



แบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิค
โครงข่ายประสาทเทียมแบบสังวัตนาการ และแบบหน่วยความจำระยะสั้นแบบยาว
24-HOUR FORECASTING MODELS FOR PM2.5 CONCENTRATION FROM PHOTOS
USING CONVOLUTIONAL NEURAL NETWORK AND LONG SHORT-TERM MEMORY

ทรงพล เกริกิดาการ

แบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิค
โครงข่ายประสาทเทียมแบบสังวัตนาการ และแบบหน่วยความจำระยะสั้นแบบยาว



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2563
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

24-HOUR FORECASTING MODELS FOR PM_{2.5} CONCENTRATION FROM PHOTOS
USING CONVOLUTIONAL NEURAL NETWORK AND LONG SHORT-TERM MEMORY



SONGPON KLERKKIDAKAN

A Master's Project Submitted in Partial Fulfillment of the Requirements

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2020

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

แบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิค

โครงข่ายประสาทเทียมแบบสังวัตนาการ และแบบหน่วยความจำระยะสั้นแบบยาว

ของ

ทรงพล เกริกิดาการ

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.นุรีย์ วิวัฒน์วัฒนา) (อาจารย์ ดร.ดวงดาว วิชาดากุล)

..... กรรมการ
(อาจารย์ ดร.วีระ สอึ้ง)

ชื่อเรื่อง	แบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบสังวัตนาการ และแบบหน่วยความจำระยะสั้นแบบยาว
ผู้วิจัย	ทรงพล เกริกิตาการ
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2563
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. นุรีย์วิวัฒน์วัฒนา

สถานการณ์ปัญหาฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน หรือ PM2.5 (Particulate Matter with Diameter of Less Than 2.5 Micron) ได้เกิดขึ้นเป็นประจำทุกปี และมีแนวโน้มจะมีความรุนแรงมากขึ้น อย่างไรก็ตามเราสามารถมองเห็นฝุ่น PM2.5 ได้จากการสังเกตขึ้นไปยังท้องฟ้า ดังนั้นในงานวิจัยนี้ผู้วิจัยจึงเล็งเห็นความสำคัญของการพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้า 24 ชั่วโมงโดยใช้ภาพถ่ายสภาพอากาศ และเลือกใช้วิธีการเรียนรู้เชิงลึก (Deep Learning) แบบสังวัตนาการ (Convolutional Neural Network) ในการเรียนรู้ข้อมูลที่เป็นรูปภาพ พร้อมสกัดเป็นคุณลักษณะของข้อมูลภาพถ่าย และเนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่นๆ เช่น เมฆ ฝน หรือ แสงอาทิตย์ จึงได้ใช้แบบจำลองแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) ซึ่งมีประสิทธิภาพในการเรียนรู้ลำดับ (Sequence) ของข้อมูล มาทำงานร่วมกัน ซึ่งแบบจำลองที่ใช้สองเทคนิคทำงานร่วมกัน ให้ผลดีกว่าการใช้เทคนิคแบบสังวัตนาการเพียงอย่างเดียว โดยให้ผลการทดลองที่ดีกว่าถึง 4 ไมโครกรัมต่อลูกบาศก์เมตร เมื่อวัดด้วยค่า Root Mean Square Error (RMSE) และ Mean Absolute Error (MAE) หรือ คิดเป็น 8 เปอร์เซ็นต์ เมื่อวัดด้วยค่า Mean Absolute Percentage Error (MAPE)

คำสำคัญ : สังวัตนาการ, หน่วยความจำระยะสั้นแบบยาว, การพยากรณ์ PM2.5, แบบจำลองการพยากรณ์

Title	24-HOUR FORECASTING MODELS FOR PM2.5 CONCENTRATION FROM PHOTOS USING CONVOLUTIONAL NEURAL NETWORK AND LONG SHORT-TERM MEMORY
Author	SONGPON KLERKKIDAKAN
Degree	MASTER OF SCIENCE
Academic Year	2020
Thesis Advisor	Assistant Professor Nuwee Wiwatwattana , Ph.D.

High particulate matter of less than 2.5 microns in diameter (PM2.5) occurs annually and tends to be more aggravated by the day. As the effects of PM2.5 effects can be observed easily from the sky, in this research, we realized the importance of 24-hour forecasting models for PM2.5 concentration from photos using deep learning. Based on the hybrid design using the Convolutional Neural Network (CNN) as the base layer, automatically extracting features of photos, the Long Short-Term Memory (LSTM) was used for the output layer to consider the sequence features of photos. The hybrid models provided better results than using a single Convolutional Neural Network, which showed up to four micrograms per cubic meter for the root mean square error (RMSE) and the mean absolute error (MAE) or more than 8% overall for the mean absolute percentage error (MAPE) was more accurate than the single model.

Keyword : Convolutional Neural Network, Long Short-Term Memory, PM2.5, Forecasting models

กิตติกรรมประกาศ

สารนิพนธ์ฉบับนี้ สำเร็จลุล่วงได้ด้วยความช่วยเหลือจาก ผศ.ดร.นุรีย์ วิวัฒน์วัฒนา อาจารย์ที่ปรึกษา ที่ให้คำปรึกษา และคำแนะนำแนวทางในการทำสารนิพนธ์ ตลอดจนสนับสนุนข้อมูลทางวิชาการ และข้อมูลในการทำสารนิพนธ์ฉบับนี้ รวมไปถึงคอยตรวจสอบความถูกต้องในทุกขั้นตอนของการทำสารนิพนธ์

ขอกราบขอบพระคุณกรมควบคุมมลพิษ ที่ให้ความอนุเคราะห์ข้อมูลค่าฝุ่นละออง PM2.5 ที่ถูกจัดเก็บในพื้นที่กรุงเทพมหานครชั้นในมาใช้ในการทำสารนิพนธ์นี้

ขอกราบขอบพระคุณคณะกรรมการสอบสารนิพนธ์ และ อ.ดร.ศิริสรรพ เหล่าหะเกียรติ ที่ได้ให้คำแนะนำ และข้อเสนอแนะ สำหรับการปรับปรุง แก้ไขความถูกต้องของสารนิพนธ์

ขอกราบขอบพระคุณบัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ สำหรับทุนสนับสนุนการนำเสนอผลงานวิจัยของนิสิตบัณฑิตศึกษา ทำให้ได้รับประสบการณ์การนำเสนอสารนิพนธ์ รวมถึงได้แลกเปลี่ยนความรู้ทางด้านเทคโนโลยีต่าง ๆ

สุดท้ายนี้ขอกล่าวขอบพระคุณ คุณขวัญเรือน วิริยาวัชร มีศักดิ์เป็นมารดาของผู้วิจัย ผู้ซึ่งเปิดโอกาสให้ได้รับการศึกษาเล่าเรียน ตลอดจนคอยช่วยเหลือ และให้กำลังใจผู้วิจัยเสมอมาจนสำเร็จการศึกษา

ทรงพล เกริกิตตาการ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ณ
สารบัญรูปภาพ	ญ
บทที่ 1 บทนำ.....	1
1.1 ความสำคัญและความเป็นมาของงานวิจัย.....	1
1.2 วัตถุประสงค์.....	4
1.3 ขอบเขตของงานวิจัย	4
1.4 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย	5
บทที่ 2 วรรณกรรม และงานวิจัยที่เกี่ยวข้อง.....	6
2.1 ทฤษฎีเกี่ยวกับอัลกอริทึม	6
2.2 งานวิจัยที่เกี่ยวข้อง	17
บทที่ 3 การดำเนินการวิจัย.....	24
3.1 กระบวนการทำงานของแบบจำลอง	25
3.2 การเก็บรวบรวมข้อมูล (Data Collection).....	26
3.3 การสำรวจข้อมูล (Data Exploration).....	28
3.4 การเตรียมข้อมูล (Data Preparation)	33
3.5 การสร้างแบบจำลองพยากรณ์.....	33
บทที่ 4 ผลการดำเนินการวิจัย	37

บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	47
5.1 สรุปผลการวิจัย.....	47
5.2 อภิปรายผลการวิจัย	48
5.3 ข้อเสนอแนะ	49
บรรณานุกรม	50
ประวัติผู้เขียน.....	53



สารบัญตาราง

หน้า

ตาราง 1 แสดงผลสรุปการทดลอง และโมเดลที่ใช้ของงานวิจัยที่เกี่ยวข้อง	20
ตาราง 2 แสดงรายละเอียดข้อมูลค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานี ตำรวจนครบาลโชคชัย	28
ตาราง 3 แสดงค่าทางสถิติของข้อมูลค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานี ตำรวจนครบาลโชคชัย ในช่วงวันที่ 3 สิงหาคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2562.....	30
ตาราง 4 แสดงรายละเอียด Hyperparameters ของแบบจำลอง	37
ตาราง 5 ตารางเปรียบเทียบผลการทดลองของแบบจำลอง CNN กับ CNN + LSTM	40

สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 แสดงกราฟจำนวนผู้เสียชีวิตก่อนวัยอันควรในประเทศไทยจากมลพิษฝุ่น PM2.5 1	
ภาพประกอบ 2 แสดงกราฟภัยต่าง ๆ ที่ทำให้อายุขัยลดลง และกราฟแสดงแหล่งที่มาของฝุ่น PM2.5 ในกรุงเทพฯ 2	2
ภาพประกอบ 3 แสดงภาพถ่ายสภาพอากาศของกรุงเทพฯ ในวันที่ 21 ธันวาคม พ.ศ. 2561 เป็นวันที่มีค่ามลพิษฝุ่น PM2.5 เกินค่ามาตรฐาน 3	3
ภาพประกอบ 4 แสดงรูปภาพที่ซ้อนกันหลายชั้นโครงข่าย (Layer) ที่จะทำให้เกิดความสามารถในการจดจำ..... 6	6
ภาพประกอบ 5 แสดงรูปภาพตัวอย่างการทำงานของ Neural Networks 7	7
ภาพประกอบ 6 แสดงรูปภาพการทำงานของ Filter 9	9
ภาพประกอบ 7 แสดงรูปภาพการทำงานของ Stride และ Padding..... 9	9
ภาพประกอบ 8 แสดงรูปภาพการจำลองของ Max Pooling 10	10
ภาพประกอบ 9 แสดงรูปภาพการทำงานของ LSTM 14	14
ภาพประกอบ 10 แสดงรูปภาพการทำงานร่วมกันของ CNN กับ LSTM..... 15	15
ภาพประกอบ 11 แสดง Flowchart กระบวนการสร้างแบบจำลอง 25	25
ภาพประกอบ 12 แสดงตัวอย่างภาพถ่ายสภาพอากาศจากกล้อง IP Camera วันที่ 5 สิงหาคม พ.ศ.2562 เวลา 07:00 น. 27	27
ภาพประกอบ 13 แสดงตัวอย่างภาพถ่ายสภาพอากาศ จากกล้อง IP Camera วันที่ 29 ธันวาคม พ.ศ.2562 เวลา 09:00 น. 27	27
ภาพประกอบ 14 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย 29	29
ภาพประกอบ 15 แสดงภาพถ่ายสภาพอากาศ ช่วงเดือนสิงหาคม พ.ศ.2562..... 29	29
ภาพประกอบ 16 แสดงภาพถ่ายสภาพอากาศ ช่วงเดือนธันวาคม พ.ศ.2562..... 30	30


ภาพประกอบ 17 แสดงภาพถ่ายสภาพอากาศ จากกล้อง IP Camera วันที่ 27 กันยายน พ.ศ.	
2562 เวลา 07:00 - 18:00 น.....	32
ภาพประกอบ 18 แสดงข้อมูลค่าฝุ่น PM 2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาล	
โชคชัย วันที่ 27 กันยายน พ.ศ. 2562 เวลา 07:00 – 18:00 น.	32
ภาพประกอบ 19 แสดงตัวอย่างข้อมูลการตัดวิดีโอให้เป็นภาพทุก ๆ 1 ชั่วโมง	33
ภาพประกอบ 20 โมเดลการสร้างแบบจำลองโดยใช้ Convolutional Neural Networks	34
ภาพประกอบ 21 โมเดลการสร้างแบบจำลองโดยใช้ Convolutional Neural Networks ร่วมกับ Long	
Short-Term Memory	36
ภาพประกอบ 22 แสดงการทำงานของแบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-	
Term Memory)	39
ภาพประกอบ 23 แสดงกราฟเปรียบเทียบผลการทดลองของแบบจำลอง CNN เพียงอย่างเดียว	
และแบบจำลอง CNN ทำงานร่วมกับ LSTM ของค่า RMSE, MAE และ MAPE	41
ภาพประกอบ 24 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัด เปรียบเทียบกับผลการ	
พยากรณ์โดยใช้ CNN เพียงอย่างเดียว	42
ภาพประกอบ 25 แสดงกราฟเปรียบเทียบกับการพยากรณ์ และค่า PM2.5 จริง โดยใช้ CNN	
เพียงอย่างเดียว.....	43
ภาพประกอบ 26 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัด เปรียบเทียบกับผลการ	
พยากรณ์โดยใช้ CNN ทำงานร่วมกับ LSTM	43
ภาพประกอบ 27 แสดงกราฟเปรียบเทียบกับการพยากรณ์ และค่า PM2.5 จริง โดยใช้ CNN	
ทำงานร่วมกับ LSTM.....	44
ภาพประกอบ 28 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ตรงกับค่า PM2.5 จริง.....	45
ภาพประกอบ 29 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ใกล้เคียงกับค่า PM2.5 จริง	
.....	45
ภาพประกอบ 30 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ห่างจากค่า PM2.5 จริง...	46

