลอง FBProphet สำหรับการพยากรณ์ค่าฝุ่น PM2.5 โดยกำหนดค่า changepoint_prior_scale เท่ากับ 0.3 เพื่อควบคุมความยืดหยุ่นของการเปลี่ยนแปลงแนวโน้ม (Trend) ให้สามารถตอบสนองต่อการเปลี่ยนแปลงของข้อมูลได้โดยไม่เกิดการปรับตัวมากเกินไป ขณะที่ changepoint_range กำหนดเป็น 0.8 เพื่อให้แบบจำลองค้นหาจุดเปลี่ยนแนวโน้มจากข้อมูลร้อยละ 80 แรกของชุดข้อมูล และกำหนด n_changepoints เท่ากับ 25 เพื่อจำกัดจำนวนจุดเปลี่ยนแนวโน้มที่แบบจำลองสามารถเรียนรู้ได้ สำหรับองค์ประกอบเชิงฤดูกาล ได้เลือกใช้ seasonality_mode แบบ additive เนื่องจากข้อมูล PM2.5 มีรูปแบบฤดูกาลที่มีขนาดการเปลี่ยนแปลงค่อนข้างคงที่ตลอดช่วงเวลาที่ศึกษา พร้อมกำหนด seasonality_prior_scale เท่ากับ 10 เพื่อเพิ่มความยืดหยุ่นในการเรียนรู้รูปแบบเชิงฤดูกาล นอกจากนี้ กำหนด interval_width เท่ากับ 0.8 เพื่อให้แบบจำลองรายงานช่วงความเชื่อมั่นของผลการพยากรณ์ที่ระดับร้อยละ


ละ 80 ส่วน `mcmc_samples` ถูกกำหนดเป็น 0 เพื่อให้แบบจำลองประมาณค่าพารามิเตอร์ด้วยวิธี Maximum a Posteriori ซึ่งช่วยลดเวลาในการคำนวณและเหมาะสมกับการศึกษาครั้งนี้

ภาพที่ 6 นำเสนอรูปแบบการทำนายค่าฝุ่น PM2.5 รายวันโดยใช้โมเดล FBProphet ครอบคลุมช่วงเวลา 1 มกราคม 2019 ถึง 31 ธันวาคม 2024 โดยมีการแบ่งข้อมูลออกเป็น ชุดฝึก (Train) และ ชุดทดสอบ (Test) ด้วยเส้นประแนวตั้งสีแดงในวันที่ 20 ตุลาคม 2023 เพื่อแยกช่วงข้อมูลที่ใช้ฝึกและทดสอบ โดย FBProphet ใช้แนวทางแบบ decomposition โดยจำลององค์ประกอบหลักของชุดข้อมูล ได้แก่ เทรนด์ (trend), ฤดูกาล (seasonality) และผลกระทบจากเหตุการณ์พิเศษ โมเดลสามารถจับลักษณะการเปลี่ยนแปลงของค่าฝุ่นที่มีรูปแบบตามฤดูกาลได้อย่างชัดเจน เช่น การเพิ่มขึ้นของ PM2.5 ในช่วงปลายปีถึงต้นปี ซึ่งมักสัมพันธ์กับสภาพอากาศที่ปิด ทำให้มลพิษสะสม เส้นพยากรณ์สีน้ำเงินที่ปรากฏในกราฟแสดงถึงการคาดการณ์ที่ต่อเนื่องจากช่วงฝึกไปยังช่วงทดสอบ โดยสามารถรักษารูปแบบการเปลี่ยนแปลงตามฤดูกาลไว้ได้

