



การเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA, LSTM และแบบจำลองผสมผสาน สำหรับการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร A Comparative Study of SARIMA, LSTM, and Hybrid Models for Daily Maximum Temperature Forecasting in Bangkok

นิวัฒน์ เตชะเกียรตินันท์^{1*}, ศรัญธร มั่งมี² และ พงศ์พัฒน์ ฉายศิริพันธ์³

Niwat Techakiattinun^{1*}, Saranthon Maungmee² and Pongpat Chaisiripan³

^{1,2} อาจารย์สาขาวิชาธุรกิจดิจิทัลและเทคโนโลยี, คณะเทคโนโลยีสารสนเทศ, มหาวิทยาลัยสยาม

^{1,2} Lecturer in Digital Business and Technology, Faculty of Information Technology, Siam University

³ อาจารย์สาขาวิชาเทคโนโลยีสารสนเทศ, คณะเทคโนโลยีสารสนเทศ, มหาวิทยาลัยสยาม

³ Lecturer in Information Technology, Faculty of Information Technology, Siam University

* Corresponding author, E-mail: Niwattec@siam.edu

บทคัดย่อ

การวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA, LSTM และแบบจำลองผสมผสาน ในการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร ช่วงปี 2021–2026 ข้อมูลถูกวิเคราะห์ในลักษณะอนุกรมเวลา โดยแบ่งชุดข้อมูลฝึกสอนและทดสอบ ผลการประเมินด้วยค่า MAE, RMSE และ MAPE พบว่า แบบจำลอง LSTM ให้ค่าความคลาดเคลื่อนต่ำที่สุด (MAE = 1.405, RMSE = 1.699, MAPE = 4.093%) ขณะที่แบบจำลองผสมผสานไม่ได้ให้ผลดีกว่าแบบจำลองเดี่ยว ผลการศึกษาชี้ให้เห็นว่าโครงสร้างข้อมูลมีลักษณะไม่เชิงเส้น ทำให้แบบจำลองเชิงลึกมีความเหมาะสมมากกว่า ผลการพยากรณ์ล่วงหน้า 30 วันแสดงแนวโน้มอุณหภูมิเฉลี่ย 33–34°C โดยมีช่วงความไม่แน่นอนอนจำกัด การศึกษานี้สนับสนุนแนวคิดว่าการเลือกแบบจำลองควรพิจารณาตามลักษณะโครงสร้างข้อมูลเป็นสำคัญ

คำสำคัญ: อุณหภูมิสูงสุดรายวัน, อนุกรมเวลา, SARIMA, LSTM, การพยากรณ์

Abstract

This study aims to compare the performance of SARIMA, LSTM, and hybrid models in forecasting daily maximum temperature in Bangkok during 2021–2026. The time series data were divided into training and testing sets. Model performance was evaluated using MAE, RMSE, and MAPE. The results indicate that LSTM achieved the lowest forecasting errors (MAE = 1.405, RMSE = 1.699, MAPE = 4.093%), while the hybrid model did not outperform the individual models. The findings suggest that the dataset exhibits nonlinear characteristics, making deep learning approaches more suitable. The 30-day ahead forecast shows an average temperature range of 33–34°C with relatively narrow uncertainty bounds. The study highlights the importance of selecting forecasting models based on data structure rather than assuming hybrid superiority

Keywords: Daily Maximum Temperature, Time Series, SARIMA, LSTM, Forecasting



บทนำ

อุณหภูมิอากาศเป็นปัจจัยด้านสิ่งแวดล้อมที่มีความสำคัญอย่างยิ่งต่อระบบนิเวศ สุขภาพของประชาชน การบริหารจัดการพลังงานและการวางแผนพัฒนาเมือง โดยเฉพาะ “อุณหภูมิสูงสุดรายวัน” ซึ่งสะท้อนระดับความร้อนที่ประชาชนต้องเผชิญโดยตรง ในช่วงทศวรรษที่ผ่านมากรุงเทพมหานคร มีแนวโน้มเผชิญกับอุณหภูมิที่สูงขึ้นและเหตุการณ์คลื่นความร้อนบ่อยครั้งขึ้น อันเป็นผลจากการขยายตัวของเมืองและปรากฏการณ์เกาะความร้อนในเมือง (Urban Heat Island) รวมถึงผลกระทบจากการเปลี่ยนแปลงสภาพภูมิอากาศโลกที่รายงานโดย Intergovernmental Panel on Climate Change (2021) ซึ่งชี้ให้เห็นถึงแนวโน้มอุณหภูมิเฉลี่ยของโลกที่เพิ่มสูงขึ้นอย่างมีนัยสำคัญ

การพยากรณ์อุณหภูมิสูงสุดรายวันจึงมีบทบาทสำคัญ ต่อการเตรียมความพร้อมของหน่วยงานที่เกี่ยวข้อง เช่น การจัดการพลังงาน การวางแผนสาธารณสุข การเตือนภัยคลื่นความร้อน และการบริหารจัดการโครงสร้างพื้นฐานในเขตเมือง อย่างไรก็ตาม ข้อมูลอุณหภูมิรายวันมักมีลักษณะเป็นอนุกรมเวลาที่ประกอบด้วยแนวโน้ม (Trend) ฤดูกาล (Seasonality) และความผันผวนที่ไม่เป็นเชิงเส้น (Nonlinear Patterns) ซึ่งทำให้การเลือกแบบจำลองพยากรณ์ที่เหมาะสมเป็นประเด็นสำคัญทางวิชาการ

