

การทำนายค่าฝุ่น PM2.5 ทั้งในเชิงแผนที่และเชิงเวลาด้วยเทคนิคการเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2565

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

SPATIO-TEMPORAL PM2.5 FORECASTING USING DEEP LEARNING APPROACH



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Engineering in Computer Engineering

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การทำนายค่าฝุ่น PM2.5 ทั้งในเชิงแผนที่และเชิงเวลาด้วย
	เทคนิคการเรียนรู้เชิงลึก
โดย	นายณัฐ ศรีสัมพันธ์
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.พีรพล เวทีกุล
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ดร.กริชชาติ ว่องไวลิขิต

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์  
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(รองศาสตราจารย์ ดร.พีรพล เวทีกุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม  
(ดร.กริชชาติ ว่องไวลิขิต)

..... กรรมการ  
(ดร.พรรณราย ศิริเจริญ)

..... กรรมการภายนอกมหาวิทยาลัย  
(ดร.ธนภัทร ช้างคะจิตร)

ณัฐ ศิริสัมพันธ์ : การทำนายค่าฝุ่น PM2.5 ทั้งในเชิงพื้นที่และเชิงเวลาด้วยเทคนิคการเรียนรู้เชิงลึก. ( SPATIO-TEMPORAL PM2.5 FORECASTING USING DEEP LEARNING APPROACH) อ.ที่ปรึกษาหลัก : รศ. ดร.พีรพล เวทีกุล, อ.ที่ปรึกษาร่วม : ดร.กริชชาติ ว่องไวลิขิต

PM2.5 เป็นอนุภาคขนาดเล็กที่มีส่วนทำให้เกิดปัญหามลพิษทางอากาศในประเทศไทย การหายใจนำฝุ่น PM2.5 เข้าไปสามารถทำให้เกิดปัญหาสุขภาพตามมาได้ เช่น โรคทางเดินหายใจและโรคหัวใจเสื่อมสภาพ รวมถึงเพิ่มความเสี่ยงต่อการเสียชีวิตก่อนวัยอันควร งานวิจัยนี้เสนอแบบจำลองที่ใช้การเรียนรู้เชิงลึกเพื่อทำนายค่าฝุ่น PM2.5 ในระดับประเทศซึ่งเป็นการทำนายทั้งในเชิงพื้นที่และเวลา โดยแบบจำลองที่นำเสนอมีชื่อว่า SimVP-CFLL-ML มีพื้นฐานมาจากแบบจำลองการทำนายวิดีโอที่เรียกว่า "SimVP" และเพื่อเพิ่มประสิทธิภาพในการทำนายค่าฝุ่น PM2.5 ในช่วงที่มีค่าฝุ่นสูง SimVP ได้มีการพัฒนาเพิ่มเติมสองประการ คือ 1.Cross-Feature Learning Layer (CFLL) ซึ่งใช้ 1x1 convolution layer เพื่อเรียนรู้ความสัมพันธ์ของคุณลักษณะ และ 2.Masking Layer (ML) ซึ่งใช้สำหรับคำนวณค่าเฉลี่ยเฉพาะส่วนที่สำคัญที่ต้องการทำนาย โดยในที่นี้คือส่วนที่เป็นประเทศไทย การทดลองดำเนินการโดยใช้ข้อมูลที่เก็บรวบรวมจากกรมควบคุมมลพิษของประเทศไทยและโครงการ Sensor For All (SFA) ผลการทดลองแสดงให้เห็นว่าแบบจำลองของเราเหนือกว่าแบบจำลองพื้นฐานทั้งหมด โดยเฉพาะในกรณีที่ต้องการจำแนกช่วงที่ค่าฝุ่นมีค่าสูง แบบจำลองของเราได้ผลลัพธ์ค่าคะแนน F1 สูงกว่าแบบจำลองพื้นฐานที่ดีที่สุดถึง 3.51%

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมคอมพิวเตอร์  
ปีการศึกษา 2565

ลายมือชื่อนิสิต .....  
ลายมือชื่อ อ.ที่ปรึกษาหลัก .....  
ลายมือชื่อ อ.ที่ปรึกษาร่วม .....

# # 6470174621 : MAJOR COMPUTER ENGINEERING

KEYWORD: PM2.5 Prediction, Spatio-Temporal Prediction, Machine Learning,  
Deep learning, Video Prediction

Natch Sirisumpun : SPATIO-TEMPORAL PM2.5 FORECASTING USING DEEP  
LEARNING APPROACH. Advisor: Assoc. Prof. PEERAPON VATEEKUL, Ph.D. Co-  
advisor: KRITCHART WONGWAILIKHIT, Ph.D.

PM2.5, a form of fine particulate matter, contributes to the air pollution in Thailand throughout the year. Exposure to PM2.5 can lead to immediate health issues, such as respiratory and cardiovascular diseases, as well as an increased risk of premature death. This study introduces a spatio-temporal model, which employs a deep learning approach resembling images, to predict the concentration of PM2.5 at a national level. Our model, named SimVP-CFLL-ML, is built upon a video prediction model called "SimVP." To improve its performance in predicting high PM2.5 concentration, SimVP incorporates two significant enhancements: a cross-feature learning layer (CFLL), which employs a 1x1 convolution layer to understand feature correlations, and a masking layer (ML), which calculates the loss in specific locations. We conducted experiments using data gathered from the Pollution Control Department (PCD) of Thailand and the Sensor for All (SFA). The results demonstrate that our model surpasses all comparison models. Specifically, our model achieves a 3.51% higher F1 performance than the best baseline model when classifying high PM2.5 concentration levels.

Field of Study: Computer Engineering

Student's Signature .....

Academic Year: 2022

Advisor's Signature .....

Co-advisor's Signature .....

## กิตติกรรมประกาศ

ขอบพระคุณ รศ. ดร. พีรพล เวทีกุล, ดร. กริชชาติ ว่องไวลิขิต, ศ. ดร. บุญเสริม กิจศิริกุล, ดร. พรรณราย ศิริเจริญ และดร. ธนภัทร ชังคะจิตร มากๆ ครับผม อาจารย์ทุกท่านจะอยู่ในใจของผมตลอดไปครับ

ขอบพระคุณ ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย สถานที่ที่เปรียบเสมือนบ้านในสวนที่แสนอบอุ่น และขอบพระคุณอาจารย์ทุกท่านครับ

ขอบพระคุณกรมควบคุมมลพิษของประเทศไทยและโครงการ Sensor for All ที่ให้ข้อมูลค่าฝุ่น PM2.5 ที่ใช้ในงานวิจัยนี้

ขอบคุณพี่ๆ และเพื่อนๆ ในห้องปฏิบัติการการทำเหมืองข้อมูล (Data Mining Lab) สำหรับกำลังใจและคำแนะนำดีๆ เพื่อนำมาปรับใช้ในวิทยานิพนธ์ครับผม

สุดท้ายนี้ ขอบพระคุณพ่อกับแม่ ลุง ป้า น้า อา และครอบครัวที่ให้กำลังใจ สนับสนุนให้ผมศึกษาต่อระดับปริญญาโทมาจนถึงวันนี้ สนับสนุนผมตลอดมาครับ

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

ณัฐ ศิริสัมพันธ์

## สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญรูปภาพ.....	1
สารบัญตาราง.....	3
บทที่ 1 บทนำ.....	4
1.1 ที่มาและความสำคัญของปัญหา.....	4
1.2 วัตถุประสงค์ของการวิจัย.....	7
1.3 ขอบเขตของการวิจัย.....	7
1.4 ประโยชน์ที่ได้รับ.....	7
1.5 วิธีดำเนินการวิจัย.....	7
1.6 ผลงานตีพิมพ์จากงานวิจัย.....	8
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	9
2.1 นิวรอลเน็ตเวิร์ก (Neural Network).....	9
2.2.1 นิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า (Feedforward Neural Network).....	10
2.2.2 การแพร่กระจายย้อนกลับ (Backpropagation).....	11
2.2 นิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolutional Neural Network).....	11
2.2.1 ชั้นคอนโวลูชัน (Convolutional Layer).....	12

2.2.2	ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer).....	13
2.3	นิเวรอลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network หรือ RNN) .....	13
2.3.1	นิเวรอลเน็ตเวิร์กแบบความจำระยะสั้นแบบยาว (Long-Short Term Memory Neural Network หรือ LSTM).....	14
2.3.2	นิเวรอลเน็ตเวิร์กแบบด่านวนกลับ (Gated Recurrent Unit หรือ GRU).....	15
2.4	การทำนายเฟรมถัดไป (Next Frame Prediction) .....	16
2.5	วิธีการเข้า-ถอดรหัส (Encoder-Decoder) .....	16
2.6	การประมาณค่าในช่วงของข้อมูลกริด (Grid Data Interpolation).....	17
2.7	การวัดประสิทธิภาพ (Performance Evaluation).....	18
2.7.1	การวัดประสิทธิภาพของงานด้านการถดถอย (Regression Performance Evaluation) .....	18
2.7.2	การวัดประสิทธิภาพด้านการจำแนก (Classification Performance Evaluation) ..	19
2.7.3	การวัดประสิทธิภาพของงานการวิเคราะห์เชิงพื้นที่และเวลา .....	20
บทที่ 3	งานวิจัยที่เกี่ยวข้อง .....	21
3.1	งานวิจัยเกี่ยวกับการเรียนรู้เชิงลึกสำหรับการทำนายค่าฝุ่น (Deep Learning for PM2.5 Prediction) .....	21
3.2	งานวิจัยเกี่ยวกับเทคนิคการเรียนรู้เชิงลึกใหม่ในการทำนายเฟรมถัดไป (Recent Deep Learning Techniques in Next Frame Prediction).....	23
บทที่ 4	แนวคิดและวิธีการดำเนินงาน .....	25
4.1	การเตรียมข้อมูล .....	25
4.1.1.2	ชุดข้อมูลฝุ่นประเทศไทยจาก Sensor For All .....	26
4.1.2	ชุดข้อมูลลมจาก ERA5 .....	27
4.1.3	ชุดข้อมูลการตรวจจับความร้อนบนผิวโลกจาก FIRMS .....	27
4.2	การประมวลผลก่อน (Data Preprocessing).....	27
4.3	การทำนายค่าฝุ่นเชิงแผนที่ในอนาคต (Spatiotemporal Model) .....	30



บทที่ 5 การทดลองและผลการทดลอง .....	33
5.1 การเปรียบเทียบภาพรวมของการทำนายทั้งหมดทั้งเชิงพื้นที่และเชิงเวลา .....	33
5.2 การเปรียบเทียบความสำคัญของแต่ละคุณลักษณะข้อมูลที่ใช้ในการทดลอง .....	36
5.3 การเปรียบเทียบความสามารถในการทำนายของแต่ละเวลาที่ทำนาย.....	37
5.4 การเปรียบเทียบความสามารถในการทำนายของแต่ละพื้นที่ .....	40
5.5 การเปรียบเทียบความสามารถในการทำนายเมื่อเพิ่มแต่ละโมดูลให้กับ SimVP .....	44
5.6 การทดลองเพิ่มเติม .....	44
5.6.1 การเปรียบเทียบคุณลักษณะของข้อมูลประเภทอื่น ๆ ที่มีความเกี่ยวข้องกับค่าฝุ่น PM2.5 .....	44
5.6.2 การเปรียบเทียบผลของการทำนายในช่วงต่างๆของเดือน .....	45
5.6.3 การทดลองเปรียบเทียบกับแบบจำลอง Prophet.....	46
บทที่ 6 สรุปการวิจัยและแนวทางการวิจัยในขั้นถัดไป .....	47
6.1 สรุปการวิจัย.....	47
6.2 ข้อเสนอแนะและข้อจำกัดในงานวิทยานิพนธ์นี้ .....	47
6.3 แนวทางวิจัยขั้นถัดไป .....	47
บรรณานุกรม.....	48
ประวัติผู้เขียน.....	54

## สารบัญรูปภาพ

รูปที่ 1 ค่าฝุ่น PM2.5 เฉลี่ยรายวันในประเทศไทยปี 2022 .....	5
รูปที่ 2 โครงสร้างของเพอร์เซ็ปตรอน .....	9
รูปที่ 3 โครงสร้างของนิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า.....	10
รูปที่ 4 นิวรอลเน็ตเวิร์กคอนโวลูชัน.....	11
รูปที่ 5 ตัวอย่างการทำคอนโวลูชัน โดยมีข้อมูลรับเข้าขนาด 3x3 และเมทริกตัวกรองขนาด 2x2... ..	12
รูปที่ 6 ตัวอย่าง (a) ขนาดการก้าวข้ามเท่ากับ 1 และ (b) ขนาดการก้าวข้ามเท่ากับ 2 .....	13
รูปที่ 7 แสดงการทำงานของนิวรอลเน็ตเวิร์กแบบวกกลับเมื่อคลี่ออกมาดูตามลำดับของข้อมูลนำเข้า .....	14
รูปที่ 8 แสดงความแตกต่างของ LSTM กับ ConvLSTM .....	16
รูปที่ 9 ตัวอย่างการนำวิธี encoder-decoder มาใช้ในโจทย์ machine translation .....	17
รูปที่ 10 ตัวอย่างผลลัพธ์การทำการประมาณค่าในช่วงของข้อมูลกริดด้วยวิธีใกล้สุด .....	18
รูปที่ 11 โครงสร้างแบบจำลองการทำนายค่าฝุ่นในอนาคตในเชิงแผนที่.....	23
รูปที่ 12 โครงสร้างแบบจำลอง SimVP .....	24
รูปที่ 13 ภาพรวมของขั้นตอนทั้งหมดที่วิทยานิพนธ์นี้นำเสนอ .....	25
รูปที่ 14 แสดงภาพหน้าเว็บ sensorforall.com ในการติดตามค่าฝุ่น.....	26
รูปที่ 15 แสดงภาพรูปแบบของข้อมูลเชิงพื้นที่ในแต่ละเวลาที่เป็นผลลัพธ์จากการประมวลผลก่อน .	28
รูปที่ 16 ตัวอย่างของการนำข้อมูลลมไปใส่ลงกริด .....	28
รูปที่ 17 ตัวอย่างของการนำข้อมูลการตรวจจับความร้อนบนผิวโลกไปใส่ลงกริด.....	29
รูปที่ 18 ตัวอย่างของการนำข้อมูลฝุ่นเมื่อแบ่งคลาสแล้วใส่ลงกริด.....	29
รูปที่ 19 แสดงภาพรวมของแบบจำลอง SimVP-CFLL-ML .....	32
รูปที่ 20 แสดง confusion matrix ของแบบจำลอง SimVP และ SimVP-CFLL-ML โดยมีหน่วยเป็นเปอร์เซ็นต์.....	36
รูปที่ 21 แสดงผลตัวแทนของค่า Pearson correlation coefficient ในแต่ละกริดด้วยสี .....	41

รูปที่ 22 แสดงภาพตัวอย่างของข้อมูลขาเข้าและขาออกจากแบบจำลอง SimVP-CFLL-ML โดย A คือ ข้อมูลลมและจุดความร้อนขาเข้า B คือข้อมูลฝุ่นขาเข้า C คือ ค่าจริงของฝุ่นที่ต้องการทำนาย D คือ ค่าทำนายของฝุ่นขาออก..... 43



## สารบัญตาราง

ตารางที่ 1 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวม โดยใช้ MAE และ RMSE ซึ่งตัวหนาคือวิธีการที่ดีที่สุด.....	34
ตารางที่ 2 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวม โดยใช้ Macro F1, Micro F1 และ F1 ของแต่ละกลุ่มซึ่งตัวหนาคือวิธีการที่ดีที่สุด .....	35
ตารางที่ 3 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวมตามแต่ละคุณลักษณะข้อมูล โดยใช้ MAE และ RMSE ซึ่งตัวหนาคือวิธีการที่ดีที่สุด.....	36
ตารางที่ 4 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวมตามแต่ละคุณลักษณะข้อมูล โดยใช้ Macro F1, Micro F1 และ F1 ของแต่ละกลุ่มซึ่งตัวหนาคือวิธีการที่ดีที่สุด.....	37
ตารางที่ 5 ประสิทธิภาพการทำนายค่าฝุ่นแต่ละชั่วโมงที่ทำนายด้วย MAE โดย ts คือแต่ละชั่วโมงที่ทำนาย ซึ่งตัวหนาคือวิธีการที่ดีที่สุด .....	38
ตารางที่ 6 ประสิทธิภาพการทำนายค่าฝุ่นแต่ละชั่วโมงที่ทำนายด้วย Macro F1 โดย ts คือแต่ละชั่วโมงที่ทำนาย ซึ่งตัวหนาคือวิธีการที่ดีที่สุด.....	39
ตารางที่ 7 แสดงจำนวนกริดที่มีค่า Pearson correlation coefficient อยู่ในช่วงที่กำหนด.....	42
ตารางที่ 8 ประสิทธิภาพการทำงานเมื่อเพื่อแต่ละโมดูลเข้าไปใน SimVP ซึ่งตัวหนาคือวิธีการที่ดีที่สุด .....	44
ตารางที่ 9 ประสิทธิภาพการทำงานของแบบจำลอง SimVP-CFLL-ML เมื่อเพิ่มคุณลักษณะอื่นๆ ซึ่งตัวหนาคือวิธีการที่ดีที่สุด.....	45
ตารางที่ 10 ประสิทธิภาพการทำงานเมื่อทำนายช่วงอื่นของเดือนด้วย 3-fold cross validation ซึ่งตัวหนาคือวิธีการที่ดีที่สุดของแต่ละ fold.....	46
ตารางที่ 11 เปรียบเทียบ SimVP-CFLL-ML กับแบบจำลองที่ไม่ได้เป็นการเรียนรู้เชิงลึก Prophet ตัวหนาคือวิธีการที่ดีที่สุด .....	46

