

ผลกระทบของสภาพอากาศต่อความเข้มข้นฝุ่นละอองขนาด 2.5 ไมครอน ในกรุงเทพฯ และปริมณฑล โดยใช้ MACHINE LEARNING THE EFFECT OF WEATHER ON PM2.5 IN BANGKOK AREA AND BANGKOK METROPOLITAN REGION USING MACHINE LEARNING

ชนิดาภา วินาลัย ศตวรรษ นันทะเสน และสุดารัตน์ ชาตีสุทธิ*

Chanidapa Winalai, Satawat Nanthasen and Sudarat Chadsuthi*

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาความสัมพันธ์ระหว่างตัวแปรทางสภาพอากาศ ได้แก่ อุณหภูมิ ปริมาณน้ำฝน ความชื้นสัมพัทธ์ ความเร็วลม และความดันบรรยากาศมาตรฐาน ที่ส่งผลต่อการเพิ่มหรือลดความเข้มข้นฝุ่นละออง PM2.5 รวมถึงสร้างแบบจำลองโครงข่ายประสาทเทียม หน่วยความจำระยะสั้นแบบยาว (LSTM) เพื่อทำนายความเข้มข้นฝุ่นละออง PM2.5 โดยผู้วิจัยใช้ข้อมูลฝุ่นละออง PM2.5 จากกรมควบคุมมลพิษ (กระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อม) และข้อมูลตัวแปรทางสภาพอากาศจาก Global Surface Summary of the Day (GSOD) ซึ่งมีขอบเขตงานวิจัยคือ พื้นที่กรุงเทพฯ และปริมณฑล ผู้วิจัยมีสมมติฐานว่า ตัวแปรทางสภาพอากาศจะมีความสัมพันธ์ต่อการเกิดฝุ่นละออง PM2.5 และสามารถใช้อนุกรมการสร้างแบบจำลองทำนายค่าความเข้มข้นของฝุ่นละออง PM2.5 ได้ จากการศึกษาพบว่าตัวแปรทางสภาพอากาศที่สามารถใช้ทำนายค่าความเข้มข้นของฝุ่นละออง PM2.5 ได้ดี ได้แก่ อุณหภูมิและปริมาณน้ำฝน และช่วงเวลาที่เป็นแบบจำลองทำนายได้แม่นยำที่สุด คือช่วงข้อมูลตัวแปรทางสภาพอากาศ ณ เวลาเดียวกันกับปริมาณความเข้มข้นของ PM2.5

คำสำคัญ: ฝุ่นละออง PM2.5 ตัวแปรทางสภาพอากาศ โครงข่ายประสาทเทียม

คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร อำเภอเมือง จังหวัดพิษณุโลก 65000

Faculty of Science, Naresuan University, Muang District, Phitsanulok Province 65000

*corresponding author e-mail: sudaratc@nu.ac.th

Received: 14 April 2022; Revised: 19 July 2022; Accepted: 20 July 2022

DOI: <https://doi.org/10.14456/lsej.2022.31>

Abstract

The purpose of this study was to investigate the effects of five weather variables (temperature, precipitation, relative humidity, wind speed, and STP) on the particulate matter 2.5 (PM2.5) concentrations and to apply a long short-term memory model (LSTM) in order to predict PM2.5 concentrations from these weather variables. We used the PM2.5 data from the Pollution Control Department (Thai Ministry of Natural Resources and the Environment) and weather variables data from the Global Surface Summary of the Day (GSOD) in the area of study (Bangkok area and Bangkok Metropolitan Region). We hypothesized that weather variables relate to PM2.5 concentrations and could be used to predict the concentrations of PM2.5. The results showed that temperature and precipitation could be used to predict PM2.5 concentrations. We also found that a more accurate model can be obtained by using data of predictor variations over the same period.

Keywords: PM2.5, Weather variables, Neural network

บทนำ

ฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) เป็นฝุ่นที่มีเส้นผ่านศูนย์กลางไม่เกิน 2.5 ไมครอน เกิดจากการเผาไหม้ทั้งจากยานพาหนะ การเผาวัสดุการเกษตร ไฟป่า และกระบวนการอุตสาหกรรม การสะสมของควันหรือฝุ่นในอากาศ โดยส่วนใหญ่เกิดจากการเผาเศษวัสดุเหลือใช้ทางการเกษตร ไฟป่า และการจราจรที่แออัด ปัจจัยด้านสิ่งแวดล้อมอาจส่งผลต่อค่าความเข้มข้นของฝุ่นละอองของ PM2.5 ในปัจจุบันจังหวัดที่มีการจราจรหนาแน่น เช่น กรุงเทพมหานคร และปริมณฑล กำลังประสบปัญหามลพิษทางอากาศอย่างรุนแรง ซึ่งเป็นผลมาจากการพัฒนาเศรษฐกิจและการขยายตัวของเมืองอย่างรวดเร็ว จากข้อมูลของกรมควบคุมมลพิษประจำปี พ.ศ. 2563 พบว่าค่าความเข้มข้นของฝุ่นละออง PM2.5 ในหลาย ๆ พื้นที่มีค่าเกินค่ามาตรฐาน โดยเฉพาะภาคกลางในประเทศไทย (Air Quality and Noise Management Bureau, 2020) ในระยะยาวฝุ่นละอองเหล่านี้จะส่งผลกระทบต่อสุขภาพของปอดลดลงเป็นสาเหตุทำให้เกิดโรคหอบหืด โรคหลอดเลือดหัวใจ และในผู้ป่วยที่มีปัญหาทางด้านระบบทางเดินหายใจ โรคหัวใจ เต็ก และผู้สูงอายุ จะมีความไวต่ออนุภาคขนาดเล็ก และกระตุ้นให้เกิดอาการต่าง ๆ ได้ง่ายกว่าบุคคลทั่วไป (Dajsakdipon, 2020)