ในเชิงทฤษฎี แบบจำลองเชิงสถิติอย่าง Seasonal Autoregressive Integrated Moving Average (SARIMA) ได้รับการพัฒนาเพื่อรองรับข้อมูลที่มอดูลประกอบเชิงฤดูกาลอย่างชัดเจน โดยอาศัยหลักการทำให้ข้อมูลมีคุณสมบัติ Stationary และการวิเคราะห์ความสัมพันธ์เชิงเส้นระหว่างค่าปัจจุบันกับค่าในอดีต (Box, Jenkins & Reinsel, 2015; Hyndman & Athanasopoulos, 2018) แบบจำลองดังกล่าวมีจุดเด่นในการอธิบายโครงสร้างเชิงเส้นและฤดูกาลที่สม่ำเสมอของข้อมูล

ขณะเดียวกัน ความก้าวหน้าทางปัญญาประดิษฐ์ได้ก่อให้เกิดแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) โดยเฉพาะ Long Short-Term Memory (LSTM) ซึ่งสามารถเรียนรู้ความสัมพันธ์ระยะยาว และรูปแบบที่ไม่เป็นเชิงเส้นของข้อมูลอนุกรมเวลาได้อย่างมีประสิทธิภาพ (Hochreiter & Schmidhuber, 1997) LSTM จึงเหมาะสมกับข้อมูลสภาพอากาศที่มีความซับซ้อนและความผันผวนสูง

แม้ว่า SARIMA จะมีความแม่นยำในการจับรูปแบบเชิงเส้นและฤดูกาลที่คงที่ และ LSTM จะมีศักยภาพในการเรียนรู้โครงสร้างที่ไม่เป็นเชิงเส้น แต่การใช้แบบจำลองเพียงชนิดเดียวอาจไม่สามารถสะท้อนคุณลักษณะทั้งหมดของข้อมูลอุณหภูมิได้อย่างครบถ้วน ดังนั้น แนวคิดของ “แบบจำลองผสมผสาน” (Hybrid Model) ซึ่งรวมข้อดีของแบบจำลองเชิงสถิติกับแบบจำลองเชิงลึก จึงเป็นแนวทางที่ได้รับความสนใจในงานวิจัยสมัยใหม่ โดยมีวัตถุประสงค์เพื่อลดค่าความคลาดเคลื่อนและเพิ่มความสามารถในการพยากรณ์

จากเหตุผลดังกล่าว งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองผสมผสาน SARIMA–LSTM สำหรับการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร โดยทำการเปรียบเทียบประสิทธิภาพของแบบจำลองเดี่ยวและแบบจำลองผสมผสานผ่านตัวชี้วัดความคลาดเคลื่อนมาตรฐาน ได้แก่ Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) และ Mean Absolute Percentage Error (MAPE) เพื่อเสนอแนวทางเชิงวิชาการในการเลือกใช้แบบจำลองที่เหมาะสม สำหรับการพยากรณ์ข้อมูลสภาพอากาศในเขตเมืองขนาดใหญ่ต่อไปในอนาคต นอกจากนี้ ยังมีงานวิจัยที่ศึกษาการพยากรณ์อุณหภูมิด้วยแบบจำลองเชิงลึกและแบบจำลองผสมผสาน ซึ่งพบว่าสามารถเพิ่มความแม่นยำได้ในกรณีข้อมูลที่มีลักษณะไม่เชิงเส้นสูง



วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองพยากรณ์อนุกรมเวลาของกรุงเทพมหานคร โดยใช้แบบจำลอง SARIMA และแบบจำลองโครงข่ายประสาทเทียมชนิด Long Short-Term Memory (LSTM)
2. เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง SARIMA, LSTM และแบบจำลองผสมผสาน SARIMA-LSTM โดยใช้ตัวชี้วัดความคลาดเคลื่อน ได้แก่ Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) และ Mean Absolute Percentage Error (MAPE)

แนวคิด ทฤษฎี กรอบแนวคิด

การพยากรณ์ข้อมูลอนุกรมเวลารายวันจัดอยู่ในกลุ่มข้อมูลอนุกรมเวลา (Time Series Data) ซึ่งเป็นข้อมูลที่มีลำดับตามเวลาและมีความสัมพันธ์เชิงเวลา (Temporal Dependency) โดยองค์ประกอบสำคัญของอนุกรมเวลา ได้แก่ แนวโน้ม (Trend) ฤดูกาล (Seasonality) วัฏจักร (Cyclical) และส่วนสุ่ม (Irregular Component) (Hyndman & Athanasopoulos, 2018) ตามแนวคิดของ George Box และคณะ (2015) และ Hyndman และ Athanasopoulos (2018)

ในเชิงทฤษฎี แบบจำลอง SARIMA พัฒนาต่อยอดจาก ARIMA โดยเพิ่มพจน์ฤดูกาลเข้าไปในสมการแบบจำลอง เพื่อรองรับข้อมูลที่มีรูปแบบซ้ำตามรอบเวลา เช่น อนุกรมเวลาที่มีลักษณะฤดูกาลรายปี แบบจำลองดังกล่าวสามารถอธิบายความสัมพันธ์เชิงเส้น (Linear Relationship) ของข้อมูลได้อย่างมีประสิทธิภาพ (Box et al., 2015; Brockwell & Davis, 2016)

อย่างไรก็ตาม ข้อมูลภูมิอากาศมักมีความซับซ้อนและมีพฤติกรรมไม่เชิงเส้น (Nonlinear Pattern) ร่วมอยู่ด้วย จึงมีการประยุกต์ใช้โครงข่ายประสาทเทียมแบบลำดับเวลา โดยเฉพาะ Long Short-Term Memory (LSTM) ซึ่งเป็นโครงข่ายประสาทเทียมแบบ Recurrent Neural Network ที่ถูกออกแบบมาเพื่อแก้ปัญหา vanishing gradient และสามารถเรียนรู้ความสัมพันธ์ระยะยาวในข้อมูลลำดับเวลาได้ (Hochreiter & Schmidhuber, 1997; Goodfellow, Bengio & Courville, 2016) LSTM จึงเหมาะสมต่อการพยากรณ์ข้อมูลที่มีรูปแบบซับซ้อนและไม่เชิงเส้น

