



## การเปรียบเทียบประสิทธิภาพแบบจำลอง SARIMA และ Residual Hybrid SARIMA-LSTM สำหรับการพยากรณ์ค่า PM2.5 รายเดือน ในกรุงเทพมหานคร

### A Comparative Study of SARIMA and Residual Hybrid Models for Monthly PM2.5 Forecasting in Bangkok

ศรัณธร มั่งมี<sup>1\*</sup>, นิวัฒน์ เตชะเกียรตินันท์<sup>2</sup>, ภูริชัฐ วงศ์เจตจันทร์<sup>3</sup> และพงศ์พัฒน์ ฉายศิริพันธ์<sup>4</sup>  
Saranthon Maungmee<sup>1\*</sup>, Niwat Techakiattinun<sup>2</sup>, Phoosis Wongjetjun<sup>3</sup> and Pongpat Chaisiripan<sup>4</sup>

<sup>1,2,3</sup> อาจารย์สาขาวิชาธุรกิจดิจิทัลและเทคโนโลยี คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

<sup>1,2,3</sup> Lecturer in Digital Business and Technology Faculty of Information Technology Siam University

<sup>4</sup> อาจารย์สาขาวิชาเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศ มหาวิทยาลัยสยาม

<sup>4</sup> Lecturer in Information Technology Faculty of Information Technology Siam University

\* Corresponding author, E-mail: Saranthon.mau@siam.edu

#### บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองอนุกรมเวลาในการพยากรณ์ค่าฝุ่นละอองขนาดเล็ก PM2.5 รายเดือนในกรุงเทพมหานคร โดยเปรียบเทียบระหว่างแบบจำลองเชิงสถิติ Seasonal Autoregressive Integrated Moving Average (SARIMA) และแบบจำลองเชิงผสมแบบ Residual Hybrid ที่ผสมผสาน SARIMA ร่วมกับ Long Short-Term Memory (LSTM) โดยใช้ข้อมูลรายเดือนในช่วงระยะเวลา 10 ปี (พ.ศ. 2559–2569) ข้อมูลถูกนำมาวิเคราะห์หองค์ประกอบอนุกรมเวลา และตรวจสอบความนิ่งด้วยกราฟ ACF และ PACF จากนั้นพัฒนาแบบจำลอง SARIMA และตรวจสอบความเหมาะสมด้วยการวิเคราะห์ residual สำหรับแบบจำลอง Hybrid ได้นำ residual จาก SARIMA ไปเรียนรู้เพิ่มเติมด้วย LSTM ผลการประเมินด้วยค่า Mean Absolute Error (MAE), Root Mean Square Error (RMSE) และ Mean Absolute Percentage Error (MAPE) พบว่าแบบจำลอง SARIMA ให้ค่าความคลาดเคลื่อนต่ำกว่าแบบจำลอง Hybrid อย่างชัดเจน และมีค่า  $R^2$  สูงกว่า แสดงให้เห็นว่าโครงสร้างข้อมูล PM2.5 รายเดือนสามารถอธิบายได้ดีด้วยแบบจำลองเชิงเส้นและฤดูกาล โดยไม่พบโครงสร้างโครงสร้างเชิงไม่เชิงเส้น ที่มีนัยสำคัญในค่าคลาดเคลื่อน (residual) ผลการศึกษานี้ชี้ให้เห็นว่าแบบจำลอง Hybrid ไม่ได้ให้ประสิทธิภาพเหนือกว่าในทุกกรณี โดยเฉพาะเมื่อข้อมูลมีขนาดจำกัด ซึ่งเป็นข้อพิจารณาสำคัญในการเลือกใช้แบบจำลองสำหรับงานพยากรณ์คุณภาพอากาศ

**คำสำคัญ:** PM2.5, การพยากรณ์อนุกรมเวลา, SARIMA, LSTM, คุณภาพอากาศ, การเรียนรู้เชิงลึก

#### Abstract

This study aims to develop and compare the performance of time series models for forecasting monthly PM2.5 concentrations in Bangkok, Thailand. The comparison is conducted between the statistical Seasonal Autoregressive Integrated Moving Average (SARIMA) model and a Residual Hybrid model that integrates SARIMA with a Long Short-



Term Memory (LSTM) neural network. Monthly air quality data over a 10-year period (2016–2026) were utilized in this study. The data were first analyzed using time series decomposition, and stationarity was examined through Autocorrelation Function (ACF) and Partial Autocorrelation Function (PACF) plots. The SARIMA model was then developed and evaluated through residual diagnostics. For the hybrid approach, residuals obtained from the SARIMA model were further modeled using LSTM to capture potential nonlinear patterns. Model performance was evaluated using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results indicate that the SARIMA model outperforms the Hybrid model, achieving lower forecasting errors and a higher coefficient of determination ( $R^2$ ). This suggests that the monthly PM<sub>2.5</sub> data can be effectively modeled using linear and seasonal components, with no significant nonlinear structure remaining in the residuals. The findings highlight that Hybrid models do not necessarily provide superior performance in all cases, particularly when the dataset is limited in size. This study provides important insights for selecting appropriate forecasting models for air quality prediction and policy planning.

**Keywords:** PM<sub>2.5</sub>, Time Series Forecasting, SARIMA, LSTM, Air Quality, Deep Learning

## บทนำ

ปัญหาฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM<sub>2.5</sub>) ได้รับการยอมรับว่าเป็นหนึ่งในปัจจัยเสี่ยงด้านสิ่งแวดล้อมที่สำคัญต่อสุขภาพของประชากรโลก โดยเฉพาะในเขตเมืองขนาดใหญ่ที่มีความหนาแน่นของประชากรสูงและมีกิจกรรมทางเศรษฐกิจอย่างเข้มข้น เช่น กรุงเทพมหานคร ซึ่งเป็นศูนย์กลางด้านคมนาคม อุตสาหกรรม และการขยายตัวของเมืองในประเทศไทย ปัจจัยดังกล่าวส่งผลให้กรุงเทพมหานครเผชิญปัญหาคุณภาพอากาศที่มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่อง โดยเฉพาะในช่วงฤดูหนาว ซึ่งมีสถานะอุตุนิยมวิทยาที่เอื้อต่อการสะสมของมลพิษในบรรยากาศชั้นล่าง รายงานขององค์การอนามัยโลก (World Health Organization: WHO) ระบุว่า การได้รับสัมผัส PM<sub>2.5</sub> ในระดับสูงอย่างต่อเนื่องสัมพันธ์กับความเสี่ยงที่เพิ่มขึ้นของโรคระบบทางเดินหายใจ โรคหัวใจและหลอดเลือด และการเสียชีวิตก่อนวัยอันควร (WHO, 2021) ทั้งนี้ แนวทางคุณภาพอากาศฉบับปรับปรุงล่าสุดได้กำหนดค่ามาตรฐานที่เข้มงวดขึ้นสะท้อนถึงหลักฐานเชิงประจักษ์ที่ยืนยันผลกระทบเชิงลบต่อสุขภาพในระยะยาว