บทที่ 1

บทนำ

1.1 ความสำคัญและความเป็นมาของงานวิจัย

เนื่องจากปัจจุบัน สถานการณ์ปัญหามลพิษทางอากาศในเมืองได้เกิดขึ้นเป็นประจำทุกปี และมีแนวโน้มจะมีความรุนแรงมากขึ้น โดยเฉพาะมลพิษของฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอนหรือ PM2.5 (Particulate Matter with Diameter of Less Than 2.5 Micron) ซึ่งมีความอันตรายต่อร่างกาย ส่งผลกระทบต่อปัญหาสุขภาพ และการใช้ชีวิตประจำวันเป็นอย่างมาก เช่น ทำให้เกิดอาการไอ จาม หรือ ภูมิแพ้ เกิดโรคทางเดินหายใจเรื้อรัง เกิดโรคหลอดเลือด และหัวใจเรื้อรัง และเกิดโรคปอดเรื้อรัง หรือ มะเร็งปอด เป็นต้น และยังมีผลกระทบทางผิวหนัง เช่น มีผื่นคันตามตัว มีอาการระคายเคือง เกิดลมพิษ และทำร้ายเซลล์ผิวหนัง เป็นต้น ซึ่งองค์การอนามัยโลก หรือ World Health Organization (WHO) กำหนดให้ฝุ่น PM2.5 จัดอยู่ในกลุ่มที่ 1 ของสารก่อมะเร็ง ("PM2.5 คืออะไร? อันตรายและการป้องกันฝุ่นละอองขนาดเล็ก," 2563) และรายงานขององค์กรกรีนพีซ (Greenpeace) ยังระบุว่า ประเทศไทยมีผู้เสียชีวิตก่อนวัยอันควรจากมลพิษฝุ่น PM2.5 มากถึง 37,500 ราย ในปี พ.ศ. 2558 ("รายงานการวิเคราะห์เบื้องต้นมลพิษทางอากาศข้ามพรมแดน," 2562) ดังภาพประกอบที่ 1




ภาพประกอบ 1 แสดงกราฟจำนวนผู้เสียชีวิตก่อนวัยอันควรในประเทศไทยจากมลพิษฝุ่น PM2.5

ที่มา : (GREENPEACE, 2560)

ปัญหามลพิษทางอากาศส่งผลต่อระบบเศรษฐกิจ รวมไปถึงค่าใช้จ่ายที่รัฐต้องสูญเสียไปกับการรักษาพยาบาลผู้ป่วยจากมลพิษทางอากาศ โดยสาเหตุของการเกิดฝุ่นละอองมีหลายปัจจัย เช่น โรงผลิตไฟฟ้า ควันท่อไอเสียจากรถยนต์ การเผาไม้ทำลายป่า เผาขยะ แต่แหล่งต้นตอสำคัญของ PM2.5 ในบรรยากาศ คือ การเผาไหม้เชื้อเพลิงธรรมชาติที่ไม่สมบูรณ์ และฝุ่นจากการเผาชีวมวล ดังภาพประกอบที่ 2 ซึ่งตัวเมืองที่มีตึกสูงรายล้อมจะมีลักษณะคล้ายๆ แอ่งกระทะ เกิดการสะสมของฝุ่นละอองได้ง่าย ซึ่งปกติฝุ่นเหล่านี้จะลอยขึ้นไปในอากาศ ถูกลมพัดฟุ้งกระจายไป แต่ถ้าวันไหนที่อากาศนิ่ง ไม่ค่อยมีลมพัด ฝุ่นละอองจะไม่ฟุ้งกระจาย ส่งผลให้ระดับความเข้มข้นของฝุ่นในพื้นที่นั้น ๆ สูงมากขึ้นจนกลายเป็นระดับที่อันตรายต่อสุขภาพ ("รู้จักฝุ่นพิษ PM 2.5 ที่มากับมลภาวะ และวิธีการเลือกหน้ากากป้องกัน," 2562)


อายุขัยเฉลี่ยที่ลดลงจากภัยต่างๆ

หน่วย: เดือน



แหล่งที่มาของ PM 2.5 ในกรุงเทพฯ

หน่วย: %



ภาพประกอบ 2 แสดงกราฟภัยต่างๆ ที่ทำให้อายุขัยลดลง และกราฟแสดงแหล่งที่มาของฝุ่น PM2.5 ในกรุงเทพฯ

ที่มา : (Team, 2561)

จากปัญหามลพิษทางอากาศที่มีแนวโน้มที่จะรุนแรงมากขึ้นนี้ ทำให้ผู้วิจัยเห็นความสำคัญของการพยากรณ์มลพิษทางอากาศล่วงหน้า ด้วยวิธีการเรียนรู้เชิงลึก (Deep Learning) เพราะสาเหตุการเกิดปัญหามลพิษทางอากาศในปัจจุบัน เมื่อเทียบกับอดีตนั้น มีปัจจัยที่ทำให้เกิดมลพิษที่ซับซ้อนขึ้นเป็นอย่างมาก และวิธีการพยากรณ์แบบดั้งเดิม เช่น การวิเคราะห์

เชิงตัวเลข (Numerical Methods) อาจไม่มีประสิทธิภาพที่ดีพอกับความซับซ้อนของข้อมูลในปัจจุบัน และการเรียนรู้ของเครื่อง (Machine Learning) นั้นไม่ได้ให้ความสัมพันธ์เชิงลึกของข้อมูล ดังนั้นผู้วิจัยจึงเลือกใช้ วิธีการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นการเรียนรู้ของเครื่องรูปแบบหนึ่ง

ทั้งนี้ในงานวิจัยนี้ ทางผู้วิจัยได้พบว่าเราสามารถคาดเดาความเข้มข้นของฝุ่น PM2.5 ที่มีความเข้มข้นมากหรือน้อย ได้จากการสังเกตสภาพอากาศบนท้องฟ้าดังตัวอย่างในภาพประกอบที่ 3 ซึ่งดูได้อย่างชัดเจนว่ามีความขมุกขมัวจากค่าฝุ่น PM2.5 ที่เกินมาตรฐาน จึงเป็นที่มาของการเลือกใช้ภาพถ่ายสภาพอากาศเพื่อพยากรณ์ค่ามลพิษ PM2.5 โดยเลือกใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) แบบสังวัตนาการ (Convolutional Neural Network : CNN) มาประยุกต์ใช้กับการเรียนรู้ข้อมูลที่เป็นรูปภาพพร้อมสกัดเป็นคุณลักษณะของข้อมูลภาพถ่าย และเนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่น ๆ เช่น เมฆ ฝน หรือ แสงอาทิตย์ จึงได้ใช้แบบจำลองแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory : LSTM) ซึ่งมีประสิทธิภาพในการเรียนรู้ลำดับ (Sequence) ของข้อมูล มาช่วยเพิ่มประสิทธิภาพในการเรียนรู้ข้อมูลในการพยากรณ์ค่าความเข้มข้นของ PM2.5 ในช่วงเวลาอนาคต โดยนำแบบจำลองทั้งสองมาประยุกต์ใช้ร่วมกัน



ภาพประกอบ 3 แสดงภาพถ่ายสภาพอากาศของกรุงเทพฯ ในวันที่ 21 ธันวาคม พ.ศ. 2561 เป็นวันที่มีค่ามลพิษฝุ่น PM2.5 เกินค่ามาตรฐาน

ที่มา: (MOMENTUM, 2561)

เนื่องจากปัญหามลพิษทางอากาศมีสาเหตุมาจากปัจจัยที่ซับซ้อน ทางผู้วิจัยจึงได้ประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) มาสร้างแบบจำลองการพยากรณ์ค่ามลพิษ PM2.5 จากข้อมูลภาพถ่ายสภาพอากาศ และข้อมูลความเข้มข้นของ PM2.5 จากกรมควบคุมมลพิษ นำมาเป็นข้อมูลผลลัพธ์ของการพยากรณ์ในการฝึกฝนแบบจำลอง โดยที่ผ่านมามีผู้พัฒนาแบบจำลองเพื่อแก้ปัญหาต่าง ๆ โดยใช้ภาพถ่าย เช่น การสร้างแบบจำลองเพื่อทำนายมัมบังคัสเลียวของรถยนต์ขับเคลื่อนด้วยตัวเอง โดยใช้ข้อมูลสำหรับฝึกแบบจำลองจากภาพถ่ายการขับรถ (Qatawneh, Alshraideh, Almasri, Tahat, & Awidi, 2019) หรือ การใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) กับข้อมูลสภาพอากาศมาสร้างแบบจำลอง เช่น การสร้างแบบจำลองเพื่อใช้สำหรับทำนายการก่อตัวของพายุไต้ฝุ่น โดยใช้ข้อมูลจากคุณลักษณะเชิงพื้นที่ และข้อมูลผิวน้ำทะเล (Chen et al., 2019) เป็นต้น

ค่าความเข้มข้น PM2.5 ในระหว่างวันนั้น มีการเปลี่ยนแปลงขึ้นลงในแต่ละช่วงเวลาในหนึ่งวัน ทำให้แบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ส่วนใหญ่มักจะทำการทำนายล่วงหน้าหน่วยเป็นวันมากกว่าการพยากรณ์เป็นรายชั่วโมง เพราะการพยากรณ์รายชั่วโมงนั้นมักจะขาดความแม่นยำ จึงเป็นที่มาของการสร้างแบบจำลองการพยากรณ์ค่ามลพิษ PM2.5 ล่วงหน้า 24 ชั่วโมง (Perez, 2017)

1.2 วัตถุประสงค์

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายไว้ดังนี้

1. เพื่อศึกษาวิธีการ และสร้างแบบจำลองในการพยากรณ์ค่าความเข้มข้นของฝุ่นละออง PM2.5 ในอากาศล่วงหน้า 24 ชั่วโมง จากภาพสภาพอากาศ โดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) และประเมินผลแบบจำลองที่สร้างขึ้น กับชุดข้อมูลทดสอบ เพื่อประเมินประสิทธิภาพของแบบจำลอง

2. เพื่อเปรียบเทียบการสร้างแบบจำลองที่สร้างจากการใช้เทคนิคการเรียนรู้เชิงลึกแบบ Convolutional Neural Network เพียงอย่างเดียว กับแบบจำลองที่สร้างจากเทคนิคการเรียนรู้เชิงลึกแบบ Convolutional Neural Network ทำงานร่วมกัน กับเทคนิคแบบ Long Short-Term Memory

1.3 ขอบเขตของงานวิจัย

1. เก็บข้อมูลภาพถ่ายสภาพอากาศจากอาคารวิทยาศาสตร์ อาคาร 19 มหาวิทยาลัยศรีนครินทรวิโรฒ โดยสถานที่เก็บภาพ คือ มุมที่หันไปทางทิศตะวันออกเฉียงเหนือ และเก็บข้อมูล

อนุกรมเวลาของค่าความเข้มข้น PM2.5 จากกรมควบคุมมลพิษ จากสถานีวัดคุณภาพอากาศ สถานีตำรวจนครบาลโชคชัย ซึ่งอยู่ในทิศทางเดียวกัน

2. สร้างแบบจำลองการพยากรณ์ค่าความเข้มข้นของฝุ่นละออง PM2.5 ในอากาศจากภาพถ่ายสภาพอากาศ โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) แบบ Convolutional Neural Network (CNN) ร่วมกับ Long Short-Term Memory (LSTM) มาประยุกต์ใช้ในการพยากรณ์ค่าความเข้มข้นของฝุ่นละอองในอากาศ ในช่วงเวลาถัดไปล่วงหน้า 24 ชั่วโมง

3. เนื่องจากงานวิจัยนี้เป็นปัญหาแบบ การวิเคราะห์เชิงถดถอย (Regression) จึงใช้การประเมินการทดลองด้วยค่า Root Mean Square Error (RMSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE)

1.4 ประโยชน์ที่คาดว่าจะได้รับจากงานวิจัย

1. แบบจำลองที่ใช้สำหรับพยากรณ์ค่าความเข้มข้นของฝุ่นละออง PM2.5 ในอากาศ จากภาพถ่ายสภาพอากาศ ที่พัฒนาขึ้นจากเทคนิคที่มีประสิทธิภาพ

2. สามารถนำแบบจำลองที่ได้ ไปประยุกต์ใช้กับแอปพลิเคชัน (Application) เพื่อพยากรณ์ค่า PM2.5 ล่วงหน้า

3. ลดค่าใช้จ่ายในการตั้งสถานีวัดค่าความเข้มข้นของฝุ่นละออง PM2.5 โดยใช้แบบจำลองในการประมาณค่าแทน

4. สามารถเพิ่มพื้นที่ในการพยากรณ์ค่าความเข้มข้นของฝุ่นละออง PM2.5 ในจุดที่สถานีวัดไม่ครอบคลุม