จากข้อจำกัดของแบบจำลองเดี่ยว นักวิจัยได้เสนอแนวคิดแบบจำลองผสมผสาน (Hybrid Model) โดยอธิบายว่า ข้อมูลอนุกรมเวลาสามารถแยกเป็นองค์ประกอบเชิงเส้นและไม่เชิงเส้น และสามารถใช้แบบจำลองต่างประเภทในการอธิบายองค์ประกอบที่แตกต่างกันเพื่อเพิ่มความแม่นยำในการพยากรณ์ (Zhang, 2003; Khashei & Bijari, 2011) แนวคิดดังกล่าวเป็นรากฐานสำคัญของการรวม SARIMA และ LSTM เข้าด้วยกัน

1. ทฤษฎีแบบจำลองอนุกรมเวลาเชิงสถิติ แบบจำลอง Seasonal Autoregressive Integrated Moving Average (SARIMA) พัฒนาจากกรอบแนวคิดของ Box-Jenkins ซึ่งเน้นการสร้างแบบจำลองผ่านขั้นตอน Identification, Estimation และ Diagnostic Checking (Box et al., 2015) แบบจำลองมีรูปแบบทั่วไปดังนี้

$$SARIMA(p,d,q)(P,D,Q)_s$$

โดยที่

- p, d, q แทน พารามิเตอร์ของส่วน Autoregressive, Integrated และ Moving Average
- P, D, Q แทน องค์ประกอบเชิงฤดูกาล
- S คือ คาบฤดูกาล



SARIMA มีความสามารถในการอธิบายความสัมพันธ์เชิงเส้นระหว่างค่าปัจจุบันกับค่าในอดีต และเหมาะสมกับข้อมูลที่มีฤดูกาลสม่ำเสมอ (Hyndman & Athanasopoulos, 2018)

2. ทฤษฎีโครงข่ายประสาทเทียมแบบวนซ้ำ Long Short-Term Memory (LSTM) เป็นโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่พัฒนาโดย Hochreiter & Schmidhuber (1997) เพื่อแก้ปัญหา Vanishing Gradient Problem

LSTM ประกอบด้วยหน่วยความจำ (Memory Cell) และกลไกประตู ได้แก่ Input Gate, Forget Gate และ Output Gate ซึ่งช่วยให้สามารถเรียนรู้ความสัมพันธ์ระยะยาวและโครงสร้างไม่เชิงเส้นได้อย่างมีประสิทธิภาพ ในบริบทของข้อมูลภูมิอากาศซึ่งมีความซับซ้อนและไม่เป็นเชิงเส้น LSTM จึงมีศักยภาพในการเพิ่มประสิทธิภาพการพยากรณ์ (Goodfellow, Bengio, & Courville, 2016)

3. แนวคิดแบบจำลองผสมผสาน แนวคิดการผสมผสาน SARIMA-LSTM ตั้งอยู่บนสมมติฐานว่าข้อมูลอนุกรมเวลาสามารถแยกองค์ประกอบออกเป็นส่วนเชิงเส้นและไม่เชิงเส้น กล่าวคือ

$$Y_t = L_t + N_t$$

โดยที่

- L_t แทน องค์ประกอบเชิงเส้น ซึ่งประมาณค่าด้วย SARIMA
- N_t แทน องค์ประกอบที่เหลือซึ่งมีลักษณะไม่เป็นเชิงเส้น และเรียนรู้ด้วย LSTM

แนวคิดดังกล่าวได้รับการเสนอโดย Zhang (2003) ซึ่งพบว่าการรวมแบบจำลอง ARIMA กับ Neural Network สามารถลดค่าความคลาดเคลื่อนของการพยากรณ์ได้ดีกว่าการใช้แบบจำลองเดี่ยว

กรอบแนวคิดของการวิจัยกำหนดให้ข้อมูลอุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร เป็นข้อมูลตั้งต้น ซึ่งผ่านกระบวนการเตรียมข้อมูล ได้แก่ การตรวจสอบค่าผิดปกติ การทดสอบความนิ่งของข้อมูล (Stationarity Test) และการปรับสเกลข้อมูล

โดยกระบวนการพัฒนาแบบจำลองผสมผสาน ประกอบด้วยขั้นตอนดังนี้

- 1) ใช้แบบจำลอง SARIMA ในการพยากรณ์องค์ประกอบเชิงเส้น
- 2) คำนวณค่าคลาดเคลื่อน (Residuals)
- 3) นำค่าคลาดเคลื่อนดังกล่าวไปใช้เป็นข้อมูลนำเข้าในการฝึกแบบจำลอง LSTM
- 4) รวมผลลัพธ์จากทั้งสองแบบจำลองเพื่อให้ได้ค่าพยากรณ์สุดท้าย

ผลลัพธ์การพยากรณ์ของแต่ละแบบจำลองจะถูกประเมินด้วยตัวชี้วัด ความคลาดเคลื่อนมาตรฐาน ได้แก่ Mean Absolute Error (MAE), Root Mean Squared Error (RMSE) และ Mean Absolute Percentage Error (MAPE)

ความสัมพันธ์เชิงแนวคิดสามารถอธิบายได้ดังนี้

ข้อมูลอุณหภูมิย้อนหลัง

- วิเคราะห์โครงสร้างอนุกรมเวลา
- พัฒนาแบบจำลองเชิงเส้น (SARIMA)
- พัฒนาแบบจำลองไม่เชิงเส้น (LSTM)
- ผสมผสานผลลัพธ์
- ประเมินประสิทธิภาพ
- เลือกแบบจำลองที่เหมาะสม