ในบริบทประเทศไทย ข้อมูลจาก กรมควบคุมมลพิษ (Pollution Control Department: PCD) แสดงให้เห็นว่าค่าความเข้มข้น PM<sub>2.5</sub> ในกรุงเทพมหานคร มีลักษณะผันผวนตามฤดูกาล (Seasonality) และมีแนวโน้มเพิ่มสูงในบางช่วงเวลา โดยมีปัจจัยสนับสนุน ได้แก่ การจราจรหนาแน่น การก่อสร้างในเขตเมือง การเผาในที่โล่ง รวมถึงอิทธิพลของมลพิษข้ามพรมแดน (Pollution Control Department, 2023) ลักษณะข้อมูลดังกล่าวจัดเป็นข้อมูลอนุกรมเวลา (Time Series) ที่มีแนวโน้ม (Trend) ฤดูกาล (Seasonality) วัฏจักร (Cycle) และความผันผวนไม่ปกติ (Irregular Component)

การพยากรณ์ข้อมูลอนุกรมเวลาสำหรับ PM<sub>2.5</sub> มีความสำคัญเชิงนโยบาย เนื่องจากช่วยสนับสนุนการเตือนภัยล่วงหน้า การกำหนดมาตรการควบคุมแหล่งกำเนิด และการบริหารจัดการความเสี่ยงด้าน



สุขภาพประชาชน แบบจำลองเชิงสถิติ เช่น ARIMA และ SARIMA มีความสามารถในการอธิบายโครงสร้างเชิงเส้นของข้อมูลได้อย่างมีประสิทธิภาพ (Box et al., 2015) ขณะที่แบบจำลองเชิงโครงข่ายประสาทเทียม เช่น LSTM มีศักยภาพในการเรียนรู้ความสัมพันธ์โครงสร้างโครงสร้างเชิงไม่เชิงเส้น และรูปแบบที่ซับซ้อนของข้อมูล (Hochreiter & Schmidhuber, 1997) อย่างไรก็ตาม การใช้แบบจำลองเดี่ยวอาจยังไม่สามารถสะท้อนโครงสร้างข้อมูลที่มีทั้งส่วนเชิงเส้นและไม่เชิงเส้นได้อย่างครบถ้วน

ด้วยเหตุนี้ แนวคิดแบบจำลองเชิงผสม (Hybrid Model) โดยเฉพาะแนวทาง Residual Hybrid ซึ่งทำการสร้างแบบจำลองหลักเพื่ออธิบายโครงสร้างเชิงเส้น และนำค่าคลาดเคลื่อน (Residual) ไปเรียนรู้เพิ่มเติมด้วยแบบจำลองโครงสร้างเชิงไม่เชิงเส้น จึงได้รับความสนใจในงานวิจัยด้านอนุกรมเวลา เนื่องจากสามารถลดค่าความคลาดเคลื่อนรวมและเพิ่มความแม่นยำ ในการพยากรณ์ได้อย่างชัดเจน (Zhang, 2003)

ดังนั้น การศึกษานี้มุ่งพัฒนาและประเมินประสิทธิภาพของแบบจำลอง Residual Hybrid SARIMA–LSTM สำหรับการพยากรณ์ค่า PM2.5 รายเดือนในกรุงเทพมหานคร โดยใช้ข้อมูลย้อนหลัง 10 ปี เพื่อเปรียบเทียบกับแบบจำลองเดี่ยวในเชิงความแม่นยำ ทั้งนี้ผลลัพธ์ที่ได้จะเป็นข้อมูลเชิงประจักษ์สำหรับสนับสนุนการตัดสินใจเชิงนโยบาย และเป็นต้นแบบเชิงระเบียบวิธีสำหรับการพยากรณ์ข้อมูลสิ่งแวดล้อมในเขตเมืองขนาดใหญ่ของประเทศไทย

### วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองพยากรณ์ค่า PM2.5 รายเดือนในพื้นที่กรุงเทพมหานคร โดยใช้แบบจำลอง SARIMA และ Residual Hybrid SARIMA–LSTM
2. เพื่อประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งสอง ในด้านความแม่นยำของการพยากรณ์ โดยใช้ตัวชี้วัดทางสถิติ ได้แก่ MAE, RMSE และ MAPE

### สมมติฐาน

- H1: แบบจำลอง SARIMA และ Residual Hybrid SARIMA–LSTM ให้ค่าความคลาดเคลื่อนแตกต่างกันอย่างมีนัยสำคัญ
- H2: ค่าคลาดเคลื่อน (residual) จากแบบจำลอง SARIMA อาจมีโครงสร้างที่สามารถนำไปเรียนรู้เพิ่มเติมด้วยแบบจำลองไม่เชิงเส้นได้

### ขอบเขตของการวิจัย

1. ขอบเขตด้านพื้นที่ศึกษา: การวิจัยนี้มุ่งศึกษาความเข้มข้นของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) ในพื้นที่กรุงเทพมหานคร โดยใช้ข้อมูลจากสถานีตรวจวัดคุณภาพอากาศที่รายงานอย่างเป็นทางการโดยกรมควบคุมมลพิษ
2. ขอบเขตด้านข้อมูล: ใช้ข้อมูลค่าเฉลี่ยรายเดือนของ PM2.5 ตั้งแต่เดือนมกราคม พ.ศ. 2559 ถึงเดือนมกราคม พ.ศ. 2569 รวมระยะเวลา 10 ปี 1 เดือน ซึ่งเพียงพอสำหรับการวิเคราะห์องค์ประกอบของอนุกรมเวลา ได้แก่ แนวโน้ม (Trend) และฤดูกาล (Seasonality) โดยเป็นข้อมูลอนุกรมเวลาแบบตัวแปรเดียว (Univariate Time Series) และไม่รวมตัวแปรอธิบายภายนอก เช่น อุณหภูมิ ความชื้น หรือความเร็วลม