5. เพื่อเป็นการเตรียมการป้องกันสุขภาพร่างกายของตนเอง และรับมือเมื่อเราทราบค่าความเข้มข้นของฝุ่น PM2.5 ล่วงหน้าจากแบบจำลองแล้ว

6. เป็นต้นแบบที่สามารถนำไปต่อยอด และพัฒนาแบบจำลองสำหรับพยากรณ์ค่าความเข้มข้นของฝุ่น PM2.5 ให้มีประสิทธิภาพมากขึ้นในอนาคต

7. สามารถประยุกต์ใช้วิธีการสร้างแบบจำลองนี้ กับปัญหาอื่น ๆ ได้

บทที่ 2

วรรณกรรม และงานวิจัยที่เกี่ยวข้อง


ในงานวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาเอกสารทฤษฎี และงานวิจัยที่เกี่ยวข้องกับการพัฒนาแบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิค CNN กับ LSTM และได้นำเสนอตามหัวข้อดังต่อไปนี้

2.1 ทฤษฎีเกี่ยวกับอัลกอริทึม

2.2 งานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีเกี่ยวกับอัลกอริทึม

การเรียนรู้เชิงลึก (Deep Learning) คือ วิธีการเรียนที่คอมพิวเตอร์จะทำการเรียนรู้แบบอัตโนมัติ ด้วยการจำลองแบบการทำงานของโครงข่ายประสาท (Neurons) ซึ่งการเรียนรู้เชิงลึก (Deep Learning) นั้น เป็นการนำระบบโครงข่ายประสาท (Neural Networks) มาซ้อนกันหลายชั้น (Layer) และทำการเรียนรู้จากข้อมูลที่เราต้องการศึกษา และทำการค้นหารูปแบบ (Pattern) หรือทำการจัดหมวดหมู่ของข้อมูล (Classify the Data) ในข้อมูล ตามปัญหาที่เราศึกษา ดังภาพประกอบที่ 4




ภาพประกอบ 4 แสดงรูปภาพที่ซ้อนกันหลายชั้นโครงข่าย (Layer) ที่จะทำให้เกิดความสามารถ ในการจดจำ

ที่มา: (Athiwat, 2560)

การทำงานของการเรียนรู้เชิงลึก (Deep Learning) นั้น คล้ายกับการทำงานในสมองของมนุษย์ที่ โดยจะมีเซลล์ประสาท (Neurons) ทำงานเชื่อมต่อกันเป็นระบบโครงข่ายประสาท (Neural Networks) ซึ่ง Neuron ถูกแบ่งการทำงานเป็น 3 กลุ่ม ได้แก่

1. Input Layer เป็นตัวรับข้อมูลเข้า และส่งข้อมูลต่อไป Neuron ใน Hidden Layer ชั้นแรก
2. Hidden Layer(s) สามารถมีได้มากกว่า 1 Layer ซึ่งจะทำการคำนวณผลข้อมูลที่ได้จาก Layer ก่อนหน้า โดยใช้วิธีการทางคณิตศาสตร์ และส่งผลไปยัง Layer ชั้นถัดไป
3. Output Layer เป็นตัวให้ผลลัพธ์ของการพยากรณ์ หรือการทำนายจาก Hidden Layer

ซึ่งการสร้าง Deep Learning ต้องสร้าง Neural Networks โดยการตัดสินใจว่าต้องมี Hidden Layers กี่ชั้น และมี Neuron เท่าไร ในแต่ละ Layer จึงจะเหมาะสม ดังภาพประกอบที่ 5



ภาพประกอบ 5 แสดงรูปภาพตัวอย่างการทำงานของ Neural Networks

ในการคำนวณของ Neural Networks ระหว่าง Neuron แต่ละตัว จะมีการถ่วงน้ำหนัก (Weight) ซึ่งเป็นการกำหนดค่าความสำคัญของข้อมูลที่ได้รับมาแต่ และมี Activation Function เป็นตัวปรับค่าของผลลัพธ์ที่ได้จาก Neuron

ด้วยความสามารถของการเรียนรู้เชิงลึก (Deep Learning) จึงถูกนำไปประยุกต์ใช้ในธุรกิจต่าง ๆ อย่างกว้างขวาง เช่น บทบาทของ Deep Learning ในด้านการเงิน ปัจจุบันมีการนำ

Deep Learning ไปใช้ประมวลผลถึงเครดิตการกู้ยืมเงินของผู้กู้ หรือ บทบาทของ Deep Learning ในด้านการจัดการทรัพยากรมนุษย์ มีการนำ Deep Learning ไปใช้ในการคัดเลือกบุคคลเข้าทำงานกับบริษัท และในด้านการตลาด ใช้ Deep Learning เป็นเครื่องมือในการวิเคราะห์โทนเสียงของลูกค้า เพื่อรับรู้ถึงอารมณ์ ณ ขณะนั้นของลูกค้าได้ เป็นต้น จากตัวอย่างข้างต้นจะเห็นว่า Deep Learning ถูกนำไปใช้ในหลากหลายธุรกิจ

ในงานวิจัยสร้างแบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมง จากภาพถ่ายที่เป็นปัญหาแบบ Supervised Machine Learning แบบผลลัพธ์ตัวเลขจำนวนจริง (Regression) นี้ ได้เลือกใช้การเรียนรู้เชิงลึก (Deep Learning) 2 เทคนิค คือ Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM)

2.1.1 ทฤษฎีโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network)

โครงข่ายประสาทเทียมแบบสังวัตนาการ หรือ Convolutional Neural Network (CNN) คือ ระบบโครงข่ายประสาท (Neural Networks) รูปแบบหนึ่ง โดยหลักการทำงาน คือ จำลองการมองเห็นข้อมูลของมนุษย์เป็นพื้นที่ย่อย ๆ และนำกลุ่มพื้นที่ย่อย ๆ มารวมกันเพื่อหาความสัมพันธ์ที่นำไปสู่ผลลัพธ์ของข้อมูล ซึ่งการมองข้อมูลเป็นพื้นที่ย่อย ๆ นั้น คือ การแยกคุณลักษณะ (Feature Extraction) ของข้อมูล ยกตัวอย่าง ข้อมูลรูปภาพ จะมีการมองย่อยข้อมูล เช่น การตัดกันของสี ลายเส้น และสีของรูปภาพ เป็นต้น


การคำนวณของ CNN นั้นจะเริ่มจากกำหนดค่าในตัวกรอง (Filter) เพื่อดึงคุณลักษณะของข้อมูลออก ซึ่งโดยปกติ 1 ตัวกรอง (Filter) จะดึงคุณลักษณะออกมา 1 อย่าง ดังนั้นจึงต้องใช้ตัวกรอง (Filter) หลายตัวเพื่อดึงคุณลักษณะออกมาหลาย ๆ อย่างมารวมกัน โดยรายละเอียดของขั้นตอนนี้มีดังนี้

1. ลักษณะของ Filter สำหรับปัญหาที่เป็นรูปภาพ โดยมากจะเป็นตารางสองมิติ ตามขนาดที่เราอยากพิจารณา เช่น 3x3 หรือ 4x4 ซึ่งจะนำตัวกรองไปทาบบนพิกเซลบนรูปภาพ และขยับเลื่อนตัวกรองไปเรื่อย ๆ ซึ่งในระหว่างที่ขยับ Filter จะได้ ผังคุณลักษณะ (Feature Map) ออกมา ดังภาพประกอบที่ 6



ภาพประกอบ 6 แสดงรูปภาพการทำงานของ Filter

2. Stride และ Padding โดย Stride เป็นตัวกำหนดการเลื่อน Filter ว่าจะเลื่อนไปเท่าไรใน 1 Step ซึ่งหากกำหนดมาก หมายถึง เราต้องการคุณลักษณะที่มีพื้นที่ทับซ้อนกันน้อย และได้ฟังก์ชันคุณลักษณะ (Feature Map) ที่เล็กลง ส่วน Padding คือ การขยายขอบเขตการเลื่อน Filter ไปยังขอบของข้อมูลเพื่อให้ได้ Feature Map ที่ใหญ่ขึ้น หรือ มีขนาดเท่ากับข้อมูล เพราะว่าบางกรณี ขอบของข้อมูลก็มีความสำคัญ ดังภาพประกอบที่ 7



ภาพประกอบ 7 แสดงรูปภาพการทำงานของ Stride และ Padding

3. Pooling เป็นการปรับสเกลข้อมูล โดยการกรองค่าที่ได้จากการหาตัวกรองลงบนข้อมูล ซึ่งมีสองประเภทที่นิยม คือ Max Pooling กรองเอาค่ามากที่สุด ดังภาพประกอบที่ 8 กับ Average Pooling กรองเอาค่าเฉลี่ย เพื่อให้ได้เป็นผลลัพธ์ใหม่ ซึ่งการทำ Pooling นั้นเพื่อดึงค่า

คุณลักษณะข้อมูลออกมาใหม่เพื่อใช้คำนวณต่อ และเป็นการปรับขนาดข้อมูลเพื่อเรียนรู้จากข้อมูลในหลาย ๆ ความละเอียด



ภาพประกอบ 8 แสดงรูปภาพการจำลองของ Max Pooling

4. Fully Connected คือขั้นตอนการนำผลลัพธ์จากการทำขั้นตอนก่อนหน้านี้ มาทำการเรียนรู้ (Training) และจำแนกผลลัพธ์ตามปัญหาของข้อมูลที่นำเข้ามา

5. Activation Function คือ ฟังก์ชันสำหรับประมวลผล ผลลัพธ์ที่ได้จากการคำนวณในหนึ่งนิวรอน และนำผลลัพธ์นั้นมาพิจารณาปรับ Output ที่จะส่งต่อไปยังอีก นิวรอนว่าต้องเป็นเท่าไร โดยในงานวิจัยนี้ใช้ Activation Function แบบ Rectified Linear Unit (ReLU) ซึ่งเป็นฟังก์ชันที่แปลง Output จากนิวรอนหนึ่ง เป็นค่าตั้งแต่ 0 ขึ้นไป ส่วน Output ที่มีค่าน้อยกว่า 0 จะแปลงเป็นค่า 0 ทั้งหมด ดังสมการที่ (1)

$$f(x) = \begin{cases} 0 & \text{สำหรับ } x \leq 0 \\ x & \text{สำหรับ } x > 0 \end{cases} \quad (1)$$

โดยที่

x

คือผลลัพธ์ที่ได้จากการคำนวณในหนึ่งนิวรอน

2.1.2 ทฤษฎีโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory)

โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว หรือ Long Short-Term Memory (LSTM) คือ ระบบโครงข่ายประสาท (Neural Networks) รูปแบบหนึ่ง ที่ทำงานกับปัญหาของข้อมูลที่มีลักษณะลำดับ (Sequence) เช่น Video หรือ Text ที่ต้องอาศัยข้อมูลที่เกิดขึ้นก่อนหน้ามารวมกับข้อมูลใหม่ เพื่อทำความเข้าใจข้อมูลต่อเนื่องไปเรื่อย ๆ โดย LSTM ได้ถูก

พัฒนามาจาก ระบบโครงข่ายประสาท (Neural Networks) แบบ Recurrent Neural Networks (RNN) โดยเพิ่มรายละเอียดเพื่อแก้ปัญหาของ RNN ซึ่งยังมีปัญหากับข้อมูลที่มีลำดับ (Sequence) ยาวเกินไป โดยที่ LSTM สามารถบอกได้ว่า เมื่อไหร่ที่ควร Write, Forget หรือ Read ได้ ซึ่งมี Cell State เป็นตัวเก็บ State ของ Memory Cell และ Gate เป็นตัวควบคุมการไหลของข้อมูลซึ่งมีค่า (Analog) ที่ไว้ควบคุมว่าเมื่อไหร่ควร Write, Read หรือ Forget ข้อมูล โดยการทำงานมีดังนี้

1. Forget คือ การล้าง Cell State เดิมออกไปเพื่อเตรียมพื้นที่รับข้อมูลใหม่ โดยการตัดสินใจที่จะ Forget จะเป็นหน้าที่ของ Forget Gate ซึ่งถูกคำนวณมาจาก ข้อมูลที่เข้ามา ประกอบกับ Hidden State ก่อนหน้า ซึ่งแสดงได้ดังสมการที่ (2)

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

โดยที่

f_t	คือผลลัพธ์ของ Forget Gate ณ เวลา t
σ	คือ Activation Function
w_f	คือค่า Weight ของ Forget Gate
h_{t-1}	คือค่าตอบของเวลา t - 1
x_t	คือข้อมูลนำเข้าเวลา t
b_f	คือค่า Bias ของ Forget Gate

2. Write คือ เมื่อมีข้อมูลเข้ามามีตัดสินใจว่าจะอัปเดต Cell State ด้วยข้อมูลใหม่หรือไม่ โดยการตัดสินใจจะเป็นหน้าที่ของ Input Gate และถ้าอัปเดต จะใช้ข้อมูลอะไรใน อัปเดตซึ่งจะเป็นหน้าที่ของ Input Modulation Gate ซึ่งแสดงได้ดังสมการที่ (3)