กรอบแนวคิดดังกล่าวสะท้อนความสัมพันธ์ระหว่างข้อมูลตั้งต้น กระบวนการสร้างแบบจำลอง และผลลัพธ์เชิงประสิทธิภาพ เพื่อให้ได้ข้อสรุปเชิงประจักษ์เกี่ยวกับความเหมาะสมของแบบจำลองผสมผสานในการพยากรณ์อุณหภูมิสูงสุดรายวัน ในเขตเมืองขนาดใหญ่

วิธีดำเนินการวิจัย

การวิจัยเรื่อง “การพัฒนาแบบจำลองผสมผสาน SARIMA–LSTM สำหรับการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร” เป็นการวิจัยเชิงปริมาณ โดยประยุกต์การวิเคราะห์ข้อมูลอนุกรมเวลา และการเรียนรู้เชิงลึก เพื่อเปรียบเทียบและประเมินประสิทธิภาพของแบบจำลองพยากรณ์ มีขั้นตอนดำเนินการดังต่อไปนี้

1. แหล่งที่มาและขอบเขตของข้อมูล ข้อมูลที่ใช้ในการวิจัยเป็นข้อมูลอุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร ระหว่างวันที่ 1 มกราคม ค.ศ. 2021 ถึง 31 มกราคม ค.ศ. 2026 (พ.ศ. 2564 ถึง 2569) รวมระยะเวลาประมาณ 5 ปี โดยรวบรวมจากแหล่งข้อมูลทางการที่มีความน่าเชื่อถือ เช่น กรมอุตุนิยมวิทยา ซึ่งเป็นหน่วยงานหลักด้านการตรวจวัดและเผยแพร่ข้อมูลภูมิอากาศของประเทศไทย ช่วงเวลาดังกล่าวครอบคลุมความแปรปรวนตามฤดูกาล แนวโน้มระยะยาว และความผันผวนระยะสั้น อันเป็นคุณลักษณะสำคัญของข้อมูลอุณหภูมิในเขตเมืองขนาดใหญ่

2. การแบ่งชุดข้อมูลเพื่อการวิเคราะห์ การแบ่งชุดข้อมูลดำเนินการตามลำดับเวลา (Chronological Splitting) เพื่อรักษาคุณลักษณะของข้อมูลอนุกรมเวลาและป้องกันการรั่วไหลของข้อมูล (Data Leakage) โดยกำหนดดังนี้

2.1 ชุดข้อมูลฝึกสอนแบบจำลอง (Training Set): ช่วงวันที่ 1 มกราคม ค.ศ. 2021 ถึง 31 ธันวาคม ค.ศ. 2024 ใช้สำหรับการประมาณค่าพารามิเตอร์ของแบบจำลอง SARIMA และการฝึกโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM)

2.2 ชุดข้อมูลทดสอบแบบจำลอง (Testing Set): ช่วงวันที่ 1 มกราคม ค.ศ. 2025 ถึง 1 มกราคม ค.ศ. 2026 ใช้สำหรับประเมินสมรรถนะของแบบจำลอง โดยไม่ได้นำข้อมูลส่วนนี้เข้าสู่กระบวนการฝึก

2.3 ช่วงการใช้งานจริง (Operational Forecasting Phase): ภายหลังจากวันที่ 1 มกราคม ค.ศ. 2026 เป็นต้นไป แบบจำลองที่ผ่านการประเมินแล้วจะถูกนำไปใช้พยากรณ์อุณหภูมิสูงสุดล่วงหน้า ในระยะสั้นและระยะกลาง เช่น 7 วัน 30 วัน หรือ 90 วัน เพื่อจำลองสถานการณ์การใช้งานจริง

3. การเตรียมและประมวลผลข้อมูล การเตรียมข้อมูลดำเนินการตามขั้นตอนเชิงระเบียบวิธี ดังนี้

1. ตรวจสอบและจัดการค่าที่ขาดหาย (Missing Values)
2. ตรวจสอบค่าผิดปกติ (Outliers) และประเมินผลกระทบต่อแบบจำลอง
3. วิเคราะห์องค์ประกอบแนวโน้มและฤดูกาลของข้อมูล
4. ทดสอบความนิ่งของข้อมูลด้วยสถิติ Augmented Dickey–Fuller (ADF Test)
5. ดำเนินการ Differencing สำหรับแบบจำลอง SARIMA หากข้อมูลไม่เป็นสถานี
6. ปรับสเกลข้อมูล (Normalization) สำหรับแบบจำลอง LSTM เพื่อเพิ่มเสถียรภาพในการฝึก



4. การพัฒนาแบบจำลองพยากรณ์ การพัฒนาแบบจำลองประกอบด้วย 3 แนวทาง ได้แก่

4.1 แบบจำลอง SARIMA กำหนดพารามิเตอร์ $SARIMA(p,d,q)(P,D,Q)_s$ โดยพิจารณาจากกราฟ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) ร่วมกับเกณฑ์ Akaike Information Criterion (AIC) เพื่อคัดเลือกแบบจำลองที่เหมาะสม โดยประยุกต์ใช้เทคนิคการค้นหาแบบ Grid Search บนข้อมูลที่ปรับความถี่เป็นรายเดือน เพื่อจับรูปแบบฤดูกาล ($s=12$) จากนั้นดำเนินการตรวจสอบความเป็นอิสระและการกระจายตัว ของค่าคลาดเคลื่อน (Residual Diagnostics)