3. ขอบเขตด้านตัวแปร: ตัวแปรหลักที่ใช้ในการวิเคราะห์ คือ ค่าเฉลี่ยรายเดือนของ PM2.5 (หน่วยไมโครกรัมต่อลูกบาศก์เมตร) โดยไม่รวมตัวแปรอุตุนิยมวิทยาหรือปัจจัยภายนอกอื่น เพื่อมุ่งเน้นการพัฒนาแบบจำลองอนุกรมเวลาแบบตัวแปรเดียว

4. ขอบเขตด้านวิธีการวิเคราะห์: การวิจัยใช้แบบจำลอง SARIMA และแบบจำลองเชิงผสม (Residual Hybrid SARIMA-LSTM) โดยในขั้นแรกสร้างแบบจำลอง SARIMA เพื่ออธิบายโครงสร้างเชิงเส้นของข้อมูล จากนั้นนำค่าคลาดเคลื่อน (Residual) ไปพัฒนาแบบจำลอง LSTM เพื่อเรียนรู้โครงสร้างไม่เชิงเส้นที่อาจเหลืออยู่ และประเมินประสิทธิภาพด้วยตัวชี้วัดความแม่นยำ ได้แก่ MAE, RMSE และ MAPE

5. ขอบเขตด้านการประเมินผล: การประเมินประสิทธิภาพของแบบจำลองดำเนินการโดยแบ่งข้อมูลเป็นชุดฝึก (Training Set) และชุดทดสอบ (Testing Set) ตามลำดับเวลา (Time-based Split) เพื่อสะท้อนสถานการณ์การพยากรณ์จริง และเปรียบเทียบผลภายใต้เงื่อนไขเดียวกัน

### แนวคิด ทฤษฎี กรอบแนวคิด

1. ข้อมูลอนุกรมเวลา (Time Series Data) ข้อมูลอนุกรมเวลา หมายถึง ชุดข้อมูลเชิงปริมาณที่ถูกรวบรวมและจัดเรียงตามลำดับเวลาอย่างต่อเนื่อง เช่น รายปี รายไตรมาส รายเดือน รายวัน หรือรายชั่วโมง โดยวัตถุประสงค์เพื่อศึกษาพฤติกรรมและการเปลี่ยนแปลงของตัวแปรตามช่วงเวลา (Box et al., 2015) สำหรับการศึกษาครั้งนี้ ข้อมูลค่า PM2.5 รายเดือนในพื้นที่กรุงเทพมหานคร จัดเป็นข้อมูลอนุกรมเวลาแบบตัวแปรเดียว (Univariate Time Series)

องค์ประกอบสำคัญของอนุกรมเวลา ประกอบด้วย 4 ส่วน ได้แก่

1. แนวโน้ม (Trend) คือ ทิศทางการเพิ่มขึ้นหรือลดลงของข้อมูลในระยะยาว

2. วัฏจักร (Cycle) คือ การแกว่งตัวของข้อมูลรอบแนวโน้มที่ใช้ระยะเวลามากกว่า 1 ปี โดยมักสัมพันธ์กับปัจจัยเศรษฐกิจหรือสิ่งแวดล้อม

3. ฤดูกาล (Seasonality) คือ รูปแบบการเปลี่ยนแปลงที่เกิดขึ้นภายในช่วงเวลาคงที่ เช่น ภายใน 12 เดือน

4. ความผันผวนไม่ปกติ (Irregular Component) คือ ส่วนที่เหลือซึ่งไม่สามารถอธิบายได้ด้วยแนวโน้ม วัฏจักร หรือฤดูกาล

ในเชิงคณิตศาสตร์ อนุกรมเวลาสามารถเขียนในรูปแบบบวก (Additive Model) ได้ดังนี้

$$Y_t = T_t + C_t + S_t + I_t$$

2. แบบจำลอง SARIMA (Seasonal ARIMA Model) แบบจำลอง SARIMA เป็นการขยายแบบจำลอง ARIMA เพื่อรองรับข้อมูลที่มีองค์ประกอบฤดูกาล โดยแทนด้วยสัญลักษณ์ SARIMA(p,d,q)(P,D,Q)<sub>s</sub> ซึ่งมีโครงสร้างทั่วไปดังนี้ (Box et al., 2015)

$$\Phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Y_t = \Theta_q(B)\Theta_Q(B^s)\epsilon_t$$

เมื่อ

$B$  คือ Backshift operator

$p,d,q$  คือ อันดับของ AR, Differencing และ MA

$P,D,Q$  คือ อันดับของ Seasonal AR, Seasonal Differencing และ Seasonal MA

$s$  คือ ความยาวรอบฤดูกาล (เช่น 12 สำหรับข้อมูลรายเดือน)



แบบจำลอง SARIMA มีจุดแข็งในการอธิบายโครงสร้างเชิงเส้นของข้อมูลอนุกรมเวลา โดยเฉพาะข้อมูลที่มีฤดูกาลชัดเจน

**3. โครงข่ายประสาทเทียมแบบ LSTM (Long Short-Term Memory)** LSTM เป็นโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่ออกแบบมาเพื่อแก้ปัญหา vanishing gradient และสามารถเรียนรู้ความสัมพันธ์ระยะยาวของข้อมูล (Hochreiter & Schmidhuber, 1997) โครงสร้าง LSTM ประกอบด้วย 3 ส่วนหลัก ได้แก่

1. Forget Gate
2. Input Gate
3. Output Gate

สมการพื้นฐานของ LSTM ได้แก่

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

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

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

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t$$

$$h_t = o_t \tanh(C_t)$$

LSTM มีความสามารถในการเรียนรู้โครงสร้างเชิงไม่เชิงเส้น (Nonlinear Pattern) ที่แบบจำลองเชิงสถิติไม่สามารถอธิบายได้

**4. แนวคิดแบบจำลองเชิงผสมแบบ Residual Hybrid** แนวคิด Hybrid Model ตั้งอยู่บนสมมติฐานว่าข้อมูลอนุกรมเวลาประกอบด้วย ทั้งองค์ประกอบเชิงเส้นและไม่เชิงเส้น (Zhang, 2003) ขั้นตอนของ Residual Hybrid Model มีดังนี้