ต่อมา ภาพที่ 7 แสดงการประเมินผลการพยากรณ์ของโมเดล FBProphet โดยเปรียบเทียบระหว่างค่าจริงของ PM2.5 กับค่าที่โมเดลทำนายได้ ทั้งในชุดฝึกและชุดทดสอบผ่านกราฟกระจาย เพื่อพิจารณาความแม่นยำของการทำนาย พบว่า ค่า R^2 ของชุดฝึกอยู่ที่ 0.636 และ RMSE เท่ากับ 7.54 แสดงว่าโมเดลสามารถเรียนรู้แนวโน้มของข้อมูลในอดีตได้ดีระดับหนึ่ง ต่อมาเมื่อประเมินกับชุดทดสอบ ค่า R^2 อยู่ที่ 0.626 และ RMSE เท่ากับ 7.29 ซึ่งใกล้เคียงกับชุดฝึก แสดงให้เห็นว่าโมเดลสามารถพยากรณ์ค่าฝุ่น PM2.5 ในอนาคตได้อย่างน่าเชื่อถือ โดยไม่เกิดปัญหา overfitting ทั้งนี้เห็นได้ว่า FBProphet นั้นมีเหมาะสมกับการวิเคราะห์ข้อมูลเชิงเวลาที่มีความผันแปรตามฤดูกาล เช่น ค่าฝุ่นละอองในบริบทของประเทศไทย




ภาพที่ 6 การทำนายค่าฝุ่น PM2.5 รายวันโดยใช้โมเดล FBProphet ครอบคลุมช่วงเวลา 1 มกราคม 2019 ถึง 31 ธันวาคม 2024



ภาพที่ 7 การประเมินผลการพยากรณ์ของโมเดล FBProphet

หลังจากการทำ Train Test Split แล้ว ได้นำข้อมูลมาทำการพยากรณ์ล่วงหน้าใน ปี 2025 ผลการพยากรณ์ค่าฝุ่น PM2.5 รายวัน ครอบคลุมระยะเวลา 7 ปี ตั้งแต่ปี 2019 ถึงปลายปี 2025 ถูกแสดงในภาพที่ 8 โดยแบ่งข้อมูลเป็นสองส่วน คือ ช่วงฝึกโมเดลจนถึงสิ้นปี 2024 และช่วงพยากรณ์ล่วงหน้าตลอดปี 2025 สามารถเรียนรู้และจับแนวโน้มของค่าฝุ่น PM2.5 ได้ในระดับที่น่าพอใจ โดยรูปแบบของข้อมูลสะท้อนให้เห็นการเปลี่ยนแปลงตามฤดูกาลอย่างชัดเจน กล่าวคือ ค่าฝุ่นมักพุ่งสูงขึ้นในช่วงต้นปี ซึ่งสอดคล้องกับฤดูหนาวและสภาพอากาศนิ่งในประเทศไทย และลดลงในช่วงกลางปีซึ่งเป็นฤดูฝนและฤดูร้อนที่อากาศถ่ายเทได้ดีขึ้น ส่งผลให้ค่าฝุ่นลดลงโดยธรรมชาติ แม้ว่าแนวโน้มโดยรวมจะสามารถอธิบายได้ดี แต่ในบางช่วงเวลา โมเดลยังมีข้อจำกัดในการจับความเปลี่ยนแปลงอย่างฉับพลันของค่าฝุ่น PM2.5 ที่อาจเกิดจากเหตุการณ์เฉพาะหน้า เช่น การเผาในที่โล่ง การจราจรหนาแน่น หรือสภาพอากาศที่เปลี่ยนแปลงอย่างรวดเร็ว




ภาพที่ 8 การพยากรณ์ค่าฝุ่น PM2.5 รายวัน ครอบคลุมระยะเวลา 7 ปี ตั้งแต่ปี 2019 ถึงปลายปี 2025

เมื่อพิจารณาการพยากรณ์ค่าฝุ่น PM2.5 รายวันโดยเฉพาะในปี 2025 ดังภาพที่ 9 สามารถอธิบายแนวโน้มแบบละเอียดในแต่ละเดือนได้ดังนี้ ช่วงแรกมกราคม ถึง กุมภาพันธ์ 2025 พบว่า ค่าฝุ่นเริ่มต้นปีในระดับสูง โดยเฉพาะช่วงปลายมกราคมถึงต้นกุมภาพันธ์ที่ PM2.5 พุ่งเกินค่ามาตรฐาน 37.5 µg/m³ อย่างชัดเจน เป็นช่วงที่อากาศเย็น อากาศนิ่ง และความชื้นต่ำซึ่งเอื้อต่อการสะสมของฝุ่นละออง