4.2 แบบจำลอง LSTM ออกแบบโครงสร้างโครงข่ายโดยกำหนดจำนวนชั้นซ่อน (Hidden Layers) จำนวนหน่วยความจำ (Units) ฟังก์ชันกระตุ้น และจำนวนรอบการฝึก (Epochs) ให้เหมาะสมกับลักษณะข้อมูล โดยกำหนดสถาปัตยกรรมการทดลอง ประกอบด้วย ชั้นซ่อนแบบ LSTM จำนวน 2 ชั้น (ขนาด 64 และ 32 Units) ใช้เทคนิค Dropout ที่ระดับร้อยละ 20 เพื่อป้องกันปัญหาการเรียนรู้เกิน (Overfitting) และเชื่อมต่อกับชั้น Dense Layer (32 Units) ที่ใช้ฟังก์ชันกระตุ้นชนิด ReLU โครงข่ายนี้ใช้ข้อมูลอุณหภูมิย้อนหลัง 30 วันเป็นปัจจัยนำเข้า และฝึกสอนด้วยอัลกอริทึม Adam Optimizer โดยใช้ฟังก์ชันสูญเสียแบบ Mean Squared Error (MSE) ร่วมกับระบบ Early Stopping

4.3 แบบจำลองผสมผสาน SARIMA-LSTM ดำเนินการพยากรณ์องค์ประกอบเชิงเส้นด้วย SARIMA ก่อนจากนั้นนำค่าคลาดเคลื่อน (Residuals) ไปฝึกด้วย LSTM (โดยใช้สถาปัตยกรรมเดียวกันกับหัวข้อ 4.2) เพื่อเรียนรู้โครงสร้างเชิงไม่เส้นและรวมผลลัพธ์ทั้งสองส่วน เพื่อให้ได้ค่าพยากรณ์ขั้นสุดท้าย

5. การประเมินประสิทธิภาพแบบจำลอง การประเมินประสิทธิภาพดำเนินการโดยใช้ชุดข้อมูลทดสอบ (1 มกราคม ค.ศ. 2021 – 1 มกราคม ค.ศ. 2026) และใช้ตัวชี้วัดมาตรฐาน ได้แก่


1. Mean Absolute Error (MAE)
2. Root Mean Squared Error (RMSE)
3. Mean Absolute Percentage Error (MAPE)

ผลการเปรียบเทียบค่าความคลาดเคลื่อนจะใช้เป็นเกณฑ์ ในการพิจารณาความเหมาะสมของแบบจำลองแต่ละประเภท และวิเคราะห์ศักยภาพของแบบจำลองผสมผสาน ในการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร

ผลการวิจัย

1. ลักษณะข้อมูลอุณหภูมิสูงสุดรายวัน

จากการวิเคราะห์ข้อมูลอุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร ในช่วงปี ค.ศ. 2021-2026 (ระยะเวลา 5 ปี) พบว่า ข้อมูลมีลักษณะเป็นอนุกรมเวลา (Time Series) ที่ประกอบด้วยองค์ประกอบแนวโน้ม (Trend) และฤดูกาล (Seasonality) อย่างชัดเจน ดังแสดงในภาพที่ 1 นอกจากนี้ ผู้วิจัยได้ประเมินประสิทธิภาพของแบบจำลองในชุดข้อมูลฝึกสอน (Training Set) เพื่อวิเคราะห์ความสามารถในการเรียนรู้ของแบบจำลอง



ภาพที่ 1 Daily Maximum Temperature – Bangkok (2021–2026)

ผลการวิเคราะห์เชิงพรรณนาพบว่า อุณหภูมิสูงสุดรายวันมีค่าการแกว่งตัวอยู่ในช่วงประมาณ 28–41 องศาเซลเซียส โดยค่าที่สูงที่สุดมักปรากฏในช่วงเดือนมีนาคมถึงพฤษภาคมของแต่ละปี สะท้อนลักษณะฤดูร้อนของพื้นที่ศึกษาอย่างสม่ำเสมอ

การคำนวณค่าเฉลี่ยเคลื่อนที่ 30 วัน พร้อมส่วนเบี่ยงเบนมาตรฐาน แสดงในภาพที่ 1 ส่วน Rolling Mean \pm Std ซึ่งให้เห็นรูปแบบฤดูกาลที่เกิดขึ้นเป็นรอบปีและมีความแปรปรวนเพิ่มขึ้น ในช่วงอุณหภูมิสูงสุดสอดคล้องกับกรอบแนวคิดองค์ประกอบอนุกรมเวลาของ Time Series Analysis: Forecasting and Control ซึ่งอธิบายว่าข้อมูลด้านอนุกรมวิทย์มักประกอบด้วย องค์ประกอบเชิงแนวโน้มและฤดูกาลร่วมกัน