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

โดยที่

i_t	คือผลลัพธ์ของ Input Gate ณ เวลา t
σ	คือ Activation Function

w_i	คือค่า Weight ของ Input Gate
h_{t-1}	คือคำตอบของเวลา $t - 1$
x_t	คือข้อมูลนำเข้าเวลา t
b_i	คือค่า Bias ของ Input Gate

3. การอัปเดต Cell State คือ ขั้นการรวมข้อมูลจาก Forget Gate, Input Gate และ Input modulation gate เพื่อมาประกอบการพิจารณาการอัปเดต Cell State ซึ่งแสดงได้ดังสมการที่ (4) และ (5)

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

โดยที่

$\tilde{C}_t$	คือค่า Context ทางเลือก ณ เวลา t
σ	คือ Activation Function
w_c	คือค่า Weight ของ Update Cell Gate
h_{t-1}	คือคำตอบของเวลา $t - 1$
x_t	คือข้อมูลนำเข้าเวลา t
b_c	คือค่า Bias ของ Update Cell Gate

$$C_t = (f_t \cdot C_{t-1}) + (\tilde{C}_t \cdot i_t) \quad (5)$$

โดยที่

C_t	คือค่า Context ณ เวลา t
f_t	คือผลลัพธ์ของ Forget Gate ณ เวลา t
C_{t-1}	คือค่า Context ณ เวลา $t - 1$
$\tilde{C}_t$	คือค่า Context ทางเลือก ณ เวลา t
i_t	คือผลลัพธ์ของ Input Gate ณ เวลา t

4. Read คือ การอนุญาตให้อ่านผลลัพธ์ของการทำงานของอัลกอริทึม โดยการตัดสินใจจะเป็นหน้าที่ของ Output Gate ซึ่งแสดงได้ดังสมการที่ (6) และ (7)

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

โดยที่


o_t	คือผลลัพธ์ของ Output Gate ณ เวลา t
σ	คือ Activation Function
w_o	คือค่า Weight ของ Output Gate
h_{t-1}	คือค่าตอบของเวลา t - 1
x_t	คือข้อมูลนำเข้าเวลา t
b_o	คือค่า Bias ของ Output Gate

$$h_t = o_t \cdot \tanh(C_t) \quad (7)$$

โดยที่

h_t	คือผลลัพธ์ ณ เวลา t
o_t	คือผลลัพธ์ของ Output Gate ณ เวลา t
$\tanh$	คือ Hyperbolic Tangent Function
C_t	คือค่า Context ณ เวลา t

ดั่งภาพประกอบที่ 9




ภาพประกอบ 9 แสดงรูปภาพการทำงานของ LSTM

2.1.3 การทำงานร่วมกันของโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) และโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory)

เนื่องจากงานวิจัยการสร้างแบบจำลองการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่ายนี้ มีการใช้ข้อมูล Input เป็นภาพถ่ายสภาพอากาศ จึงใช้ความสามารถของอัลกอริทึม CNN ในการเรียนรู้ข้อมูลที่เป็นรูปภาพพร้อมสกัดเป็นคุณลักษณะ และเนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่น ๆ เข้ามาเกี่ยวข้อง จึงมีการใช้อัลกอริทึม LSTM เข้ามาช่วยเรียนรู้ลำดับความสัมพันธ์ของข้อมูลในภาพถ่าย ในการพยากรณ์ค่าความเข้มข้นของฝุ่น PM2.5

จากภาพประกอบที่ 10 เริ่มจากนำภาพถ่ายสภาพอากาศ ที่เป็นข้อมูล Input เข้าไปที่โครงข่ายประสาทเทียมแบบ CNN เพื่อจัดการเรื่องสกัดคุณลักษณะ เรียนรู้ และดึงคุณลักษณะ ซึ่งหลังจากการทำงานของ CNN จะได้ Output ออกมาเพื่อเป็น Input เข้าไปที่โครงข่ายประสาทเทียมแบบ LSTM เพื่อช่วยเรียนรู้ลำดับของข้อมูลในภาพ และส่ง Output ของ LSTM เข้า Fully Connected Layer เพื่อพยากรณ์ค่าความเข้มข้น PM2.5 สุดท้ายออกมา หลังจากนั้นทดสอบผลลัพธ์กับ Loss Function และทำการวนซ้ำโครงข่ายประสาทเทียมซ้ำเพื่อปรับค่า Weight ต่อไปจนครบรอบการทำงาน



ภาพประกอบ 10 แสดงรูปภาพการทำงานร่วมกันของ CNN กับ LSTM

2.1.4 การวัดประสิทธิภาพของแบบจำลอง

เนื่องจากการวิจัยนี้เป็นการทำนายผลลัพธ์ที่เป็นตัวเลขจำนวนจริง (Regression) จึงใช้การวัดผลประสิทธิภาพของแบบจำลอง 3 ค่า คือ Root Mean Square Error (RMSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE) ซึ่งค่าเหล่านี้เป็นค่าความคลาดเคลื่อน ดังนั้นแบบจำลองที่ดีจะต้องมีค่าที่น้อย

2.1.4.1 Root Mean Square Error (RMSE)

การประเมินผลโดยการยกกำลังสองของค่าความแตกต่างระหว่างค่าจริงและค่าที่ได้จากการทำนาย ทำให้หากผลการทำนายมีความแตกต่างจากค่าจริงมาก ผลของ RMSE ก็จะสะท้อนค่าที่สูงมาก โดยมีหน่วยเดียวกับค่าที่พยากรณ์ และวิธีการคำนวณดังสมการที่ (8)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (8)$$

2.1.4.2 Mean Absolute Error (MAE)

การหาค่าเฉลี่ยของผลรวมค่าสัมบูรณ์ (Absolute) แสดงความแตกต่างระหว่างค่าจริง และค่าที่ได้จากผลการทำนาย โดยมีหน่วยเดียวกับค่าที่พยากรณ์ และวิธีการคำนวณดังสมการที่ (9)

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (9)$$

2.1.4.3 Mean Absolute Percentage Error (MAPE)

การประเมินผลเพื่อวัดเป็นเปอร์เซ็นต์ความคลาดเคลื่อนของค่าที่พยากรณ์ จากค่าจริง และเนื่องจากการหารค่าจริง ทำให้ผลของ MAPE สะท้อนถึงความแตกต่างของความคลาดเคลื่อนด้วย ดังสมการที่ (10)

$$MAPE = \left(\frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \right) \times 100 \quad (10)$$

โดยที่

y_i	คือ ค่าฝุ่น PM2.5 ณ เวลานั้นจริง
$\hat{y}_i$	คือ ค่าฝุ่น PM2.5 ณ เวลานั้นที่ได้จากการพยากรณ์
N	คือ จำนวนค่าที่พยากรณ์ทั้งหมด

ผลลัพธ์ที่ได้จาก RMSE และ MAE วัดในหน่วยไมโครกรัมต่อลูกบาศก์เมตร ค่าความคลาดเคลื่อนที่ต่างกันของ RMSE และ MAE แสดงถึงประสิทธิภาพการพยากรณ์ แต่เครื่องมือ RMSE มีความไวต่อการคลาดเคลื่อนในการคำนวณมากกว่า MAE ทำให้ RMSE เหมาะกับการใช้วัดประสิทธิภาพในงานที่มีค่าความคลาดเคลื่อนเกิดขึ้นเป็นจำนวนมากดังเช่นงานวิจัยนี้ ส่วนค่า MAPE จะให้ผลลัพธ์เป็นเปอร์เซ็นต์ความคลาดเคลื่อนของการพยากรณ์ ซึ่ง ขนาดค่าของการทดลองมีผลแต่ค่า MAPE เช่น ผลการทดลองที่มีความคลาดเคลื่อนเท่ากัน แต่ค่าของการทดลองมีขนาดเล็ก จะให้เปอร์เซ็นต์ความผิดพลาดมากกว่าค่าการทดลองที่มีค่ามาก

2.2 งานวิจัยที่เกี่ยวข้อง

การทบทวนวรรณกรรมของงานวิจัยนี้ได้ทำการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้อง ซึ่งงานวิจัยต่อไปนี้มีบางงานจะไม่เกี่ยวกับการพยากรณ์ค่าฝุ่น PM2.5 โดยตรงแต่เป็นงานที่ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) หรือใช้ภาพถ่ายในการสร้างแบบจำลองที่เหมือนกัน โดยมีรายละเอียดดังนี้

1. บทความวิจัยเรื่อง Driving Style Classification Based on Driving Operational Pictures (G. Li et al., 2019)

งานวิจัยนี้ได้กล่าวถึงความพยายามเพิ่มความปลอดภัยในการขับขี่ยานพาหนะโดยสร้างวิธีการจำแนกสไตล์การขับขี่ ด้วยภาพถ่าย เพื่อลดค่าใช้จ่ายในความพยายามจำแนกประเภทการขับขี่ โดยใช้ Neural Networks Algorithms สามวิธี คือ CNN, LSTM และ Pretrain-LSTM พบว่า วิธีเหล่านี้ให้ประสิทธิภาพสูงกว่าวิธีการ Machine Learning แบบดั้งเดิม โดย CNN ดำเนินการได้ดีที่สุดด้วยความแม่นยำ 98.5% ดีกว่าวิธีการ Support Vector Machines (SVM)

2. บทความวิจัยเรื่อง Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model (Barzegar, Aalami, & Adamowski, 2020)

งานวิจัยนี้ได้กล่าวถึงความพยายามในการพยากรณ์คุณภาพน้ำจาก 2 ตัวแปร คือ ออกซิเจนที่ละลายในน้ำ (DO; mg / L) และ Chlorophyll-a (Chl-a; lg / L) ในทะเลสาบ Prespa ประเทศกรีซ โดยใช้แบบจำลอง Neural Networks Algorithms คือ LSTM และ CNN กับแบบจำลอง Machine Learning คือ Support Vector Regression (SVR) และ Decision Tree (DT) และได้ใช้แบบจำลองไฮบริด CNN – LSTM ซึ่งให้ผลลัพธ์ที่ดีกว่า แบบจำลองแบบวันแยกวัน โดยได้ผลการทดลอง ดังนี้ตัวแปร DO ได้ค่า R-squared = 0.960, RMSE = 0.682 และ MAE = 0.526 ส่วนตัวแปร Chl-a ได้ค่า R-squared = 0.923, RMSE = 0.646 และ MAE = 0.308

3. บทความวิจัยเรื่อง A hybrid CNN-LSTM model for typhoon formation forecasting (Chen et al., 2019)

งานวิจัยนี้ได้กล่าวถึงปัญหาของพายุไต้ฝุ่นที่เป็นภัยธรรมชาติ สร้างความเสียหายอย่างมาก จึงได้มีความพยายามสร้างแบบจำลองเพื่อใช้สำหรับทำนาย การก่อตัวของพายุไต้ฝุ่น โดยใช้ข้อมูลจากคุณลักษณะเชิงพื้นที่ และข้อมูลผิวน้ำทะเล โดยใช้แบบจำลอง Deep Learning แบบไฮบริด คือ 3D Convolutional Neural Networks (3DCNN), 2D Convolutional Neural

Networks (2DCNN) และ LSTM ทำงานด้วยร่วมกัน และได้ผลลัพธ์ที่สามารถนำไปใช้ได้จริง โดยมีความแม่นยำ 85.2%

4. บทความวิจัยเรื่อง Self-Driving Car Steering Angle Prediction Based on Image Recognition (Qatawneh et al., 2019)

งานวิจัยนี้ได้กล่าวถึงความพยายามสร้างแบบจำลองเพื่อทำนายมุมบังคับเลี้ยวของรถยนต์ขับเคลื่อนด้วยตัวเอง โดยใช้ข้อมูลสำหรับฝึกแบบจำลองจากภาพถ่ายการขับรถของผู้ทดสอบ ที่ได้จาก Udacity Challenge และมีการปรับแต่งภาพในสถานการณ์ต่าง ๆ เพื่อเพิ่มจำนวนข้อมูลทดสอบ โดยใช้แบบจำลอง Deep Learning หลาย ๆ แบบเพื่อทดสอบประสิทธิภาพ คือ 3D Convolutional Neural Networks, Recurrent Neural Networks แบบ LSTM และ ResNet ซึ่งผลการทดลองนั้นสามารถแข่งขันกับ โมเดลอื่น ๆ ได้ โดยได้ผลการทดลองดังนี้ โมเดล 3DCNN และ LSTM ได้ค่า RMSE = 0.1123 และ โมเดล ResNet ได้ค่า RMSE = 0.0709

5. บทความวิจัยเรื่อง Exploring Spatial Influence of Remotely Sensed PM2.5 Concentration Using a Developed Deep Convolutional Neural Network Model (Li, Jin, & Li, 2019)

งานวิจัยนี้ได้กล่าวถึงความพยายามสร้างแบบจำลองเพื่อทำนายมลพิษของฝุ่นละอองที่เก็บข้อมูลเชิงพื้นที่จากอุปกรณ์ระยะไกล จากข้อมูล PM2.5 ทั่วประเทศจีน 4 ปีวิจัย คือ ความหนาแน่นของประชากร, ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP), ภูมิประเทศ, Land-Use และ Land-Cover (LULC) โดยใช้แบบจำลอง Deep Convolutional Network (CNN) ซึ่งผลการทดลองทำให้เห็นถึงประสิทธิภาพที่ดีของแบบจำลองนี้ โดยมีความแม่นยำ 97.8%