ในการศึกษาการเปลี่ยนแปลงคุณภาพทางอากาศโดยใช้โครงข่ายประสาทเทียมประเภทต่าง ๆ สามารถทำนายได้หลายรูปแบบ โดยในปี พ.ศ. 2560 ได้มีการใช้โครงข่ายประสาทเทียมแบบ Multilayer Perceptron (MLP) เพื่อทำนายก๊าซไนโตรเจนไดออกไซด์ (NO_2) จากข้อมูลมลพิษและข้อมูลทางอุตุนิยมวิทยารายชั่วโมง ในบริเวณถนน Marylebone เมืองลอนดอน ประเทศอังกฤษ (Cabaneros et al., 2017) ต่อมาในปี พ.ศ. 2564 Shams et al. (2021) ได้ศึกษาโครงข่ายประสาทเทียม (Artificial Neural Networks, ANN) และแบบจำลองการถดถอยเชิงพหุคูณ (Multiple Linear Regressions, MLR) เพื่อทำนายก๊าซซัลเฟอร์ไดออกไซด์ (SO_2) โดยทำการเก็บรวบรวมข้อมูล SO_2 ทั้งหมด 16 สถานี ภายในปี ค.ศ. 2015 บริเวณเมืองหลวง เตหะราน ประเทศอิหร่าน (Shams et al., 2021)

แบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory, LSTM) ซึ่งเป็นส่วนหนึ่งของโครงข่ายประสาทเทียม (Artificial neural networks) โดยแบบจำลอง LSTM เป็นแบบจำลองที่พัฒนามาจากโครงข่ายประสาทเทียมเดิมคือ Recurrent Neural Network (RNN) แต่เพิ่มเติมจาก RNN คือสามารถจดจำ (Memory) สถานะของแต่ละโหนดได้ โดยมีประตู (Gate) ที่ทำหน้าที่ควบคุมการเข้า-ออกของข้อมูล โดยงานวิจัยก่อนหน้าศึกษาการทำนายค่าความเข้มข้นของฝุ่นละออง $\text{PM}_{2.5}$ ใน 24 ชั่วโมงข้างหน้า โดยใช้แบบจำลองหน่วยจำระยะสั้นแบบยาว LSTM เปรียบเทียบกับแบบจำลองอนุกรมเวลา (Seasonal Autoregressive Integrated Moving Averages with Exogenous Regression, SARIMAX) ในจังหวัดกรุงเทพมหานคร โดยทำการตรวจสอบความแม่นยำของแบบจำลองโดยใช้ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error; RMSE) และค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error; MAE) ผลการวิจัยพบว่าแบบจำลอง LSTM สามารถทำนายค่าความเข้มข้นของฝุ่นละออง $\text{PM}_{2.5}$ ได้แม่นยำกว่าแบบจำลอง SARIMAX (Thaweephol & Wivatwattana, 2020) นอกจากนี้ในปี พ.ศ. 2563 งานวิจัยของ Singhaworawong (2020) ยังสนับสนุนประสิทธิภาพของแบบจำลอง LSTM โดยงานวิจัยดังกล่าวมีการศึกษาแบบจำลอง (LSTM) เพื่อทำนายค่าฝุ่นละออง $\text{PM}_{2.5}$ ใน 24 ชั่วโมงข้างหน้า ในจังหวัดเชียงใหม่ โดยทำการเก็บข้อมูลฝุ่นละออง $\text{PM}_{2.5}$ รายวัน ตั้งแต่ 1 มกราคม พ.ศ. 2562 ถึง 31 พฤษภาคม พ.ศ. 2563 และทำการสร้างแบบจำลอง LSTM ผลการวิจัยพบว่าแบบจำลองสามารถทำนายค่าฝุ่นละออง $\text{PM}_{2.5}$ ใน 24 ชั่วโมงข้างหน้าได้อย่างแม่นยำ

การเพิ่มจำนวนของฝุ่นละออง $\text{PM}_{2.5}$ อาจเกิดจากปัจจัยทางอุตุนิยมวิทยาที่มาจาก การเปลี่ยนแปลงของบรรยากาศโลกและสิ่งมีชีวิตซึ่งส่งผลต่อการกระจายตัวของฝุ่นละออง (Thai Meteorological Department, 2021) โดยปัจจัยทางอุตุนิยมวิทยาส่งผลต่อความเข้มข้นและการกระจายตัวของฝุ่นละอองอย่างมาก (Mok & Hoi, 2005) เนื่องจากการกระจายตัวของ

ฝุ่นละอองจะถูกกำหนดโดยปัจจัยทางอุตุนิยมวิทยา (Aryal et al., 2008) ซึ่งในปี พ.ศ. 2564 Das et al. (2021) ได้วิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (simple linear regression analysis) เพื่อศึกษาผลของปัจจัยทางอุตุนิยมวิทยาต่อค่าความเข้มข้นของฝุ่นละออง ในประเทศอินเดีย โดยใช้ข้อมูลความเข้มข้นฝุ่นละออง PM2.5 PM10 อุณหภูมิ ความเร็วลม ความชื้นสัมพัทธ์ ปริมาณน้ำฝน ความกดอากาศ แสงแดดรายชั่วโมง และการปกคลุมของเมฆ ตั้งแต่ปี พ.ศ. 2561-2563 พบว่าตัวทางสภาพอากาศ ได้แก่ อุณหภูมิ และปริมาณน้ำฝน ส่งผลต่อค่าความเข้มข้นของฝุ่นละออง PM2.5 และ PM10 อย่างมาก (Das et al., 2021)