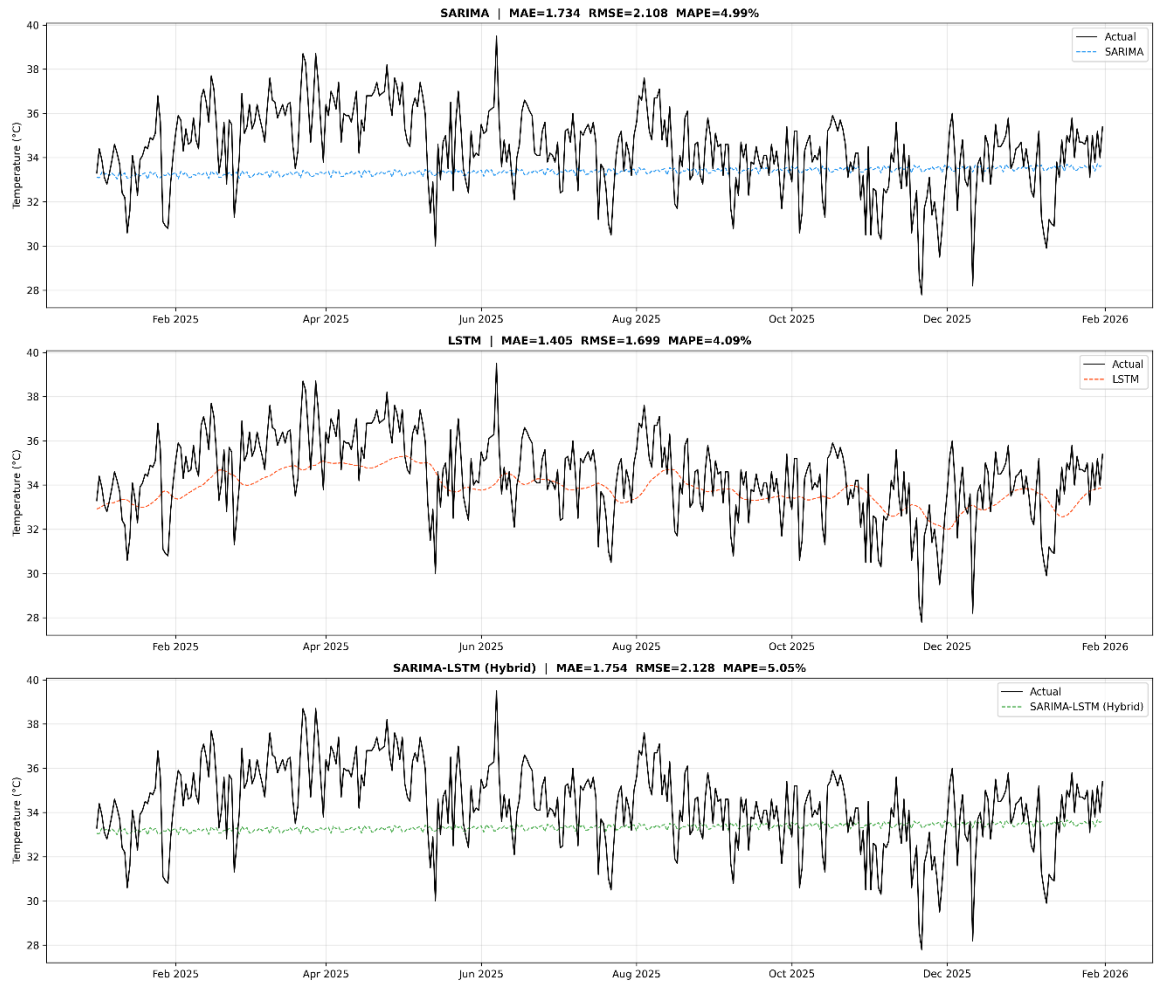
นอกจากนี้ การกระจายตัวรายเดือนในภาพที่ 1 ส่วน Monthly Temperature Distribution แสดงให้เห็นว่าเดือนเมษายนมีค่ามัธยฐานสูงที่สุด และมีช่วงการกระจายกว้างกว่าบางเดือนในช่วงปลายปี สะท้อนความผันผวนของอุณหภูมิ ในฤดูร้อนของกรุงเทพมหานครอย่างมีนัยสำคัญเชิงโครงสร้าง

2. ผลการเปรียบเทียบประสิทธิภาพแบบจำลอง

ผลการประเมินประสิทธิภาพแบบจำลองในช่วงทดสอบ (มกราคม ค.ศ. 2025 – มกราคม ค.ศ. 2026) แสดงใน ภาพที่ 2- 4




Forecast vs Actual - Test Period (Jan 2025 - Jan 2026)




ภาพที่ 2 Forecast vs Actual – Test Period (Jan 2025 – Jan 2026)

Model Performance Comparison: SARIMA vs LSTM vs Hybrid



ภาพที่ 3 Model Performance Comparison: SARIMA vs LSTM vs Hybrid



ภาพที่ 4 Actual vs Predicted Temperature (Test Set)

ผลการคำนวณค่าความคลาดเคลื่อนสรุปได้ดังนี้

ตารางที่ 1 แสดงผลการเปรียบเทียบประสิทธิภาพ

แบบจำลอง	MAE	RMSE	MAPE (%)
SARIMA	1.734	2.108	4.994
LSTM	1.405	1.699	4.093
SARIMA-LSTM	1.754	2.128	5.047

จากตารางที่ 1 พบว่า ผลการทดลองชี้ชัดว่าแบบจำลอง LSTM ให้ค่าความคลาดเคลื่อนต่ำที่สุดในทุกตัวชี้วัด โดยลดค่า RMSE ลงประมาณร้อยละ 19 เมื่อเทียบกับ SARIMA แสดงถึงประสิทธิภาพที่เหนือกว่าอย่างมีนัยสำคัญเชิงปฏิบัติ (Practical Significance) นอกจากนี้ ผู้วิจัยได้วิเคราะห์ความซับซ้อนของแบบจำลอง LSTM โดยพิจารณาจำนวนชั้นซ่อน (Hidden Layers) และจำนวนหน่วยความจำ (Units) ซึ่งแบบจำลองที่ใช้ในงานวิจัยนี้ประกอบด้วย LSTM จำนวน 2 ชั้น (64 และ 32 Units) จัดอยู่ในระดับความซับซ้อนปานกลาง

ผลการทดลองไม่พบปัญหาการเรื้อรังเกิน (Overfitting) อย่างมีนัยสำคัญ โดยพิจารณาจากค่าความคลาดเคลื่อนระหว่างชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบที่มีความใกล้เคียงกัน แสดงให้เห็นว่าโครงสร้างแบบจำลองที่เลือกมีความเหมาะสมกับลักษณะข้อมูล


ทั้งนี้ หากเพิ่มความซับซ้อนของแบบจำลองมากขึ้น อาจส่งผลให้เกิด Overfitting ได้ ดังนั้น การเลือกโครงสร้างแบบจำลองที่เหมาะสม จึงเป็นปัจจัยสำคัญในการพยากรณ์ข้อมูลอนุกรมเวลา