1. สร้างแบบจำลองเชิงเส้น (เช่น SARIMA) เพื่อพยากรณ์ค่า  $\hat{Y}_t^{(L)}$
2. คำนวณค่าคลาดเคลื่อน (Residual)

$$e_t = Y_t - \hat{Y}_t^{(L)}$$

3. นำ Residual ไปสร้างแบบจำลอง LSTM เพื่อพยากรณ์  $\hat{e}_t^{(NL)}$
4. รวมผลลัพธ์เป็นค่าพยากรณ์สุดท้าย

$$\hat{Y}_t = \hat{Y}_t^{(L)} + \hat{e}_t^{(NL)}$$

สมการของแบบจำลอง Residual Hybrid สามารถเขียนได้ดังนี้

$$\hat{Y}_t = \hat{Y}_t(\text{SARIMA}) + \hat{Y}_t(\text{LSTM residual})$$

โดยที่  $\hat{Y}_t(\text{SARIMA})$  คือ ค่าพยากรณ์จากแบบจำลองเชิงเส้น และ  $\hat{Y}_t(\text{LSTM residual})$  คือ ค่าที่ได้จากการเรียนรู้ residual ด้วยแบบจำลอง LSTM กรอบแนวคิดนี้มีหลักการสำคัญ คือ การแยกโครงสร้างข้อมูลออกเป็นส่วนเชิงเส้นและไม่เชิงเส้น แล้วนำผลลัพธ์มาผสานกันเพื่อเพิ่มความแม่นยำ



**5. การประเมินประสิทธิภาพแบบจำลอง (Model Evaluation)** การประเมินประสิทธิภาพของแบบจำลองพยากรณ์อนุกรมเวลาเป็นขั้นตอนเชิงระเบียบวิธีที่มีความสำคัญอย่างยิ่ง เนื่องจากเป็นกลไกในการตรวจสอบทั้ง “ความแม่นยำเชิงปริมาณ” (Predictive Accuracy) และ “ความเหมาะสมเชิงโครงสร้าง” (Model Adequacy) ของแบบจำลองภายใต้กรอบแนวคิดการพยากรณ์สมัยใหม่ การประเมินผลไม่ควรอาศัยตัวชี้วัดเพียงค่าเดียว แต่ควรใช้ชุดตัวชี้วัดที่สะท้อนมิติของความคลาดเคลื่อนหลายรูปแบบ ได้แก่ ความคลาดเคลื่อนสัมบูรณ์ ความคลาดเคลื่อนกำลังสอง ความคลาดเคลื่อนเชิงร้อยละ และการวิเคราะห์อคติ (Bias) รวมถึงการตรวจสอบคุณสมบัติของค่าคลาดเคลื่อน (Residual Diagnostics) (Hyndman & Athanasopoulos, 2021)

ในการศึกษานี้ ใช้ตัวชี้วัดหลักดังต่อไปนี้

### 1. Mean Absolute Error (MAE)

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

MAE เป็นค่าเฉลี่ยของค่าสัมบูรณ์ของความคลาดเคลื่อน ซึ่งสะท้อน “ขนาดของความผิดพลาดโดยเฉลี่ย” ในหน่วยเดียวกับข้อมูลจริง โดยไม่มีการยกกำลังสองจึงไม่เพิ่มน้ำหนักให้กับความผิดพลาดขนาดใหญ่เกินสัดส่วน

ในเชิงทฤษฎี MAE มีคุณสมบัติเป็นมาตรวัดความคลาดเคลื่อนแบบเชิงเส้น (linear loss function) และมีความเสถียรต่อค่าผิดปกติ (robust to outliers) มากกว่า RMSE จึงเหมาะสำหรับการประเมินความแม่นยำโดยรวมของแบบจำลอง (Willmott & Matsuura, 2005) ค่า MAE ที่ต่ำกว่าสะท้อนถึงความสามารถในการพยากรณ์ที่แม่นยำกว่า

### 2. Root Mean Squared Error (RMSE)

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

RMSE เป็นรากที่สองของค่าเฉลี่ยกำลังสองของความคลาดเคลื่อน ซึ่งมีพื้นฐานจากแนวคิด quadratic loss function โดยให้ค่าน้ำหนักกับความผิดพลาดขนาดใหญ่สูงกว่าความผิดพลาดขนาดเล็กอย่างชัดเจน

ในเชิงสถิติ RMSE สัมพันธ์กับการประมาณค่าภายใต้สมมติฐาน การแจกแจงแบบปกติของความคลาดเคลื่อน (Gaussian error assumption) และสอดคล้องกับหลักการประมาณค่าแบบ Maximum Likelihood ในกรณีที่ residual มีการแจกแจงปกติ (Box et al., 2015) ดังนั้น RMSE จึงเหมาะสำหรับกรณีที่ต้องการลดความผิดพลาดรุนแรงโดยเฉพาะ หากค่า RMSE สูงกว่า MAE อย่างชัดเจน แสดงถึงการมี outliers หรือความผันผวนรุนแรงในบางช่วงเวลา

### 3. Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

MAPE วัดความคลาดเคลื่อนในรูปแบบเปอร์เซ็นต์ ทำให้สามารถตีความผลลัพธ์ได้โดยไม่ขึ้นกับหน่วยของข้อมูล และเอื้อต่อการเปรียบเทียบระหว่างแบบจำลองหรือชุดข้อมูลที่มีสเกลแตกต่างกัน



อย่างไรก็ตามในเชิงระเบียบวิธี MAPE มีข้อจำกัดสำคัญเมื่อค่าจริงเข้าใกล้ศูนย์ ซึ่งอาจทำให้ค่าความคลาดเคลื่อนพุ่งสูงอย่างไม่สมเหตุผล ดังนั้น Hyndman และ Koehler (2006) เสนอให้ใช้ MAPE ด้วยความระมัดระวัง และพิจารณาร่วมกับตัวชี้วัดอื่นเสมอ

#### 4. Symmetric Mean Absolute Percentage Error (SMAPE)

$$SMAPE = \frac{100}{n} \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{(|Y_t| + |\hat{Y}_t|)/2}$$

SMAPE ถูกพัฒนาขึ้นเพื่อลดข้อจำกัดของ MAPE โดยใช้ค่าเฉลี่ยของค่าจริงและค่าพยากรณ์เป็นตัวหาร ซึ่งช่วยลดปัญหาการหารด้วยศูนย์และลดความเอนเอียงเมื่อค่าจริงมีขนาดเล็ก

Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998) ชี้ให้เห็นว่า SMAPE เหมาะสำหรับการเปรียบเทียบประสิทธิภาพแบบจำลองในงานแข่งขันพยากรณ์ (forecasting competitions) เนื่องจากสะท้อนความคลาดเคลื่อนเชิงสัดส่วนได้สมมาตรมากกว่า MAPE

#### 5. Coefficient of Determination ( $R^2$ )

$$R^2 = 1 - \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$

$R^2$  แสดงสัดส่วนของความแปรปรวนในข้อมูลที่แบบจำลองสามารถอธิบายได้ โดยมีค่าระหว่าง 0 ถึง 1 ค่าใกล้ 1 หมายถึง แบบจำลองสามารถอธิบายโครงสร้างข้อมูลได้ดี

อย่างไรก็ตาม ในบริบทของการพยากรณ์อนุกรมเวลา  $R^2$  ควรใช้ร่วมกับตัวชี้วัดความคลาดเคลื่อนอื่น เนื่องจากค่า  $R^2$  สูงไม่ได้รับประกันว่าการพยากรณ์ล่วงหน้าจะมีความแม่นยำสูง (Montgomery, D. C., Jennings, C. L., & Kulahci, M. 2012)

#### 6. Mean Bias Error (MBE)

$$MBE = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)$$

MBE ใช้วัด “อคติเชิงระบบ” (systematic bias) ของแบบจำลอง หากค่า MBE มีค่าใกล้ศูนย์ แสดงว่าแบบจำลองไม่มีแนวโน้มพยากรณ์สูงหรือต่ำเกินจริงอย่างเป็นระบบ

- MBE > 0 หมายถึง แบบจำลองมีแนวโน้มพยากรณ์ต่ำกว่าค่าจริง
- MBE < 0 หมายถึง แบบจำลองมีแนวโน้มพยากรณ์สูงเกินจริง

การพิจารณา MBE มีความสำคัญในงานสิ่งแวดล้อมและสาธารณสุข เนื่องจากการประเมินต่ำเกินจริง (underestimation) อาจนำไปสู่การกำหนดนโยบายที่ไม่เพียงพอ

#### 7. การวิเคราะห์ Residual (Residual Diagnostics) Residual นิยามเป็น

$$e_t = Y_t - \hat{Y}_t$$

โดย  $Y_t$  คือค่าจริง และ  $\hat{Y}_t$  คือค่าประมาณจากแบบจำลองตามหลักของ Box-Jenkins residual ที่เหมาะสมควรมีคุณสมบัติเป็น White Noise Process กล่าวคือ

1. มีค่าเฉลี่ยเข้าใกล้ศูนย์ (zero mean)
2. มีความแปรปรวนคงที่ (homoscedasticity)
3. ไม่มีความสัมพันธ์เชิงอนุกรม (serial independence)



การตรวจสอบดำเนินการผ่านทั้งการวิเคราะห์เชิงกราฟและเชิงสถิติ ได้แก่

- Residuals vs Fitted Plot เพื่อตรวจสอบความเป็นอิสระและ homoscedasticity
- Residuals vs Time Plot เพื่อตรวจสอบรูปแบบเชิงเวลา
- Histogram และ Q-Q Plot เพื่อตรวจสอบการกระจายตัว
- Ljung-Box Test เพื่อตรวจสอบ autocorrelation อย่างเป็นทางการ

หากผลการตรวจสอบพบว่า residual ยังมีโครงสร้างเชิงเวลา หรือมีรูปแบบที่ไม่เป็นสุ่มอย่างมีนัยสำคัญทางสถิติ แสดงว่าแบบจำลองเชิงเส้นยังไม่สามารถอธิบายพลวัตของข้อมูลได้ครบถ้วน ซึ่งสอดคล้องกับแนวคิด decomposition-based hybrid modeling ที่เสนอให้ใช้แบบจำลองโครงสร้างเชิงไม่เชิงเส้น เพิ่มเติมเพื่อประมาณค่าองค์ประกอบที่เหลืออยู่ (Box et al., 2015)

### วิธีดำเนินการวิจัย

1. การรวบรวมและเตรียมข้อมูล เก็บรวบรวมข้อมูลค่า PM2.5 รายเดือนเฉลี่ย 24 ชั่วโมง จากสถานีตรวจวัดคุณภาพอากาศของกรมควบคุมมลพิษ ครอบคลุมช่วงเดือนมกราคม 2559 ถึง มกราคม 2569 ข้อมูลถูกตรวจสอบความครบถ้วน ความสอดคล้องของหน่วยวัด และค่าผิดปกติ (outliers) ก่อนจัดรูปแบบให้อยู่ในลักษณะอนุกรมเวลา จากนั้นแบ่งข้อมูลเป็นชุดฝึกสอน (Training Set) และชุดทดสอบ (Test Set) ตามหลักการพยากรณ์แบบลำดับเวลา (time-ordered split) เพื่อป้องกันข้อมูลรั่วไหล (data leakage)

2. การวิเคราะห์คุณสมบัติอนุกรมเวลา (Exploratory Time Series Analysis) วิเคราะห์แนวโน้ม ฤดูกาลและความนิ่งของข้อมูล โดยใช้การทดสอบหน่วยราก (Unit Root Test) และวิเคราะห์โครงสร้างสหสัมพันธ์ผ่าน ACF และ PACF เพื่อระบุรูปแบบเชิงเวลาและความจำเป็นในการทำ differencing ทั้งในมิติทั่วไปและเชิงฤดูกาล

3. การพัฒนาแบบจำลอง SARIMA (Linear Modeling Stage) สร้างแบบจำลอง SARIMA ภายใต้กรอบ Box-Jenkins โดยดำเนินการตามขั้นตอน identification-estimation-diagnostic checking อย่างเป็นระบบ พารามิเตอร์ของโมเดลถูกคัดเลือกโดยอาศัยเกณฑ์สารสนเทศ (AIC และ BIC) ร่วมกับการตรวจสอบคุณสมบัติของ residual เพื่อให้แน่ใจว่าโมเดลสามารถอธิบายองค์ประกอบเชิงเส้นของข้อมูลได้อย่างเหมาะสม