ต่อมาเดือนมีนาคม ถึง เมษายน นั้นค่าฝุ่นเริ่มลดลงอย่างต่อเนื่อง แต่ยังคงอยู่ในระดับปานกลาง โดยมีการแกว่งตัวบ้างในช่วงสงกรานต์ อันอาจเชื่อมโยงกับกิจกรรมในพื้นที่เปิดโล่งและสภาพอากาศที่ยังแห้งอยู่ จากนั้นในช่วงเดือนพฤษภาคม ถึง สิงหาคม ซึ่งช่วงนี้เป็นช่วงที่ค่าฝุ่นลดลงอย่างมีนัยสำคัญ และอยู่ในระดับต่ำสุดของปี โดยเฉพาะในเดือนมิถุนายนถึงกรกฎาคม ค่าฝุ่นบางวันอยู่ต่ำกว่า 10 µg/m³ ซึ่งสอดคล้องกับฤดูฝนที่มีลมและฝนช่วยชะล้างมลพิษในอากาศให้ตกลงมาที่พื้น

ถัดมาในเดือนกันยายน ถึง ตุลาคม ค่าฝุ่นเองเริ่มขยับขึ้นอีกครั้งอย่างค่อยเป็นค่อยไปแสดงให้เห็นการเปลี่ยนผ่านจากฤดูฝนสู่ฤดูหนาวตอนต้น มีแนวโน้มที่จะเข้าสู่ช่วงการสะสมของฝุ่น สุดท้ายเดือนพฤศจิกายน ถึง ธันวาคม ในช่วงนี้ค่าฝุ่นเพิ่มขึ้นต่อเนื่อง โดยเฉพาะปลายเดือนพฤศจิกายนเป็นต้นไป PM2.5 เริ่มไต่ระดับสูงขึ้นชัดเจน จนแตะระดับเสี่ยงอีกครั้งในปลายธันวาคม ซึ่งเป็นสัญญาณเตือนอย่างชัดเจนก่อนเข้าสู่ช่วงวิกฤตฝุ่นปลายปีถึงต้นของปีถัดไป



ภาพที่ 9 การพยากรณ์ค่าฝุ่น PM2.5 ในช่วงปี 2025

5. อภิปรายผล

การทำความสะอาดข้อมูลอย่างเป็นระบบก่อนนำข้อมูลไปใช้ในการพยากรณ์มีความสำคัญอย่างยิ่ง เนื่องจากช่วยให้โมเดลเรียนรู้จากข้อมูลที่มีความน่าเชื่อถือและสอดคล้องกับความเป็นจริง การลบค่าผิดปกติและจัดการกับค่าที่ขาดหาย ช่วยลดโอกาสที่โมเดลจะเกิดการเรียนรู้แบบผิดพลาดหรือเข้าใจแนวโน้มที่คลาดเคลื่อน นอกจากนี้ การจัดรูปแบบวันที่ให้อยู่ในรูปแบบที่ FBProphet รองรับ รวมถึงยังช่วยให้โมเดลประมวลผลลำดับเวลาของข้อมูลได้อย่างถูกต้อง ส่งผลให้การพยากรณ์มีความแม่นยำมากขึ้น ทั้งนี้ การใช้ข้อมูลรายวันต่อเนื่องตลอดระยะเวลา 6 ปี ทำให้โมเดลสามารถตรวจจับแนวโน้มและรูปแบบตามฤดูกาลได้ชัดเจน