จากภาพที่ 2 พบว่า เส้นพยากรณ์ของ LSTM มีความสอดคล้องกับค่าจริงมากที่สุด โดยเฉพาะในช่วงที่อุณหภูมิเกิดความผันผวนระยะสั้น ขณะที่ SARIMA มีลักษณะการพยากรณ์ที่เรียบกว่าและมีแนวโน้มเข้าสู่ค่าเฉลี่ย

ภาพที่ 4 แสดงกราฟกระจายระหว่างค่าจริงและค่าพยากรณ์ พบว่า จุดข้อมูลของ LSTM กระจายตัวใกล้เส้น Perfect Fit ($y = x$) มากที่สุด สะท้อนความสามารถในการเรียนรู้ความสัมพันธ์เชิงไม่เชิงเส้นตามแนวคิดของ Long Short-Term Memory

3. ผลการพยากรณ์ล่วงหน้า 30 วัน

ผลการพยากรณ์อุณหภูมิสูงสุดรายวันล่วงหน้า 30 วัน แสดงในภาพที่ 5 Daily Maximum Temperature Forecast – Next 30 Days



ภาพที่ 5 Daily Maximum Temperature Forecast – Next 30 Days

ผลการพยากรณ์พบว่า แนวโน้มอุณหภูมิ ในช่วงเวลาที่คาดการณ์มีค่าเฉลี่ยประมาณ 33–34 องศาเซลเซียส โดยมีช่วงความไม่แน่นอนประมาณ ± 1.5 องศาเซลเซียส ซึ่งอยู่ในกรอบที่จำกัดและไม่ปรากฏการเปลี่ยนแปลงเชิงโครงสร้างอย่างฉับพลัน แสดงถึงเสถียรภาพของแบบจำลองในการประยุกต์ใช้เชิงปฏิบัติการระยะสั้น

อภิปรายผล

ผลการวิจัยแสดงให้เห็นว่าแบบจำลอง LSTM มีประสิทธิภาพสูงกว่าแบบจำลอง SARIMA และแบบจำลองผสมผสาน (SARIMA–LSTM) ในการพยากรณ์อุณหภูมิสูงสุดรายวันของกรุงเทพมหานคร ทั้งในด้านค่าความคลาดเคลื่อนและความสามารถในการติดตามความผันผวนของข้อมูลและผลลัพธ์ดังกล่าวสามารถอธิบายได้จากลักษณะของข้อมูลอุณหภูมิในเขตเมืองที่มีความซับซ้อน และมีโครงสร้างไม่เชิงเส้น (Nonlinear) ซึ่งได้รับอิทธิพลจากปัจจัยหลายด้าน เช่น ปรากฏการณ์เกาะความร้อนในเมือง (Urban Heat Island) และการเปลี่ยนแปลงสภาพภูมิอากาศ ส่งผลให้แบบจำลองเชิงสถิติอย่าง SARIMA ซึ่งเน้นการอธิบายความสัมพันธ์เชิงเส้น อาจไม่สามารถจับรูปแบบข้อมูลได้อย่างครบถ้วน ในขณะที่แบบจำลอง LSTM ซึ่งเป็นโครงข่ายประสาทเทียมแบบลำดับเวลา สามารถเรียนรู้ความสัมพันธ์ระยะยาวและรูปแบบที่ไม่เชิงเส้นได้อย่างมีประสิทธิภาพ จึงสามารถสะท้อนพฤติกรรมของข้อมูลได้แม่นยำมากกว่า โดยเฉพาะในช่วงที่ข้อมูลมีความผันผวนสูง และสำหรับแบบจำลองผสมผสาน (SARIMA–LSTM) ที่ไม่สามารถให้ผลลัพธ์ดีกว่าแบบจำลอง LSTM อาจเกิดจากข้อจำกัดในการแยกองค์ประกอบเชิงเส้นและไม่เชิงเส้นของข้อมูล ซึ่งอาจทำให้เกิดการสูญเสียสารสนเทศบางส่วนในกระบวนการสร้างแบบจำลอง ส่งผลให้ค่าคลาดเคลื่อนที่เหลือไม่สามารถสะท้อนโครงสร้างของข้อมูลได้อย่างชัดเจน

นอกจากนี้ แบบจำลองผสมผสานที่ใช้ในงานวิจัยนี้ เป็นเพียงหนึ่งในแนวทางการรวมแบบจำลอง โดยอาศัยสมมติฐาน $Y_t = L_t + N_t$ อย่างไรก็ตาม ยังมีแนวทางอื่นที่สามารถพัฒนาเพิ่มเติมได้ เช่น การรวมแบบถ่วงน้ำหนัก (Weighted Hybrid Model) ในรูปแบบ $Y_t = w_1L_t + w_2N_t$ ซึ่งกำหนดค่าน้ำหนักล่วงหน้า หรือการเรียนรู้น้ำหนักแบบอัตโนมัติในระหว่างการฝึกแบบจำลอง เช่น แนวคิดของ Gradient Boosting ซึ่งอาจช่วยเพิ่มประสิทธิภาพในการพยากรณ์ได้ในบางกรณี

ผลการวิจัยนี้สอดคล้องกับแนวคิด No Free Lunch Theorem ซึ่งระบุว่าไม่มีแบบจำลองใดที่สามารถให้ผลลัพธ์ที่ดีที่สุดในทุกสถานการณ์ การเลือกใช้แบบจำลองจึงควรพิจารณาจากลักษณะของข้อมูลเชิงประจักษ์เป็นสำคัญ โดยเฉพาะในกรณีข้อมูลอนุกรมเวลาที่มีความไม่เชิงเส้นสูง ซึ่งแบบจำลอง