4. การวิเคราะห์ Residual และการพัฒนา LSTM (Nonlinear Modeling Stage) ค่าคลาดเคลื่อน (Residual) จากแบบจำลอง SARIMA ถูกนำมาวิเคราะห์เชิงกราฟและเชิงสถิติ ได้แก่ Residuals vs Time, Histogram, Q-Q Plot และการทดสอบ Ljung-Box เพื่อตรวจสอบว่า residual ยังมีโครงสร้างที่ไม่เป็นสุ่มหรือไม่ หากพบความสัมพันธ์เชิงเวลาโครงสร้างเชิงไม่เชิงเส้น จึงนำ residual ดังกล่าวไปพัฒนาแบบจำลอง Long Short-Term Memory (LSTM) เพื่อประมาณค่าองค์ประกอบโครงสร้างเชิงไม่เชิงเส้นที่เหลืออยู่ โดยกำหนดโครงสร้างเครือข่ายและ hyperparameters อย่างเหมาะสมเพื่อป้องกัน overfitting

5. การสร้างแบบจำลอง Residual Hybrid SARIMA-LSTM และการพยากรณ์ ค่าพยากรณ์สุดท้ายถูกคำนวณจากผลรวมของค่าพยากรณ์เชิงเส้นจาก SARIMA และค่าพยากรณ์ residual จาก LSTM ตามสมมติฐานการแยกองค์ประกอบของอนุกรมเวลาเป็นส่วนเชิงเส้นและโครงสร้างเชิงไม่เชิงเส้น (Residual Hybrid Framework)

6. การประเมินประสิทธิภาพของแบบจำลอง เปรียบเทียบสมรรถนะของ SARIMA, LSTM และ Hybrid Model บนชุดข้อมูลทดสอบ โดยใช้ตัวชี้วัดเชิงปริมาณ ได้แก่

- Mean Absolute Error (MAE)
- Root Mean Square Error (RMSE)
- Mean Absolute Percentage Error (MAPE)
- Coefficient of Determination ( $R^2$ )


นอกจากนี้ดำเนินการตรวจสอบ residual diagnostics ของโมเดลสุดท้ายเพื่อยืนยันว่าไม่มีโครงสร้างคงเหลือในข้อมูล

7. การวิเคราะห์เชิงเปรียบเทียบและอภิปรายผล วิเคราะห์ความแตกต่างของค่าความคลาดเคลื่อนและความสามารถในการจับพลวัตของข้อมูลเชิงเวลา เปรียบเทียบข้อได้เปรียบและข้อจำกัดของแต่ละแนวทาง เพื่อพิจารณาความเหมาะสมในการประยุกต์ใช้กับข้อมูลมลพิษทางอากาศในบริบทเมืองใหญ่

## ผลการวิจัย

### 1. การวิเคราะห์องค์ประกอบของอนุกรมเวลา

จากการแยกองค์ประกอบอนุกรมเวลา (Time Series Decomposition) ดังแสดงในภาพที่ 1




ภาพที่ 1 การแยกองค์ประกอบของข้อมูลอนุกรมเวลา PM2.5 รายเดือนในกรุงเทพมหานคร

จากภาพที่ 1 พบว่า องค์ประกอบแนวโน้ม (Trend) มีการเปลี่ยนแปลงตามช่วงเวลา โดยมีแนวโน้มลดลงในช่วงก่อนปรับเพิ่มขึ้นเล็กน้อยในช่วงท้าย องค์ประกอบฤดูกาล (Seasonal) แสดงรูปแบบซ้ำรอบ 12 เดือนอย่างชัดเจน ขณะที่ค่าคลาดเคลื่อน (Residual) กระจายรอบศูนย์โดยไม่ปรากฏรูปแบบเชิงระบบเด่นชัดพบ

- องค์ประกอบ Trend มีแนวโน้มลดลงช่วงปี 2016–2021 ก่อนปรับตัวเพิ่มขึ้นเล็กน้อยในช่วงท้ายข้อมูล
  - องค์ประกอบ Seasonal แสดงรูปแบบซ้ำรอบ 12 เดือนอย่างชัดเจน โดยค่าฝุ่นสูงในช่วงต้นปี และต่ำในช่วงกลางปี
  - องค์ประกอบ Residual กระจายรอบศูนย์ ไม่มีรูปแบบเชิงระบบเด่นชัด
- ผลดังกล่าวสะท้อนโครงสร้างแบบ Additive Model ตามแนวคิดของ Box, George E. P. และ Jenkins, Gwilym M. ซึ่งสนับสนุนการใช้แบบจำลอง SARIMA สำหรับข้อมูลที่มีฤดูกาลชัดเจน

## 2. การวิเคราะห์ ACF และ PACF



ภาพที่ 2 กราฟ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) ของข้อมูล PM2.5 รายเดือนในกรุงเทพมหานคร

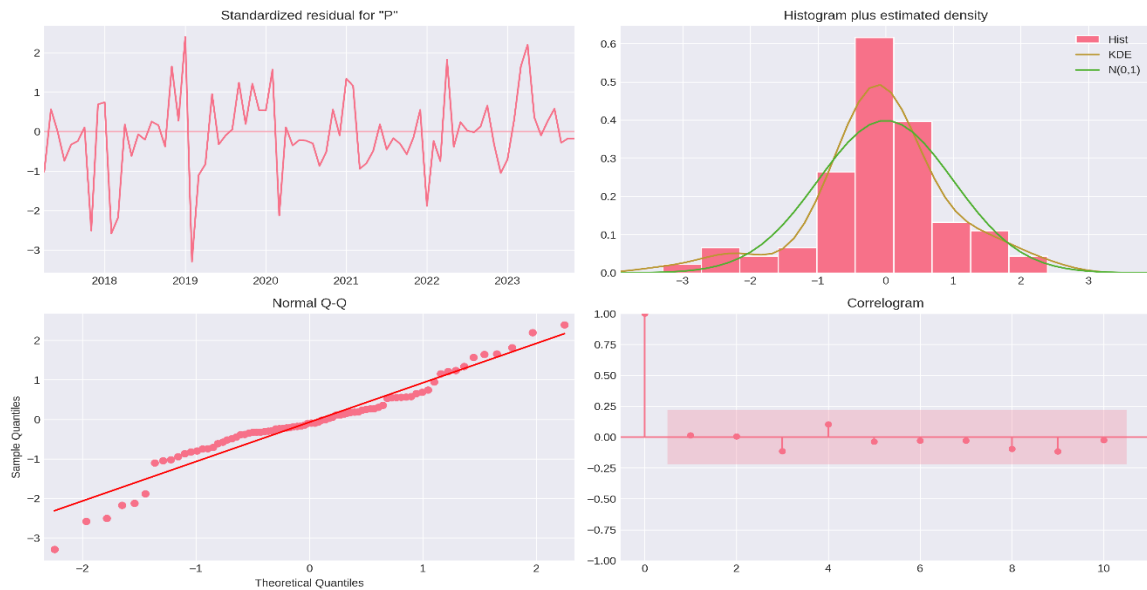
จากภาพที่ 2 พบว่า กราฟ ACF มีค่าสหสัมพันธ์เด่นชัดที่ lag 12 และทวิคูณของ 12 ซึ่งสะท้อนถึงองค์ประกอบฤดูกาลรายปีของข้อมูล ขณะที่กราฟ PACF มีค่า spike ที่ชัดเจนใน lag แรกและลดลงอย่างรวดเร็วใน lag ถัดไป ลักษณะดังกล่าวสนับสนุนการกำหนดพารามิเตอร์ของแบบจำลอง SARIMA ที่มีองค์ประกอบของ autoregressive และ seasonal autoregressive ในลำดับต่ำ