## บทที่ 1


### บทนำ

#### 1.1 ที่มาและความสำคัญของปัญหา

ฝุ่น PM2.5 (Particulate matter with diameter of less than 2.5 micron) คือ ฝุ่นละอองขนาดเล็กที่มีขนาดไม่เกิน 2.5 ไมครอน ซึ่งถือเป็นหนึ่งในมลพิษทางอากาศ (Air Pollution) ที่ส่งผลกระทบต่อสุขภาพ ในช่วงต้นปี 2019 ประเทศไทยเกิดปรากฏการณ์ฝุ่นปกคลุมอย่างหนาแน่น เป็นเหตุให้ทุกภาคส่วนตั้งแต่ภาครัฐ จนถึงประชาชน ได้ตระหนักถึงปัญหานี้อย่างจริงจัง เพื่อที่จะหาสาเหตุ, วิธีรับมือ และการป้องกันแก้ไข เพราะหากไปสูดอากาศในสถานที่ที่มีฝุ่น PM2.5 หนาแน่น ในระยะสั้น ทำให้ระคายเคืองตา ตาแดง คัดจมูก น้ำมูกไหล ไอ อากาภูมิแพ้ หอบหืดกำเริบ ปอดอักเสบติดเชื้อง่ายขึ้น ผิวหนังอักเสบ มีผื่นคันที่ผิวหนัง และเนื่องจากขนาดของฝุ่นที่เล็กเพียงพองจะเล็ดลอดผ่านการกรองของขนจมูกและเข้าสู่ชั้นในสุดของปอดได้นั้น ในระยะยาว การทำงานของปอดจะแย่งลง เสี่ยงต่อโรกระบบทางเดินหายใจ โรคหัวใจและโรคหลอดเลือดสมอง เพิ่มความเสี่ยงการเกิดมะเร็งปอด ผิวหนังเหี่ยวก่อนวัย ดังนั้นการเข้าถึงข้อมูลรายงานสถานการณ์และคุณภาพอากาศประเทศไทย เพื่อดูข้อมูลของฝุ่น PM2.5 ในสถานที่ต่าง ๆ แต่ช่วงเวลาจึงมีความสำคัญในการใช้ประกอบการตัดสินใจของประชาชนในการหลีกเลี่ยงเส้นทางหรือเพื่อเตรียมพร้อมอุปกรณ์ป้องกันในกรณีที่ไม่สามารถหลีกเลี่ยงได้ อาทิเช่น หน้ากากที่สามารถกันฝุ่น PM2.5 ดังนั้นนอกจากความสำคัญของการจัดเก็บข้อมูลฝุ่น PM2.5 จากแต่ละสถานีเก็บข้อมูลเพื่อดูข้อมูลฝุ่น การทำนาย (Forecast) ค่าฝุ่น PM2.5 ที่คาดว่าจะเกิดขึ้นในอนาคตจึงมีความสำคัญไม่แพ้กัน

ในแต่ละปีระหว่างเดือนธันวาคมและเมษายน เกษตรกรในภูมิภาคเอเชียตะวันออกเฉียงใต้จะมีการเผาเศษพืชผลเพื่อเคลียร์ไรในปีต่อไป แม้ว่าวิธีนี้จะคุ้มค่าและมีประสิทธิภาพต่อเกษตรกร แต่วิธีนี้จะกลายเป็นปัญหาด้านสิ่งแวดล้อมและสุขภาพที่สำคัญ เนื่องผลที่ได้จากการเผาก่อให้เกิดกลุ่มควันและมลพิษทางอากาศ โดยกลุ่มควันเหล่านี้สามารถข้ามพรมแดนระหว่างประเทศได้ การเผาไหม้เหล่านี้จึงเป็นปัจจัยสำคัญที่สามารถทำให้ค่าฝุ่น PM2.5 ในประเทศไทยมีค่าสูง ในรูปที่ 1 แสดงค่าฝุ่น PM2.5 เฉลี่ยรายวันในประเทศไทยปี 2022 แสดงให้เห็นว่าในช่วงเดือนที่ค่าฝุ่น PM2.5 มีค่าสูงจะสอดคล้องกับช่วงเวลาที่เป็นการเผาไหม้ของเกษตรกร โดยการเผาไหม้เหล่านี้สามารถตรวจจับได้จากดาวเทียมในรูปแบบของจุดความร้อนบนพื้นผิวโลก ซึ่งข้อมูลนี้สามารถช่วยในการหาความสัมพันธ์ระหว่างค่าฝุ่น PM2.5 และจุดความร้อนบนพื้นผิวโลกได้ [1-4] นอกจากนี้ค่าฝุ่น PM2.5 ยังมีความสัมพันธ์กับลักษณะของลมที่พัดผ่าน [5-8] จากข้อมูลจุดความร้อนบนผิวโลกและข้อมูลลมสามารถช่วยในการทำนายได้ว่ากลุ่มควันมีแนวโน้มจะเดินทางไปไหนและเมื่อไหร่ ซึ่งผลลัพธ์จะทำให้ค่าฝุ่น PM2.5 ในจุดที่ถูกพัดพาจะมีความเข้มข้นของค่าฝุ่น PM2.5 สูงขึ้น นอกจากนี้ยังมีหลาย

งานวิจัยได้ยืนยันว่าคุณภาพอากาศในประเทศไทยมีความสัมพันธ์กับการเผาไหม้และลักษณะลมในเอเชียตะวันออกเฉียงใต้ [9-12]



รูปที่ 1 ค่าฝุ่น PM2.5 เฉลี่ยรายวันในประเทศไทยปี 2022

ลักษณะข้อมูลฝุ่นเป็นข้อมูลประเภทอนุกรมเวลา (time-series) ปัจจุบันจึงมีการใช้แบบจำลองเรียนรู้ของเครื่อง (machine learning) มากมายในการทำนายแนวโน้มในอนาคตของค่าฝุ่น PM2.5 สำหรับการทำนายมลพิษทางอากาศแบบจำลองเรียนรู้เครื่องจักรแบบดั้งเดิม (traditional machine learning) ที่ใช้บ่อยคือ ARIMA [13-15] และแบบจำลอง Support Vector Machine (SVM) [16-18] นอกจากนี้ยังมีแบบจำลองรูปแบบใหม่ที่อยู่พื้นฐานบนการเรียนรู้ลึก (deep learning) เช่น Recurrent Neural Networks (RNN) โดยแบบจำลองใหม่นี้สามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนและไม่เป็นเชิงเส้น (non-linearity) ของข้อมูลชุดข้อมูลอนุกรมเวลาได้และอีกทั้งให้ความแม่นยำมากขึ้นกว่าแบบเดิม [19] Tsai et al. ใช้ Long Short-Term Memory (LSTM) [20] เพื่อทำนายค่าฝุ่น PM2.5 ใน 4 ชั่วโมงถัดไปของประเทศไต้หวัน [21] นอกจากนี้ V et al. ได้มีเปรียบเทียบผลการทำงานของการกระจายตัวแบบ Gated Recurrent Units (GRU) [22] และ LSTM และผลลัพธ์แสดงให้เห็นว่า GRU มีประสิทธิภาพในการทำนายที่ดีกว่า [23] จากลักษณะการทำนายค่าฝุ่น PM2.5 สามารถแบ่งออกเป็นสองประเภทหลักๆ คือ การทำนายค่าฝุ่น PM2.5 ในเชิงเวลา (time-series) และการทำนายค่า PM2.5 ในเชิงเวลาและพื้นที่ (spatiotemporal) สำหรับการ

ทำนายค่า PM2.5 ในเชิงเวลา ในการทำนายลักษณะนี้มักใช้แบบจำลองเรียนรู้เชิงลึกพื้นฐาน เช่น RNN, LSTM และ GRU [13-27] อย่างไรก็ตามแบบจำลองเหล่านี้ยังจำกัดอยู่ในขอบเขตของการทำนายเชิงเวลาที่ตำแหน่งเดียว อาทิเช่น การทำนายค่าฝุ่นในอนาคตของสถานีวัดค่าฝุ่นหนึ่งๆ ในทางตรงกันข้าม การทำนายค่าฝุ่น PM2.5 ในเชิงพื้นที่และเวลานั้นเกี่ยวข้องกับการทำนายค่าฝุ่น PM2.5 ในอนาคตที่หลายตำแหน่งพร้อมๆกัน [28-30]

โดยผลลัพธ์ที่ได้จากการทำนายค่าฝุ่น PM2.5 แบบทั้งเชิงพื้นที่และเวลานั้นสามารถแสดงผลได้เสมือนเป็นรูปภาพที่แสดงถึงค่าของฝุ่นในแต่ละพื้นที่ ณ ช่วงเวลาหนึ่งๆ นอกจากนี้ผลลัพธ์ที่เป็นในเชิงรูปภาพนี้ทำให้มนุษย์ทั่วไปสามารถมองเห็นการกระจายตัวของค่าฝุ่น PM2.5 ได้ง่ายขึ้น ปัจจุบันมีงานวิจัยเดียวที่เกี่ยวกับวิธีการทำนายค่าฝุ่น PM2.5 โดยใช้ข้อมูลเชิงพื้นที่และเชิงเวลาที่และแสดงผลการทำนายในรูปแบบเช่นภาพ แบบจำลองนี้มีพื้นฐานบนแบบจำลอง CNN และ LSTM เพื่อประมาณค่าฝุ่น PM2.5 ภายในเมืองหนึ่งๆ [31] แบบจำลองนี้ใช้คุณลักษณะหลายอย่างรวมถึงสภาพอากาศ สภาพการจราจร และรูปแบบการเจริญเติบโตของเมือง ในขณะที่เรียนรู้ความสัมพันธ์ระหว่างคุณลักษณะด้วย ResNet และ 1x1 Convolution Layer อย่างไรก็ตามงานวิจัยนี้ได้ทำนายค่าฝุ่น PM2.5 ในระดับของเมืองเท่านั้น อีกทั้งยังไม่ได้พิจารณาจุดความร้อนบนผิวโลกที่เป็นแหล่งกำเนิดฝุ่นจากนอกเมืองด้วย ดังที่กล่าวมาจึงเป็นข้อจำกัดของงานวิจัยดังกล่าว นอกจากนี้ในการทำนายข้อมูลเชิงพื้นที่และเวลานั้น ได้มีเทคนิคการเรียนรู้เชิงลึกประเภทที่ใช้ทำนายข้อมูลแบบนี้โดยเฉพาะ โดยแบบจำลองประเภทนี้คือแบบจำลองทำนายเฟรมถัดไป (Next Frame Prediction) [32-37] ดังนั้นเทคนิคนี้จึงเป็นแรงบันดาลใจในการนำมาประยุกต์ในการทำนายค่าฝุ่นทั้งเชิงพื้นที่และเวลา โดยการแปลงข้อมูลฝุ่นในแต่ละชั่วโมงให้เสมือนเป็นหนึ่งในเฟรมของวิดีโอเพื่อใช้ในการทำนายแต่ละเฟรมถัดไป

ในงานวิจัยนี้ได้นำเสนอการทำนายค่าฝุ่น PM2.5 ทั้งในเชิงแผนที่และเชิงเวลาในระดับประเทศโดยใช้ข้อมูลฝุ่นจากกรมควบคุมมลพิษและจากโครงการ Sensor For All โดยแบบจำลองที่ใช้ได้จะมีพื้นฐานบนแบบจำลองของการทำนายเฟรมถัดไปที่มีชื่อว่า Simple yet better Video Prediction (SimVP) ซึ่งเป็นแบบจำลองที่ดีที่สุดในปัจจุบัน และเพื่อเพิ่มประสิทธิภาพของ SimVP เมื่อทำการทำนายค่าฝุ่น PM2.5 ในช่วงที่มีค่าฝุ่นสูง ได้มีการเพิ่ม Cross-Feature Learning Layer (CFLL) พร้อม Masking Layer (ML) โดยการทดลองจะเป็นการทำนายค่าฝุ่น PM2.5 รายชั่วโมงของ 24 ถัดไปด้วยข้อมูลฝุ่นใน 24 ชั่วโมงก่อนหน้า นอกจากนี้ข้อมูลจุดความร้อนบนพื้นผิวโลกและข้อมูลลมที่ได้รับจากแหล่งข้อมูลภายนอกได้นำมาใช้ร่วมในงานวิจัยครั้งนี้

## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อพัฒนาและเพิ่มประสิทธิภาพการทำนายฝุ่นในอนาคตจากแต่ละสถานีมาเป็นการทำนายในภาพรวมเชิงแผนที่ โดยประยุกต์ใช้สถาปัตยกรรมการเรียนรู้เชิงลึกสำหรับการทำนายข้อมูลประเภททั้งเชิงพื้นที่และอนุกรมเวลา (Spatiotemporal Data) ให้ประสิทธิภาพดีกว่าสถาปัตยกรรมการเรียนรู้เชิงลึกพื้นฐานที่เรียนรู้จากข้อมูลอนุกรมเวลา (Time Series Data) เพียงอย่างเดียว

## 1.3 ขอบเขตของการวิจัย

- ทำนายค่าฝุ่นในอนาคตเป็นภาพรวมเชิงแผนที่
- ใช้ข้อมูลฝุ่น, ลม และจุดความร้อนบนพื้นผิวโลกในการทำนาย
- ข้อมูลที่ใช้ในการทดลองอยู่ในช่วงระหว่าง เดือนมกราคม 2022 ถึง ธันวาคม 2022

## 1.4 ประโยชน์ที่ได้รับ

- ทำนายค่าฝุ่นในเชิงของแผนที่ได้โดยมีความแม่นยำและมีประสิทธิภาพมากกว่าวิธีการเดิมที่ใช้อนุกรมเวลาเพียงอย่างเดียว
- สามารถใช้การทำนายค่าฝุ่นในเชิงแผนที่ไปประกอบการตัดสินใจในการรับมือในพื้นที่ต่าง ๆ ได้ดียิ่งขึ้น

## 1.5 วิธีดำเนินการวิจัย

1. ศึกษาวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับหัวข้อที่จะทำ เช่น การเรียนรู้ของเครื่อง การเรียนรู้เชิงลึก อนุกรมเวลา วิธีมาตรฐานในการทำนายค่าฝุ่นในอนาคต
2. รวบรวมข้อมูลจากแต่ละแหล่งข้อมูล ได้แก่ ข้อมูลฝุ่น, ข้อมูลลม, ข้อมูลจุดความร้อนบนพื้นผิวโลก สำหรับการทดลอง
3. ศึกษาการใช้งานเครื่องมือการเรียนรู้เชิงลึก โดยในงานวิจัยเลือกใช้เครื่องมือการเรียนรู้เชิงลึกที่ชื่อว่า PyTorch โดยใช้ภาษาไพธอน (Python) ในการเขียนโค้ด
4. ศึกษาและเขียนโค้ดเพื่อจำลองการทำงานวิจัยที่เกี่ยวข้องเพื่อใช้เป็นมาตรฐานเปรียบเทียบในการประเมินประสิทธิภาพการทำงาน
5. ทดลองแนวทางวิจัยที่จะนำเสนอในเบื้องต้น รวมถึงประเมินประสิทธิภาพสิ่งที่น่าสนใจกับวิธีการมาตรฐาน



6. เขียนและตีพิมพ์เพื่อนำไปเสนอผลงานทางวิชาการ
7. จัดทำวิทยานิพนธ์

#### 1.6 ผลงานตีพิมพ์จากงานวิจัย

ส่วนหนึ่งของวิทยานิพนธ์ฉบับนี้ ได้รับการตีพิมพ์เป็นบทความทางวิชาการ ในวารสารระดับนานาชาติ IEEE Access (ISSN 2169-3536) อยู่ในฐานข้อมูล ISI Journal/SCImago Journal Rank (SJR): Q1/ Impact Factor (2022), 3.476

“N. Sirisumpun, K. Wongwailikhit, P. Painmanakul and P. Vateekul, "Spatio-Temporal PM2.5 Forecasting in Thailand Using Encoder-Decoder Networks," in IEEE Access, vol. 11, pp. 69601-69613, 2023, doi: 10.1109/ACCESS.2023.3293398.”




## บทที่ 2

### ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับวิทยานิพนธ์นี้ประกอบด้วย นิวรอลเน็ตเวิร์ก (Neural Network) นิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolutional Neural Network) นิวรอลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network) การทำนายเฟรมถัดไป (Next Frame Prediction) วิธีการเข้ารหัส-ถอดรหัส (Encoder-Decoder) การประมาณค่าในช่วงของข้อมูลกริด (Grid Data Interpolation) และการวัดประสิทธิภาพ (Performance Evaluation)

#### 2.1 นิวรอลเน็ตเวิร์ก (Neural Network)

ด้วยแรงบันดาลใจจากสมองของมนุษย์ทำให้เกิดเป็นแบบจำลองที่เรียกว่า นิวรอลเน็ตเวิร์ก ซึ่งทำให้คอมพิวเตอร์รู้จักคิดและจดจำในทำนองเดียวกับสมอง การทำงานของนิวรอลเน็ตเวิร์ก เปรียบเสมือนการทำงานของโครงข่ายประสาทในสมอง คือ การเรียนรู้จากข้อมูลที่มีอยู่แล้ว เพื่อใช้ทำนายข้อมูลในลักษณะเดียวกัน<sup>1</sup> โดยมีส่วนประกอบที่เล็กที่สุดของนิวรอลเน็ตเวิร์ก คือ เพอร์เซ็ปตรอน (Perceptron) เปรียบเสมือนหนึ่งเซลล์ของสมองมนุษย์



รูปที่ 2 โครงสร้างของเพอร์เซ็ปตรอน<sup>2</sup>

เพอร์เซ็ปตรอนประกอบด้วย 4 ส่วนหลักดังนี้ ข้อมูลรับเข้า ค่าน้ำหนัก ผลรวม และฟังก์ชันกระตุ้น (Activation Function) ดังรูปที่ 2 หลักการทำงานโดยย่อ เริ่มต้นกระบวนการจะนำข้อมูลเข้ามา จากนั้นในแต่ละข้อมูลรับเข้าจะถูกนำไปคูณกับค่าน้ำหนัก นำผลลัพธ์การคูณที่ได้มารวมกัน

<sup>1</sup> อ้างอิงจาก 38. Koomsubha, T., *Text Categorization for Thai Corpus Using Character-Level Convolutional Neural Network*, in *Department of Computer Engineering*. 2016, Chulalongkorn University.