ดังนั้นผู้วิจัยจึงเลือกตัวแปรทางสภาพอากาศ ได้แก่ อุณหภูมิ ปริมาณน้ำฝน ความชื้นสัมพัทธ์ ความเร็วลม และความกดอากาศ โดยใช้แบบจำลองหน่วยความจำระยะสั้นแบบยาว (LSTM) เพื่อทำนายหาปริมาณความเข้มข้นฝุ่นละออง และศึกษาความสัมพันธ์กับตัวแปรทางสภาพอากาศ โดยนำข้อมูลจากกรมควบคุมมลพิษในพื้นที่กรุงเทพฯ และปริมาณชลมาใช้ในการศึกษา ผู้วิจัยหวังว่างานวิจัยนี้จะสามารถนำมาเป็นข้อมูลที่ใช้สำหรับวางแผนบริหารจัดการคุณภาพอากาศให้มีประสิทธิภาพมากยิ่งขึ้น

วิธีดำเนินการวิจัย

1. ขั้นตอนและวิธีการรวบรวมข้อมูล

งานวิจัยนี้มีการเก็บรวบรวมข้อมูลตามพื้นที่ต่าง ๆ ซึ่งประกอบไปด้วย กรุงเทพมหานคร นครปฐม นนทบุรี ปทุมธานี สมุทรปราการ และสมุทรสาคร มาใช้ในการศึกษา โดยใช้ข้อมูลค่าความเข้มข้นของฝุ่นละออง PM2.5 รายเดือน ตั้งแต่ปี พ.ศ. 2558 - 2563 จากกรมควบคุมมลพิษ ทั้งหมด 23 สถานี (Air Quality and Noise Management Bureau, 2020) และนำมาหาค่าเฉลี่ยรายเดือน และใช้ข้อมูลตัวแปรทางสภาพอากาศจาก Global Surface Summary of the Day (GSOD) ซึ่งเก็บรวบรวมข้อมูลสภาพอากาศจากสถานีต่าง ๆ ทั่วโลก ตั้งแต่ปี พ.ศ.2472 ซึ่งครอบคลุมช่วงเวลา และพื้นที่ที่ผู้วิจัยต้องการศึกษา โดยข้อมูลดังกล่าวสามารถดาวน์โหลดได้ผ่านเว็บไซต์ <https://www1.ncdc.noaa.gov/pub/data/g sod/> (NOAA, 2021) ผู้วิจัยใช้ข้อมูลจากภาคพื้นดิน 10 สถานี ในพื้นที่กรุงเทพมหานคร และปริมาณชล ประเทศไทย ประกอบด้วย สถานีกรุงเทพมหานคร สถานีสนามบินกรุงเทพมหานคร สถานีท่าพระ สถานีดอนเมือง สถานีท่าอากาศยานสุวรรณภูมิ สถานีบางนา สถานีนครปฐม สถานีปทุมธานี สถานีสมุทรปราการ และสถานีสมุทรสาคร จากนั้นนำข้อมูลทั้ง 10 สถานี นำมาหาค่าเฉลี่ยรายเดือน โดยข้อมูลตัวแปรทั้งหมดประกอบด้วยอุณหภูมิ ปริมาณน้ำฝน ความชื้นสัมพัทธ์ ความเร็วลม และความดันบรรยากาศมาตรฐานดังตารางที่ 1 (Table 1)

Table 1 Long-Short Term Memory model parameters

Parameter	Description
PM 2.5	Mean Particulate Matter 2.5; PM2.5 ($\mu\text{g}/\text{m}^3$)
Temperature	Mean Temperature (Celcius)
Rain	Mean Precipitation (mm)
Relative humidity	Mean Relative humidity; RH (%)
Wind speed	Mean Wind Speed (m/s)
Standard Temperature and Pressure	Mean Standard Temperature and Pressure; STP (mbar)

2. วิเคราะห์ข้อมูล

นำข้อมูลมา scale ตามสมการที่ 1 เพื่อให้ข้อมูลนั้นมีขนาดเท่า ๆ กัน จากนั้นศึกษาความสัมพันธ์ (correlation) ระหว่างตัวแปรทางสภาพอากาศกับความเข้มข้นฝุ่นละออง PM2.5 และใช้ฟังก์ชันสหสัมพันธ์ร่วม (Cross Correlation Function; CCF) ดังสมการที่ 2 ระหว่างตัวแปรทางสภาพอากาศกับ PM2.5 เพื่อหาเวลาย้อนหลังที่เหมาะสม เลือกช่วงเวลาย้อนหลังที่เหมาะสมเพื่อสร้างแบบจำลอง LSTM ในการทำนายข้อมูล

$$\frac{x - \bar{x}}{S.D.} \tag{1}$$

กำหนดให้ x คือ ข้อมูล ณ จุดนั้น
 \bar{x} คือ ค่าเฉลี่ยของข้อมูล
 $S.D.$ คือ ส่วนเบี่ยงเบนมาตรฐานของข้อมูล

$$CCF = \frac{\sum (x - \bar{x})(y - \bar{y})}{\sqrt{\sum (x - \bar{x})^2 \sum (y - \bar{y})^2}} \tag{2}$$