6. บทความวิจัยเรื่อง A Hybrid Time Series Model based on Dilated Conv1D and LSTM with Applications to PM2.5 Forecasting (Zhao, Cheng, & Chen, 2019)

งานวิจัยนี้ได้กล่าวถึงความรุนแรงของปัญหา PM2.5 ที่มีผลต่อสุขภาพ และการดำรงชีวิตของประชากรในกรุงปักกิ่ง จึงมีการสร้างแบบจำลองเพื่อทำนายค่าความเข้มข้นของ PM2.5 ด้วยปัจจัยทางอุตุนิยมวิทยา และจากข้อมูลในอดีต โดยเลือกใช้แบบจำลอง รูปแบบไฮบริดระหว่าง LSTM และ CNN คือ DConvLSTM ซึ่งสามารถทำนายผลได้อย่างมีประสิทธิภาพ และได้ค่า R-squared ที่ 0.932

7. บทความวิจัยเรื่อง Hybrid Spatio-temporal Deep Learning Framework for Particulate Matter (PM_{2.5}) Concentration Forecasting (Abirami, Chitra, Madhumitha, & Kesavan, 2020)

งานวิจัยนี้ได้กล่าวถึงการนำแบบจำลอง Deep Learning แบบไฮบริดที่ทำงานร่วมกันระหว่าง LSTM และ CNN ที่ทำงานร่วมกับข้อมูลที่รวบรวมได้จากเซ็นเซอร์ ตรวจวัดคุณภาพอากาศ (IoT) โดยใช้ทั้ง 3D CNN และ 1D CNN ทำงานกับข้อมูลที่เป็นลักษณะข้อมูลเชิงพื้นที่ เพื่อแปลงข้อมูลเป็น Input ให้กับโมเดล LSTM เพื่อทำนายผลในอนาคตต่อไป ซึ่งได้ผลการทำนายอย่างมีประสิทธิภาพ และได้ค่า R-squared ที่ 0.940

8. บทความวิจัยเรื่อง A Novel Combined Prediction Scheme Based on CNN and LSTM for Urban PM_{2.5} Concentration (Qin et al., 2019)

งานวิจัยนี้ได้กล่าวถึงวิธีการทำนายความเข้มข้นของมลพิษทางอากาศของเมืองเซี่ยงไฮ้ ด้วยแบบจำลอง Deep Learning รูปแบบใหม่ โดยใช้ข้อมูลสิ่งแวดล้อมขนาดใหญ่ ซึ่งเป็นการทำงานร่วมกันของแบบจำลอง CNN ที่ทำการสร้าง Feature แบบ Auto เพื่อใช้เป็น Input ของโมเดล LSTM ทำนายผลในอนาคต ผลลัพธ์ที่ได้นั้นพบว่า มีประสิทธิภาพกว่า โมเดลประเภท Numerical Models และได้ค่า R-squared ที่ 0.970

9. บทความวิจัยเรื่อง Deep-AIR: A Hybrid CNN-LSTM Framework for Fine-Grained Air Pollution Forecast (Zhang, Lam, Li, & Han, 2020)

งานวิจัยนี้ได้กล่าวถึงการสร้างแบบจำลอง Deep-Air รูปแบบไฮบริด จาก Deep Learning Framework 2 ชนิด คือ Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) โดยใช้ ข้อมูลความสัมพันธ์เชิงพื้นที่ ของชุดข้อมูลจากการวัดระดับคุณภาพอากาศตามมาตรฐานคุณภาพอากาศ ที่ออกโดยรัฐบาลจีน ซึ่งได้ผลลัพธ์สอดคล้องกับผลที่เกิดขึ้นจริง โดยได้ผลการทดลองค่า MAPE = 27.1

10. บทความวิจัยเรื่อง Deep Air Quality Forecasting Using Hybrid Deep Learning Framework (Du, Li, Yang, & Horng, 2020)

งานวิจัยนี้ได้กล่าวถึงความพยายามที่จะสร้างแบบจำลองเพื่อทำนายคุณภาพอากาศ (PM_{2.5}) เนื่องจากข้อมูลที่เกี่ยวข้องกับการเกิดมลพิษ PM_{2.5} เป็นข้อมูลลักษณะไม่เชิงเส้น และเป็นข้อมูลที่เกี่ยวข้องกับช่วงเวลา ดังนั้นจึงสร้างโดยใช้ Deep Learning แบบไฮบริดทำงานร่วมกัน

ระหว่าง 1D-CNNs เป็นตัวจัดการข้อมูลที่เป็น Input และใช้ Bi-LSTM ทำนายผลในอนาคต จากข้อมูลในอดีต และผลการทำนายในช่วง 24 ชั่วโมง ได้ค่า RMSE = 77.88

ตาราง 1 แสดงผลสรุปการทดลอง และโมเดลที่ใช้ของงานวิจัยที่เกี่ยวข้อง

ลำดับ	ชื่องานวิจัย	โมเดลที่ใช้เปรียบเทียบ	ผลการทดลอง
1	Driving Style Classification Based on Driving Operational Pictures	SVM	Accuracy = 0.922
		LSTM	Accuracy = 0.957
		CNN	Accuracy = 0.985
2	Short-term Water Quality Variable Prediction Using a Hybrid CNN-LSTM Deep Learning Model	CNN ตัวแปร DO	R-squared = 0.967
		LSTM ตัวแปร DO	R-squared = 0.968
		CNN - LSTM ตัวแปร DO	R-squared = 0.970
		CNN ตัวแปร Chl-a	R-squared = 0.872
		LSTM ตัวแปร Chl-a	R-squared = 0.869
		CNN - LSTM ตัวแปร Chl-a	R-squared = 0.874

ตาราง 1 (ต่อ)

ลำดับ	ชื่องานวิจัย	โมเดลที่ใช้เปรียบเทียบ	ผลการทดลอง
		2DCNN - LSTM	Accuracy = 0.766
3	A hybrid CNN-LSTM Model for Typhoon Formation Forecasting	3DCNN - LSTM	Accuracy = 0.812
		3DCNN, 2DCNN และ LSTM	Accuracy = 0.852
		NVIDIA	RMSE = 0.0986
4	Self-Driving Car Steering Angle Prediction Based on Image Recognition	3DCNN - LSTM	RMSE = 0.1123
		ResNet	RMSE = 0.0709
5	Exploring Spatial Influence of Remotely Sensed PM2.5 Concentration Using a Developed Deep Convolutional Neural Network Model	CNN	Accuracy = 0.978

ตาราง 1 (ต่อ)

ลำดับ	ชื่องานวิจัย	โมเดลที่ใช้เปรียบเทียบ	ผลการทดลอง
6	A Hybrid Time Series Model based on Dilated	LSTM	R-squared = 0.918
	Conv1D and LSTM with Applications to PM2.5 Forecasting	Conv1D	R-squared = 0.905
		DConvLSTM	R-squared = 0.932
7	Hybrid Spatio-temporal Deep Learning Framework for Particulate Matter (PM2.5) Concentration Forecasting	ConvLSTM	R-squared = 0.850
		CNN - LSTM	R-squared = 0.940
8		CNN	RMSE = 30.66
	A Novel Combined Prediction Scheme Based on CNN and LSTM for Urban PM2.5 Concentration	RNN	RMSE = 30.66
		LSTM	RMSE = 17.95
		CNN - LSTM	RMSE = 14.3

ตาราง 1 (ต่อ)

ลำดับ	ชื่องานวิจัย	โมเดลที่ใช้เปรียบเทียบ	ผลการทดลอง
9	Deep-AIR: A Hybrid CNN-LSTM Framework for Fine-Grained Air Pollution Forecast	LSTM	MAPE = 35.6
		ConvLSTM	MAPE = 32.7
		ResNet-LSTM	MAPE = 28.5
		Deep - AIR	MAPE = 27.1
10	Deep Air Quality Forecasting Using Hybrid Deep Learning Framework	LSTM (24 ชั่วโมง)	RMSE = 96.64
		CNN (24 ชั่วโมง)	RMSE = 94.85
		CNN - LSTM (24 ชั่วโมง)	RMSE = 77.88

บทที่ 3


การดำเนินการวิจัย

ในงานวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

- 3.1 กระบวนการทำงานของแบบจำลอง
- 3.2 การเก็บรวบรวมข้อมูล (Data Collection)
- 3.3 การสำรวจข้อมูล (Exploratory Data Analysis: EDA)
- 3.4 การเตรียมข้อมูล (Data Preparation)
- 3.5 การสร้างแบบจำลองพยากรณ์



3.1 กระบวนการทำงานของแบบจำลอง



ภาพประกอบ 11 แสดง Flowchart กระบวนการสร้างแบบจำลอง

จากภาพประกอบที่ 11 Flowchart ได้อธิบายถึงกระบวนการสร้างแบบจำลอง โดยกระบวนการสร้างแบบจำลอง เริ่มจากขั้นตอนการนำเข้าข้อมูล (Input Data) การสำรวจข้อมูล (Exploratory Data Analysis : EDA) การเตรียม และจัดการข้อมูลก่อนเข้ากระบวนการสร้างแบบจำลอง (Data Preparation) และจากนั้นแบ่งข้อมูล (Split Data) ออกเป็นข้อมูลฝึกสอน (Training Set) และข้อมูลทดสอบ (Test Set) เพื่อนำไปสร้าง และทดสอบประสิทธิภาพของแบบจำลอง

ขั้นตอนการสร้างแบบจำลองในการทำนาย ได้สร้างแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) สองแบบเพื่อเปรียบเทียบประสิทธิภาพกัน คือ สร้างแบบจำลองโดยใช้เทคนิค Convolutional Neural Network (CNN) เพียงอย่างเดียว เปรียบเทียบกับแบบจำลองที่สร้างโดยใช้เทคนิค Convolutional Neural Network (CNN) ทำงานร่วมกับ Long Short-Term Memory (LSTM) โดย CNN ใช้กับการเรียนรู้รายละเอียด และสกัดคุณลักษณะของข้อมูล และ LSTM ใช้ในการเรียนรู้ลำดับความสัมพันธ์ของข้อมูลในภาพ เพื่อใช้ในการพยากรณ์ฝุ่น PM2.5 ล่วงหน้า และทำการปรับจูนพารามิเตอร์ (Hyperparameter Optimization) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง จากการประเมินผลประสิทธิภาพของแบบจำลอง (Evaluation) และสุดท้าย ขั้นตอนการนำเสนอแบบจำลองประสิทธิภาพของแบบจำลองในการพยากรณ์ค่าความเข้มข้นของ PM2.5 ผ่านข้อมูลทดสอบ (Test Set) โดยใช้ ค่า Root Mean Squared Error (RMSE), Mean Squared Error (MSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE)

3.2 การเก็บรวบรวมข้อมูล (Data Collection)


ในงานวิจัยครั้งนี้ มีการใช้ข้อมูลสองประเภท คือ ใช้ข้อมูลภาพถ่ายท้องฟ้า และข้อมูลอนุกรมเวลาค่าความเข้มข้น PM2.5 จากกรมควบคุมมลพิษ จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย โดยมีรายละเอียดการเก็บรวบรวมข้อมูลดังนี้

3.2.1 การติดตั้งกล้องเพื่อเก็บข้อมูลวิดีโอสภาพถ่ายท้องฟ้า

การติดตั้งกล้องเพื่อเก็บข้อมูลวิดีโอสภาพอากาศ เป็นการติดตั้งกล้อง IP Camera เพื่อเก็บข้อมูลวิดีโอสภาพอากาศ โดยตั้งกล้องจากตึกอาคารวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และหันกล้องไปทางทิศตะวันออกเฉียงเหนือ โดยเริ่มจากเวลา 7 นาฬิกา ถึงเวลา 18 นาฬิกา ของวันที่ 3 สิงหาคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2562 จำนวนทั้งหมด 1,690 ภาพ ดังตัวอย่างภาพประกอบที่ 12 และ 13



ภาพประกอบ 12 แสดงตัวอย่างภาพถ่ายสภาพอากาศจากกล้อง IP Camera วันที่ 5 สิงหาคม
พ.ศ.2562 เวลา 07:00 น.



ภาพประกอบ 13 แสดงตัวอย่างภาพถ่ายสภาพอากาศ จากกล้อง IP Camera วันที่ 29 ธันวาคม
พ.ศ.2562 เวลา 09:00 น.