<sup>2</sup> อ้างอิงจาก <https://deepai.org/machine-learning-glossary-and-terms/perceptron>


และบวกกับไบแอส (Bias) แล้วผ่านฟังก์ชันกระตุ้นออกมาเป็นผลลัพธ์สุดท้ายของเพอร์เซ็ปตรอน สามารถเขียนได้ดังสมการ

$$\hat{y} = f(x) = \sigma \left( \sum_{i=1}^m w_i x_i + b \right) \quad (1)$$

โดย  $m$  คือ ขนาดของข้อมูลรับเข้า  
 $x_i$  คือ ค่าข้อมูลรับเข้าลำดับที่  $i$   
 $w_i$  คือ ค่าน้ำหนักเข้าลำดับที่  $i$   
 $b$  คือ ไบแอส  
 $\sigma$  คือ ฟังก์ชันกระตุ้น

### 2.2.1 นิรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า (Feedforward Neural Network)

นิรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า ความหมายมาจากการที่ข้อมูลให้ไหลไปในทิศทางเดียว โดยข้อมูลจะไหลผ่านเพอร์เซ็ปตรอนในแต่ละชั้นของเน็ตเวิร์ก โครงสร้างจะประกอบไปด้วย 3 ชั้นหลัก ดังนี้ ชั้นรับข้อมูล (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นผลลัพธ์ (Output Layer) โดยชั้นซ่อนและชั้นผลลัพธ์ประกอบไปด้วยเพอร์เซ็ปตรอนหลายตัวและจะมีเส้นเชื่อมกับเพอร์เซ็ปตรอนตัวอื่นที่อยู่ในลำดับชั้นที่ติดกันทั้งหมด โดยข้อมูลส่งออกของเพอร์เซ็ปตรอนในชั้นก่อนหน้าเป็นข้อมูลรับเข้าของเพอร์เซ็ปตรอนในชั้นปัจจุบัน โดยแสดงได้ดังรูปที่ 3



รูปที่ 3 โครงสร้างของนิรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า<sup>3</sup>


<sup>3</sup> อ้างอิงจาก <https://deeppai.org/machine-learning-glossary-and-terms/feed-forward-neural-network>

## 2.2.2 การแพร่กระจายย้อนกลับ (Backpropagation)

การแพร่กระจายย้อนกลับเป็นกระบวนการในการเรียนรู้ของเครื่องเพื่อปรับค่าน้ำหนักของแต่ละเพอร์เซปตรอนให้ได้ผลลัพธ์สุดท้ายเข้าใกล้ค่าที่ถูกต้องให้มากที่สุด จากขั้นตอนนิรอลเน็ตเวิร์กแบบป้อนไปข้างหน้าจะได้ผลลัพธ์ที่เป็นค่าทำนายของแบบจำลอง เพื่อนำค่าดังกล่าวมาเปรียบเทียบกับค่าที่ถูกต้องจึงมีการใช้ลอสฟังก์ชัน (Loss Function) ซึ่งเป็นฟังก์ชันที่ใช้คำนวณว่าค่าทำนายมีความถูกต้องมากน้อยเพียงใดโดยค่าที่ได้ยิ่งน้อยก็ยิ่งดี จากนั้นก็นำค่าที่ได้มาคำนวณเกรเดียนต์ (Gradient) เพื่อไปปรับค่าน้ำหนักของแต่ละชั้นแบบย้อนกลับต่อไป

## 2.2 นิรอลเน็ตเวิร์กคอนโวลูชัน (Convolutional Neural Network)


นิรอลเน็ตเวิร์กคอนโวลูชันเป็นนิรอลเน็ตเวิร์กเชิงลึกรูปแบบหนึ่งที่ใช้ในงานที่เกี่ยวข้องกับด้านรูปภาพ มีจุดเริ่มต้นมาจากงานวิจัยทางการจำแนกรูปภาพ โดยสิ่งที่แตกต่างจากนิรอลเน็ตเวิร์กทั่วไปคือจะเพิ่มชั้นคอนโวลูชัน (Convolutional Layer) ขึ้นมาสำหรับสกัดข้อมูลจากรูปภาพ เริ่มต้นจะมีการแปลงรูปภาพให้อยู่ในรูปของเมทริกซ์จากนั้นก็ส่งเข้าแบบจำลองต่อไป โดยแบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันจะแบ่งออกเป็น 2 ส่วนหลักคือส่วนของคอนโวลูชันที่ไว้สกัดข้อมูลและส่วนของชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer) โครงสร้างของนิรอลเน็ตเวิร์กคอนโวลูชันทางการจำแนกรูปภาพดังรูปที่ 4



รูปที่ 4 นิรอลเน็ตเวิร์กคอนโวลูชัน<sup>4</sup>

<sup>4</sup> อ้างอิงจาก <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>

## 2.2.1 ชั้นคอนโวลูชัน (Convolutional Layer)



รูปที่ 5 ตัวอย่างการทำคอนโวลูชัน โดยมีข้อมูลรับเข้าขนาด  $3 \times 3$  และเมทริกตัวกรองขนาด  $2 \times 2$ <sup>5</sup>

เป็นชั้นที่ทำหน้าที่หาคุณลักษณะจากกลุ่มของข้อมูลรับเข้าที่อยู่ใกล้ๆกัน โดยใช้วิธีการดอทเมทริกซ์กับตัวกรอง (Kernel) น้ำหนักของตัวกรองนั้นจะใช้ร่วมกันในทุกๆ การทำคอนโวลูชันของข้อมูลรับเข้า (รูปที่ 5) กำหนดให้ข้อมูลรับเข้าแทนด้วยเมทริกซ์  $a^{l-1}$  ขนาด  $N \times N$  และมีตัวกรองที่มีน้ำหนัก  $w$  ขนาด  $m \times m$  ผลลัพธ์  $a^l$  ของการทำคอนโวลูชันคำนวณได้ดังสมการต่อไปนี้

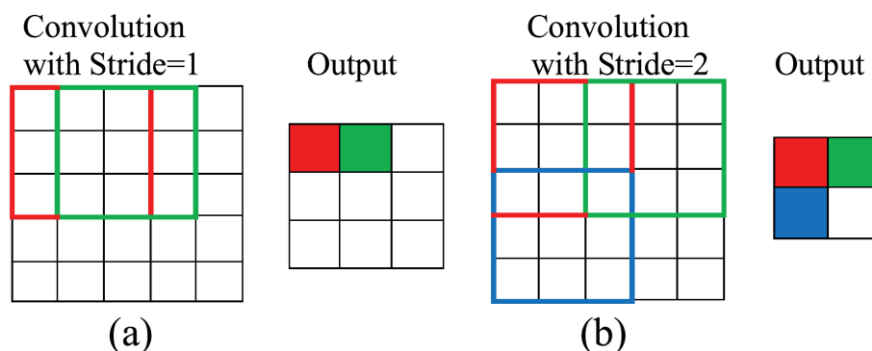
$$z_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} w_{a,b}^l a_{i+a,j+b}^{l-1} + b^l \quad (2)$$

$$a_{ij}^l = g(z_{ij}^l) \quad (3)$$

ในชั้นคอนโวลูชัน มีองค์ประกอบที่เกี่ยวข้องดังต่อไปนี้

- ขนาดของตัวกรอง (Kernel Size)  
คือ ความกว้างและความสูงของตัวกรองที่จะนำมาใช้ในการทำคอนโวลูชัน
- ขนาดของการก้าวข้าม (Stride Size)  
ขนาดของการก้าวข้าม คือจำนวนช่องของข้อมูลรับเข้าที่จะเลื่อนไปเมื่อทำการหาผลลัพธ์ของคอนโวลูชันในแต่ละครั้ง โดยทั่วไปขนาดของการก้าวข้ามจะมีค่าเท่ากับหนึ่งหรือสอง ดังรูปที่ 6

<sup>5</sup> อ้างอิงจาก [http://d2l.ai/chapter\\_convolutional-neural-networks/conv-layer.html](http://d2l.ai/chapter_convolutional-neural-networks/conv-layer.html)



รูปที่ 6 ตัวอย่าง (a) ขนาดการก้าวข้ามเท่ากับ 1 และ (b) ขนาดการก้าวข้ามเท่ากับ 2<sup>6</sup>

- จำนวนตัวกรอง (Number of Kernels)  
ในการดำเนินการสำหรับแต่ละชั้นคอนโวลูชันมีตัวกรองได้มากกว่าหนึ่งตัว และน้ำหนักของตัวกรองแต่ละตัวอาจต่างกันได้ การกำหนดจำนวนตัวกรองในชั้นคอนโวลูชันใดๆ จะเป็นการกำหนดจำนวนช่องสัญญาณ (Channel) ของข้อมูลรับเข้าในชั้นถัดไป
- จำนวนช่องสัญญาณ (Channel)  
จำนวนช่องสัญญาณ หรือเรียกได้อีกอย่างหนึ่งว่า ความลึกของข้อมูลรับเข้า มีค่าได้มากกว่าหนึ่งค่า ยกตัวอย่างเช่น ในงานวิจัยทางด้านการใช้รูปภาพมีการใช้ช่องสัญญาณทั้งหมด 3 ช่อง สัญญาณแทนค่าของแม่สี หรือเกิดจากจำนวนของตัวกรองในชั้นคอนโวลูชันก่อนหน้า


## 2.2.2 ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer)

คือชั้นที่ถัดมา เมื่อทำคอนโวลูชันเพื่อสกัดข้อมูลเสร็จเรียบร้อยแล้วจึงทำการ Flatten ข้อมูลให้เรียงกันอยู่ในรูปที่สามารถนำเข้านิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้าได้และทำการนำข้อมูลต่อไปได้ผลลัพธ์สุดท้ายคือการจำแนกรูปภาพว่าอยู่ในประเภทใด

## 2.3 นิวรอลเน็ตเวิร์กแบบวนกลับ (Recurrent Neural Network หรือ RNN)

นิวรอลเน็ตเวิร์กแบบวนกลับเป็นนิวรอลเน็ตเวิร์กเชิงลึกรูปแบบหนึ่งที่ใช้ในงานที่เกี่ยวข้องกับด้านอนุกรมเวลาหรืองานที่ข้อมูลนำเข้าเป็นข้อมูลที่ลำดับ (Sequential) มีความสำคัญ ซึ่งหลักการการทำงานจะคล้ายกับนิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้าที่สามารถนำข้อมูลส่งออกมาเป็นข้อมูลรับเข้าสำหรับข้อมูลรับเข้าที่อยู่ในลำดับถัดไปได้ โดยสามารถแสดงกระบวนการได้ดังรูปที่ 7

<sup>6</sup> อ้างอิงจาก <https://www.computer.org/csdl/journal/si/2020/04/08957307/1lQS7GE9MY>



รูปที่ 7 แสดงการทำงานของนิวรอลเน็ตเวิร์กแบบวนกลับเมื่อคลี่ออกมาดูตามลำดับของข้อมูลนำเข้า <sup>7</sup>

### 2.3.1 นิวรอลเน็ตเวิร์กแบบความจำระยะสั้นแบบยาว (Long-Short Term Memory Neural Network หรือ LSTM)

นิวรอลเน็ตเวิร์กแบบความจำระยะสั้นแบบยาวหรือ LSTM เป็นนิวรอลเน็ตเวิร์กที่ออกแบบมาแก้ปัญหานิวรอลเน็ตเวิร์กแบบวนกลับที่ไม่สามารถจำข้อมูลที่มีขนาดยาวมากๆ ได้ อันเนื่องมาจากไม่สามารถปรับค่าน้ำหนัก ณ ลำดับที่อยู่ไกลมากๆ โดยปัญหานี้มีชื่อว่า Vanishing Gradient แนวคิดของ LSTM จึงใช้การเลือกจำข้อมูลเข้ามาช่วย เพื่อให้เน็ตเวิร์กทำการเลือกจำแต่ข้อมูลที่สำคัญเท่านั้น โดยสามารถเขียนเป็นสมการได้ดังนี้

$$i_t = \sigma(x_t U_i + h_{t-1} W_i + b_i) \quad (3)$$

$$f_t = \sigma(x_t U_f + h_{t-1} W_f + b_f) \quad (4)$$

$$o_t = \sigma(x_t U_o + h_{t-1} W_o + b_o) \quad (5)$$

<sup>7</sup> อ้างอิงจาก 39. Lioma, C., et al., *Deep Learning Relevance: Creating Relevant Information (as Opposed to Retrieving it)*. 2016.

$$C_t = f_t \circ C_{t-1} + i_t \circ \tanh(x_t U_C + h_{t-1} W_C + b_C) \quad (6)$$

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

- โดย
- $i$  คือ ด้านสำหรับจำ (Input Gate)
  - $f$  คือ ด้านสำหรับการลืม (Forget Gate)
  - $o$  คือ ด้านสำหรับผลลัพธ์ (Output Gate)
  - $b$  คือ ไบแอส (Bias)
  - $C$  คือ หน่วยความจำ (Cell)
  - $h$  คือ สถานะซ่อน (Hidden State)
  - $\circ$  คือ ผลคูณแบบอาดามาร์ (Hadamard Product)

### 2.3.2 นิรอรลเน็ตเวิร์กแบบด้านวกกลับ (Gated Recurrent Unit หรือ GRU)

นิรอรลเน็ตเวิร์กแบบด้านวกกลับหรือ GRU คือนิรอรลเน็ตเวิร์กที่พยายามลดความซับซ้อนของ LSTM โดยได้ทำการลดจำนวนด้านล่างแล้วสร้างด้านใหม่คือด้านอัปเดต (Update Gate) และรวมหน่วยความจำและสถานะซ่อนของ LSTM เข้าด้วยกัน ได้ออกมาเป็นดังสมการ

$$z_t = \sigma(x_t U_z + h_{t-1} W_z + b_z) \quad (8)$$

$$f_t = \sigma(x_t U_f + h_{t-1} W_f + b_f) \quad (9)$$


$$h_t = z_t \circ h_{t-1} + (1 - z_t) \circ \tanh(x_t U_h + f_t \circ h_{t-1} W_h + b_h) \quad (10)$$

- โดย
- $z$  คือ ด้านสำหรับอัปเดต (Update Gate)
  - $f$  คือ ด้านสำหรับการลืม (Forget Gate)
  - $b$  คือ ไบแอส (Bias)
  - $h$  คือ สถานะซ่อน (Hidden State) และหน่วยความจำ (Cell)
  - $\circ$  คือ ผลคูณแบบอาดามาร์ (Hadamard Product)



## 2.4 การทำนายเฟรมถัดไป (Next Frame Prediction)

การทำนายเฟรมถัดไปคือการทำนายรูปในอนาคตกที่กำลังเกิดขึ้น หรืออีกนัยหนึ่งสามารถเรียกได้ว่าเป็นการทำนายการเคลื่อนไหว ซึ่งหมายถึงการพยากรณ์ข้อมูลเชิงแนวทางการเคลื่อนไหว เช่นการเคลื่อนไหวของมนุษย์และเส้นทางการเคลื่อนไหวของวัตถุจากภาพ โดยพิจารณาจากเฟรมวิดีโอสองภาพหรือหลายภาพ (Video Frames) ก่อนหน้านี้ ลักษณะข้อมูลแบบวิดีโอประกอบไปด้วย 2 ส่วนคือข้อมูลในเชิงพื้นที่ และข้อมูลในเชิงเวลา ซึ่งจะเรียกข้อมูลประเภทนี้ว่า Spatiotemporal Data ดังนั้นจึงเกี่ยวข้องกับการเรียนรู้เชิงลึกทั้งแบบนิรอรลเน็ตเวิร์กคอนโวลูชัน และนิรอรลเน็ตเวิร์กแบบวกกลับ ในปี 2015 ที่ทีมงาน SHI Xingjian, Zhouong Chen, Hao Wang, Dit-Yan Yeung, Wai-Kin Wong, and Wang-chun Woo. ได้เสนอ ConvLSTM [40] โดยแนวคิดคือการประยุกต์ใช้ Convolution เข้าไปใน LSTM ดังรูปที่ 8 เพื่อเรียนรู้ข้อมูลเชิงพื้นที่และข้อมูลเชิงเวลาไปพร้อมกันๆ ซึ่งต่างจากวิธีที่มีงานวิจัยก่อนหน้านี้ที่ใช้นิรอรลเน็ตเวิร์กแต่ละประเภทเรียนรู้ข้อมูลเชิงพื้นที่และข้อมูลเชิงเวลาแยกกัน



รูปที่ 8 แสดงความแตกต่างของ LSTM กับ ConvLSTM <sup>8</sup>

CHULALONGKORN UNIVERSITY

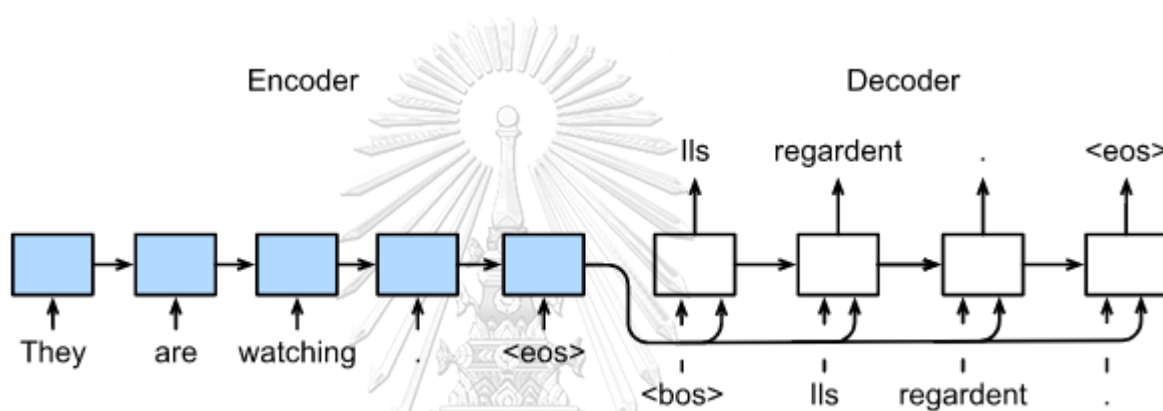
## 2.5 วิธีการเข้า-ถอดรหัส (Encoder-Decoder)

วิธีการเข้า-ถอดรหัส เป็นวิธีการที่ได้แนวคิดมาจากการแปลงข้อมูลให้เป็นรหัสลับ โดยจะแบ่งออกเป็น 2 ขั้นตอนคือการเข้ารหัสเพื่อให้ข้อมูลถูกแปลงไปอยู่ในรูปที่ไม่อาจเข้าใจได้ ถึงจะโดนขโมยไปแต่ผู้ที่ขโมยก็ไม่สามารถนำไปทำอะไรต่อได้ แต่ข้อมูลที่ถูกลบไปก็ยังคงเก็บข้อมูลตั้งต้นไว้อย่างครบถ้วน จากนั้นขั้นตอนต่อไปคือการถอดรหัสก็คือการแปลงข้อมูลกลับมาอยู่ในรูปที่สามารถเข้าใจและนำไปใช้ต่อได้ ดังที่กล่าวมาการเรียนรู้เชิงลึกได้นำแนวคิดนี้มาใช้กับโจทย์ที่ข้อมูลนำเข้าเป็นข้อมูล

<sup>8</sup> อ้างอิงจาก 41. Yang, Z., et al., *Dynamic Gesture Recognition Using Surface EMG Signals Based on Multi-Stream Residual Network*. *Frontiers in Bioengineering and Biotechnology*, 2021. 9: p. 779353.