กำหนดให้ x, y คือ ข้อมูล PM2.5 และตัวแปรทางสภาพอากาศต่าง ๆ ตามลำดับ
 \bar{x}, \bar{y} คือ ค่าเฉลี่ยของข้อมูล PM2.5 และตัวแปรทางสภาพอากาศต่าง ๆ ตามลำดับ

ในการตรวจสอบความแม่นยำของแบบจำลอง ผู้วิจัยเลือกใช้ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean absolute error, MAE) ดังสมการที่ 3 และค่าสูญเสียจากชุดข้อมูลทดสอบ (validation loss) จากนั้นผู้วิจัยเลือกแบบจำลองที่มีค่าคลาดเคลื่อนที่ต่ำที่สุด และผลการทำนายความเข้มข้นของฝุ่นละออง PM2.5 ที่ดีที่สุด

$$MAE = \frac{1}{n} \sum_{i=1}^n |actual - predicted| \tag{3}$$

ผู้วิจัยเลือกค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE) เนื่องจากค่าความคลาดเคลื่อนชนิดนี้ มีความอ่อนไหวต่อค่าผิดปกติ (outlier) ต่ำ ซึ่งเหมาะสมในการนำไปใช้ประเมินประสิทธิภาพของแบบจำลองกว่าค่าความคลาดเคลื่อนชนิดอื่น ๆ เช่น รากที่สองของค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square Error; RMSE) หรือค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง (Mean Square Error; MSE) ส่วนการหาค่าสูญเสียจากชุดข้อมูลทดสอบ (validation loss) เป็นการคำนวณความคลาดเคลื่อนของแบบจำลองที่ถูกทดสอบด้วยชุดข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน เสมือนการทดสอบในกรณีนำแบบจำลองไปใช้จริง ดังนั้นวิธีทั้งสองจึงเหมาะสมต่อการตรวจสอบความแม่นยำของแบบจำลองที่สุด

3. การสร้างแบบจำลอง LSTM

กระบวนการทำงานของแบบจำลอง LSTM แสดงดังภาพที่ 1 (Figure 1) โดยเริ่มจากการจัดการข้อมูลเบื้องต้น และปรับค่าข้อมูลด้วยการ scale ดังกล่าวข้างต้น จากนั้นแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลที่ใช้ฝึกฝน (training dataset) 85 เปอร์เซ็นต์ และชุดข้อมูลที่ใช้ทดสอบ (testing dataset) 15 เปอร์เซ็นต์ และนำชุดข้อมูลที่ใช้ฝึกฝนในการสร้างแบบจำลอง และทดสอบแบบจำลองด้วย ชุดข้อมูลที่ใช้ทดสอบซึ่งเป็นข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน เสมือนการนำแบบจำลองไปใช้จริง

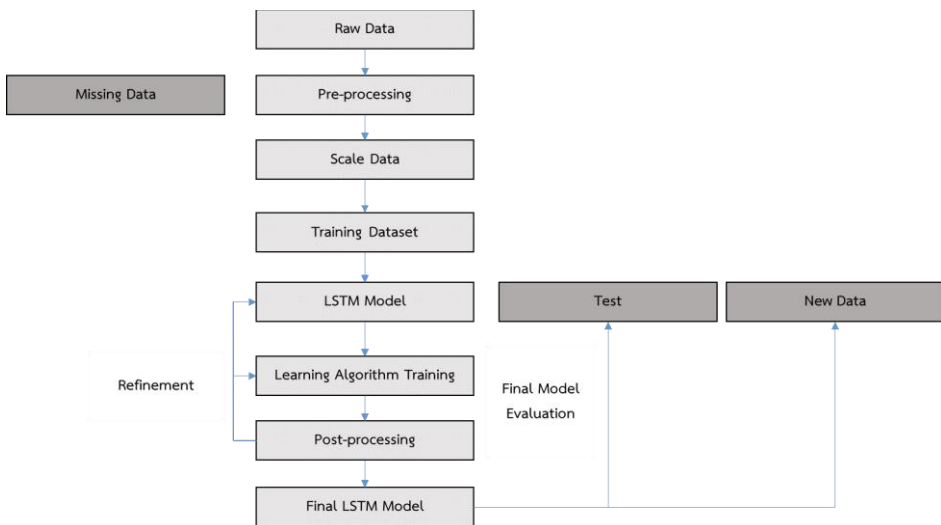


Figure 1 Flowchart for Long Short-Term Memory (LSTM) training

ผลการวิจัย

ในงานวิจัยนี้ทำนายค่าความเข้มข้นของฝุ่นละออง PM2.5 โดยใช้ข้อมูลสภาพอากาศของกรุงเทพฯ และปริมณฑล ด้วยวิธีการเรียนรู้ของเครื่อง (machine learning) ข้อมูลค่าความเข้มข้นของฝุ่นละออง PM2.5 รายเดือน อุณหภูมิเฉลี่ย ปริมาณน้ำฝนเฉลี่ย ค่าความชื้นสัมพัทธ์เฉลี่ย ค่าความเร็วลมเฉลี่ย และความดันมาตรฐานเฉลี่ย ย้อนหลัง 5 ปี สามารถสรุปข้อมูลทางสถิติ ดังตารางที่ 2 (Table 2)

Table 2 Parameter statistics from 2015 to 2020

Parameters	Max.	Min.	Mean	SD
PM 2.5	56.6667	12	26.78312639	11.13892292
Temperature	31.7743	25.5429	29.00569167	1.317650589
Rain	11.8529	0	4.005445833	3.328104932
Relative humidity	82.2116	63.0437	72.35485694	4.470958354
Wind speed	3.104	1.2722	1.877015278	0.375114195
Standard Temperature and Pressure; STP	122.0108	110.1262	117.0459431	2.541834349