ต่อมาเมื่อเปรียบเทียบผลการปรับแต่งพารามิเตอร์และ Manual Grid Search ในการพัฒนาโมเดล FBProphet กับงานวิจัยที่เกี่ยวข้องหลายฉบับ พบว่าการปรับค่าพารามิเตอร์ในงานวิจัยนี้มีความสมเหตุสมผลและช่วยเพิ่มความสามารถในการพยากรณ์ของแบบจำลองได้อย่างชัดเจน โดยเฉพาะการเลือกค่า changepoint_prior_scale อย่างเหมาะสม ทำให้แบบจำลองสามารถเรียนรู้การเปลี่ยนแปลงแนวโน้มของค่าฝุ่น PM2.5 ที่เกิดขึ้นตามฤดูกาลได้แม่นยำขึ้น โดยแบบจำลองที่ได้มีค่า RMSE เท่ากับ $7.29 \mu\text{g}/\text{m}^3$ ซึ่งอยู่ในระดับใกล้เคียงกับโมเดลที่ผ่านการ tuning อย่างเป็นระบบในงานของ Panisa Puripanic [7] ที่ใช้ Grid Search ร่วมกับ Cross-Validation และได้ค่า RMSE เท่ากับ 7.44

เมื่อเทียบกับงานของ Songpon Klerkkidakan [2]) ที่ใช้โมเดล CNN ร่วมกับ LSTM บนภาพถ่ายท้องฟ้า แม้จะเป็นการใช้ข้อมูลที่แตกต่างกันแต่ค่า RMSE ยังสูงถึง 11.39 ซึ่งอาจสะท้อนถึงข้อจำกัดด้านความไม่แน่นอนของแสงและเมฆในภาพ ต่อในด้านความง่ายและไม่ยุ่งยากนั้น FBProphet จึงยังเป็นทางเลือกที่ดี โดยเฉพาะในบริบทที่ต้องการการพยากรณ์ระยะกลางถึงยาว และต้องการอธิบายแนวโน้มตามฤดูกาล ซึ่งโมเดลนี้สามารถแสดงผลพยากรณ์ได้ชัดเจน เข้าใจง่าย และสามารถนำไปใช้วางแผนในระดับพื้นที่ เช่น การบินโดรนหรือเตือนภัยล่วงหน้าได้อย่างมีประสิทธิภาพ นอกจากนี้ ยังดีกว่าโมเดล SARIMA อย่างชัดเจน โดยมีค่า RMSE ที่ 11.20 ตามที่ Saranthon Maungmee and Pongpat Chaisiripan [5] รายงานไว้

อย่างไรก็ตามโมเดล LSTM ของ Sriruk Srithongchai [3] จะให้ค่า RMSE ต่ำเพียง 4.55 และแม่นยำกว่า FBProphet ในแง่ตัวเลข แต่โมเดลนี้ต้องใช้ข้อมูลหลายตัวแปร ซึ่งบางสถานีอาจไม่มีครบ และไม่สามารถอธิบายแนวโน้มตามฤดูกาลได้ชัดเจนเท่ากับ FBProphet และมีความยุ่งยากมากกว่า

สุดท้ายการนำผลการพยากรณ์ค่าฝุ่น PM2.5 ไปใช้ในการวางแผนเส้นทางการบินของอากาศยานไร้คนขับ (UAV) เพื่อภารกิจตรวจการณ์ ถือเป็นแนวทางเชิงรุกที่มีความจำเป็นอย่างยิ่ง โดยเฉพาะในพื้นที่ชายแดน เช่น อำเภอรัญประเทศ จังหวัดสระแก้ว ที่มีบทบาทสำคัญต่อความมั่นคง การค้า และการเฝ้าระวังการลักลอบเข้าเมืองหรือเหตุผิดปกติ โดย UAV ที่

ปฏิบัติหน้าที่ในพื้นที่ดังกล่าวต้องทำงานในสภาพอากาศกลางแจ้งอย่างต่อเนื่อง ดังนั้นข้อมูลคุณภาพอากาศโดยเฉพาะค่าฝุ่นละออง PM2.5 ซึ่งส่งผลกระทบต่อทัศนวิสัย กลไกของอากาศยาน และประสิทธิภาพของกล้องตรวจการณ์ จึงมีความสำคัญต่อการตัดสินใจวางแผนบิน