มีลำดับและต้องการทำนายข้อมูลที่เป็นลำดับเช่นกัน ซึ่งโจทย์ประเภทนี้มีชื่อว่า Sequence-to-Sequence

นำวิธีการเข้า-ถอดรหัสมาประยุกต์ใช้กับการเรียนรู้เชิงลึกทำได้โดย ในส่วนของการเข้ารหัส จะใช้นิวรอลเน็ตเวิร์กแบบวนกลับรับข้อมูลเข้าแล้วนำผลลัพธ์สุดท้ายที่ได้ทำการสรุปมาแล้ว ซึ่งผลลัพธ์ที่ได้มีชื่อว่า Context Vector จากนั้นก็นำไปเข้าในส่วนของการถอดรหัสซึ่งก็เป็นนิวรอลเน็ตเวิร์กแบบวนกลับ โดยสามารถกำหนดจำนวนลำดับของผลลัพธ์ได้ด้วยการวนซ้ำการนำ Context Vector เข้าในส่วนของการถอดรหัสจนกว่าจะได้จำนวนลำดับผลลัพธ์ที่ต้องการ ตัวอย่างดังรูปที่ 9




รูปที่ 9 ตัวอย่างการนำวิธี encoder-decoder มาใช้ในโจทย์ machine translation <sup>9</sup>

## 2.6 การประมาณค่าในช่วงของข้อมูลกริด (Grid Data Interpolation)

เนื่องจากข้อมูลในเชิงพื้นที่อาจจะมีการสูญหายของข้อมูลในบางตำแหน่งได้ ดังนั้นจึงต้องทำการประมาณค่าเพื่อให้ข้อมูลสมบูรณ์ที่สุด ซึ่งข้อมูลในเชิงพื้นที่จะอยู่ในรูปของกริดหรือก็คือเมทริกซ์ 2 มิติ โดยการประมาณค่าที่ใช้ในงานวิจัยชิ้นนี้คือการใช้ค่าของตำแหน่งที่ใกล้ที่สุดโดยตำแหน่งนั้นเป็นตำแหน่งที่ข้อมูลไม่สูญหาย แล้วนำค่าใกล้สุดตามจำนวนที่กำหนดมาหาค่าเฉลี่ยแล้วเติมไปยังตำแหน่งที่สูญหาย โดยมี ดังรูปที่ 10

<sup>9</sup> อ้างอิงจาก [https://d2l.ai/chapter\\_recurrent-modern/seq2seq.html](https://d2l.ai/chapter_recurrent-modern/seq2seq.html)



รูปที่ 10 ตัวอย่างผลลัพธ์การทำการประมาณค่าในช่วงของข้อมูลกริดด้วยวิธีใกล้เคียง<sup>10</sup>

## 2.7 การวัดประสิทธิภาพ (Performance Evaluation)

การวัดประสิทธิภาพในงานวิจัยนี้จะแบ่งออกเป็น 3 ประเภทตามประเภทของงาน ได้แก่ การถดถอย (Regression) การจำแนกประเภท (Classification) และการวิเคราะห์เชิงพื้นที่และเวลา (Spatiotemporal Analysis)

### 2.7.1 การวัดประสิทธิภาพของงานด้านการถดถอย (Regression Performance Evaluation)

ผลลัพธ์จากแบบจำลองที่เป็นประเภทการถดถอยจะมีลักษณะเป็นเลขจำนวนจริง ดังนั้นเพื่อวัดประสิทธิภาพว่าแบบจำลองสามารถทำนายค่าที่ถูกต้องได้ใกล้เคียงกับค่าที่เป็นจริงเท่าไร จึงต้องมีตัววัดที่สามารถบอกได้ถึงระยะห่างที่ทำนายผิดพลาดไป โดยถ้าระยะห่างยิ่งน้อยก็จะยิ่งดี ตัววัดที่ใช้ในงานวิจัยมีดังนี้

- รากกำลังสองเฉลี่ยผิดพลาด (Root Mean Square Error)

รากกำลังสองเฉลี่ยผิดพลาด คือ การวัดค่าความแตกต่างระหว่างค่าจริงและค่าที่ประมาณจากแบบจำลองยกกำลังสอง โดยสามารถเขียนเป็นสมการได้ดังนี้

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (11)$$

โดย  $n$  คือ จำนวนข้อมูลที่ทำนาย

$x_i$  คือ ค่าจริงลำดับที่  $i$

$\hat{x}_i$  คือ ค่าทำนายลำดับที่  $i$

<sup>10</sup> อ้างอิงจาก <https://docs.scipy.org/doc/scipy/reference/generated/scipy.interpolate.griddata.html>

- ค่าผิดพลาดเฉลี่ยสมบูรณ์ (Mean Absolute Error)

ค่าผิดพลาดเฉลี่ยสมบูรณ์ คือ ค่าเฉลี่ยของความแตกต่างสมบูรณ์ระหว่างค่าพยากรณ์และค่าจริง โดยสามารถเขียนเป็นสมการได้ดังนี้

$$MAE = \sqrt{\frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i|} \quad (12)$$

โดย  $n$  คือ จำนวนข้อมูลที่ทำนาย

$x_i$  คือ ค่าจริงลำดับที่  $i$

$\hat{x}_i$  คือ ค่าทำนายลำดับที่  $i$

### 2.7.2 การวัดประสิทธิภาพด้านการจำแนก (Classification Performance Evaluation)

ผลลัพธ์จากแบบจำลองที่เป็นประเภทการจำแนกจะมีลักษณะเป็นค่าประเภท ดังนั้นเพื่อวัดประสิทธิภาพว่าแบบจำลองสามารถทำนายค่าที่ถูกต้องตรงกับค่าจริง จึงต้องมีตัววัดที่สามารถบอกได้ถึงจำนวนการทำนายที่สามารถทำนายได้อย่างถูกต้อง โดยยิ่งมากยิ่งดี ตัววัดที่ใช้ในงานวิจัย ได้แก่ Precision Recall และ F1 โดยสามารถเขียนสมการได้ ดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (13)$$

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

$$F_1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (15)$$

โดย TP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและผลลัพธ์คือคลาสนั้น (True Positive)

FP คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นแต่ผลลัพธ์คือคลาสนอื่น (False Positive)

TN คือ จำนวนข้อมูลที่ทำนายได้คลาสนอื่นและผลลัพธ์คือคลาสนอื่น (True Negative)

FN คือ จำนวนข้อมูลที่ทำนายได้คลาสนอื่นแต่ผลลัพธ์คือคลาสนั้น (False Negative)

### 2.7.3 การวัดประสิทธิภาพของงานการวิเคราะห์เชิงพื้นที่และเวลา

จากผลลัพธ์ของแบบจำลองประเภทการทำนายเฟรมถัดไปจะได้ผลลัพธ์ออกมาเป็นข้อมูลประเภท Spatiotemporal Data จึงต้องมีตัววัดที่สามารถดูทั้งเชิงพื้นที่และเชิงเวลาควบคู่กัน ซึ่งในงานวิจัยนี้ได้ใช้ตัววัดชื่อว่า Temporal Coefficient Correlation หรือก็คือการทำ Pearson Correlation ในแต่ละกริดของข้อมูลแล้วรวมออกมาเป็นรูปเชิงแผนที่ เพื่อดูค่าความถูกต้องในเชิงแผนที่เทียบกับเวลาในแต่ละกริด โดยสามารถเขียนสมการ Pearson Correlation ได้ดังนี้

$$R = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (16)$$

โดย  $n$  คือ จำนวนข้อมูลที่ทำนาย  
 $y_i$  คือ ค่าจริงลำดับที่  $i$   
 $\bar{y}$  คือ ค่าเฉลี่ยของค่าจริง  
 $x_i$  คือ ค่าทำนายลำดับที่  $i$   
 $\bar{x}$  คือ ค่าทำนายของค่าจริง

### บทที่ 3 งานวิจัยที่เกี่ยวข้อง

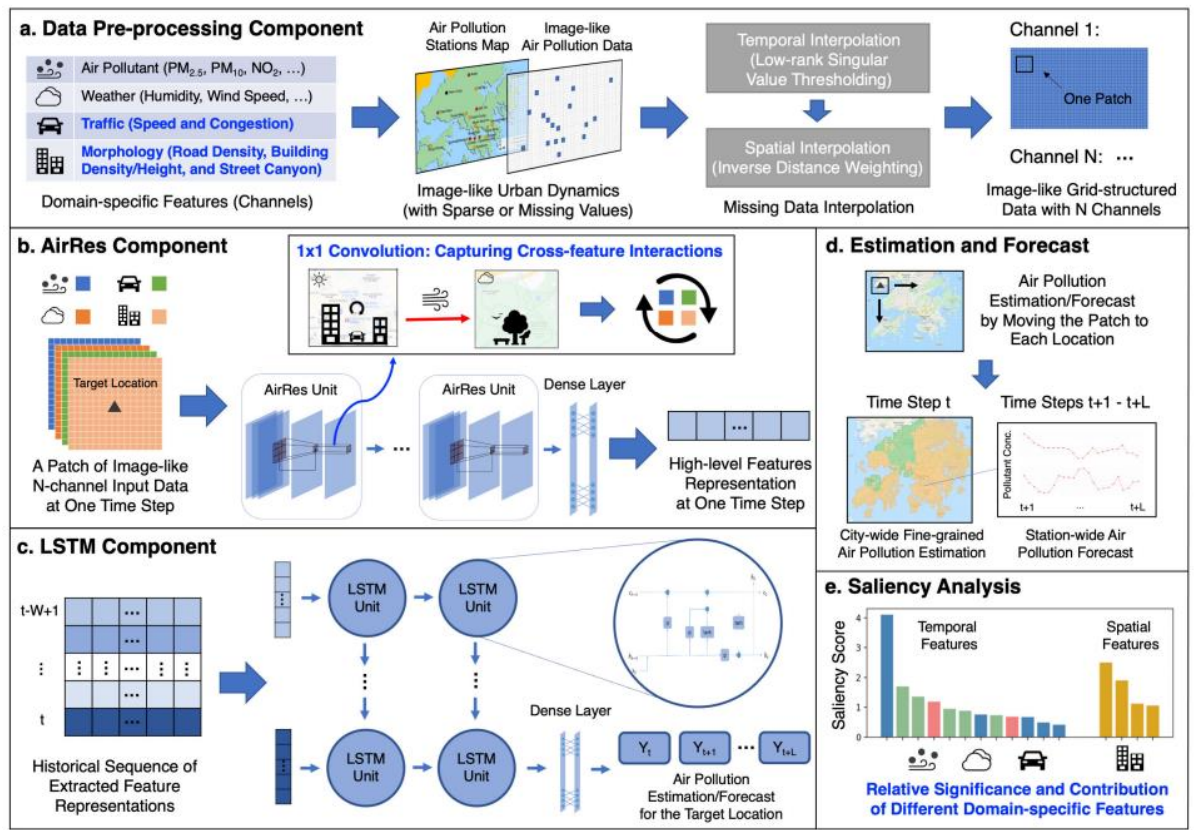
งานวิจัยที่เกี่ยวข้องในวิทยานิพนธ์นี้แบ่งออกเป็น 2 กลุ่ม ได้แก่ งานวิจัยเกี่ยวกับการเรียนรู้เชิงลึกสำหรับการทำนายค่าฝุ่น (Deep Learning for PM2.5 Prediction) และงานวิจัยเกี่ยวกับเทคนิคการเรียนรู้เชิงลึกใหม่ในการทำนายเฟรมถัดไป (Recent Deep Learning Techniques in Next Frame Prediction)

#### 3.1 งานวิจัยเกี่ยวกับการเรียนรู้เชิงลึกสำหรับการทำนายค่าฝุ่น (Deep Learning for PM2.5 Prediction)

ปัจจุบันการทำนายค่าฝุ่นในอนาคตนิยมใช้การเรียนรู้เชิงลึก เนื่องจากความสามารถเรียนรู้ความสัมพันธ์แบบไม่เชิงเส้นได้ ทำให้สามารถทำนายได้อย่างแม่นยำ เทคนิคที่นักวิจัยใช้บ่อยที่สุดสำหรับการทำนายคุณภาพอากาศคือเทคนิคการเรียนรู้ลึกทั่วไปสำหรับการทำนายชุดข้อมูลตามเวลา เช่น RNN, LSTM, และ GRU Tsai et al. กำหนดวิธีการทำนายค่าฝุ่น PM2.5 ในประเทศไต้หวันโดยใช้ LSTM ที่ผนวกคุณลักษณะที่ใช้ร่วมกับ PM2.5 [21] V et al. เปรียบเทียบ RNN, LSTM, และ GRU สำหรับการพยากรณ์ PM10 โดยใช้ข้อมูล AirNet [23] Liu et al. สร้างตัวทำนายคุณภาพอากาศ AAQP ซึ่งเป็นแบบจำลองเอนโคเดอร์-ดีโคเดอร์ที่ใช้ Fully Connected Layer เป็น Encoder และ RNN เป็น Decoder โดยใช้ LSTM หรือ GRU [25] Nguyen et al. ใช้อัลกอริทึมพันธุกรรมสำหรับการเลือกคุณลักษณะและแบบจำลองเอนโคเดอร์-ดีโคเดอร์ที่มีหน่วยความจำระยะสั้นยาว (LSTM) สำหรับการทำนายค่าฝุ่น PM2.5 [27] นอกจากนี้ยังมีการศึกษาที่ใช้ข้อมูล PM2.5 จากสถานีที่อยู่ใกล้เคียงเพื่อเพิ่มความแม่นยำของการทำนาย เช่น Cheng et al. แนะนำเครือข่ายการอ่านคุณภาพอากาศที่สนใจ (ADAIN) ซึ่งรวมเครือข่ายประสาทกำลังส่งตรง, ระบบประสาทเชื่อมต่อที่เป็นเวลาและชั้นการรวมที่ใช้เทคนิคการรวมที่อยู่ในพื้นที่การให้ความสนใจซึ่งเรียนรู้น้ำหนักของคุณลักษณะจากสถานีตรวจวัดต่างๆ [24] Liu et al. นำเสนอแผนที่แบบเรขาคณิตศาสตร์ (GeoSOM) ร่วมกับ GRU ซึ่งจัดกลุ่มสถานีและทำนายค่าฝุ่น PM2.5 ที่สถานีเป้าหมายโดยใช้ข้อมูลจากสถานีทั้งหมดภายในกลุ่ม [26] ซึ่งงานวิจัยที่กล่าวมาทั้งหมดนั้นยังเป็นการจำกัดการทำนายค่าฝุ่นเป็นรายสถานีเท่านั้น

ปัจจุบันได้มีงานวิจัยที่เกี่ยวข้องกับการทำนายฝุ่นในเชิงแผนที่ ซึ่งเป็นอีกแนวทางหนึ่งในการทำนายค่าฝุ่น PM2.5 ในหลายๆสถานที่พร้อมๆกันหรืออาจมองได้ว่าเป็นการทำนายค่าฝุ่นในภาพรวมเชิงพื้นที่ วัตถุประสงค์หลักของกลยุทธ์นี้คือเพื่อเพิ่มประสิทธิภาพโดยการใช้แบบจำลองเพียงตัวในการทำนายข้อมูลจากสถานี PM2.5 หลายแห่งพร้อมกันและเรียนรู้ความสัมพันธ์ระดับภาพรวมในพื้นที่ที่

น่าสนใจ นอกจากนี้สำหรับการทำนายค่าฝุ่น PM2.5 ในเชิงพื้นที่และเวลา ในการทำนายเชิงพื้นที่และเวลาสามารถวิธีการนี้เป็นสองประเภทย่อยคือการทำนายค่าฝุ่น PM2.5 ที่หลายสถานีพร้อมกันและการทำนายข้อมูลแบบเซ็นภาพ ตัวอย่างการทำนายค่าฝุ่นหลายสถานีพร้อมกัน มีดังนี้ Xu et al. นำเสนอแบบจำลองด้วย LSTM autoencoder เพื่อทำนายค่าฝุ่น PM2.5 ในหลายสถานที่ในเมืองพร้อมๆกัน [30] Shi et al. นำเสนอ SA-LSTM ที่ใช้ LSTM และ Spatial Attention เพื่อใช้ข้อมูลเชิงพื้นที่และเวลาในการทำนาย [29] Wen et al. นำเสนอ ST-E-LSTME ที่ใช้สถานีที่ใกล้ที่สุดร่วมกับ CNN และ LSTM เพื่อทำนายค่าฝุ่น PM2.5 ที่สถานีหลายแห่ง ต่อมางานวิจัยที่ต้องการทำนายค่าฝุ่นในเชิงรูปภาพได้มีงานวิจัยที่ใกล้เคียงที่สุดดังต่อไปนี้ [28] Q. Zhang et al. ได้เสนอแบบจำลอง Deep-AIR ซึ่งมีพื้นฐานมาจากการใช้ CNN-LSTM ในการเรียนรู้ข้อมูลเชิงพื้นที่และเวลาของค่าฝุ่น [31] โครงสร้างของวิธีการที่นำเสนอได้แบ่งออกเป็น 3 ส่วนหลัก ได้แก่ ส่วนประมวลผลก่อน ส่วนการเรียนรู้เชิงพื้นที่ และส่วนการเรียนรู้เชิงเวลา โดยใช้ข้อมูลในการสอนแบบจำลองคือ ค่าฝุ่น สภาพอากาศ สภาพการจราจร และสภาพแวดล้อมของเมือง เมื่อได้ข้อมูลนำเข้าแล้วจึงส่งไปที่ส่วนประมวลผลก่อน โดยในส่วนนี้จะทำการแปลงข้อมูลจากแต่ละประเภทข้อมูลออกมาในลักษณะของรูปภาพ โดยแต่ละกริดในรูปภาพจะสื่อถึงค่าของข้อมูลที่อยู่ในกริดนั้นๆ ดังนั้นผลลัพธ์ที่ได้จากส่วนประมวลผลก่อนจะอยู่ในรูปของข้อมูลเชิงพื้นที่และเวลา ต่อมาในส่วนของการเรียนรู้เชิงพื้นที่ จะใช้ ResNet (convolution layer with skip connection) ในการสกัดข้อมูลในเชิงพื้นที่ หลังจากนั้นก็จะใช้ 1x1 คอนโวลูชันในเรียนรู้ความสัมพันธ์ของข้อมูลข้ามประเภทข้อมูล จากนั้นก็จะถึงส่วนสุดท้ายซึ่งก็คือส่วนการเรียนรู้เชิงเวลา ในส่วนนี้จะใช้ LSTM ในการทำนายค่าฝุ่นของแต่ละกริดต่อไป ดังรูปที่ 11 จากการทดลองพบว่าวิธีที่งานวิจัยนี้เสนอสามารถมีประสิทธิภาพดีกว่าการใช้แบบจำลองแบบมาตรฐาน ได้แก่ Arima, LSTM และ ConvLSTM แต่ข้อจำกัดของงานวิจัยเป็นการทำนายเชิงรูปภาพภายในเมืองเท่านั้น อีกทั้งข้อมูลจากภายนอกเมือง อาทิเช่นค่าจุดความร้อนที่อาจเป็นแหล่งกำเนิดฝุ่นภายนอกเมืองยังไม่ได้ถูกนำมาพิจารณา