โดยมีผลการศึกษาและประสิทธิภาพ ดังนี้

1. ผลของอุณหภูมิต่อค่าความเข้มข้นของฝุ่นละออง PM2.5

จากการหาค่าสหสัมพันธ์ร่วม พบว่าค่าสหสัมพันธ์ร่วมมีค่าสูงในช่วงอุณหภูมีย้อนหลัง 0 ถึง 3 เดือน โดยอุณหภูมิมี่ความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 และการใช้เวลาย้อนหลัง 0 เดือน หรืออุณหภูมิ ณ เวลาเดียวกันกับ PM2.5 ทำนายความเข้มข้นของฝุ่น PM2.5 พบว่าผลการทำนายออกมาใกล้เคียงกับค่าจริงที่สุด และใช้ทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ ดังภาพที่ 2 (Figure 2) โดยมี MAE ของข้อมูลที่ใช้ฝึกฝน (loss) เท่ากับ 0.2361 และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.2558

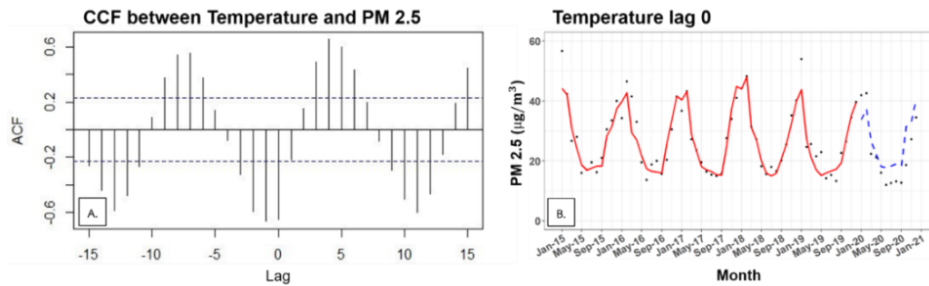


Figure 2 A) Cross-correlation between temperature and PM2.5 at the different time lags. B) The prediction results of PM2.5 by using temperature with a 0-month lag (black dots showed the raw data points of PM2.5, the red line is the training line and the blue line is the prediction results of the test dataset).

2. ผลของปริมาณน้ำฝนต่อค่าความเข้มข้นของฝุ่นละออง PM2.5

ค่าปริมาณน้ำฝนย้อนหลัง 0 ถึง 2 เดือน มีค่าสหสัมพันธ์ร่วมสูงในแบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 และผลการทำนายความเข้มข้นฝุ่น PM2.5 แสดงว่าการใช้ปริมาณน้ำฝนย้อนหลัง 0 เดือน หรือปริมาณน้ำฝน ณ เวลาเดียวกันกับ PM2.5 สามารถใช้ทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดีที่สุด ดังภาพที่ 3 (Figure 3) โดยมี MAE ของข้อมูลที่ใช้ฝึกฝน (loss) เท่ากับ 0.4330 และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.5062

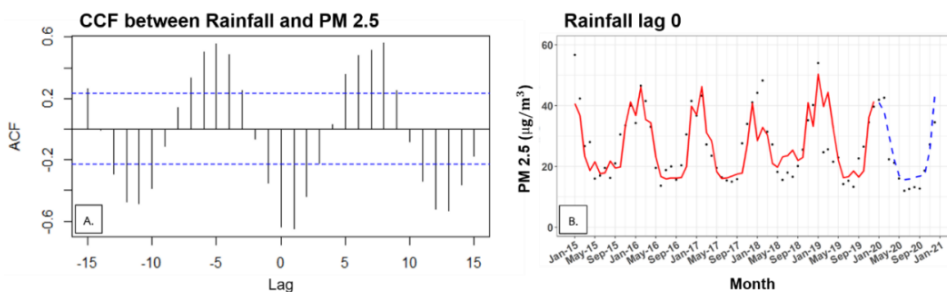


Figure 3 A) Cross-correlation between rainfall and PM2.5 at the different time lags. B) The LSTM prediction results of PM2.5 by rainfall with 0-month lag.

3. ผลของค่าความสัมพันธ์สัมพัทธ์ต่อค่าความเข้มข้นของฝุ่นละออง PM2.5

ค่าความสัมพันธ์สัมพัทธ์ย้อนหลัง 0 ถึง 1 เดือน มีความสัมพันธ์สูงแบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 และจากการสร้างแบบจำลอง LSTM พบว่าการใช้เวลาย้อนหลัง 0 เดือน หรือ ณ เวลาเดียวกันกับ PM2.5 ในการทำนายค่าความเข้มข้นของฝุ่น PM2.5 ผลออกมาใกล้เคียงกับค่าจริงที่สุด ดังภาพที่ 4 (Figure 4) โดยมี MAE ของข้อมูลที่ใช้ฝึกฝน (loss) เท่ากับ 0.3547 และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.4196

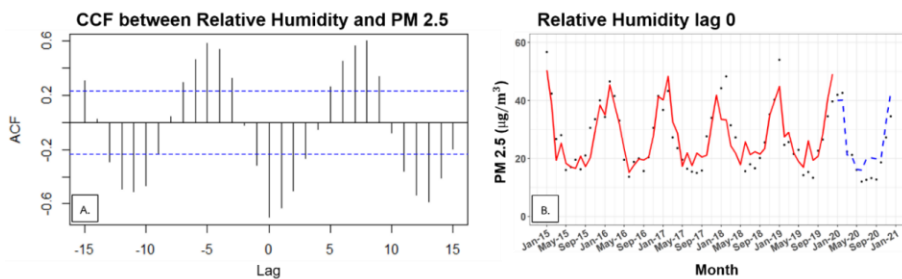


Figure 4 A) Cross-correlation between RH and PM2.5 at the different time lags.