การพยากรณ์ PM2.5 ด้วยโมเดล FBProphet ที่สามารถให้ผลล่วงหน้าได้หลายวันหรือแม้กระทั่งรายปี ช่วยให้เจ้าหน้าที่สามารถเลือกช่วงเวลาที่เหมาะสมในการปล่อย UAV ทำหน้าที่บินลาดตระเวนได้อย่างแม่นยำ โดยหลีกเลี่ยงช่วงที่ค่าฝุ่นเกินมาตรฐาน ซึ่งอาจก่อให้เกิดความเสี่ยงต่อการมองเห็น ลดอายุการใช้งานของเซนเซอร์ และเพิ่มภาระในการบำรุงรักษา อีกทั้งการบินในสภาพอากาศที่มีค่าฝุ่นสูงยังอาจทำให้ภาพที่บันทึกจากกล้องมีความคมชัดลดลง ส่งผลต่อความแม่นยำในการวิเคราะห์ภาพและการประเมินสถานการณ์ในพื้นที่

นอกจากนี้ การใช้ข้อมูลพยากรณ์ในการวางแผนยังเอื้อให้สามารถจัดสรรทรัพยากรและกำลังพลได้อย่างมีประสิทธิภาพ โดยสามารถเตรียมแผนสำรองได้ล่วงหน้าในกรณีที่ค่าฝุ่นมีแนวโน้มเกินเกณฑ์อย่างต่อเนื่อง ประโยชน์ที่ได้รับจึงครอบคลุมทั้งด้านประสิทธิภาพในการปฏิบัติงาน ความปลอดภัยของอุปกรณ์ UAV และการบริหารจัดการทรัพยากรอย่างคุ้มค่าในระดับยุทธศาสตร์ โดยเฉพาะในบริบทสถานการณ์ชายแดนที่ต้องเฝ้าระวังตลอด 24 ชั่วโมง

อย่างไรก็ตาม งานวิจัยนี้ยังมีข้อจำกัดที่ควรพิจารณา กล่าวคือ แบบจำลองใช้ค่าฝุ่น PM2.5 ในอดีตเป็นตัวแปรเดียวในการพยากรณ์ (univariate) โดยไม่ได้นำข้อมูลเชิงอุตุนิยมวิทยา เช่น ความเร็วและทิศทางลม ความชื้นสัมพัทธ์ ปริมาณน้ำฝน และอุณหภูมิ มาร่วมพิจารณาในแบบจำลอง ทั้งที่ปัจจัยเหล่านี้มีอิทธิพลโดยตรงต่อการสะสมและการกระจายตัวของฝุ่นละอองในบรรยากาศ การไม่รวมตัวแปรดังกล่าวอาจเป็นสาเหตุหนึ่งที่ทำให้แบบจำลองมีข้อจำกัดในการจับความเปลี่ยนแปลงอย่างฉับพลันของค่าฝุ่นตามที่กล่าวไว้ข้างต้น นอกจากนี้ข้อมูลจากสถานี 71T ยังเป็นเพียงค่าตัวแทนเชิงพื้นที่ของอำเภออยู่ประเทศ ซึ่งอาจมีความคลาดเคลื่อนเชิงพื้นที่อยู่บ้าง งานวิจัยในอนาคตจึงควรพิจารณาแบบจำลองแบบหลายตัวแปร (multivariate) ที่นำปัจจัยด้านอุตุนิยมวิทยาเข้ามาร่วมวิเคราะห์ เพื่อเพิ่มความแม่นยำและความสามารถในการจับความผันผวนเฉียบพลันของค่าฝุ่นในพื้นที่ชายแดน

6. สรุปผลการศึกษา

จากการศึกษาครั้งนี้ เพื่อพัฒนาแบบจำลองในการพยากรณ์ค่าฝุ่นละอองขนาดเล็ก PM2.5 รายวันในพื้นที่อำเภออยู่ประเทศ จังหวัดสระแก้ว โดยมีเป้าหมายหลักเพื่อสนับสนุนภารกิจของอากาศยานไร้คนขับ (UAV) ในการตรวจการณ์บริเวณชายแดน ผลการศึกษาสามารถสรุปได้ดังนี้