รูปที่ 11 โครงสร้างแบบจำลองการทำนายค่าฝุ่นในอากาศในเชิงแผนที่<sup>11</sup>

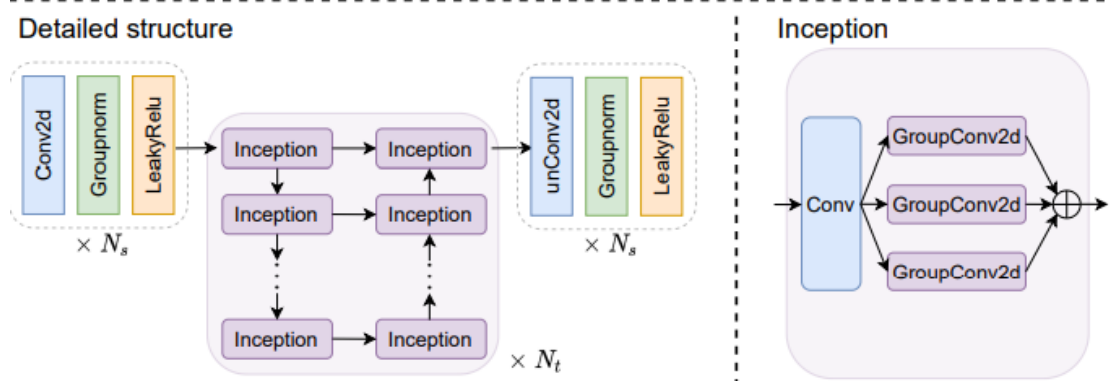

### 3.2 งานวิจัยเกี่ยวกับเทคนิคการเรียนรู้เชิงลึกใหม่ในการทำนายเฟรมถัดไป (Recent Deep Learning Techniques in Next Frame Prediction)

การทำนายเฟรมถัดไปหรืออาจเรียกอีกชื่อหนึ่งได้ว่า Video Prediction เป็นสาขาย่อยของการเรียนรู้ลึกในการมองเห็นคอมพิวเตอร์ซึ่งเกี่ยวข้องกับการทำนายเฟรมที่กำลังจะมาจากเฟรมก่อนหน้า Shi et al. นำเสนอ ConvLSTM ซึ่งเป็นชนิดของโครงข่ายประสาทเชื่อมต่อแบบเวลา-พื้นที่สำหรับการทำนายในการทำนายข้อมูลเชิงพื้นที่และเวลาซึ่งเป็นการประยุกต์ใช้ Convolution ในขั้นตอนการเปลี่ยนสถานะข้อมูลเข้าสู่สถานะถัดไปและในขั้นตอนการเปลี่ยนสถานะระหว่างสถานะของ LSTM [32] Wang et al. นำเสนอ PredRNN: ส่วนหลักของแบบจำลองนี้ คือนำเสนอหน่วยสัญญาณทางเวลาและพื้นที่แบบยาวระยะสั้น spatio-temporal long short-term memory (ST-LSTM) ซึ่งสกัดและจดจำลักษณะทางเวลาและพื้นที่พร้อมกัน [33] Wang et al. เสนอเครือข่าย MIM

<sup>11</sup> อ้างอิงจาก 31. Zhang, Q., et al., *Deep-AIR: A Hybrid CNN-LSTM Framework for Fine-Grained Air Pollution Estimation and Forecast in Metropolitan Cities*. IEEE Access, 2022. 10: p. 55818-55841.



เพื่อเรียนรู้ความไม่คงที่ระดับสูงจากแนวโน้มทางเวลาและพื้นที่ [34] Lin et al. นำเสนอกลไกสัมพันธ์ตนเองเข้าสู่ ConvLSTM ซึ่งเป็นหน่วยความจำที่สัมพันธ์ตนเอง (SAM) เพื่อจดจำลักษณะที่มีความสัมพันธ์ในระยะไกลในทั้งระดับเชิงพื้นที่และเวลา [35] Chang et al. นำเสนอหน่วยที่ตระหนักถึงการเคลื่อนไหวระหว่างเฟรม Motion-Aware Unit (MAU) เพื่อจับข้อมูลเคลื่อนไหวระหว่างเฟรม [36] และสุดท้ายแบบจำลองที่ได้นำมาประยุกต์ใช้ในงานวิจัยนี้ Zhangyang et al. นำเสนอ SimVP ย่อมาจาก Simpler yet Better Video Prediction [37] ซึ่งเป็นแบบจำลองประเภทแบบจำลองที่ใช้คอนโวลูชันเพียงอย่างเดียว ทำให้เป็นแบบจำลองที่มีความซับซ้อนน้อยและสามารถเรียนรู้ได้อย่างรวดเร็ว และสามารถทำนายได้อย่างแบบจำลองอื่นๆ ในปัจจุบัน โครงสร้างของ SimVP จะแบ่งออกเป็น 3 ส่วนหลัก ได้แก่ ส่วน Encoder ใช้สำหรับสกัดข้อมูลเชิงพื้นที่ ส่วน Translator ใช้สำหรับการเรียนรู้เชิงเวลา และส่วนสุดท้าย Decoder ใช้สำหรับแปลงข้อมูลที่ได้เรียนรู้ให้ออกมาเป็นข้อมูลเชิงพื้นที่และเวลาเหมือนเดิม โดย SimVP สามารถแสดงได้ดังรูปที่ 12



รูปที่ 12 โครงสร้างแบบจำลอง SimVP<sup>12</sup>

<sup>12</sup> อ้างอิงจาก 37. Zhangyang, G., et al., *SimVP: Simpler yet Better Video Prediction*. 2022.

## บทที่ 4

### แนวคิดและวิธีการดำเนินงาน

ในบทนี้นำเสนอวิธีการเรียนรู้เชิงลึกเพื่อเข้ามาทำนายค่าฝุ่นในอนาคตโดยมีผลลัพธ์ที่ได้เป็นเชิงแผนที่ โดยวิธีการที่นำเสนอทั้งหมดถูกแบ่งออกเป็น 4 ส่วน ดังรูปที่ 13 ได้แก่ ในส่วนแรก (1) เป็นการอธิบายชุดข้อมูลทั้งหมดที่ใช้ในวิทยานิพนธ์นี้ (2) แสดงวิธีการประมวลผลก่อน (Pre Processing) ก่อนนำไปฝึกสอนให้กับการเรียนรู้เชิงลึก (3) แสดงวิธีการที่ใช้ในการทำนายค่าฝุ่นในอนาคตโดยมีผลลัพธ์ที่ได้เป็นเชิงแผนที่ด้วยการเรียนรู้เชิงลึกที่วิทยานิพนธ์นี้นำเสนอ



รูปที่ 13 ภาพรวมของขั้นตอนทั้งหมดที่วิทยานิพนธ์นี้นำเสนอ

#### 4.1 การเตรียมข้อมูล

ในส่วนของการเตรียมข้อมูลแบ่งออกเป็น 3 ส่วน โดยเริ่มจากเตรียมชุดข้อมูลฝุ่นของประเทศ ไทย ชุดข้อมูลลม และชุดข้อมูลการตรวจจับความร้อนบนผิวโลก

##### 4.1.1 ชุดข้อมูลฝุ่น PM2.5

ในงานวิจัยนี้ใช้ข้อมูลฝุ่นจาก 2 แหล่งข้อมูล ซึ่งคือข้อมูลฝุ่นจากกรมควบคุมมลพิษและข้อมูลฝุ่นจากโครงการ Sensor For All โดยข้อมูลที่ฝุ่นจะสามารถแบ่งคลาสของฝุ่นออกเป็น 3 ระดับ ได้แก่ ฝุ่นน้อยคือมีค่าฝุ่นน้อยกว่า  $35.5 \mu\text{g}/\text{m}^3$  ฝุ่นกลางคือมีค่าฝุ่นในช่วง  $35.5 - 55.5 \mu\text{g}/\text{m}^3$  และสุดท้าย ฝุ่นมากคือมีค่าฝุ่นมากกว่า  $55.5 \mu\text{g}/\text{m}^3$

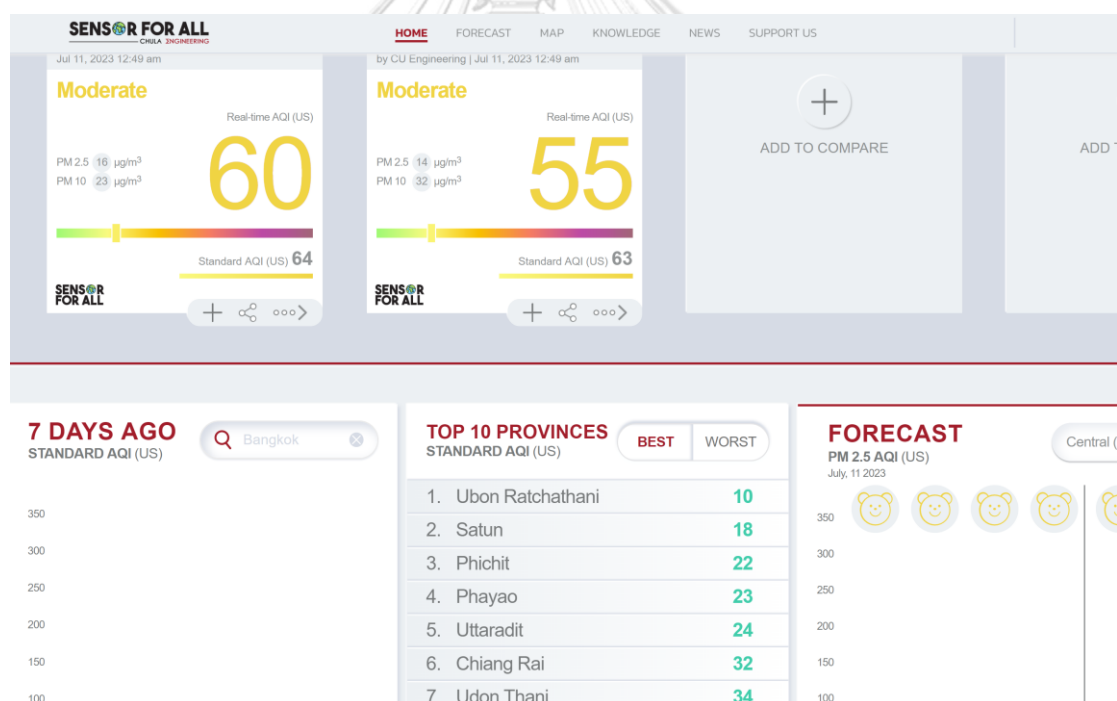
##### 4.1.1.1 ชุดข้อมูลฝุ่นประเทศไทยจากกรมควบคุมมลพิษ

กรมควบคุมมลพิษ (Pollution Control Department) เป็นหน่วยงานประเภทกรม อยู่ในสังกัดของกระทรวงทรัพยากรธรรมชาติและสิ่งแวดล้อม มีหน้าที่ดูแลจัดการ, ควบคุม, ดูแล และรักษาสิ่งแวดล้อมไม่ให้เกิดมลพิษ บทบาทและภารกิจทั่วไป ซึ่งถือปฏิบัติตามบทบัญญัติที่เกี่ยวข้องในพระราชบัญญัติส่งเสริมและรักษาคุณภาพสิ่งแวดล้อมแห่งชาติ พ.ศ. 2535 โดยให้อำนาจคณะกรรมการสิ่งแวดล้อมแห่งชาติ คณะกรรมการควบคุมมลพิษ และเจ้าพนักงานควบคุมมลพิษ ในการบังคับใช้มาตรการต่างๆ ตามกฎหมาย เพื่อประโยชน์ในการควบคุม ป้องกันและแก้ไขปัญหา

สิ่งแวดล้อมอันเนื่องมาจากภาวะมลพิษ โดยปัจจุบันมีสถานีวัดค่าฝุ่นทั้งหมด 213 สถานี (นับจากจำนวนตำแหน่งที่ปรากฏในข้อมูล) ลักษณะข้อมูลฝุ่นที่ได้จะเป็นข้อมูลฝุ่นรายชั่วโมง

#### 4.1.1.2 ชุดข้อมูลฝุ่นประเทศไทยจาก Sensor For All

Sensor For All คือ การตรวจสอบคุณภาพอากาศ ด้วยการติดตั้งเซนเซอร์ ตรวจวัดฝุ่นจิ๋วไว้สถานที่ต่าง ๆ ทั่วประเทศ สำหรับติดตามข้อมูลด้านคุณภาพอากาศ และปริมาณฝุ่น PM2.5 โดยจะแสดงผลข้อมูลคุณภาพของอากาศแบบ Real Time โดยจะแสดงผลข้อมูล ผ่านทางเว็บไซต์ [sensorforall.com](http://sensorforall.com) และ แอปพลิเคชัน Sensor for All โดยความร่วมมือของคณะวิศวกรรมจุฬาลงกรณ์มหาวิทยาลัย กระทรวงพลังงาน กฟผ. และสำนักงานพลังงานจังหวัดทั่วประเทศ โดยปัจจุบันมีสถานีวัดค่าฝุ่นทั้งหมด 501 สถานี เวลาในการตรวจวัดค่าฝุ่นแต่ละครั้งในแต่ละสถานีจะเป็นอิสระจากกัน นั่นคือในแต่ละสถานีไม่จำเป็นต้องวัดค่าฝุ่นในเวลาเดียวกัน และระยะห่างระหว่างการวัดค่าฝุ่นในแต่ละครั้งจะอยู่ที่ 5 นาที



รูปที่ 14 แสดงภาพหน้าเว็บไซต์ [sensorforall.com](http://sensorforall.com) ในการติดตามค่าฝุ่น

#### 4.1.2 ชุดข้อมูลจาก ERA5

ERA5 (ECMWF Reanalysis v5) [42] เป็นเครื่องมือวิเคราะห์สภาพบรรยากาศโลกแบบซ้ำๆ โดยเป็นรุ่นที่ 5 ที่ ECMWF ได้พัฒนาขึ้นมา หลังจากที่ได้มีการเปิดตัวระบบวิเคราะห์ซ้ำๆ เป็นครั้งแรกในยุค 1980 โดยใช้ชื่อว่า FGGE ตามมาด้วย ERA-15, ERA-40 และล่าสุดคือ ERA-Interim พัฒนาขึ้นโดย Copernicus Climate Change Service ซึ่งได้รับเงินสนับสนุนจากสหภาพยุโรป การวิเคราะห์สภาพภูมิอากาศโลกซ้ำๆ ถือเป็นข้อมูลสำคัญในการทำความเข้าใจและติดตามกระบวนการต่างๆที่เกี่ยวข้องกับการเปลี่ยนแปลงสภาพภูมิอากาศ และคาดการณ์การเปลี่ยนแปลงสภาพภูมิอากาศในอนาคต การวิเคราะห์ซ้ำๆ เป็นการผนวกข้อมูลจากการสำรวจทางอุตุนิยมวิทยาทั้งในอดีตและปัจจุบัน เข้ากับแบบจำลองพยากรณ์อันทันสมัย โดยใช้เทคนิคกลมกลืนข้อมูล (data assimilation) ที่เดิมพัฒนาขึ้นสำหรับการพยากรณ์อากาศเชิงตัวเลข โดยในงานวิจัยนี้ได้ใช้ข้อมูลจาก ERA5 ได้แก่ u-component of wind ซึ่งเป็นความเร็วของลมที่พัดไปทางทิศตะวันออกมีหน่วยเป็น m/s และ v-component of wind ซึ่งเป็นความเร็วของลมที่พัดไปทางทิศเหนือมีหน่วยเป็น m/s โดยในงานวิจัยได้ใช้ค่าลมที่ระดับความสูง 850 hPa ซึ่งที่ความสัมพันธ์ที่เกี่ยวกับการพัดพาฝุ่น PM2.5 ข้ามประเทศมากที่สุด


#### 4.1.3 ชุดข้อมูลการตรวจจับความร้อนบนผิวโลกจาก FIRMS

Fire Information for Resource Management System (FIRMS) [43-45] พัฒนาโดย NASA สำหรับเผยแพร่ข้อมูลจุดความร้อนทั่วโลก ซึ่งข้อมูลนี้เป็นระบบติดตามและแจ้งเตือนจุดบริเวณที่มีค่าความร้อนสูงผิดปกติ บนพื้นผิวโลก ที่แสดงผลเกือบจะ real time โดยจะรายงานผลภายใน 3 ชั่วโมง หลังจากดาวเทียมจับจุดความร้อนได้ ซึ่งการได้มาของข้อมูลดังกล่าว FIRMS ได้ทำการวิเคราะห์ข้อมูลจากเซ็นเซอร์ 2 ระบบ คือ VIIRS และ MODIS โดยเซ็นเซอร์ระบบแรกอยู่บนดาวเทียม Suomi-NPP และ ดาวเทียม NOAA-20 ส่วนเซ็นเซอร์ระบบที่ 2 อยู่บนดาวเทียม Terra และ ดาวเทียม Aqua โดยข้อมูลที่ได้จะเป็นการบอกตำแหน่งบนพื้นผิวโลกที่สามารถตรวจจับความร้อนได้พร้อมทั้งระบุเวลาที่พบ

#### 4.2 การประมวลผลก่อน (Data Preprocessing)


ในส่วนของการประมวลผลก่อนแบ่งออกเป็น 3 ส่วน ตามประเภทของข้อมูลจากแต่ละแหล่ง โดยมีวัตถุประสงค์ให้ข้อมูลทั้งหมดสามารถรวมกันได้เป็นแบบเดียวกันในรูปของข้อมูลแบบ Spatiotemporal ที่มีขนาดของกริดเท่ากับ 0.5 ดีกรีละติจูดและ 0.5 ดีกรีลองจิจูด พื้นที่ของแผนที่จะครอบคลุมประเทศไทย โดยจะมีค่าละติจูดอยู่ที่ 4.0 ดีกรีเหนือถึง 22.0 ดีกรีเหนือและค่าลองจิจูด

จะอยู่ที่ 95.0 องศาตะวันออกถึง 110.0 องศาตะวันออกซึ่งจะได้เป็นข้อมูลเชิงพื้นที่ ดังรูปที่ 15 จากนั้น  
 ในส่วนของข้อมูลเชิงเวลาแต่ละแผนที่จะห่างกันเป็นเวลา 1 ชั่วโมง



รูปที่ 15 แสดงภาพรูปแบบของข้อมูลเชิงพื้นที่ในแต่ละเวลาที่เป็ผลลัพท์จากการประมวลผลก่อน