B) The LSTM prediction results of PM2.5 by RH with a 0-month lag.

4. ผลของค่าความเร็วลมต่อค่าความเข้มข้นของฝุ่นละออง PM2.5

ค่าสหสัมพันธ์ร่วมมีค่าสูงในช่วงความเร็วลมย้อนหลัง 1 ถึง 4 เดือน โดยความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 และผลการทำนายความเข้มข้นฝุ่น PM2.5 โดยใช้ค่าความเร็วลมย้อนหลัง 1 เดือน สามารถทำนายค่าความเข้มข้นของฝุ่นละออง PM2.5 ได้ดีที่สุด ดังภาพที่ 5 (Figure 5) โดยมี MAE ของข้อมูลที่ใช้ฝึกฝน (loss) เท่ากับ 0.2479 และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.3500




Figure 5 A) Cross-correlation between wind speed and PM2.5 at the different time lags.

B) The LSTM prediction results of PM2.5 by wind speed with a 1-month lag.

5. ผลของค่าความดันบรรยากาศมาตรฐานต่อค่าความเข้มข้นของฝุ่นละออง PM2.5

ค่าความดันบรรยากาศมาตรฐานย้อนหลัง 0 ถึง 1 เดือน มีความสัมพันธ์สูงในรูปแบบแปรผันตรงกับความเข้มข้นฝุ่นละออง PM2.5 และผลการทำนายความเข้มข้นฝุ่น PM2.5 พบว่าการใช้ค่าความดันบรรยากาศมาตรฐานย้อนหลัง 0 เดือน หรือความดันบรรยากาศมาตรฐานเวลาเดียวกันกับ PM2.5 สามารถใช้ทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดีที่สุด ดังภาพที่ 6 (Figure 6) โดยมี MAE ของข้อมูลที่ใช้ฝึกฝน (loss) เท่ากับ 0.2205 และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.3596

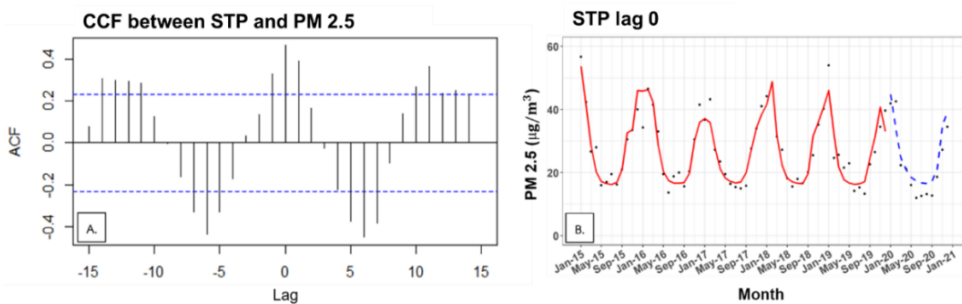


Figure 6 A) Cross-correlation between STP and PM2.5 at the different time lags.
B) The LSTM prediction results of PM2.5 by STP with a 0-month lag.

อภิปรายผล

ในการศึกษานี้ ผู้วิจัยใช้ค่าสหสัมพันธ์ร่วมในการศึกษาความสัมพันธ์ระหว่างตัวแปรทางสภาพอากาศและความเข้มข้นของฝุ่นละออง PM2.5 รวมถึงใช้ในการเลือกเวลาย้อนหลังของแต่ละตัวแปรทางสภาพอากาศ โดยความสัมพันธ์มีทั้งแบบแปรผันตรงกันและตรงข้ามกัน ซึ่งสอดคล้องกับผลการวิจัยของ Harnkijroong & Panich (2013) ที่ศึกษาอิทธิพลของปัจจัยทางอุตุนิยมวิทยาต่อความเข้มข้นของฝุ่นละอองขนาดไม่เกิน 10 ไมครอน ในเขตกรุงเทพมหานคร โดยงานวิจัยดังกล่าวศึกษาตัวแปรทางสภาพอากาศได้แก่ อุณหภูมิ ปริมาณน้ำฝน ความชื้นสัมพัทธ์ ความเร็วลม และความเข้มแสง พบว่าความสัมพันธ์ของตัวแปร อุณหภูมิ ปริมาณน้ำฝน ความชื้นสัมพัทธ์ และความเร็วลมมีความสัมพันธ์แนวนอนเดียวกันกับงานวิจัยข้างต้น นอกจากนี้ผู้วิจัยยังศึกษาผลของตัวแปรความดันบรรยากาศมาตรฐานเพิ่มเติม และสร้างแบบจำลองเพื่อทำนายความเข้มข้นของฝุ่น PM2.5 จากตัวแปรทางสภาพอากาศดังกล่าว ซึ่งผลการศึกษาพบว่าแบบจำลอง LSTM สามารถทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดังนี้

อุณหภูมิมีความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 เนื่องจากเมื่ออุณหภูมิภาคพื้นดินลดลงจะทำให้เกิดแนวความร้อนที่ชั้นบรรยากาศส่งผลให้ฝุ่น PM2.5