3.2.2 ข้อมูลอนุกรมเวลาค่าความเข้มข้น PM2.5 จากกรมควบคุมมลพิษ


นำข้อมูลอนุกรมเวลาค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย ของวันที่ 3 สิงหาคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2562 โดยลักษณะข้อมูลจะเป็นรายชั่วโมง และมีรายละเอียดของข้อมูลดังตารางที่ 2

ตาราง 2 แสดงรายละเอียดข้อมูลค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย

ข้อมูล	คำอธิบาย	ตัวอย่างข้อมูล
ปี/เดือน/วัน	วันที่	190101
ชั่วโมง	ชั่วโมงที่	800
PM2.5 หน่วยเป็นไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$)	ฝุ่นขนาดไม่เกิน 2.5 ไมครอนวัดที่ความสูง 3 เมตร	35

3.3 การสำรวจข้อมูล (Data Exploration)

การสำรวจ และวิเคราะห์ความสัมพันธ์ระหว่างข้อมูลภาพถ่ายสภาพอากาศ จากกล้อง IP Camera และข้อมูลอนุกรมเวลาค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย จะเห็นว่าค่าความเข้มข้นของ PM2.5 ที่ได้จากสถานีวัดคุณภาพอากาศจากเดือนสิงหาคม พ.ศ. 2562 ถึงเดือนธันวาคม พ.ศ.2562 มีแนวโน้มสูงขึ้นในช่วงเดือนหลัง จากภาพประกอบที่ 14 และเมื่อเทียบกับข้อมูลภาพถ่ายสภาพอากาศพบว่าช่วงเดือนสิงหาคมมีสภาพท้องฟ้าใสกว่า เดือนธันวาคม จากภาพประกอบที่ 15 และ 16



ภาพประกอบ 14 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัดคุณภาพอากาศสถานี
ตำรวจนครบาลโชคชัย



ภาพประกอบ 15 แสดงภาพถ่ายสภาพอากาศ ช่วงเดือนสิงหาคม พ.ศ.2562



ภาพประกอบ 16 แสดงภาพถ่ายสภาพอากาศ ช่วงเดือนธันวาคม พ.ศ.2562

ตารางที่ 3 แสดงข้อมูลทางสถิติของข้อมูลค่าความเข้มข้นของ PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย ที่นำมาใช้เป็นข้อมูลคำตอบของค่า PM2.5 ประกอบกับข้อมูลภาพถ่ายในแต่ละช่วงเวลา


ตาราง 3 แสดงค่าทางสถิติของข้อมูลค่าความเข้มข้น PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย ในช่วงวันที่ 3 สิงหาคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2562

ค่าทางสถิติของ PM2.5	ค่าจากข้อมูล
ค่าสูงสุด	99 $\mu\text{g}/\text{m}^3$ (29/09/19 08:00 น.)
ค่าต่ำสุด	2 $\mu\text{g}/\text{m}^3$ (30/08/19 13:00 น.)


ตาราง 3 (ต่อ)

ค่าทางสถิติของ PM2.5	ค่าจากข้อมูล
ส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation)	14.96 $\mu\text{g}/\text{m}^3$
ค่าเฉลี่ย (Mean)	24.04 $\mu\text{g}/\text{m}^3$
จำนวนชั่วโมงทั้งหมด	1,690 ชั่วโมง
จำนวนวันทั้งหมด	144 วัน

ภาพประกอบที่ 17 และ 18 แสดงตัวอย่างความสัมพันธ์ระหว่างข้อมูลภาพถ่ายสภาพอากาศ จากกล้อง IP Camera และข้อมูลอนุกรมเวลาของค่าฝุ่น PM2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัย ในวันที่ 27 กันยายน พ.ศ. 2562 เวลา 07:00 - 18:00 น. จะเห็นว่าในช่วงเวลาที่มีค่าของ PM2.5 สูง (ช่วงเช้า) รูปจะมีสีที่ขุ่นกว่า ช่วงเวลาที่มีค่า PM2.5 ต่ำกว่า แต่จากภาพก็จะพบว่าอาจจะมีปัจจัยอื่น ๆ มารบกวนสีของภาพ เช่น แสงอาทิตย์ หรือ ปริมาณของเมฆ เป็นต้น



ภาพประกอบ 17 แสดงภาพถ่ายสภาพอากาศ จากกล้อง IP Camera วันที่ 27 กันยายน พ.ศ. 2562 เวลา 07:00 - 18:00 น.



ภาพประกอบ 18 แสดงข้อมูลค่าฝุ่น PM 2.5 จากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาล ไซค์ชัย วันที่ 27 กันยายน พ.ศ. 2562 เวลา 07:00 - 18:00 น.

3.4 การเตรียมข้อมูล (Data Preparation)

การทดลองของงานวิจัยนี้ ใช้ข้อมูลภาพถ่ายสภาพอากาศขนาด 256 X 256 พิกเซล และข้อมูลจากสถานีวัดคุณภาพอากาศในกรุงเทพมหานคร ระหว่างเดือนสิงหาคม 2562 ถึงเดือนธันวาคม 2562 โดยใช้ข้อมูลสำหรับฝึกฝนแบบจำลอง คือ ช่วงเดือนสิงหาคม 2562 ถึงเดือนพฤศจิกายน 2562 และใช้ข้อมูลเดือนธันวาคม 2562 เป็นชุดข้อมูลทดสอบ

การเตรียมข้อมูลสำหรับการฝึกฝนของแบบจำลอง พบว่าข้อมูลสภาพอากาศจากสถานีวัดคุณภาพอากาศสถานีตำรวจนครบาลโชคชัยนั้น มีบางข้อมูลขาดหายไป จึงใช้วิธีการจัดการกับข้อมูลที่ขาดหายไป ด้วยการใส่ข้อมูลอนุกรมเวลาก่อนหน้ามาเติม (Forward Filling)

และเนื่องจากงานวิจัยนี้ต้องการข้อมูลที่เป็นรูปภาพ ซึ่งหลังจากได้วิดีโอที่บันทึกสภาพอากาศไว้แล้ว ได้ทำการตัดวิดีโอให้เป็นรูปภาพทุก ๆ 1 ชั่วโมงในช่วงเวลา 7 นาฬิกา ถึงเวลา 18 นาฬิกา ของวันที่ 3 สิงหาคม พ.ศ. 2562 ถึงวันที่ 31 ธันวาคม พ.ศ. 2562




ภาพประกอบ 19 แสดงตัวอย่างข้อมูลการตัดวิดีโอให้เป็นภาพทุก ๆ 1 ชั่วโมง

3.5 การสร้างแบบจำลองพยากรณ์

ในการสร้างแบบจำลองการพยากรณ์ค่าความเข้มข้น PM_{2.5} ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) นั้น ได้ใช้ข้อมูลภาพถ่ายสภาพอากาศและใช้ข้อมูลค่าความเข้มข้นของ PM_{2.5} จากสถานีวัดคุณภาพอากาศ ณ ช่วงเวลาล่วงหน้า 24 ชั่วโมง เป็นข้อมูลสำหรับการฝึกฝนแบบจำลอง ซึ่งข้อมูลภาพถ่ายสภาพอากาศนั้นจะเป็นข้อมูลสำหรับการเรียนรู้ และข้อมูลค่าความเข้มข้น PM_{2.5} นั้นจะเป็นข้อมูลคำตอบ และเพื่อเป็นการ

เปรียบเทียบผลการทดลองของงานวิจัยนี้ ผู้วิจัยได้แบ่งการทดลองออกเป็น 2 แบบ คือ การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว กับ การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) โดยมีรายละเอียดดังนี้

1. การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว ซึ่งเนื่องจากงานวิจัยนี้ ใช้รูปภาพเป็นข้อมูลในการสร้างแบบจำลอง ทางผู้วิจัยเห็นว่าสามารถใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว ดังภาพประกอบที่ 20 เพื่อให้ได้ผลการทดลองพื้นฐาน (Baseline) และนำไปเปรียบเทียบกับแบบจำลองที่ใช้โครงข่ายประสาทเทียมในรูปแบบอื่น โดยการทำงานของแบบจำลองนี้จะใช้รูปภาพเพียงภาพเดียว ณ เวลาใดเวลาหนึ่ง และทำการพยากรณ์ค่า PM2.5 ไปล่วงหน้า 24 ชั่วโมงจากการเรียนรู้ข้อมูล Input ด้วยเทคนิค CNN เพียงอย่างเดียว ซึ่งในการทดลองนี้ ใช้ CNN 3 Layer และในแต่ละ Layer ใช้ Filter เท่ากับ 64 เพื่อให้แบบจำลองเรียนรู้ความสัมพันธ์ของข้อมูลให้มากที่สุด เนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่นๆ ในภาพ เช่น แสงอาทิตย์ ฝนตก และปริมาณเมฆ เป็นต้น



ภาพประกอบ 20 โมเดลการสร้างแบบจำลองโดยใช้ Convolutional Neural Networks

สมการที่ (11) แสดงถึงการพยากรณ์ค่าความเข้มข้นของ PM2.5 ล่วงหน้า 24 ชั่วโมงของการทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network)


เพียงอย่างเดียว โดยใช้ภาพถ่ายสภาพอากาศ ณ ช่วงหนึ่ง และพยากรณ์ค่า PM2.5 ล่วงหน้าไป 24 ชั่วโมง ยกตัวอย่าง เช่น ใช้ภาพถ่ายสภาพอากาศ วันที่ 19 ธันวาคม พ.ศ.2562 เวลา 10:00 น. แบบจำลองจะใช้ภาพถ่ายนี้ภาพเดียวในการพยากรณ์ค่า PM2.5 ล่วงหน้า 24 ชั่วโมง ซึ่งคือ พยากรณ์ค่า PM2.5 ของวันที่ 20 ธันวาคม พ.ศ.2562 เวลา 10:00 น.

$$f(i_t) = PM2.5_{t+24} \quad (11)$$

โดยที่

i_t คือ ภาพถ่ายสภาพอากาศ ณ เวลาที่ t
 $PM2.5_{t+24}$ คือ ค่าฝุ่น PM2.5 ณ เวลาที่ $t + 24$ ชั่วโมง ที่ได้จากการพยากรณ์

2. การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับ โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) ซึ่งเนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่น ๆ เช่น เมฆ ฝน หรือ แสงอาทิตย์ ทำให้ผู้วิจัยเห็นว่าสามารถนำโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) ที่สามารถเรียนรู้ลำดับ (Sequence) ของข้อมูลได้ดี มาทำงานร่วมกับโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) โดยใช้ข้อมูลรูปภาพเป็น Input เข้าโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Networks) เพื่อเป็นการแยกคุณลักษณะ (Feature Extraction) ของข้อมูล และใช้ Output ของ CNN เป็นอินพุตของโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) เพื่อเรียนรู้ลำดับของคุณลักษณะของข้อมูล เพื่อทำนายค่าฝุ่น PM2.5 ดังภาพประกอบที่ 21



ภาพประกอบ 21 โมเดลการสร้างแบบจำลองโดยใช้ Convolutional Neural Networks ร่วมกับ Long Short-Term Memory

สมการที่ (11) แสดงถึงการพยากรณ์ค่าความเข้มข้นของ PM2.5 ล่วงหน้า 24 ชั่วโมงของการทดลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) ซึ่งเป็นสมการเดียวกันกับแบบจำลองที่ใช้ CNN เพียงอย่างเดียว แต่มีการทำงานภายในซึ่งแตกต่างกัน

จากนั้นทำการปรับปรุงพารามิเตอร์ของแบบจำลองที่เหมาะสมเพื่อให้แบบจำลองทำนายได้อย่างมีประสิทธิภาพ และพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมง

สุดท้ายนำแบบจำลองมาทดสอบประสิทธิภาพโดยใช้ Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE) กับข้อมูลทดสอบ (Test Set)

บทที่ 4

ผลการดำเนินการวิจัย

ในงานวิจัยครั้งนี้ ผู้วิจัยได้ทำการทดลองเพื่อทำนายค่าความเข้มข้นของ PM2.5 ล่วงหน้า โดยก่อนนำข้อมูลเข้าแบบจำลองได้มีการจัดการกับข้อมูลที่ขาดหายไป (Missing Values) ของข้อมูลอนุกรมเวลาที่ได้จากสถานีวัด คือ การเติมข้อมูลที่หายไปด้วยการใช้ข้อมูลอนุกรมเวลาก่อนหน้ามาเติม (Forward Filling) โดยการทดลองทั้งสองแบบนี้ ในส่วนของ Convolutional Neural Networks ใช้ Hyperparameters เหมือนกัน และในแบบที่ทำงานร่วมกับ Long Short-Term Memory ได้เพิ่ม LSTM Layer เข้ามา 1 Layer เพื่อพยากรณ์ค่า PM2.5 ล่วงหน้า