ในส่วนของชุดข้อมูลลม ลักษณะข้อมูลที่ได้จะอยู่ในรูปกริดที่มีขนาด 0.5 องศาละติจูดและ  
 0.5 องศาลองจิจูดอยู่แล้ว เพียงแต่ต้องมีการประมวลผลเพิ่มในการเปลี่ยนประเภทไฟล์จากต้นทางที่  
 เป็นไฟล์ประเภท GRIB ให้เป็นในรูปเวกเตอร์นั้นมพาย โดยสามารถรวม u-component of wind และ  
 v-component of wind แสดงผลหลังการประมวลผลก่อนได้ ดังรูปที่ 16



รูปที่ 16 ตัวอย่างของการนำข้อมูลลมไปใส่ลงกริด


ในส่วนของชุดข้อมูลการตรวจจับความร้อนบนผิวโลก ลักษณะข้อมูลที่ได้จะเป็นตำแหน่งที่  
 ตรวจจับความร้อนบนพื้นผิวโลกในรูปแบบละติจูดและลองจิจูดพร้อมทั้งบอกเวลาที่พบ ดังนั้นในการ

ประมวลผลก่อนจึงทำการนับจำนวนที่พบในกริดที่กำหนดและในชั่วโมงที่กำหนด จากนั้นก็ทำกับทุกกริดได้ตัวอย่างผลลัพธ์ออกมาดังรูปที่ 17



รูปที่ 17 ตัวอย่างของการนำข้อมูลการตรวจจับความร้อนบนผิวโลกไปใส่ลงกริด

ในส่วนของชุดข้อมูลฝุ่น เนื่องจากข้อมูลฝุ่นจะเก็บข้อมูลโดยเฉลี่ยทุกๆ 5 นาที จึงต้องทำการเฉลี่ยค่าฝุ่นที่ได้วัดในหนึ่งชั่วโมงเพื่อให้ตรงกับผลลัพธ์การประมวลผลก่อนที่ต้องการ จากนั้นจึงนำค่าฝุ่นที่กลายเป็นรายชั่วโมงแล้วใส่ลงแต่ละกริดแล้วเฉลี่ยค่าฝุ่นของกริดนั้นๆ แต่ในบางกริดในบางช่วงเวลาอาจจะมีการสูญหายของข้อมูล จึงทำการประมาณค่าในช่วงของข้อมูลกริดด้วยวิธีใกล้เคียงที่สุดเพื่อเติมค่าดังกล่าว ได้ตัวอย่างผลลัพธ์ออกมาดังรูปที่ 18 โดยในรูปนี้จะแสดงให้เห็นภาพโดยการแบ่งคลาสค่าฝุ่นในแต่ละกริด



รูปที่ 18 ตัวอย่างของการนำข้อมูลฝุ่นเมื่อแบ่งคลาสแล้วใส่ลงกริด

### 4.3 การทำนายค่าฝุ่นเชิงแผนที่ในอนาคต (Spatiotemporal Model)

จากงานวิจัยที่ผ่านมา ผู้วิจัยได้เห็นว่าได้มีงานวิจัยที่พยายามทำนายฝุ่นในรูปแบบของแผนที่ [31] และข้อมูลที่อยู่ในลักษณะของแผนที่แล้วยังเป็นอนุกรมเวลาเป็นข้อมูลในลักษณะ Spatiotemporal ซึ่งวิธีการการเรียนรู้เชิงลึกที่ใช้กับข้อมูลประเภทนี้มีชื่อว่าการทำนายเฟรมถัดไป (Next Frame Prediction) ดังนั้นจึงเป็นแรงบันดาลใจให้ผู้วิจัยใช้แบบจำลอง SimVP [37] ซึ่งเป็นการเรียนรู้เชิงลึกล่าสุดและดีที่สุดในปัจจุบันของการทำนายเฟรมถัดไปมาประยุกต์ใช้กับงานทำนายฝุ่น สรุปการปรับปรุงการทำนายค่าฝุ่นเชิงแผนที่ ได้ดังต่อไปนี้

เมื่อการประมวลผลข้อมูลเสร็จสิ้นแล้ว ข้อมูลจะกลายเป็นข้อมูลเชิงพื้นที่และเวลาที่ประกอบด้วย 4 channel ซึ่งประกอบด้วยข้อมูลจุดความร้อนบนพื้นผิวโลก ข้อมูลค่าฝุ่น PM2.5 และข้อมูลลมทั้ง u-component และ v-component ในรูปภาพที่ 19 แสดงโครงสร้างของแบบจำลองที่นำเสนอประกอบไปด้วยโมดูลย่อย 3 ตัว เริ่มต้นโมดูลแรกคือชั้นการเรียนรู้ความสัมพันธ์ของแต่ละคุณลักษณะข้อมูล Cross-Feature Learning Layer (CFL) โมดูลที่สองคือแบบจำลองการทำนายเฟรมถัดไปซึ่งในที่นี้ได้ใช้ SimVP และโมดูลสุดท้ายคือชั้นการทำให้ Model สนใจการคำนวณ loss function เฉพาะในส่วนของประเทศไทย Masking Layer (ML) โมดูลแรกคือการใช้ 1x1 Convolution Layer เพื่อเข้าใจความสัมพันธ์ของคุณลักษณะข้อมูลระหว่าง 4 channel การประมวลผลของเคอร์เนลขนาด 1x1 นี้มีความหมายคือเมื่อพิจารณาในแต่ละกริดแล้วจะนำข้อมูลทั้ง 4 channel ใน grid นั้นมาคำนวณความสัมพันธ์จากแต่ละลักษณะข้อมูลก่อน หากมองอีกมุมหนึ่ง 1x1 Convolution Layer เปรียบเสมือนการทำ Fully Connected ไปที่กริดหนึ่งๆ ดังนั้นในโมดูลนี้จึงเป็นเรียนรู้ความสัมพันธ์ของแต่ละคุณลักษณะเพียงอย่างเดียวยังไม่ได้สนใจในมุมมองของเวลาและพื้นที่ แนวคิดนี้ได้แรงบันดาลใจมาจาก Deep-AIR [31] โดยจากรูปตัวแปร  $T$  แทนจำนวนเวลาที่ใช้สำหรับข้อมูลขาเข้าและข้อมูลขาออก,  $C$  แทนจำนวน channel ของข้อมูลขาเข้า,  $C'$  แทนจำนวน channel ของข้อมูลหลังการเรียนรู้ที่ Cross-Feature Learning Layer,  $H$  แทนความสูงของรูป,  $W$  แทนความกว้างของรูป, และ  $X$  แทนจำนวนกริดที่ต้องการทำนายที่ได้จากการเลือกกริดที่ Masking Layer


จากนั้นข้อมูลที่ได้จะถูกส่งไปยังแบบจำลองการทำนายเฟรมถัดไป SimVP ส่วนประกอบหลักของแบบจำลองนี้ประกอบด้วยเอนโคเดอร์ (encoder), ทรานสเลเตอร์ (translator), และดีโคเดอร์ (decoder)

- เอนโคเดอร์ประกอบไปด้วยกลุ่มของบล็อก ConvNormReLU ซึ่งภายในประกอบไปด้วย ชั้น Convolution จากนั้นได้มีการทำ Layer Normalization และสุดท้ายใช้ฟังก์ชันกระตุ้นเป็น LeakyReLU ซึ่งหน้าที่หลักของโมดูลนี้รับผิดชอบในการสกัดลักษณะพื้นที่ (spatial features) ว่าในเชิงพื้นที่แต่ละกริดมีความสัมพันธ์กันอย่างไร

- ทรานสเลเตอร์ประกอบด้วยกลุ่มของอินเซปชัน (Inception modules) ซึ่งภายในประกอบไปด้วย Convolution ตามด้วยกลุ่มของ Convolution ที่มีขนาดของเคอร์เนลที่ขนาดต่างกัน โดยลักษณะการเชื่อมต่อกันของแต่ละอินเซปชันจะมีลักษณะคล้าย U-Net ซึ่งหน้าที่หลักของโมดูลนี้รับผิดชอบในการการศึกษาการเปลี่ยนแปลงเวลาว่าเมื่อข้อมูลมีแนวโน้มในอนาคตเป็นอย่างไร
- ดีโคเดอร์ประกอบด้วยกลุ่มของบล็อก UnConvNormReLU ซึ่งภายในประกอบไปด้วย ชั้น Transpose Convolution จากนั้นได้มีการทำ Group Normalization และสุดท้ายใช้ฟังก์ชันกระตุ้นเป็น LeakyReLU ซึ่งหน้าที่หลักของโมดูลนี้รับผิดชอบรวมข้อมูลเชิงพื้นที่-เวลาเข้าด้วยกันเพื่อทำนายเฟรมในอนาคต

เนื่องจากส่วนประกอบทั้งหมดของ SimVP มีพื้นฐานมาจากชั้น Convolution Neural Network ทั้งหมดทำให้แบบจำลองนี้ง่ายต่อการเข้าใจ และมีความรวดเร็วในการสอนแบบจำลองและการทำนายเมื่อเทียบกับแบบจำลองที่มีพื้นฐานมาจาก Recurrent Neural Network อีกทั้งมีประสิทธิภาพในการทำนายที่ยอดเยี่ยม ในงานวิจัยนี้ต้องการทำนายเฉพาะค่าฝุ่น PM2.5 เท่านั้น จึงทำการปรับเปลี่ยนชั้นสุดท้ายของแบบจำลอง SimVP คือชั้นของ Convolution ให้ทำนายเพียง channel เดียวกัน สำหรับโมดูลสุดท้าย ได้มีการเพิ่มชั้นการทำ Masking เพื่อเพิ่มประสิทธิภาพของแบบจำลอง โดยในชั้นนี้จะช่วยให้แบบจำลองทำการคำนวณค่า loss สำหรับกริดภายในพื้นที่ที่กำหนดไว้เท่านั้นในกรณีนี้คือกริดที่อยู่ในประเทศประเทศไทย ซึ่งจะทำให้ค่าทำนายสำหรับกริดที่ตั้งอยู่นอกประเทศไม่ถูกนำมาพิจารณาระหว่างการสอนแบบจำลอง





รูปที่ 19 แสดงภาพรวมของแบบจำลอง SimVP-CFLL-ML

## บทที่ 5

### การทดลองและผลการทดลอง

ข้อมูลที่ใช้ในการศึกษาคือข้อมูลฝุ่นในปี 2022 เนื่องจากข้อมูลฝุ่น PM2.5 จาก Sensor For All ที่มีจำนวนสถานีวัดค่าฝุ่นที่ครอบคลุมที่สุดในประเทศไทยนั้นยังเก็บรวบรวมข้อมูลมาได้ไม่นาน ทางผู้ทำวิจัยจึงเลือกใช้ข้อมูลในช่วงปี 2022 ในการทำการทดลอง และเพื่อให้แบบจำลองสามารถเรียนรู้ครอบคลุมลักษณะของค่าฝุ่นได้ตลอดทั้งปีจึงเลือกใช้ช่วงสัปดาห์สุดท้ายของแต่ละเดือนเป็นชุดข้อมูลทดสอบ ในขณะที่วันที่เหลือจะถูกแบ่งเป็นชุดข้อมูล หลังจากแยกข้อมูลเป็นชุดฝึกฝนและทดสอบสำหรับแต่ละเดือนแล้ว ได้มีใช้เทคนิค window sliding technique เพื่อสร้างข้อมูลนำเข้าและผลลัพธ์สำหรับการฝึกสอนแบบจำลองเพื่อทำนายความเข้มข้นของค่าฝุ่น PM2.5 สำหรับ 24 ชั่วโมงถัดไปโดยใช้ข้อมูลจาก 24 ชั่วโมงก่อนหน้า โดยในงานวิจัยนี้ได้ทำการเปรียบเทียบแบบจำลองที่นำเสนอกับแบบจำลองการทำนายฝุ่น ได้แก่ LSTM, GRU และ Deep-AIR นอกจากนี้ยังเปรียบเทียบกับแบบจำลองการทำนายเฟรมถัดไป ได้แก่ ConvLSTM, PredRNN และ SimVP ต่อมาในส่วนของการประเมินผลการทดลองจะเป็นการเปรียบเทียบประสิทธิภาพการทำนายค่าฝุ่นในอนาคตเชิงแผนที่ระหว่างแบบจำลองแต่ละประเภทตามที่ได้กล่าวมา โดยการเปรียบเทียบประสิทธิภาพจะแบ่งเป็น 4 ส่วน ได้แก่ (1) การเปรียบเทียบภาพรวมของการทำนายทั้งหมดทั้งเชิงแผนที่และเชิงเวลา (2) การเปรียบเทียบความสำคัญของแต่ละคุณลักษณะข้อมูลที่ใช้ในการทดลอง (3) เปรียบเทียบความสามารถในการทำนายของแต่ละเวลาที่ทำนาย (4) เปรียบเทียบความสามารถในการทำนายของแต่ละพื้นที่ (5) การเปรียบเทียบความสามารถในการทำนายเมื่อเพิ่มแต่ละโมดูลให้กับ SimVP และ (6) การทดลองเพิ่มเติมอื่นๆ

จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

#### 5.1 การเปรียบเทียบภาพรวมของการทำนายทั้งหมดทั้งเชิงแผนที่และเชิงเวลา

เพื่อเปรียบเทียบภาพรวมของการทำนายทั้งหมดทั้งเชิงแผนที่และเชิงเวลาจึงทำการพิจารณา ค่าฝุ่น PM2.5 ในทุกกริดที่ได้จากการทำนาย วัตถุประสงค์ของการประเมินนี้คือการเปรียบเทียบความสามารถในการทำงานของแบบจำลองในภาพรวม ในการประเมินแรกจะเป็นการประเมินในรูปแบบของ regression โดยใช้ค่า RMSE และ MAE ตามที่แสดงในตารางที่ 1 ผลลัพธ์แสดงให้เห็นว่า SimVP-CFLL-ML เป็นผู้ชนะที่มีค่า MAE และ RMSE ที่ได้เป็น  $4.51 \mu\text{g}/\text{m}^3$  และ  $7.59 \mu\text{g}/\text{m}^3$  ตามลำดับ โดยแบบจำลองการทำนายค่าฝุ่นที่นำมาเปรียบเทียบที่ดีที่สุดเป็น Deep-AIR ซึ่งมีค่า MAE และ RMSE ที่ได้เป็น  $4.96 \mu\text{g}/\text{m}^3$  และ  $8.27 \mu\text{g}/\text{m}^3$  ตามลำดับ โดยแบบจำลองการทำนายเฟรมถัดไปที่นำมาเปรียบเทียบที่ดีที่สุดเป็น SimVP ซึ่งมีค่า MAE และ RMSE ที่ได้เป็น  $4.51 \mu\text{g}/\text{m}^3$  และ

7.63  $\mu\text{g}/\text{m}^3$  ตามลำดับ แสดงให้เห็นว่าแบบจำลองที่ทำนายทั้งเชิงพื้นที่และเวลาให้ผลที่ดีกว่าแบบจำลองที่ทำนายเพียงเวลาอย่างเดียว

ตารางที่ 1 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวม โดยใช้ MAE และ RMSE ซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Model	MAE	RMSE
LSTM	5.82	9.34
GRU	5.55	8.99
Deep-AIR	4.96	8.27
ConvLSTM	5.02	8.26
PredRNN	4.67	7.87
SimVP	<b>4.51</b>	7.63
SimVP-CFLL-ML	<b>4.51</b>	<b>7.59</b>

เมื่อเปรียบเทียบภาพรวมของการทำนายทั้งหมดทั้งเชิงพื้นที่และเชิงเวลา การประเมินที่สองจะเป็นการประเมินในรูปแบบของ classification โดยผลลัพธ์ที่ได้จากการทำนายจะถูกจัดกลุ่มตามระดับของค่าฝุ่นดังนี้ ฝุ่นน้อย (Low) คือมีค่าฝุ่นน้อยกว่า  $35.5 \mu\text{g}/\text{m}^3$  ฝุ่นกลาง (Medium) คือมีค่าฝุ่นในช่วง  $35.5 - 55.5 \mu\text{g}/\text{m}^3$  และสุดท้ายฝุ่นมาก (High) คือมีค่าฝุ่นมากกว่า  $55.5 \mu\text{g}/\text{m}^3$  จากนั้นจึงประเมินด้านการจำแนกโดยใช้ F1 ทั้งต่อกลุ่มและ Macro F1 ในตารางที่ 3 แสดงผลการประเมินในรูปแบบนี้ ผลลัพธ์เปิดเผยว่า SimVP-CFLL-ML เป็นผู้ชนะที่มีคะแนน F1 ในกลุ่ม Low, Medium และ High คือ 0.9613, 0.5419 และ 0.4638 ตามลำดับ และคะแนน Macro F1 เท่ากับ 0.6557 โดยแบบจำลองการทำนายค่าฝุ่นที่นำมาเปรียบเทียบที่ดีที่สุดเป็น Deep-AIR ด้วยคะแนน F1 ในกลุ่ม Low คือ 0.9543, ในกลุ่ม Medium คือ 0.4907 และคะแนน Macro F1 เท่ากับ 0.5912 อย่างไรก็ตาม GRU มีประสิทธิภาพดีกว่า Deep-AIR ในกลุ่ม High ด้วยคะแนน F1 เท่ากับ 0.3687 โดยแบบจำลองการทำนายเฟรมถัดไปที่นำมาเปรียบเทียบที่ดีที่สุดเป็น SimVP ด้วยคะแนน F1 ในกลุ่ม Low คือ 0.9607, ในกลุ่ม Medium คือ 0.5282 และคะแนน Macro F1 เท่ากับ 0.6371 อย่างไรก็ตาม PredRNN มีประสิทธิภาพดีกว่า SimVP ในกลุ่ม High ด้วยคะแนน F1 เท่ากับ 0.4287

ตารางที่ 2 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวม โดยใช้ Macro F1, Micro F1 และ F1 ของแต่ละกลุ่มซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Model	Macro F1	Micro F1	F1: Low	F1: Medium	F1: High
LSTM	0.5731	0.8861	0.9468	0.4388	0.3336
GRU	0.5912	0.8911	0.9496	0.4551	0.3687
Deep-AIR	0.5912	0.8990	0.9543	0.4907	0.3347
ConvLSTM	0.5982	0.8988	0.9544	0.4937	0.3467
PredRNN	0.6318	0.9088	0.9588	0.5078	0.4287
SimVP	0.6371	0.9124	0.9607	0.5282	0.4225
SimVP-CFLL-ML	<b>0.6557</b>	<b>0.9131</b>	<b>0.9613</b>	<b>0.5419</b>	<b>0.4638</b>