ในอากาศไม่สามารถผ่านชั้นความร้อนนั้นได้ และส่งผลให้ค่าความเข้มข้นของ PM2.5 มีค่าสูงขึ้น (NGThai, 2019) โดยจากการสร้างแบบจำลองพบว่าอุณหภูมิย้อนหลัง 0 เดือน หรือ อุณหภูมิ ณ เวลาเดียวกับ PM2.5 สามารถใช้ทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ และมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.2361 และ 0.2558 ตามลำดับ

ปริมาณน้ำฝนมีความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 ซึ่งปริมาณน้ำฝนที่มากสะท้อนถึงการชะล้างอนุภาคต่าง ๆ ในอากาศ เช่น ในกรณีปริมาณน้ำฝนมีค่าสูง ฝนตกมาก แสดงว่าอนุภาคฝุ่นละอองถูกชะล้างโดยฝนมาก ส่งผลให้ค่าความเข้มข้นของฝุ่นของ PM2.5 ลดลง (Harnkijroong & Panich, 2013) โดยปริมาณน้ำฝนย้อนหลัง 0 เดือน หรือ ปริมาณน้ำฝน ณ เวลาเดียวกับ PM2.5 สามารถใช้คำนวณและทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดีที่สุด ซึ่งมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.4330 และ 0.5062 ตามลำดับ

ความชื้นสัมพัทธ์มีความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 เพราะเมื่อมีค่าไอน้ำในอากาศสูง หมายถึงไอน้ำจะไปจับกับอนุภาคต่าง ๆ ในอากาศรวมถึง PM2.5 ทำให้อนุภาคนั้นตกลงสู่พื้น ซึ่งปริมาณไอน้ำในอากาศแปรผันตรงกับค่าความชื้นสัมพัทธ์ ดังนั้นเมื่อความชื้นสัมพัทธ์ในอากาศสูง ความเข้มข้นฝุ่นจึงลดลง (Pobsuk, 2019) โดยค่าความชื้นสัมพัทธ์ย้อนหลัง 0 เดือน หรือ ค่าความชื้นสัมพัทธ์ ณ เวลาเดียวกับค่าความเข้มข้น PM2.5 สามารถใช้คำนวณและทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดีที่สุด ซึ่งมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.3547 และ 0.4196 ตามลำดับ

ความเร็วลมมีความสัมพันธ์แบบตรงกันข้ามกับความเข้มข้นฝุ่นละออง PM2.5 เนื่องจากเมื่อค่าความเร็วลมมีค่าสูง หมายถึงลมมีการเคลื่อนที่เร็ว ทำให้มีโอกาสสูงที่จะพัดเอาอากาศในบริเวณนั้นออกไป ส่งผลให้ PM2.5 ที่อยู่ในอากาศถูกพัดออกไปด้วย (Pobsuk, 2019) โดยค่าความเร็วลมย้อนหลัง 1 เดือน สามารถใช้คำนวณและทำนายค่าความเข้มข้นของฝุ่น PM2.5 ได้ดีที่สุด ซึ่งมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.2479 และ 0.3500 ตามลำดับ

และความดันบรรยากาศมาตรฐานมีความสัมพันธ์แบบแปรผันตรงกับความเข้มข้นฝุ่นละออง PM2.5 เพราะเมื่อความดันบรรยากาศมาตรฐานต่ำ ทำให้ปริมาณอากาศน้อย น้ำหนักของอากาศจะลดลง ทำให้อากาศลอยตัวสูงขึ้น และพาอนุภาคอื่น ๆ ในอากาศรวมถึง ฝุ่น PM2.5 ลอยขึ้นไปด้วย ส่งผลให้ค่าความเข้มข้นของฝุ่น PM2.5 ในภาคพื้นดินลดลง (Pobsuk, 2019)

โดยค่าความดันบรรยากาศมาตรฐานย้อนหลัง 0 เดือน หรือ ค่าความดันบรรยากาศมาตรฐาน ณ เวลาเดียวกับ PM2.5 สามารถใช้คำนวณและทำนายค่าความเข้มข้นฝุ่น PM2.5 ได้ดีที่สุด ซึ่งมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) เท่ากับ 0.2205 และ 0.3596 ตามลำดับ

เมื่อเปรียบเทียบผลการทำนายของตัวแปรทางสภาพอากาศทั้งหมดพบว่า อุณหภูมิและปริมาณน้ำฝน มีความสัมพันธ์กันและสามารถให้ผลทำนายได้ดีที่สุด ซึ่งผลการทดลองสอดคล้องกับงานวิจัยของ Das et al. (2021) ที่ทำการวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (simple linear regression analysis) ระหว่างปัจจัยทางอุตุนิยมวิทยากับค่าความเข้มข้นของฝุ่นละออง PM2.5 ซึ่งผลชี้ว่าอุณหภูมิและปริมาณน้ำฝน ส่งผลต่อค่าความเข้มข้นของฝุ่นละออง PM2.5 มากที่สุดเช่นกัน (Das et al., 2021)

ผู้วิจัยหวังว่างานวิจัยนี้จะสามารถนำมาเป็นข้อมูลที่ใช้สำหรับวางแผนบริหารจัดการคุณภาพอากาศและจัดการคุณภาพสิ่งแวดล้อมให้มีประสิทธิภาพมากยิ่งขึ้น เพื่อแก้ปัญหามลพิษทางอากาศ โดยเฉพาะจังหวัดที่มีการจราจรหนาแน่น เช่น กรุงเทพมหานคร และปริมณฑลที่กำลังประสบปัญหามลพิษทางอากาศอย่างรุนแรง อีกทั้งผู้วิจัยยังสนใจใช้แบบจำลองในการทำนายความเข้มข้นฝุ่นละอองในอนาคต เพื่อเตือนภัยประชาชนถึงช่วงเวลาที่จะเกิดค่าความเข้มข้นฝุ่นละอองเกินมาตรฐานอีกด้วย