ตารางที่ 4 แสดงรายละเอียด Hyperparameters ต่าง ๆ ของแบบจำลองทั้งสองแบบ โดยในส่วนของเทคนิค CNN นั้นจะใช้ Hyperparameters เหมือนกันทุกอย่าง คือ ใช้จำนวน 3 Layer แต่ละ Layer ใช้ Filter เท่ากับ 64 เพื่อเรียนรู้คุณลักษณะของภาพถ่ายสภาพอากาศ และเลือกใช้ขนาด Filter ของ Convolution เท่ากับ 3 X 3 เนื่องจากลักษณะภาพถ่ายสภาพอากาศจะเป็นการดูคุณลักษณะของภาพทั้งภาพ จึงเลือกใช้ Filter ขนาดเล็ก และมีการทำ Pooling Layer คั่นระหว่างแต่ละ Layer ของ Convolution Layer เพื่อทำการลดขนาดของข้อมูลทำให้การฝึกฝนของแบบจำลองเร็วขึ้น โดยใช้ขนาดของ Filter ของ Pooling เท่ากับ 3 X 3 ในส่วนของแบบจำลองที่ใช้เทคนิค LSTM รวมด้วยนั้น ได้เพิ่ม Layer ของ LSTM มา 1 Layer โดยมีค่า Timesteps เท่ากับ 9 ตามมิติของข้อมูลที่ออกจาก Convolution Layer สุดท้าย แบบจำลองทั้งสองแบบนี้ใช้ Optimizers เป็น Adam ที่ Learning Rate เท่ากับ 0.0001 ซึ่งเป็น Optimizers ที่มีประสิทธิภาพและเป็นที่นิยมในปัจจุบัน โดยแบ่งข้อมูลการฝึกฝนด้วย Batch Size เท่ากับ 30 และใช้จำนวนรอบที่ฝึกฝนด้วย Epochs เท่ากับ 20 และเนื่องจากงานวิจัยนี้เป็นการพยากรณ์ผลลัพธ์ที่เป็นค่าจำนวนเต็มบวก จึงใช้ Activation Function คือ ReLU

ตาราง 4 แสดงรายละเอียด Hyperparameters ของแบบจำลอง

Hyperparameters	Value
Optimizers	Adam


ตาราง 4 (ต่อ)

Hyperparameters	Value
จำนวน Convolution Layer	3
จำนวน Filter ของแต่ละ Convolution Layer	64
Activation Function	ReLU
Filter Size ของ Convolution	3 X 3
จำนวน Pooling Layer	3
Filter Size ของ Pooling	3 X 3
จำนวน LSTM Layer	1
จำนวน Sequence ของ LSTM (Timestep)	9
Learning Rate	0.0001
Batch Size	30

ตาราง 4 (ต่อ)

Hyperparameters	Value
Epochs	20

ภาพประกอบที่ 22 แสดงการทำงานของแบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) ที่รับ Output จากแบบจำลองเชิงวัตนาการ (Convolutional Neural Network) ซึ่ง LSTM จะทำการเรียนรู้ลำดับของคุณลักษณะของข้อมูล (Timesteps) เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ข้อมูลเพื่อพยากรณ์ค่า PM2.5 ล่วงหน้า




ภาพประกอบ 22 แสดงการทำงานของแบบจำลองหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory)

รายละเอียดของข้อมูลที่ใช้ในการสร้างแบบจำลองเพื่อพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้า 24 ชั่วโมง ณ เวลาทดสอบหนึ่ง เช่น ต้องการพยากรณ์ค่าฝุ่น PM2.5 ณ เวลา 10:00 น. ของวันพรุ่งนี้ จะใช้ข้อมูลภาพถ่ายสภาพอากาศ ณ เวลา 10:00 น. ของวันนี้ โดยข้อมูลทดสอบที่ใช้ในงานวิจัยนี้ เป็นข้อมูลวันที่ 1 ธันวาคม พ.ศ. 2562 ถึงวันที่ 30 ธันวาคม พ.ศ. 2562 ดังผลลัพธ์เปรียบเทียบกันระหว่างแบบจำลองทั้งสองแบบแสดงในตารางที่ 5 และภาพประกอบที่ 23

ตาราง 5 ตารางเปรียบเทียบผลการทดลองของแบบจำลอง CNN กับ CNN + LSTM


Measure	CNN	CNN + LSTM
RMSE ($\mu\text{g}/\text{m}^3$)	15.59	11.39
MAE ($\mu\text{g}/\text{m}^3$)	12.67	8.25
MAPE (%)	34.46	26.24




ภาพประกอบ 23 แสดงกราฟเปรียบเทียบผลการทดลองของแบบจำลอง CNN เพียงอย่างเดียว และแบบจำลอง CNN ทำงานร่วมกับ LSTM ของค่า RMSE, MAE และ MAPE

จากผลการทดลองพบว่าแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) ให้ประสิทธิภาพที่แม่นยำกว่า 4 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) เมื่อวัดด้วยค่า RMSE และ MAE หรือคิดเป็น 8 เปอร์เซ็นต์ เมื่อวัดด้วยค่า MAPE ในการพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้า เมื่อเทียบกับแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว ซึ่งไม่มีการเรียนรู้ลำดับความสัมพันธ์ของข้อมูลจึงทำให้แบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบ CNN เพียงอย่างเดียวได้ประสิทธิภาพที่แม่นยำน้อยกว่าแบบจำลองที่ใช้ CNN ทำงานร่วมกับ LSTM

ภาพประกอบที่ 24 และ 25 แสดงผลการพยากรณ์ของแบบจำลองที่สร้างโดยใช้เทคนิค Convolutional Neural Network เพียงอย่างเดียว เปรียบเทียบกับค่าจริง จะเห็นว่าผลการพยากรณ์มีแนวโน้มไปทิศทางเดียวกับค่าจริง แต่ผลการพยากรณ์ที่ได้ในช่วงแรกของข้อมูลทดสอบจะมีค่ามากกว่าค่าจริงซึ่งค่า PM2.5 จริงค่อนข้างต่ำ แต่หลังจากนั้นค่าจริงมีความผันผวนมาก ๆ ซึ่งผลการพยากรณ์จะน้อยกว่าค่าจริงตลอดในช่วงข้อมูลทดสอบที่เหลือ หรือดังแสดงในกราฟ เปรียบเทียบกับผลการพยากรณ์ และค่า PM2.5 จริง จะเห็นว่าช่วงค่า PM2.5 น้อย คือ ช่วง 10 – 40 มีทั้งที่ค่าพยากรณ์ได้มากกว่า และน้อยกว่าค่าจริง แต่หลังจากช่วงที่ค่าเกิน 40 ค่าพยากรณ์จะได้ต่ำกว่าค่าจริงทั้งหมด




ภาพประกอบ 24 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัด เปรียบเทียบกับผลการพยากรณ์โดยใช้ CNN เพียงอย่างเดียว




ภาพประกอบ 25 แสดงกราฟเปรียบเทียบกับการพยากรณ์ และค่า PM2.5 จริง โดยใช้ CNN เพียงอย่างเดียว

ภาพประกอบที่ 26 และ 27 แสดงผลการทำนายของแบบจำลองที่สร้างโดยใช้เทคนิค Convolutional Neural Network ทำงานร่วมกับ Long Short-Term Memory ที่เปรียบเทียบกับค่าจริง จะเห็นว่าผลการทำนายมีแนวโน้มไปทิศทางเดียวกับค่าจริง และได้ผลที่ใกล้เคียงกับค่าจริง ตลอดช่วงการทำนาย มากกว่าแบบจำลองที่สร้างโดยใช้เทคนิค Convolutional Neural Network เพียงอย่างเดียว หรือดังแสดงในกราฟเปรียบเทียบกับการพยากรณ์ และค่า PM2.5 จริง จะเห็นว่าได้ค่าพยากรณ์ใกล้เคียงค่าจริง เกาะกลุ่มไปตลอดช่วงค่า PM2.5 ทั้งช่วงค่าน้อย และค่าสูง



ภาพประกอบ 26 แสดงแนวโน้มค่าความเข้มข้นของ PM 2.5 จากสถานีวัด เปรียบเทียบกับการพยากรณ์โดยใช้ CNN ทำงานร่วมกับ LSTM



ภาพประกอบ 27 แสดงกราฟเปรียบเทียบกับการพยากรณ์ และค่า PM2.5 จริง โดยใช้ CNN
ทำงานร่วมกับ LSTM

จากกราฟแสดงผลการทดลองของงานวิจัยนี้พบว่า แบบจำลองที่ใช้เทคนิค Convolutional Neural Network เพียงอย่างเดียว นั้น จะให้ผลการพยากรณ์ค่อนข้างต่ำกว่าค่าจริง ตลอดช่วงข้อมูลทดสอบ ส่วนแบบจำลองที่ใช้เทคนิค Convolutional Neural Network ทำงานร่วมกับ Long Short-Term Memory นั้นให้ผลการพยากรณ์ได้ใกล้เคียงค่าจริงตลอดทั้งช่วงของข้อมูลทดสอบ ทั้งในช่วงที่มีความผันผวนของค่าความเข้มข้น PM2.5 ด้วย

ภาพประกอบ 28 แสดงตัวอย่างภาพถ่ายสภาพอากาศของวันที่ 1 ธันวาคม พ.ศ.2562 เวลา 13:00 น. ซึ่งเป็นภาพที่แบบจำลองที่ใช้เทคนิค Convolutional Neural Network ทำงานร่วมกับ Long Short-Term Memory พยากรณ์ล่วงหน้า 24 ชั่วโมงได้ตรงกับค่า PM2.5 จริง คือ ได้ค่าเท่ากับ 9 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$)



ภาพประกอบ 28 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ตรงกับค่า PM2.5 จริง

ภาพประกอบ 29 แสดงตัวอย่างภาพถ่ายสภาพอากาศของวันที่ 12 ธันวาคม พ.ศ.2562 เวลา 13:00 น. ซึ่งเป็นภาพที่แบบจำลองที่ใช้เทคนิค Convolutional Neural Network ทำงานร่วมกับ Long Short-Term Memory พยากรณ์ล่วงหน้า 24 ชั่วโมงได้ใกล้เคียงกับค่า PM2.5 จริง คือ ได้ค่าจริงได้เท่ากับ 53 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) และค่าพยากรณ์ได้เท่ากับ 50 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$)



ภาพประกอบ 29 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ใกล้เคียงกับค่า PM2.5 จริง

ภาพประกอบ 30 แสดงตัวอย่างภาพถ่ายสภาพอากาศของวันที่ 20 ธันวาคม พ.ศ.2562 เวลา 13:00 น. ซึ่งเป็นภาพที่แบบจำลองที่ใช้เทคนิค Convolutional Neural Network ทำงานร่วมกับ Long Short-Term Memory พยากรณ์ล่วงหน้า 24 ชั่วโมงได้ห่างจากค่า PM2.5 จริง คือได้ค่าจริงได้เท่ากับ 23 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) และค่าพยากรณ์ได้เท่ากับ 15 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$)



ภาพประกอบ 30 แสดงภาพถ่ายสภาพอากาศที่แบบจำลองทำนายได้ห่างจากค่า PM2.5 จริง

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

เนื่องจากปัจจุบันปัญหามลพิษทางอากาศ โดยเฉพาะปัญหาฝุ่น PM2.5 ได้เกิดขึ้นเป็นประจำทุกปี และมีแนวโน้มว่าจะรุนแรงมากขึ้นเรื่อย ๆ ประกอบกับการที่เราสามารถประเมินฝุ่น PM2.5 ได้จากการสังเกตสภาพอากาศบนท้องฟ้าด้วยตาเปล่า จึงเป็นที่มาของงานวิจัยนี้ ซึ่งในงานวิจัยนี้ได้ศึกษาเทคนิคการเรียนรู้เชิงลึก 2 รูปแบบ เพื่อสร้างแบบจำลองสำหรับพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยใช้ข้อมูลอนุกรมเวลาค่าความเข้มข้นของ PM2.5 จากสถานีวัดคุณภาพอากาศเป็นชุดข้อมูลประกอบ เพื่อนำมาเปรียบเทียบกัน ผู้วิจัยได้วัดประสิทธิภาพแบบจำลองที่ถูกสร้างขึ้นมา และสรุปผลการวิจัย โดยสามารถแบ่งหัวข้อได้ดังนี้

5.1 สรุปผลการวิจัย

5.2 อภิปรายผลการวิจัย

5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้เป็นการทดลองการพยากรณ์ค่าฝุ่น PM2.5 ล่วงหน้า 24 ชั่วโมงจากภาพถ่าย โดยมีขอบเขตของงานวิจัยอยู่ที่ บริเวณทิศตะวันออกเฉียงเหนือของอาคารคณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ จังหวัดกรุงเทพมหานคร โดยการทดลองแบ่งเป็น 2 รูปแบบ คือ ใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว และใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) โดยข้อมูลสำหรับใช้ในการฝึกฝนแบบจำลองประกอบด้วย ข้อมูลภาพถ่ายสภาพอากาศ ทุก ๆ ชั่วโมง ตั้งแต่เวลา 07:00 น. ถึง 18:00 น. เป็นข้อมูลเรียนรู้ และข้อมูลค่าความเข้มข้น PM2.5 จากสถานีวัดสภาพอากาศ ณ ช่วงเวลาล่วงหน้า 24 ชั่วโมงเป็นข้อมูลค่าตอบ ซึ่งผลลัพธ์ของแบบจำลองเป็นการพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้า 24 ชั่วโมง และผลการทดลองที่ได้นั้น แบบจำลองที่ทำงานร่วมกัน ให้ผลการทดลองที่ดีกว่าแบบจำลองที่ทำงานแบบเดียว เนื่องจากภาพถ่ายสภาพอากาศมีปัจจัยอื่น ๆ เข้ามาเกี่ยวข้องในภาพ เช่น เมฆ ฝน ตึก หรือ แสงอาทิตย์ โดยแบบจำลองที่ทำงานร่วมกันมีการใช้การเรียนรู้ลำดับของข้อมูลเพิ่มเข้ามา ซึ่งพบว่าให้ผลที่ดีกว่าถึง 4 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) เมื่อวัดด้วยค่า RMSE และ MAE หรือคิดเป็น 8 เปอร์เซ็นต์ เมื่อวัดด้วยค่า MAPE