โดยรวมแล้ว SimVP-CFLL-ML มีประสิทธิภาพดีกว่าแบบจำลองที่นำมาเปรียบเทียบทั้งหมดที่รวมถึงแบบจำลองการทำนายฝุ่นและแบบจำลองการทำนายเฟรมถัดไป ในเรื่องการประเมินทางสถิติ SimVP-CFLL-ML แสดงให้เห็นว่ามีประสิทธิภาพดีกว่าแบบจำลองการทำนายค่าฝุ่นที่ดีที่สุด (Deep-AIR) โดยมีค่า MAE ที่ดีกว่าเป็น 9.07% และค่า RMSE ที่ดีกว่าเป็น 8.22% อย่างไรก็ตาม SimVP-CFLL-ML ไม่สามารถเอาชนะแบบจำลองการทำนายเฟรมถัดไปที่นำมาเปรียบเทียบที่ดีที่สุด (SimVP) เนื่องจากผลการทดลองแสดงให้เห็นว่าประสิทธิภาพของมันไม่ได้แตกต่างกันอย่างมีนัยสำคัญอีกทั้งยังแยกว่าเล็กน้อย (อ้างอิงตารางที่ 2) อย่างไรก็ตามในการประเมินในเรื่องการจัดกลุ่มผลการทดลองแสดงให้เห็นว่า SimVP-CFLL-ML มีประสิทธิภาพดีกว่าแบบจำลองการทำนายค่าฝุ่นและแบบจำลองการทำนายเฟรมถัดไปที่นำมาเปรียบเทียบ นอกจากนี้ที่การจัดกลุ่มฝุ่นที่มีค่าสูง (High) SimVP-CFLL-ML ได้ดีที่สุด ซึ่งสามารถเอาชนะ PredRNN ที่เป็นแบบจำลองที่นำมาเปรียบเทียบและสามารถทำนายค่าฝุ่นสูงได้ดีที่สุด โดยดีกว่าเป็น 3.51% (อ้างอิงตารางที่ 3) เมื่อพิจารณาในทุกแบบจำลองในการทดลอง F1 score สูงที่สุดอยู่ในกลุ่มของฝุ่นน้อย (Low) เนื่องจากในส่วนใหญ่ของปีอาจจะเป็นฤดูหรือเป็นสภาวะปกติที่ไม่ได้มีการเผาของเศษตัก ซึ่งทำให้ค่าประสิทธิภาพของแบบจำลองในกลุ่มนี้มีค่าสูงและไม่แตกต่างกันมากนักระหว่างแบบจำลอง ส่วนในกลุ่มฝุ่นปานกลางและฝุ่นมาก แบบจำลอง SimVP-CFLL-ML ได้ประสิทธิภาพที่ดีกว่าแบบจำลองอื่นๆ อย่างเห็นได้ชัด นอกจากนี้ได้มีการแสดงรายละเอียดการทำนายค่าฝุ่น PM2.5 ของแบบจำลอง SimVP และ SimVP-CFLL-ML ด้วย confusion matrix ดังรูปที่ 20 โดยมีหน่วยเป็นเปอร์เซ็นต์

SimVP					SimVP-CFLL-ML				
		Prediction					Prediction		
		Low	Medium	High			Low	Medium	High
Actual	Low	85.6	2.2	0.1	Actual	Low	85.7	2.1	0.1
	Medium	4.4	4.8	0.2		Medium	4.4	4.8	0.2
	High	0.4	1.5	0.8		High	0.4	1.4	0.9

รูปที่ 20 แสดง confusion matrix ของแบบจำลอง SimVP และ SimVP-CFLL-ML โดยมีหน่วยเป็นเปอร์เซ็นต์

## 5.2 การเปรียบเทียบความสำคัญของแต่ละคุณลักษณะข้อมูลที่ใช้ในการทดลอง

ในการศึกษาเพื่อดูความสำคัญของแต่ละคุณลักษณะข้อมูล (features ablation study) เราได้ประเมินประสิทธิภาพของแบบจำลองโดยใช้การประเมินแบบเดียวกับการประเมินโดยภาพรวม ดังนั้นจึงทำการพิจารณาค่าฝุ่น PM2.5 ในทุกกรณีที่ได้จากการทำนาย ซึ่งในการทดลองนี้จะทำการเทียบประสิทธิภาพของแต่ละข้อมูลนำเข้าที่มีลักษณะต่างกัน โดยในการทดลองนี้ใช้แบบจำลอง SimVP-CFLL-ML ตามที่แสดงในตารางที่ 3 เป็นการประเมินในรูปแบบของ regression โดยใช้ค่า RMSE และ MAE จากตารางจะเห็นได้ว่าเมื่อข้อมูลนำเข้ามีเพียงค่าฝุ่น PM2.5 เท่านั้น แบบจำลองแสดงผลสมรรถนะที่ดีที่สุดในเรื่องของ MAE โดยได้รับค่า MAE ที่ดีที่สุดคือ 4.46  $\mu\text{g}/\text{m}^3$  อย่างไรก็ตามเมื่อข้อมูลนำเข้าประกอบด้วยค่าลม ค่าจุดความร้อนบนผิวโลก และค่าฝุ่น PM2.5 แบบจำลองได้แสดงผลสมรรถนะที่ดีที่สุดในเรื่องของ RMSE โดยได้รับค่า RMSE ที่ดีที่สุดคือ 7.59  $\mu\text{g}/\text{m}^3$  อย่างไรก็ตามในตารางที่ 4 ด้านการประเมินการจำแนก ด้วยคะแนน F1 คะแนน F1 ที่ดีที่สุดเมื่อพิจารณาคุณลักษณะทั้งหมด โดยได้รับค่า F1 ที่ดีที่สุดคือ 0.9613 ในกลุ่ม Low 0.5419 ในกลุ่ม Medium 0.4638 ในกลุ่ม High และ 0.6557 ในคะแนน Macro F1 ผลลัพธ์แสดงให้เห็นว่าคุณลักษณะไม่มีค่าผลกระทบต่อสมรรถนะของแบบจำลองเมื่อประเมินด้วย regression แต่การเลือกคุณลักษณะมีความสำคัญอย่างยิ่งในการประเมินแบบ classification

ตารางที่ 3 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวมตามแต่ละคุณลักษณะข้อมูล โดยใช้ MAE และ RMSE ซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Features	MAE	RMSE
PM2.5	<b>4.46</b>	7.64
PM2.5 + Wind	4.49	7.67
PM2.5 + Fire	4.49	7.63
PM2.5 + Wind + Fire	4.51	<b>7.59</b>

ตารางที่ 4 ประสิทธิภาพการทำนายค่าฝุ่นในภาพรวมตามแต่ละคุณลักษณะข้อมูล โดยใช้ Macro F1, Micro F1 และ F1 ของแต่ละกลุ่มซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Model	Macro F1	Micro F1	F1: Low	F1: Medium	F1: High
PM2.5	0.6290	0.9130	0.9612	0.5336	0.3922
PM2.5 + Wind	0.6294	0.9126	0.9610	0.5234	0.4038
PM2.5 + Fire	0.6373	0.9124	0.9609	0.5355	0.4155
PM2.5 + Wind + Fire	<b>0.6557</b>	<b>0.9131</b>	<b>0.9613</b>	<b>0.5419</b>	<b>0.4638</b>

จากการศึกษาเพื่อดูความสำคัญของแต่ละคุณลักษณะ ข้อมูลของลมที่ระดับความสูง 850 hPa และข้อมูลจุดความร้อนบนผิวโลกส่งผลกับค่าฝุ่น PM2.5 ในช่วงที่มีค่าฝุ่นสูงในประเทศไทย จากผลการทดลองสรุปได้ดังนี้แบบจำลอง SimVP-CFLL-ML แสดงให้เห็นว่าการเมื่อใช้ข้อมูลทั้งหมดจะไม่ส่งผลใหญ่ต่อประสิทธิภาพของแบบจำลองในเรื่องของ regression ดังที่เห็นว่าความสามารถในการทำนายเมื่อประเมินด้วยค่า MAE ของแบบจำลองมีประสิทธิภาพลดลงเล็กน้อย ในขณะที่ความสามารถในการทำนาย RMSE ของแบบจำลองดูดีขึ้นเล็กน้อย อย่างไรก็ตามในเรื่องการจัดกลุ่มการเพิ่มคุณสมบัติหรือจุดความร้อนพร้อมกับความเข้มข้น PM2.5 ได้เพิ่มประสิทธิภาพของแบบจำลองเป็นอย่างมาก การใช้คุณสมบัติทั้งหมดพร้อมกับความเข้มข้น PM2.5 ได้เพิ่ม F1 score ในคลาสความเข้มข้น PM2.5 ระดับสูงไปถึง 7.16% และ Macro F1 score เพิ่มขึ้นถึง 2.67% (ดูตารางที่ 5) ผลลัพธ์เหล่านี้แสดงให้เห็นว่าการผสมและจุดความร้อนเป็นคุณลักษณะข้อมูลที่มีผลต่อค่าฝุ่น PM2.5 นอกจากนี้ ปัจจัยของไฟที่เกิดจากการเผาผลาญวัสดุชีวภาพเป็นส่วนสำคัญที่ทำให้เกิดฝุ่น PM2.5 ทั่วโลก ทั้งในประเทศที่พัฒนาแล้วและในประเทศที่กำลังพัฒนา ดังนั้นค่าจุดความร้อนจึงส่งผลโดยตรงกับค่าฝุ่นตามที่ได้จากการทดลอง

### 5.3 การเปรียบเทียบความสามารถในการทำนายของแต่ละเวลาที่ทำนาย

จากการที่แบบจำลองสามารถทำนายค่าฝุ่น PM2.5 ออกมาเป็นรายชั่วโมงใน 24 ชั่วโมงถัดไป เพื่อประเมินประสิทธิภาพของแบบจำลองในการทำนายของแต่ละชั่วโมง การเปรียบเทียบนี้จึงใช้ MAE เพื่อเป็นตัวแทนในการประเมินแบบ regression และใช้ Macro F1 เพื่อเป็นตัวแทนในการประเมินแบบ classification ประสิทธิภาพของแบบจำลองถูกคำนวณโดยการประเมินทุกกรณีที่ได้จากการทำนายของแต่ละชั่วโมง ในตารางที่ 5 และ 6 สังเกตได้ว่าเมื่อชั่วโมงของการทำนายมากขึ้น ประสิทธิภาพของแบบจำลองทั้งหมดลดลง ในแบบจำลองทั้งหมด ชั่วโมงแรกของการทำนายแสดงให้เห็นถึงประสิทธิภาพที่ดีที่สุด ในชั่วโมงที่สองของการทำนายประสิทธิภาพจะลดลงอย่างมีนัยสำคัญ

เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่างการทำนายในระยะสั้นและระยะยาว จึงแสดงผลการประเมินด้วยชั่วโมงแรกและชั่วโมงสุดท้ายดังนี้ ในการทำนายชั่วโมงแรก แบบจำลอง SimVP-CFLL-ML แสดงคะแนน Macro F1 สูงสุดที่ 0.7833 และมีค่า MAE ต่ำสุดที่  $3.22 \mu\text{g}/\text{m}^3$  ในชั่วโมงที่ยี่สิบสี่ SimVP-CFLL-ML ได้รับคะแนน Macro F1 สูงสุดที่ 0.6054 อย่างไรก็ตามสำหรับ MAE แบบจำลอง SimVP มีประสิทธิภาพที่ดีที่สุดและมีผลสูงกว่า SimVP-CFLL-ML โดย MAE ที่ได้คือ  $5.33 \mu\text{g}/\text{m}^3$  โดยรวมแล้วจากการสังเกตด้วย Macro F1 แบบจำลอง SimVP-CFLL-ML มีประสิทธิภาพดีกว่าแบบจำลองอื่นในทุกชั่วโมงของการทำนาย ส่วนสำหรับ MAE ในขั้นตอนการทำนายสิบสองชั่วโมงแรก SimVP-CFLL-ML มีประสิทธิภาพดีที่สุด อย่างไรก็ตามในขั้นตอนการทำนายสิบสองชั่วโมงสุดท้าย SimVP ให้ประสิทธิภาพที่ดีกว่า

ตารางที่ 5 ประสิทธิภาพการทำนายค่าฝุ่นแต่ละชั่วโมงที่ทำนายด้วย MAE โดย ts คือแต่ละชั่วโมงที่ทำนาย ซึ่งตัวหนาคือวิธีการที่ดีที่สุด

ts	LSTM	GRU	Deep-AIR	ConvLSTM	PredRNN	SimVP	SimVP-CFLL-ML
1	4.71	4.96	3.29	4.73	3.27	3.32	<b>3.22</b>
2	5.50	5.01	4.23	4.86	3.76	3.72	<b>3.64</b>
3	5.58	5.08	4.40	4.95	4.16	4.05	<b>3.94</b>
4	5.72	5.18	4.67	5.02	4.46	4.26	<b>4.19</b>
5	5.82	5.29	4.86	5.08	4.67	4.42	<b>4.34</b>
6	5.90	5.41	5.00	5.12	4.82	4.55	<b>4.49</b>
7	5.96	5.52	5.11	5.16	4.91	4.65	<b>4.62</b>
8	6.01	5.63	5.20	5.20	4.97	4.76	<b>4.70</b>
9	6.05	5.72	5.29	5.23	5.02	4.83	<b>4.77</b>
10	6.09	5.80	5.35	5.26	5.05	4.88	<b>4.85</b>
11	6.13	5.87	5.40	5.29	5.08	4.93	<b>4.92</b>
12	6.16	5.93	5.46	5.32	5.13	4.99	<b>4.97</b>
13	6.21	5.98	5.51	5.36	5.18	<b>5.09</b>	5.10
14	6.25	6.03	5.57	5.40	5.24	<b>5.13</b>	5.14
15	6.29	6.07	5.62	5.44	5.29	<b>5.16</b>	5.18
16	6.33	6.10	5.66	5.47	5.32	<b>5.20</b>	5.21
17	6.35	6.12	5.68	5.50	5.34	<b>5.21</b>	5.23

18	6.38	6.15	5.69	5.53	5.35	<b>5.22</b>	5.24
19	6.42	6.19	5.70	5.55	5.37	<b>5.22</b>	5.28
20	6.45	6.25	5.71	5.59	5.38	<b>5.23</b>	5.29
21	6.49	6.34	5.72	5.62	5.39	<b>5.26</b>	5.31
22	6.53	6.45	5.74	5.66	5.43	<b>5.26</b>	5.35
23	6.58	6.59	5.77	5.70	5.48	<b>5.29</b>	5.38
24	6.64	6.76	5.84	5.76	5.58	<b>5.33</b>	5.42

ตารางที่ 6 ประสิทธิภาพการทำนายค่าฝุ่นแต่ละชั่วโมงที่ทำนายด้วย Macro F1 โดย ts คือแต่ละชั่วโมงที่ทำนาย ซึ่งตัวหนาคือวิธีการที่ดีที่สุด


ts	LSTM	GRU	Deep-AIR	ConvLSTM	PredRNN	SimVP	SimVP-CFLL-ML
1	0.6308	0.6435	0.6690	0.5263	0.7719	0.7557	<b>0.7833</b>
2	0.5659	0.6404	0.6311	0.6102	0.7289	0.7260	<b>0.7486</b>
3	0.5951	0.6342	0.6380	0.6073	0.6907	0.6892	<b>0.7224</b>
4	0.5828	0.6253	0.6175	0.6044	0.6598	0.6731	<b>0.7014</b>
5	0.5798	0.6156	0.6073	0.6022	0.6383	0.6637	<b>0.6868</b>
6	0.5751	0.6060	0.5978	0.6013	0.6249	0.6511	<b>0.6770</b>
7	0.5730	0.5963	0.5919	0.6001	0.6173	0.6458	<b>0.6632</b>
8	0.5713	0.5881	0.5862	0.5997	0.6131	0.6319	<b>0.6535</b>
9	0.5700	0.5806	0.5809	0.5994	0.6114	0.6284	<b>0.6476</b>
10	0.5690	0.5756	0.5783	0.5998	0.6113	0.6224	<b>0.6448</b>
11	0.5690	0.5725	0.5761	0.6003	0.6109	0.6241	<b>0.6361</b>
12	0.5686	0.5721	0.5746	0.6001	0.6111	0.6249	<b>0.6318</b>
13	0.5678	0.5720	0.5738	0.5996	0.6108	0.6049	<b>0.6262</b>
14	0.5668	0.5733	0.5733	0.5990	0.6099	0.6068	<b>0.6221</b>
15	0.5660	0.5747	0.5733	0.5980	0.6092	0.6104	<b>0.6191</b>
16	0.5655	0.5767	0.5740	0.5971	0.6092	0.6079	<b>0.6163</b>
17	0.5650	0.5799	0.5751	0.5971	0.6096	0.6114	<b>0.6209</b>
18	0.5652	0.5822	0.5769	0.5969	0.6103	0.6156	<b>0.6284</b>



19	0.5653	0.5837	0.5792	0.5958	0.6107	0.6117	<b>0.6213</b>
20	0.5649	0.5828	0.5810	0.5938	0.6105	0.6140	<b>0.6234</b>
21	0.5632	0.5789	0.5817	0.5909	0.6096	0.6019	<b>0.6244</b>
22	0.5607	0.5714	0.5813	0.5880	0.6065	0.6053	<b>0.6167</b>
23	0.5574	0.5616	0.5791	0.5848	0.6015	0.5971	<b>0.6122</b>
24	0.5533	0.5504	0.5744	0.5807	0.5927	0.5948	<b>0.6054</b>