สรุปผลการวิจัย

จากการใช้แบบจำลองหน่วยความจำระยะสั้นแบบยาว ในการคำนวณและทำนายค่าความเข้มข้นฝุ่นละออง PM2.5 โดยใช้สภาพอากาศ ได้ผลการวิจัยว่าอุณหภูมิย้อนหลัง 0 เดือน หรือ ณ เวลาเดียวกันกับ PM2.5 สามารถคำนวณหาค่าความเข้มข้นของฝุ่นละออง PM2.5 ได้แม่นยำที่สุดเนื่องจากมีค่า MAE ของข้อมูลที่ใช้ฝึกฝน (loss) และ MAE ของข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (validation loss) น้อยที่สุดเมื่อเทียบกับตัวแปรทางสภาพอากาศทั้งหมดที่ใช้ศึกษา และปริมาณน้ำฝนย้อนหลัง 0 เดือน หรือ ณ เวลาเดียวกันกับ PM2.5 สามารถทำนายค่าความเข้มข้นของฝุ่นละออง PM2.5 ได้ดีที่สุดจากภาพที่แสดงการทำนายความเข้มข้นฝุ่น PM2.5 เทียบกับค่าจริงโดยใช้ปริมาณน้ำฝนย้อนหลังใน 0 เดือน หรือ ณ เวลาเดียวกันกับ PM2.5

ข้อเสนอแนะ

ในการนำไปใช้ในอนาคตควรพิจารณาการใช้เวลาย้อนหลังตั้งแต่ 1 เดือน เป็นต้นไป หรือพิจารณาข้อมูลตัวแปรเป็นรายสัปดาห์ หรือรายวัน เพื่อนำแบบจำลองไปใช้ประโยชน์ในการพยากรณ์ในชีวิตจริง และเพื่อพัฒนาความแม่นยำของแบบจำลองอาจเลือกใช้แบบจำลอง Multivariate Long Short-Term Memory เป็นทางเลือกในการศึกษาเพิ่มเติม

กิตติกรรมประกาศ

ขอขอบคุณภาควิชาฟิสิกส์ คณะวิทยาศาสตร์ มหาวิทยาลัยนเรศวร และโครงการพัฒนาและส่งเสริมผู้มีความสามารถพิเศษทางวิทยาศาสตร์และเทคโนโลยี (พสวท.) ที่ให้การสนับสนุนและอำนวยความสะดวกในการทำงานวิจัย ทำให้งานวิจัยครั้งนี้ประสบความสำเร็จได้ด้วยดี

เอกสารอ้างอิง

- Air Quality and Noise Management Bureau. Thailand's air quality and situation reports. 2020. Available at: <http://air4thai.pcd.go.th/webV2/download.php>. Accessed June 6, 2021.
- Aryal RK, Lee BK, Karki R, Gurung A, Kandasamy J, Pathak BK, Sharma S. et al. Seasonal PM10 dynamics in Kathmandu Valley. *Atmospheric Environment* 2008;42(37):8623-8633.
- Cabaneros SMS, Calautit JKS, Hughes BR. Hybrid artificial neural network models for effective prediction and mitigation of Urban Roadside NO2 Pollution. *Energy Procedia* 2017;142(9):3524-3530.
- Dajsakdipon T. PM2.5. 2020. Available at: <https://www.vejthani.com/th/2020/02/pm2-5/>. Accessed June 10, 2021.
- Das M, Das A, Sarkar R, Mandal P, Saha S, Ghosh S. Exploring short term Spatio-temporal pattern of PM2.5 and PM10 and their relationship with meteorological parameters during COVID-19 in Delhi. *Urban Climate*; 2021.
- Harnkijroong T, Panich N. Influence of meteorological factors on PM10 at roadside of Bangkok. The 10th KU KPS Conference; 2013.
- Mok KM, Hoi KI. Effects of meteorological conditions on PM10 concentrations - A study in Macau. *Environ Monit Assess*; 2005.
- NGThai. PM 2.5. 2019. Available at: <https://ngthai.com/environment/18251/factofparticlematters/>. Accessed June 10, 2021.
- NOAA. 2021. Available at: <https://www1.ncdc.noaa.gov/pub/data/g sod/>. Accessed May 15, 2021.
- Pobsuk J. PM2.5. *Journal of Science and Technology (Royal Thai Naval Academy)* 2019; 2(1):48-55.
- Shams SR, Jahani A, Kalantary S, Moeinaddini M, Khorasani N. The evaluation on artificial neural networks (ANN) and multiple linear regressions (MLR) models for predicting SO2 concentration. *Urban Climate*; 2021.
- Singhaworawong P. Forecasting PM2.5 in Chiangmai using Long Short-Term Memory Models, Srinakharinwirot University; 2020.
- Thai Meteorological Department. Thailand weather. 2021. Available at: <https://www.tmd.go.th/info/info.php?FileID=22>. Accessed May 15, 2021.
- Thaweephol K, Wiwatwattana N. A long short-term memory deep neural network model for PM2.5 prediction in the Urban Bangkok Area, Srinakharinwirot University; 2020.