5.2 อภิปรายผลการวิจัย

งานวิจัยนี้เป็นการทดลองการพยากรณ์ค่าความเข้มข้นของ PM2.5 ล่วงหน้า 24 ชั่วโมง จากภาพถ่าย โดยมีขอบเขตของงานวิจัยอยู่ที่ บริเวณทิศตะวันออกเฉียงเหนือของอาคาร วิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ จังหวัดกรุงเทพมหานคร และเนื่องจากเป็นปัญหาแบบ การวิเคราะห์เชิงถดถอย (Regression) จึงใช้การประเมินการทดลองด้วยค่า Root Mean Square Error (RMSE), Mean Absolute Error (MAE) และ Mean Absolute Percentage Error (MAPE) ซึ่งเป็นวิธีที่นิยมนำมาใช้ โดยงานวิจัยนี้ วิธีการทดลองที่ได้ผลลัพธ์ที่ดีที่สุด ได้ค่า RMSE เท่ากับ 11.39 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) และได้ค่า MAE เท่ากับ 8.25 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) ซึ่งความแตกต่างของค่า RMSE กับ MAE นั้นสะท้อนถึงความคลาดเคลื่อนของค่าจริงกับค่าพยากรณ์ ถ้าทั้งสองค่าต่างกันมาก ก็จะแสดงถึงค่าพยากรณ์ที่ต่างจากค่าจริงมาก และในส่วนของค่า MAPE ได้เท่ากับ 26.24 เปอร์เซ็นต์นั้น แสดงให้เห็นว่าโดยเฉลี่ยแล้ว ค่า PM2.5 ที่พยากรณ์คลาดเคลื่อนจากค่าจริงมากจะเป็นค่า PM2.5 ที่เป็นค่าสูงมากกว่าค่าต่ำ ซึ่งสามารถเห็นได้จากภาพประกอบ 27 ว่าช่วงค่า PM2.5 ต่ำนั้น ค่าจริงกับค่าพยากรณ์จะเกาะกลุ่มตรงกลางมากกว่าช่วงค่า PM2.5 สูง

ปัจจัยที่อาจมีผลต่อผลการทดลองของงานวิจัยนี้ คือ ในช่วงขอบเขตของงานวิจัยฉบับนี้ การเก็บข้อมูลภาพถ่ายสำหรับนำสร้างแบบจำลอง ได้คาบเกี่ยวกับฤดูฝน และฤดูหนาว รวมถึงช่วงเวลาของการบันทึกภาพตั้งแต่ช่วงเช้าถึงช่วงเย็น ทำให้ภาพถ่ายที่ได้มีความแตกต่างกันตามสภาพฤดูกาล และช่วงเวลาของภาพ ทำให้อาจมีผลกระทบต่อประสิทธิภาพของแบบจำลองโดยรวม และยังมีปัจจัยเรื่องข้อมูลสภาพอากาศที่นำมาใช้ในการสร้างแบบจำลองนี้ เป็นข้อมูลภาพถ่ายสภาพในมุมมอง และทิศทางเดียวกันทั้งหมด ซึ่งหากนำภาพถ่ายในมุมอื่น ๆ มาทำการพยากรณ์อาจได้ประสิทธิภาพที่ต่ำ

การสร้างแบบจำลองของงานวิจัยนี้ได้แบ่ง การทดลองออกเป็น 2 วิธี เพื่อทดสอบประสิทธิภาพ และทดสอบผลของปัจจัยที่อาจมีผลต่อการสร้างแบบจำลอง คือ การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) เพียงอย่างเดียว กับ การทดลองโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network) ทำงานร่วมกับโครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) โดยการทดลองทั้งสองแบบนี้ ได้ให้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ทำการเรียนรู้ค่าความเข้มข้นของ PM2.5 และปัจจัยสภาพอากาศ และแสงในแต่ละช่วงเวลาจากภาพถ่ายเอง ซึ่งการนำแบบจำลองนี้ไปใช้พยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้าสามารถใช้

ภาพถ่ายสภาพอากาศ ณ ช่วงเวลาหนึ่งเพียงอย่างเดียว เพื่อพยากรณ์ค่าความเข้มข้น PM2.5 ล่วงหน้าจากเวลานั้นไป 24 ชั่วโมง

เนื่องจากการทดลองนี้ได้ใช้เพียงภาพถ่ายสภาพอากาศ และค่า PM2.5 จากกรมควบคุมมลพิษเป็นข้อมูลในการฝึกฝน กับข้อมูลคำตอบในการสร้างแบบจำลอง แต่ในภาพถ่ายสภาพอากาศนั้นมีปัจจัยอื่น ๆ เข้ามาเกี่ยวข้องด้วย เช่น ปริมาณเมฆ และฝน เป็นต้น ซึ่งถ้าหากนำข้อมูลปัจจัยที่อื่น ๆ เกิดขึ้นในสภาพอากาศ เข้ามาช่วยในการสร้างแบบจำลอง หรือเพิ่มข้อมูลภาพถ่ายสภาพอากาศหลายมุมมากขึ้น หรือใช้ข้อมูลที่โดยอาศัยลำดับเวลาของข้อมูล (Time Series) เข้ามาช่วยในการสร้างแบบจำลองด้วย อาจทำให้แบบจำลองมีประสิทธิภาพมากขึ้น ดังตัวอย่างงานวิจัยอ้างอิงนี้ (ทวิผล, 2562) ที่ใช้ข้อมูลสภาพอากาศมาสร้างแบบจำลองกับเทคนิคการเรียนรู้เชิงลึกแบบ LSTM โดยได้ผลลัพธ์ของแบบจำลอง คือ ค่า RMSE เท่ากับ 6.04 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$) และ MAE = 4.86 ไมโครกรัมต่อลูกบาศก์เมตร ($\mu\text{g}/\text{m}^3$)

5.3 ข้อเสนอแนะ

1. ในงานวิจัยนี้เป็นการสร้างแบบจำลองเพื่อพยากรณ์ค่าความเข้มข้นของ PM2.5 ล่วงหน้า 24 ชั่วโมง โดยใช้ภาพถ่ายเพียงในช่วงเวลา ๆ หนึ่งเพียงอย่างเดียว ซึ่งในอนาคตอาจมีการเพิ่มช่วงเวลา และช่วงวันที่ในการเก็บข้อมูลเพื่อให้แบบจำลองเรียนรู้ข้อมูลในช่วงเวลาที่มากขึ้น และสามารถพยากรณ์ค่าฝุ่น PM2.5 ในช่วงเวลาที่ไกลขึ้น

2. เนื่องจากงานวิจัยนี้ใช้ภาพถ่ายเพียงในช่วงเวลา ๆ หนึ่ง ซึ่งในภาพถ่ายมีทั้งปัจจัยเกี่ยวกับฤดูกาล เช่น วันที่ฝนตก วันที่มีเมฆมาก หรือ ปัจจัยของแสงในแต่ละช่วงเวลาที่แตกต่างกัน ทำให้ในอนาคตอาจจะนำข้อมูลสภาพอากาศอื่น ๆ เช่น ปริมาณน้ำฝน ข้อมูลเกี่ยวกับฤดูกาล เข้ามาช่วยในการสร้างแบบจำลองได้

3. ในงานวิจัยนี้ได้ออกแบบโครงข่ายประสาทเทียมของ CNN ทำงานร่วมกับ LSTM แบบทั้งหมด 4 Layer ซึ่งถ้าสามารถออกแบบให้โครงข่ายประสาทเทียมให้มีความซับซ้อนมากขึ้น อาจส่งผลให้ผลการพยากรณ์ที่แม่นยำมากขึ้น

4. ในงานวิจัยนี้อาจมีการนำแบบจำลองไปประยุกต์ทำงานร่วมกับโปรแกรมประยุกต์ (Application) สำหรับถ่ายภาพอากาศเพื่อพยากรณ์ค่าความเข้มข้นของ PM2.5

บรรณานุกรม

- Abirami, S., Chitra, P., Madhumitha, R., & Kesavan, S. R. (2020). *Hybrid Spatio-temporal Deep Learning Framework for Particulate Matter (PM 2.5) Concentration Forecasting*. Paper presented at the 2020 International Conference on Innovative Trends in Information Technology (ICITIIT).
- Athiwat. (2560). Deep Learning คืออะไร. <https://medium.com/machines-school/deep-learning-คืออะไร-785e16d01773>
- Barzegar, R., Aalami, M. T., & Adamowski, J. (2020). Short-term water quality variable prediction using a hybrid CNN–LSTM deep learning model. *Stochastic Environmental Research and Risk Assessment*, 34(2), 415-433.
- Chen, R., Wang, X., Zhang, W., Zhu, X., Li, A., & Yang, C. (2019). A hybrid CNN-LSTM model for typhoon formation forecasting. *Geoinformatica*, 23(3), 375-396.
- Du, S., Li, T., Yang, Y., & Horng, S.-J. (2020). Deep Air Quality Forecasting Using Hybrid Deep Learning Framework. *IEEE Transactions on Knowledge and Data Engineering*, 1-1.
- GREENPEACE (Producer). (2560). สถานการณ์มลพิษฝุ่นละอองขนาดเล็กไม่เกิน 2.5 ไมครอน (PM2.5) ใน 14 เมืองของประเทศไทย ปี พ.ศ.2560.
- Li, G., Zhu, F., Qu, X., Cheng, B., Li, S., & Green, P. (2019). Driving Style Classification Based on Driving Operational Pictures. *IEEE Access*, 7, 90180-90189.
- Li, J., Jin, M., & Li, H. (2019). Exploring Spatial Influence of Remotely Sensed PM2.5 Concentration Using a Developed Deep Convolutional Neural Network Model. *Int J Environ Res Public Health*, 16(3).
- MOMENTUM, T. (2561). ได้เวลาไล่หน้ากากเข้าหากัน ค่าฝุ่น PM2.5 ในกทม.เกินค่ามาตรฐานอีกแล้ว. <https://themomentum.co/pm2-5-in-bangkok-dec2018/>
- Perez, P. (2017). Forecasting hourly values of PM2. 5 concentrations. *WIT Transactions on Ecology and the Environment*, 210, 653-661.
- PM2.5 คืออะไร? อันตรายและการป้องกันฝุ่นละอองขนาดเล็ก. (2563). <https://www.daikin.co.th/service-knowledge/pm-2-5/>

- Qatawneh, Z., Alshraideh, M., Almasri, N., Tahat, L., & Awidi, A. (2019). Clinical decision support system for venous thromboembolism risk classification. *Applied Computing and Informatics*, 15(1), 12-18.
- Qin, D., Yu, J., Zou, G., Yong, R., Zhao, Q., & Zhang, B. (2019). A Novel Combined Prediction Scheme Based on CNN and LSTM for Urban PM2.5 Concentration. *IEEE Access*, 7, 20050-20059.
- Team, T. (2561). สองปัญหา PM 2.5 และนโยบายแก้ปัญหาของไทยและต่างชาติด้านดีเซล. <https://techsauce.co/tech-and-biz/pm-2-5-thai-and-other-countries>
- Zhang, Q., Lam, J. C., Li, V. O., & Han, Y. (2020). Deep-AIR: A Hybrid CNN-LSTM Framework for Fine-Grained Air Pollution Forecast. *arXiv preprint arXiv:2001.11957*.
- Zhao, L., Cheng, B., & Chen, J. (2019). A Hybrid Time Series Model based on Dilated Conv1D and LSTM with Applications to PM2. 5 Forecasting. *Aust. J. Intell. Inf. Process. Syst.*, 17(2), 49-60.
- ทวีผล, ก. (2562). แบบจำลองโครงข่ายประสาทเทียมแบบลึกสำหรับการทำนายปริมาณความหนาแน่นของฝุ่นละออง PM2.5 บริเวณพื้นที่จังหวัดกรุงเทพมหานครชั้นใน. (ปริญญาโทนิพนธ์). มหาวิทยาลัยศรีนครินทรวิโรฒ.
- รายงานการวิเคราะห์เบื้องต้นมลพิษทางอากาศข้ามพรมแดน. (2562). <https://www.greenpeace.org/thailand/publication/6853/satellite-derived-pm25-mapping-report/>
- รู้จักฝุ่นพิษ PM 2.5 ที่มากับมลภาวะ และวิธีการเลือกหน้ากากป้องกัน. (2562). <http://www.mnre.go.th/om/th/news/detail/31459>

ประวัติผู้เขียน

ชื่อ-สกุล	ทรงพล เกริกกิดาการ
วัน เดือน ปี เกิด	10 มิถุนายน 2532
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	พ.ศ. 2554 วิทยาศาสตรบัณฑิต คณิตศาสตร์ประยุกต์ จาก สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ที่อยู่ปัจจุบัน	785 ซอยหมู่บ้านประเวศเพลส แขวงประเวศ เขตประเวศ ถนนอ่อนนุช จังหวัดกรุงเทพมหานคร 10250