- ACF มีค่าสหสัมพันธ์เด่นชัดที่ lag 12 และทวิคูณของ 12 สะท้อนฤดูกาลรายปี
- PACF มี spike ชัดเจนที่ lag 1 และลดลงอย่างรวดเร็ว

ลักษณะดังกล่าวสนับสนุนการกำหนดพารามิเตอร์แบบ Seasonal AR และ AR ลำดับต่ำ ตามหลักการระบุโมเดลของ Hyndman, Rob J.

### 3. การวินิจฉัยแบบจำลอง SARIMA

ผลการตรวจสอบ residual diagnostics แสดงในภาพที่ 3




ภาพที่ 3 การวิเคราะห์ค่าคลาดเคลื่อน (Residual Diagnostics) ของแบบจำลอง SARIMA

จากภาพที่ 3 พบว่า ค่าคลาดเคลื่อนมาตรฐาน (Standardized Residuals) กระจายรอบศูนย์โดยไม่มีรูปแบบเชิงเวลาอย่างชัดเจน แสดงถึงความเป็นอิสระของข้อมูล นอกจากนี้ Histogram ร่วมกับเส้นประมาณค่าการแจกแจงปกติ (Normal Distribution) แสดงให้เห็นว่าค่าคลาดเคลื่อนมีการกระจายใกล้เคียงปกติ ขณะที่กราฟ Q-Q Plot มีการเรียงตัวของจุดใกล้เคียงเส้นตรง แสดงถึงความสอดคล้องกับสมมติฐานการแจกแจงแบบปกติ และจาก Correlogram ไม่พบค่าสหสัมพันธ์ของ residual ที่มีนัยสำคัญทางสถิติ จึงสรุปได้ว่า ค่าคลาดเคลื่อนมีลักษณะใกล้เคียงกับ white noise และแบบจำลอง SARIMA มีความเหมาะสมพบว่า

- Standardized residual มีค่าเฉลี่ยใกล้เคียงศูนย์
  - Histogram และ Q-Q Plot แสดงการแจกแจงใกล้เคียงปกติ
  - Correlogram ของ residual ไม่พบ Autocorrelation อย่างมีนัยสำคัญ
- แสดงว่าแบบจำลอง SARIMA มีความเหมาะสมและ residual มีคุณสมบัติใกล้เคียง white noise

4. การเรียนรู้ของ LSTM จากกราฟ Loss และ MAE ของชุด Train และ Validation ดังแสดงในภาพที่ 4




ภาพที่ 4 กราฟค่า Loss และ Mean Absolute Error (MAE) ของแบบจำลอง LSTM สำหรับชุดฝึก (Training) และชุดตรวจสอบ (Validation)

จากภาพที่ 4 พบว่า ค่า Loss และ MAE ของชุดฝึก (Training) และชุดตรวจสอบ (Validation) ลดลงอย่างรวดเร็วในช่วงต้นของการเรียนรู้ (early epochs) และมีแนวโน้มคงที่ในช่วงถัดมา โดยค่า Validation ไม่ปรากฏการเพิ่มขึ้นอย่างมีนัยสำคัญเมื่อเทียบกับ Training แสดงว่าแบบจำลอง LSTM สามารถเรียนรู้รูปแบบของข้อมูลได้ในระดับหนึ่งโดยไม่เกิด overfitting อย่างชัดเจนพบว่า

- ค่าความสูญเสียลดลงอย่างรวดเร็วในช่วงต้น epoch
- ค่า Validation loss มีเสถียรภาพ ไม่เกิด overfitting อย่างรุนแรง แสดงว่าโครงข่าย LSTM สามารถเรียนรู้ residual ได้ในระดับหนึ่ง


## 5. ผลการพยากรณ์

ผลการเปรียบเทียบค่าพยากรณ์ SARIMA และ Hybrid บนช่วงทดสอบ แสดงในภาพที่ 5: กราฟเปรียบเทียบ Actual, SARIMA และ Hybrid



ภาพที่ 5 การเปรียบเทียบค่าจริง (Actual) กับค่าพยากรณ์จากแบบจำลอง SARIMA และ Residual Hybrid SARIMA-LSTM

จากภาพที่ 5 พบว่า แบบจำลอง SARIMA สามารถพยากรณ์แนวโน้มของข้อมูลได้ใกล้เคียงกับค่าจริงมากกว่าแบบจำลอง Hybrid โดยเฉพาะในช่วงที่ข้อมูลมีการเปลี่ยนแปลงอย่างรวดเร็ว ขณะที่แบบจำลอง Hybrid มีแนวโน้มพยากรณ์ต่ำกว่าค่าจริงในหลายช่วงเวลา และมีความคลาดเคลื่อนสูงกว่าเมื่อเทียบกับ SARIMA



ภาพที่ 6 การเปรียบเทียบค่าความคลาดเคลื่อน (MAE, RMSE, MAPE) และค่า R<sup>2</sup> ของแบบจำลอง SARIMA และ Residual Hybrid SARIMA-LSTM