เชิงลึกอาจมีความเหมาะสมมากกว่าแบบจำลองเชิงสถิติแบบดั้งเดิม ในเชิงการประยุกต์ใช้ ผลการวิจัยนี้สามารถนำไปใช้สนับสนุนการวางแผนด้านพลังงาน การบริหารจัดการความเสี่ยงจากคลื่นความร้อน และการสนับสนุนการตัดสินใจเชิงนโยบายในเขตเมืองขนาดใหญ่ได้อย่างมีประสิทธิภาพ นอกจากนี้การศึกษานี้ยังชี้ให้เห็นถึงแนวทางในการพัฒนาแบบจำลองในอนาคต เช่น การเพิ่มตัวแปรภายนอก (Exogenous Variables) และการพัฒนาแบบจำลองผสมผสานในรูปแบบที่ซับซ้อนมากขึ้น เพื่อเพิ่มความแม่นยำของการพยากรณ์

1. ความซับซ้อนและโครงสร้างเชิงไม่เส้นของข้อมูลภูมิอากาศเมือง แม้ว่าในทางทฤษฎีแบบจำลอง SARIMA จะมีความเหมาะสมอย่างยิ่งกับข้อมูลอนุกรมเวลาที่มีรูปแบบฤดูกาลสม่ำเสมอ (Hyndman & Athanasopoulos, 2018) แต่ข้อมูลอุณหภูมิรายวัน ในเขตเมืองขนาดใหญ่อย่างกรุงเทพมหานคร ได้รับอิทธิพลจากปัจจัยภายนอกแบบพหุมิติที่ซับซ้อน เช่น ปรากฏการณ์เกาะความร้อนในเมือง (Urban Heat Island) และผลกระทบจากการเปลี่ยนแปลงสภาพภูมิอากาศ ปัจจัยเหล่านี้ส่งผลให้ข้อมูลมีความผันผวนสูงและเกิดโครงสร้างเชิงไม่เส้น (Nonlinear Pattern) อย่างมีนัยสำคัญ โครงข่ายประสาทเทียมแบบ LSTM ซึ่งถูกออกแบบมาให้จดจำความสัมพันธ์ระยะยาวและสกัดคุณลักษณะที่ซับซ้อนได้ดีกว่า จึงสะท้อนพลวัตของอุณหภูมิได้แม่นยำกว่าแบบจำลองเชิงสถิติแบบดั้งเดิม

2. ข้อจำกัดของแบบจำลองผสมผสาน (Hybrid Model) ในบริบทข้อมูลอุณหภูมิ กรณีที่แบบจำลองผสมผสาน SARIMA-LSTM ไม่สามารถให้ผลลัพธ์ที่ดีกว่าแบบจำลองเดี่ยว และมีค่าความคลาดเคลื่อนสูงกว่า LSTM สามารถอธิบายเชิงทฤษฎีได้จากสมการ $Y_t = L_t + N_t$ ดังนี้:

- **ปัญหาการสูญเสียสารสนเทศ (Information Loss):** ข้อมูลอุณหภูมิชุดนี้อาจไม่มีโครงสร้างเชิงเส้นที่แยกตัวออกมาชัดเจนเพียงพอ การบังคับใช้ SARIMA เพื่อสกัดองค์ประกอบเชิงเส้น (L_t) ออกไปก่อน อาจทำให้คุณลักษณะสำคัญบางประการของข้อมูลถูกบิดเบือน ส่งผลให้ค่าคลาดเคลื่อน (Residuals หรือ N_t) ที่หลงเหลืออยู่ ไม่มีรูปแบบที่ชัดเจนพอให้ LSTM สามารถเรียนรู้ได้อย่างมีประสิทธิภาพ

- **ปัญหาการปรับสเกลข้อมูล (Data Scaling):** การนำค่าคลาดเคลื่อน (Residuals) ซึ่งมีค่าแกว่งตัวทั้งบวกและลบรอบจุดศูนย์ ไปทำการปรับสเกล (Normalization) ใหม่เพื่อป้อนเข้าสู่ LSTM อาจทำให้โครงข่ายไม่สามารถจับขนาด (Magnitude) ของความผันผวนที่แท้จริงได้ดีเท่ากับการให้ LSTM เรียนรู้จากข้อมูลอุณหภูมิดิบตั้งแต่ต้น

ดังนั้น ผลการศึกษาในครั้งนี้จึงสนับสนุนข้อเสนอที่ว่า การเลือกใช้แบบจำลองพยากรณ์ ไม่ควรตั้งอยู่บนสมมติฐานเชิงทฤษฎีที่ว่าแบบจำลองผสมผสานจะดีกว่าเสมอไป แต่ควรพิจารณาตัดสินใจโดยอิงจาก "ลักษณะโครงสร้างข้อมูลเชิงประจักษ์ (Empirical Data Structure)" เป็นหัวใจสำคัญ

ข้อเสนอแนะ

1. ควรพัฒนาแบบจำลองเชิงพหุแปรโดยเพิ่มตัวแปรอธิบายภายนอก เช่น ความชื้นสัมพัทธ์หรือปริมาณฝน เพื่อเพิ่มความแม่นยำของการพยากรณ์

2. ควรประเมินความเสถียรของแบบจำลองด้วยวิธี Time Series Cross-Validation เพื่อยืนยันความสามารถในการใช้งานในช่วงเวลาที่แตกต่างกัน



เอกสารอ้างอิง

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time series analysis: Forecasting and control (5th ed.). Hoboken, NJ: John Wiley & Sons.
- Brockwell, P. J., & Davis, R. A. (2016). Introduction to time series and forecasting (3rd ed.). New York, NY: Springer
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. Cambridge, MA: MIT Press.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and practice* (2nd ed.). Melbourne, Australia: OTexts.
- Intergovernmental Panel on Climate Change (IPCC). (2021). *Climate change 2021: The physical science basis*. Cambridge, UK: Cambridge University Press.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.