(1) การพัฒนาแบบจำลองพยากรณ์ PM2.5 ด้วยโมเดล FBProphet ซึ่งได้รับการปรับแต่งพารามิเตอร์ด้วยวิธี manual grid search ร่วมกับการทำความสะอาดข้อมูลอย่างเป็นระบบ ส่งผลให้โมเดลสามารถจับแนวโน้มเชิงฤดูกาลของค่าฝุ่นได้ดี โดยเฉพาะในช่วงฤดูหนาวซึ่งเป็นช่วงเวลาที่มักเกิดค่าฝุ่นสูงเกินมาตรฐาน

(2) การประยุกต์ใช้ผลพยากรณ์ดังกล่าวในการวางแผนเส้นทางการบินของ UAV โดยข้อมูลล่วงหน้าที่ได้จากโมเดลช่วยระบุช่วงเวลาที่มีความเสี่ยงสูงต่อทัศนวิสัย เช่น วันที่ค่าฝุ่นพุ่งสูงผิดปกติ ซึ่งสามารถหลีกเลี่ยงได้ล่วงหน้า เพิ่มความปลอดภัยของการปฏิบัติการ และลดความเสียหายจากสภาพอากาศที่ไม่เอื้ออำนวย ทั้งยังช่วยจัดสรรทรัพยากรด้านการบินอย่างมีประสิทธิภาพอีกด้วย

7. เอกสารอ้างอิง

[1] PostToday. (2025, February 2). PM 2.5 causes aviation disruption at Don Mueang Airport; some flights redirected to Suvarnabhumi Airport. <https://www.posttoday.com/general-news/719026>. (In Thai)



- [2] Songpon Klerkkidakan. (2021). 24-hours Forecasting Models for Pm2.5 Concentration from Photos using Convolutional Neural Network and Long Short-term Memory. [Master of Science]. Srinakharinwirot University. (In Thai)
- [3] Sriruk Srithongchai. (2022). A PM2.5 Prediction Model Using LSTM Neural Network in Bangkok Area. Journal of Engineering and Digital Technology, 10(1), 1–9. (In Thai)
- [4] Kittika Thipkummee, Anupong Sukprasert, Supattra Kopajone and Nattakarn Shutimarrungson. (2023). The Effectiveness of Machine Learning Forecasting of PM2.5. Kalasin University Journal of Science Technology and Innovation, 2(1), 58–72. (In Thai)
- [5] Saranthon Maungmee & Pongpat Chaisiripan. (2025, May 16). Comparison of PM2.5 forecasting model performance in Bangkok: SARIMA vs. XGBoost. Paper presented at Hatyai National and International Conference, Hatyai, Songkhla. (In Thai)
- [6] Suabsakul Gururatana, Rodolphe Perrin, Pimpisa Chanted and Korawit Orkphol. (2023, 17 - 18 May). “Time Series Forecasting and Impact Assessment of Air Pollution Particulate Matter (PM 2.5) of Kasetsart University Sriracha Campus, Thailand using FBprophet.” Paper presented at National Environmental Conference, Pattaya, Chonburi. (In Thai)
- [7] Panisa Puripanic. (2024). Time Series Forecasting and Impact Assessment of Air Pollution Particulate Matter (PM 2.5) using FBprophet: Case Study on Rayong Province. [Master of Engineering]. Kasetsart University. (In Thai)
- [8] Taylor, S. J., & Letham, B. (2018). Forecasting at scale. The American Statistician, 72(1), 37–45.
- [9] Pollution Control Department. (2025, January 15). Air4Thai air quality database system. <http://air4thai.pcd.go.th/webV3/#/Home>. (In Thai)
- [10] Stone, D. C. (1995). Application of median filtering to noisy data. Canadian Journal of Chemistry, 73(10), 1573–1581.