จากภาพที่ 6 พบว่า แบบจำลอง SARIMA ให้ค่าความคลาดเคลื่อนต่ำกว่าแบบจำลอง Hybrid ในทุกตัวชี้วัด โดยมีค่า MAE เท่ากับ 2.4524 เทียบกับ 3.0777 ค่า RMSE เท่ากับ 2.9062 เทียบกับ 3.5811 และค่า MAPE เท่ากับ 14.4208 เทียบกับ 19.4475 ขณะเดียวกัน ค่า R<sup>2</sup> ของแบบจำลอง SARIMA มีค่าสูงกว่า (0.8609) เมื่อเทียบกับแบบจำลอง Hybrid (0.7888) แสดงให้เห็นว่าแบบจำลอง SARIMA มีประสิทธิภาพในการพยากรณ์ดีกว่าอย่างชัดเจน

ตารางที่ 1 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA และ Residual Hybrid SARIMA-LSTM

| ตัวชี้วัด      | SARIMA  | Hybrid  |
|----------------|---------|---------|
| MAE            | 2.4524  | 3.0777  |
| RMSE           | 2.9062  | 3.5811  |
| MAPE (%)       | 14.4208 | 19.4475 |
| R <sup>2</sup> | 0.8609  | 0.7888  |

จากตารางที่ 1 พบว่าแบบจำลอง SARIMA ให้ค่าความคลาดเคลื่อนต่ำกว่าและค่า R<sup>2</sup> สูงกว่าแบบจำลอง Hybrid ในทุกตัวชี้วัดอย่างสม่ำเสมอ สะท้อนให้เห็นถึงประสิทธิภาพในการพยากรณ์ที่ดีกว่าอย่างชัดเจน ซึ่งสอดคล้องกับผลการวิเคราะห์เชิงกราฟและการวิเคราะห์ค่าคลาดเคลื่อน (residual) ที่



พบว่าโครงสร้างของข้อมูลสามารถอธิบายได้ดีด้วยองค์ประกอบเชิงเส้นและฤดูกาล โดยไม่ปรากฏโครงสร้างไม่เชิงเส้นที่มีนัยสำคัญ

### สรุปและอภิปรายผล

ผลการวิจัยตามวัตถุประสงค์ในการเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA และ Residual Hybrid SARIMA–LSTM สำหรับการพยากรณ์ค่า PM2.5 รายเดือนในกรุงเทพมหานคร พบว่าแบบจำลอง SARIMA มีประสิทธิภาพในการพยากรณ์ดีกว่าแบบจำลอง Hybrid อย่างสม่ำเสมอในทุกตัวชี้วัด ทั้งในด้านค่าความคลาดเคลื่อนและความสามารถในการอธิบายความแปรปรวนของข้อมูลและผลลัพธ์ดังกล่าวสามารถอธิบายได้จากลักษณะของข้อมูลที่มีองค์ประกอบเชิงเส้นและฤดูกาลอย่างชัดเจน ซึ่งแบบจำลอง SARIMA สามารถอธิบายได้อย่างมีประสิทธิภาพ ส่งผลให้ค่าคลาดเคลื่อนที่เหลือมีลักษณะใกล้เคียงกับ white noise และไม่ปรากฏโครงสร้างไม่เชิงเส้นที่มีนัยสำคัญ จึงทำให้แบบจำลอง LSTM ไม่สามารถเรียนรู้รูปแบบเพิ่มเติมเพื่อปรับปรุงความแม่นยำได้อย่างมีนัยสำคัญ แม้แนวคิดแบบจำลองเชิงผสมตาม Zhang (2003) จะเสนอว่าการผสมแบบจำลองเชิงเส้นและไม่เชิงเส้นสามารถเพิ่มประสิทธิภาพการพยากรณ์ได้ แต่ผลการศึกษานี้แสดงให้เห็นว่าประสิทธิภาพของแบบจำลอง Hybrid ขึ้นอยู่กับลักษณะของข้อมูลเป็นสำคัญ โดยเฉพาะในกรณีที่ค่าคลาดเคลื่อนไม่มีโครงสร้างที่ชัดเจน การใช้แบบจำลองเชิงลึกอาจไม่ก่อให้เกิดประโยชน์เพิ่มเติม นอกจากนี้ข้อมูลที่ใช้ในการศึกษานี้เป็นข้อมูลรายเดือนซึ่งมีจำนวนข้อมูลค่อนข้างจำกัด อาจไม่เพียงพอต่อการเรียนรู้ของแบบจำลอง LSTM ซึ่งโดยธรรมชาติต้องการข้อมูลจำนวนมากเพื่อให้สามารถเรียนรู้รูปแบบที่ซับซ้อนได้อย่างมีประสิทธิภาพ ดังนั้น ผลการวิจัยนี้ชี้ให้เห็นว่าแบบจำลอง Hybrid ไม่ได้ให้ประสิทธิภาพเหนือกว่าแบบจำลองเดี่ยวในทุกกรณี และการเลือกใช้แบบจำลองควรพิจารณาจากลักษณะของข้อมูลและปริมาณข้อมูลเป็นสำคัญ

### ข้อเสนอแนะ

1. ควรขยายแบบจำลองเป็น SARIMAX โดยเพิ่มตัวแปรอธิบายภายนอก เช่น ปัจจัยอุตสาหกรรมวิทยา เพื่อเพิ่มความสามารถในการอธิบายความผันผวนเชิงพลวัต
2. หากต้องการประยุกต์ใช้ Deep Learning ควรใช้ข้อมูลรายวันหรือรายชั่วโมงและเพิ่มขนาดข้อมูลเพื่อให้โครงข่าย LSTM สามารถเรียนรู้ nonlinear dynamics ได้อย่างมีประสิทธิภาพมากขึ้น

### เอกสารอ้างอิง

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time series analysis: Forecasting and control (5th ed.). John Wiley & Sons.
- 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>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and practice* (3rd ed.). OTexts. <https://otexts.com/fpp3/>
- Makridakis, S., Wheelwright, S. C., & Hyndman, R. J. (1998). *Forecasting: Methods and applications* (3rd ed.). John Wiley & Sons.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2012). *Introduction to time series analysis and forecasting* (2nd ed.). John Wiley & Sons.



- Pollution Control Department. (2023). Air quality monitoring data report. Ministry of Natural Resources and Environment, Thailand.
- Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30, 79–82. <https://doi.org/10.3354/cr030079>
- World Health Organization. (2021). WHO global air quality guidelines: Particulate matter (PM<sub>2.5</sub> and PM<sub>10</sub>), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide. World Health Organization.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175. [https://doi.org/10.1016/S0925-2312\(01\)00702-0](https://doi.org/10.1016/S0925-2312(01)00702-0)