#### 5.4 การเปรียบเทียบความสามารถในการทำนายของแต่ละพื้นที่

สำหรับการประเมินผลลัพธ์จากแบบจำลองในเชิงพื้นที่ วัตถุประสงค์เพื่อตรวจสอบว่าแบบจำลองสามารถทำนายค่าฝุ่น PM<sub>2.5</sub> ของแต่ละพื้นที่ได้อย่างมีประสิทธิภาพ โดยใช้การทำ Pearson Correlation coefficient ในแต่ละกริดของข้อมูลทำนายแล้วแสดงผลรวมออกมาเป็นรูปเชิงแผนที่ ซึ่งความหมายในแต่ละกริดที่ได้จะหมายถึงความสัมพันธ์ว่าค่าที่ทำนายได้ในกริดนั้นๆ มีค่าสอดคล้องกับค่าจริงมากน้อยแค่ไหน โดยกริดที่มีความสอดคล้องกับค่าจริงมากจะมีสีเขียวมาก ถ้ามีความสัมพันธ์น้อยจะมีสีแดงขึ้นเรื่อยๆ ค่าที่ได้จากการทำ Pearson correlation coefficient มีช่วงค่าตั้งแต่ -1 ถึง 1 โดยค่าที่สูงกว่าแสดงถึงความสัมพันธ์ที่มากกว่าระหว่างค่าจริงและค่าทำนาย นอกจากนี้ เมื่อเปรียบเทียบประสิทธิภาพโดยรวมของแบบจำลองการทำนายค่า PM<sub>2.5</sub> ในประเภทแบบจำลองที่เรียนรู้ข้อมูลเชิงเวลาอย่างเดียวกับประเภทแบบจำลองที่เรียนรู้ทั้งเชิงพื้นที่และเชิงเวลา พบว่าวิธีการทำนายแบบทั้งเชิงพื้นที่และเชิงเวลามีประสิทธิภาพมากกว่าในการทำนายค่าฝุ่น PM<sub>2.5</sub> ในพื้นที่ส่วนใหญ่ของประเทศไทยดังที่ผลลัพธ์นี้แสดงให้เห็นว่าการแสดงผลในรูปของแผนที่ที่มีความเป็นสีเขียวมากกว่าดังรูปที่ 21 นอกจากนี้ในทุกแบบจำลองจะสังเกตเห็นได้ว่าการทำนายค่าฝุ่น PM<sub>2.5</sub> ในภาคใต้ของประเทศไทยจะยากกว่าในภูมิภาคอื่นๆ เนื่องจากจำนวนกริดที่เป็นสีเขียวในพื้นที่เหล่านี้ น้อยลงกว่าภูมิภาคอื่นๆ ซึ่งจะเห็นได้ชัดเจนที่สุดในแบบจำลอง LSTM และ GRU โดยจพแสดงผลในพท้นที่นี้เป็นสีเหลือง เนื่องจาก Pearson correlation coefficient มีค่าต่ำ จึงสรุปได้ว่าลักษณะแนวโน้มของค่าฝุ่นในภาคใต้นั้นสามารถคาดเดาได้ยาก



รูปที่ 21 แสดงผลตัวแทนของค่า Pearson correlation coefficient ในแต่ละกริดด้วยสี


นอกจากนี้ในตารางที่ 7 ได้สรุปจำนวนกริดของแต่ละช่วง Pearson correlation coefficient ผลการทดสอบแสดงให้เห็นว่า SimVP-CFLL-ML มีประสิทธิภาพดีกว่าแบบจำลองพื้นฐานอื่นๆ โดยมีจำนวนกริดที่มีค่า Pearson correlation coefficient ในช่วง 0.8-1.0 มากที่สุด โดยมีจำนวนกริดเท่ากับ 125 ซึ่งมากกว่าครึ่งหนึ่งของทั้งหมดของกริดที่ทำกริดทำนาย

ตารางที่ 7 แสดงจำนวนกริดที่มีค่า Pearson correlation coefficient อยู่ในช่วงที่กำหนด


Model	-1.0-0.2	0.2-0.4	0.4-0.6	0.6-0.8	0.8-1.0
LSTM	5	8	35	129	21
GRU	2	6	35	125	30
ConvLSTM	2	0	21	116	59
CNN-LSTM	1	1	22	105	69
PredRNN	1	1	15	83	98
SimVP	0	2	13	78	105
SimVP-CFLL-ML	0	2	8	63	<b>125</b>

แบบจำลอง SimVP-CFLL-ML สามารถแสดงตัวอย่างข้อมูลเข้าและผลลัพธ์ที่ได้จากการทำนายได้ดังเช่นที่แสดงในภาพที่ 22 โดยเวลาที่ใช้เป็นตัวอย่างของข้อมูลเข้ามีช่วงเวลาตั้งแต่ 2022-02-26 08:00:00 UTC ถึง 2022-02-27 07:00:00 UTC และเวลาที่ใช้เป็นตัวอย่างของข้อมูลผลลัพธ์มีช่วงเวลาตั้งแต่ 2022-02-27 08:00:00 UTC ถึง 2022-02-28 07:00:00 UTC กรณีของเวลาช่วงนี้ถูกเลือกมาเป็นตัวอย่างเพื่อแสดงสถานการณ์ที่พบจุดความร้อนบนผิวโลกหลายจุดในประเทศไทยกัมพูชาและได้มีทิศทางลมไหลผ่านบริเวณนี้ไปจนถึงภาคกลางของประเทศไทย จากรูปได้แสดงจุดความร้อนให้เห็นว่าการพบจุดความร้อนหลายจุดในเวลา 3 ชั่วโมงที่ผ่านมาซึ่งเป็นเวลาเดียวกันที่ข้อมูลลมแสดงให้เห็นว่าทิศทางลมไหลจากประเทศกัมพูชาสู่ภาคกลางของประเทศไทย ดังนั้นจึงส่งผลให้เกิดการเพิ่มขึ้นของค่าฝุ่น PM2.5 ในบริเวณนี้ อีกตัวอย่างหนึ่งที่สามารถแสดงได้จากภาพนี้ก็คือมีจุดความร้อนที่ตรวจพบในประเทศลาวและมีทิศทางลมไหลผ่านประเทศไทย ส่งผลให้เกิดค่าฝุ่น PM2.5 สูงในภาคตะวันออกเฉียงเหนือของประเทศไทย และนอกจากนี้ยังมีจุดความร้อนบางจุดในประเทศไทยด้วย ในสถานการณ์นี้ PM2.5 มีความเข้มข้นสูงในประเทศไทยเนื่องจากการมีองค์ประกอบของ PM2.5 ทั้งภายในและภายนอกประเทศ เมื่อเปรียบเทียบการทำนายของแบบจำลองกับผลลัพธ์จริง เราพบว่าความแม่นยำของแบบจำลองไม่เหมือนกันในทุกๆกริด อย่างไรก็ตามแบบจำลองนี้สามารถทำนายค่าฝุ่นที่เป็นภาพรวมในระดับภูมิภาคได้อย่างแม่นยำ

Input (previous 24 hours)



Output (next 24 hours)



รูปที่ 22 แสดงภาพตัวอย่างของข้อมูลขาเข้าและขาออกจากแบบจำลอง SimVP-CFLL-ML โดย A คือ ข้อมูลลมและจุดความร้อนขาเข้า B คือข้อมูลฝุ่นขาเข้า C คือ ค่าจริงของฝุ่นที่ต้องการทำนาย D คือ ค่าทำนายของฝุ่นขาออก

### 5.5 การเปรียบเทียบความสามารถในการทำนายเมื่อเพิ่มแต่ละโมดูลให้กับ SimVP

เพื่อวิเคราะห์ประสิทธิภาพการทำงานของแบบจำลอง SimVP เมื่อเพิ่มแต่ละโมดูล ได้แก่ Cross-Feature Learning Layer และ Masking Layer พบว่าแบบจำลองได้ประสิทธิภาพไม่แตกต่างกันมากนักในการประเมินด้วย MAE และ RMSE อีกทั้งยังแย่งลงเล็กน้อย

ตารางที่ 8 ประสิทธิภาพการทำงานเมื่อเพิ่มแต่ละโมดูลเข้าไปใน SimVP ซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Model	MAE	RMSE	Macro F1
SimVP	4.51	7.63	0.6371
SimVP-ML	4.51	7.59	0.6441
SimVP-CFLL	<b>4.45</b>	<b>7.57</b>	0.6383
SimVP-CFLL-ML	4.51	7.59	<b>0.6557</b>

### 5.6 การทดลองเพิ่มเติม

นอกจากการทดลองหลักที่ได้ปรากฏในงานวิจัยชิ้นนี้ ทางผู้วิจัยได้มีการทดลองเพิ่มเติมเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในแง่มุมอื่นๆ และเพื่อเป็นประโยชน์ต่องานวิจัยในอนาคตต่อไปโดยการทดลองที่ได้เพิ่มมามีดังนี้

#### 5.6.1 การเปรียบเทียบคุณลักษณะของข้อมูลประเภทอื่นๆที่มีความเกี่ยวข้องกับค่าฝุ่น PM2.5

ในการเปรียบเทียบนี้ ผู้วิจัยขอเสนอการทดลองเพิ่มเติมที่พิจารณาความสัมพันธ์ระหว่างคุณลักษณะข้อมูลเพิ่มเติมกับการทำนายค่าฝุ่น PM2.5 โดยใช้แบบจำลอง SimVP-CFLL-ML โดยคุณลักษณะข้อมูลที่เพิ่มเข้ามาได้แก่ อุณหภูมิ ความชื้น และปริมาณน้ำฝน เพื่อวิเคราะห์ผลกระทบของคุณลักษณะข้อมูลเหล่านี้ จึงใช้ข้อมูลจาก ERA5 ได้แก่ ข้อมูลอุณหภูมิ (2m temperature) ข้อมูลความชื้น (2m dewpoint temperature) และข้อมูลน้ำฝน (total precipitation) โดยประสิทธิภาพของแบบจำลองถูกประเมินทั้งแบบ regression และ classification โดยใช้ MAE, RMSE และ Macro F1

ตารางที่ 9 ประสิทธิภาพการทำงานของแบบจำลอง SimVP-CFLL-ML เมื่อเพิ่มคุณลักษณะอื่นๆ ซึ่งตัวหนาคือวิธีการที่ดีที่สุด

Features	MAE	RMSE	Macro F1
<b>(A) Our Work's Features</b>			
PM2.5	4.46	7.64	0.6290
PM2.5 + Wind	4.49	7.67	0.6294
PM2.5 + Fire	4.49	7.63	0.6373
PM2.5 + All Our Work's Features	4.51	7.59	0.6557
<b>(B) Additional Features</b>			
PM2.5 + Temperature	4.48	7.66	0.6278
PM2.5 + Humidity	4.58	7.76	0.6305
PM2.5 + Rainfall	<b>4.38</b>	7.48	0.6397
PM2.5 + All Additional Features	4.46	7.57	0.6427
<b>(C) All Features</b>			
PM2.5 + All Features	4.46	<b>7.47</b>	<b>0.6620</b>

### 5.6.2 การเปรียบเทียบผลของการทำนายในช่วงต่างๆของเดือน

จากการทดลองในงานวิจัยนี้ได้ใช้ข้อมูลในช่วง 10 วันสุดท้ายของเดือนเป็นข้อมูลทดสอบ จึงมีการลองใช้ข้อมูลในช่วงอื่นๆของเดือนในการทดสอบด้วย โดยได้ทำการแบ่งข้อมูลด้วยวิธีการ 3-fold cross validation โดยแบ่งข้อมูลของแต่ละเดือนออกเป็น 3 fold ได้แก่ ต้นเดือน, กลางเดือน และสุดท้ายปลายเดือน โดยประสิทธิภาพของแบบจำลองถูกประเมินทั้งแบบ regression และ classification โดยใช้ MAE และ Macro F1 ได้ผลการทดลองออกมาดังตารางที่ 10

ตารางที่ 10 ประสิทธิภาพการทำงานเมื่อทำนายช่วงอื่นของเดือนด้วย 3-fold cross validation ซึ่ง  
ตัวหนาคือวิธีการที่ดีที่สุดของแต่ละ fold

Model	Fold 1		Fold 2		Fold 3		Average	
	MAE	Macro F1	MAE	Macro F1	MAE	Macro F1	MAE	Macro F1
LSTM	6.27	0.6014	6.51	0.6116	5.82	0.5731	6.20	0.5954
GRU	6.00	0.6333	6.14	0.6341	5.55	0.5912	5.90	0.6195
ConvLSTM	5.28	0.6393	5.56	0.6454	4.96	0.5912	5.27	0.6253
CNN-LSTM	5.31	0.6587	5.75	0.6054	5.02	0.5982	5.36	0.6208
PredRNN	5.27	0.6643	5.43	0.6669	4.67	0.6318	5.12	0.6543
SimVP	4.99	0.6739	<b>5.03</b>	0.6776	<b>4.51</b>	0.6371	<b>4.84</b>	0.6629
SimVP- CFL-ML	<b>4.94</b>	<b>0.6892</b>	5.18	<b>0.6989</b>	<b>4.51</b>	<b>0.6557</b>	4.88	<b>0.6813</b>

### 5.6.3 การทดลองเปรียบเทียบกับแบบจำลอง Prophet

จากการที่งานวิจัยนี้ให้ความสนใจเพียงแต่แบบจำลองที่มาจากการเรียนรู้เชิงลึกเท่านั้นเพราะ  
ได้มีงานวิจัยก่อนหน้านี้ที่ได้ทดลองกับค่าฝุ่น PM2.5 รายงานว่าแบบจำลองที่เป็นการเรียนรู้เชิงลึก  
สามารถเรียนรู้ความสัมพันธ์ที่ไม่เป็นเชิงเส้นได้ดีกว่าแบบจำลองอนุกรมเวลา ในที่นี้จึงเลือกตัวแทน  
แบบจำลองที่นำมาเปรียบเทียบคือแบบจำลอง Prophet ได้ผลการทดลองดังตารางที่ 11

ตารางที่ 11 เปรียบเทียบ SimVP-CFL-ML กับแบบจำลองที่ไม่ได้เป็นการเรียนรู้เชิงลึก Prophet  
ตัวหนาคือวิธีการที่ดีที่สุด

Model	MAE	RMSE	Macro F1
Prophet	5.32	8.62	0.5407
SimVP-CFL-ML	<b>4.51</b>	<b>7.59</b>	<b>0.6557</b>

## บทที่ 6

### สรุปการวิจัยและแนวทางการวิจัยในขั้นถัดไป

#### 6.1 สรุปการวิจัย

วิทยานิพนธ์นี้นำเสนอวิธีการทำนายค่าฝุ่น PM2.5 ทั้งในเชิงพื้นที่และเวลาด้วยเทคนิคการเรียนรู้เชิงลึก โดยเป็นการทำนายแบบภาพรวมทั้งประเทศโดยใช้ข้อมูลฝุ่นของประเทศไทยแบบจำลองที่ใช้ในการทำนายมีพื้นฐานมาจากแบบจำลองที่ใช้ในงานการทำนายเฟรมถัดไปล่าสุดที่มีชื่อว่า Simple yet better Video Prediction (SimVP) นอกจากนี้เพื่อเพิ่มประสิทธิภาพในการทำนายจึงได้เพิ่มเทคนิคต่างๆ ได้แก่ การเพิ่มชั้นการเรียนรู้ความสัมพันธ์ระหว่างคุณลักษณะข้อมูลและชั้นที่กรองผลการทำนายให้ทำนายเฉพาะจุดที่สนใจเท่าซึ่งจะทำให้ระหว่งการสอนแบบจำลองการทำนายจุดที่อยู่นอกเหนือความสนใจจะไม่ถูกมาคำนวณค่าลอส จากการทดสอบวิธีการที่นำเสนอกับค่าฝุ่น PM2.5 ปรากฏว่า วิธีการที่นำเสนอมีประสิทธิภาพที่ดีกว่าวิธีการมาตรฐานในเกือบทุกการประเมิน ประโยชน์ที่ได้วิทยานิพนธ์นี้ คือ ทำนายค่าฝุ่นในเชิงของแผนที่ได้โดยมีความแม่นยำและมีประสิทธิภาพ อีกทั้งผลการทำนายค่าฝุ่นในเชิงแผนที่สามารถเห็นภาพรวมของค่าฝุ่นในพื้นที่ต่างๆ ซึ่งทำให้ง่ายต่อการประกอบการตัดสินใจในการรับมือในพื้นที่ต่างๆ ได้ดียิ่งขึ้น

#### 6.2 ข้อเสนอแนะและข้อจำกัดในงานวิทยานิพนธ์นี้

สถาปัตยกรรมของการเรียนรู้เชิงลึกที่ใช้ในงานวิทยานิพนธ์นี้เน้นการทำนายโดยใช้ข้อมูลก่อนหน้า 24 ชั่วโมงในการทำนาย 24 ชั่วโมงถัดไปเพียงเท่านั้น ทำให้ข้อมูลจำพวกฤดูกาลที่มีผลต่อค่าฝุ่น PM2.5 ยังไม่ได้ถูกนำมาพิจารณา นอกจากนี้ข้อมูลที่ใช้ในงานวิจัยนี้ยังมีเพียง 1 ปีเท่านั้น อีกทั้งจำนวนสถานีวัดค่าฝุ่นยังมีจำนวนไม่มาก ทำให้ตัวแทนค่าฝุ่นของแต่ละกริดอาจจะยังมีค่าไม่ตรงกับค่าฝุ่นที่ควรจะเป็นของกริดนั้นๆ สุดท้ายค่าลมที่ใช้ในงานวิจัยนี้ให้ความสนใจไปที่ค่าลมที่ความสูง 850 hPa เท่านั้น ซึ่งค่าลมที่ความสูงระดับอื่นๆก็สามารถส่งผลกระทบต่อค่าฝุ่นได้เช่นกัน

#### 6.3 แนวทางวิจัยขั้นถัดไป

เนื่องจากข้อจำกัดเรื่องข้อมูลหากในอนาคตมีข้อมูลค่าฝุ่นที่ครอบคลุมประเทศไทยมากยิ่งขึ้นจะสามารถทำนายค่าฝุ่นในเชิงพื้นที่ได้ละเอียดมากขึ้นได้ อีกทั้งในแต่ละฤดูกาลของหนึ่งปีสามารถบอกแนวโน้มของค่าฝุ่น PM2.5 ในช่วงนั้นๆได้ ในส่วนนี้สามารถนำค่าฤดูกาลต่างๆมาปรับใช้เพื่อเพิ่มประสิทธิภาพในการทำนายต่อไป



## บรรณานุกรม

1. Zhu, B., et al. *The impact of crop residue burning on air quality over Yangtze River delta, China: Observation and simulation*. in *2012 IEEE International Geoscience and Remote Sensing Symposium*. 2012.
2. Zhuang, Y., et al., *Understanding the Influence of Crop Residue Burning on PM2.5 and PM10 Concentrations in China from 2013 to 2017 Using MODIS Data*. *International Journal of Environmental Research and Public Health*, 2018. **15**(7): p. 1504.
3. Saxena, P., et al., *Impact of crop residue burning in Haryana on the air quality of Delhi, India*. *Heliyon*, 2021. **7**(5): p. e06973.
4. Lan, R., et al., *Air quality impacts of crop residue burning in India and mitigation alternatives*. *Nature Communications*, 2022. **13**(1): p. 6537.
5. Tai, A.P.K., L.J. Mickley, and D.J. Jacob, *Correlations between fine particulate matter (PM2.5) and meteorological variables in the United States: Implications for the sensitivity of PM2.5 to climate change*. *Atmospheric Environment*, 2010. **44**(32): p. 3976-3984.
6. Hsu, C.-H. and F.-Y. Cheng, *Synoptic Weather Patterns and Associated Air Pollution in Taiwan*. *Aerosol and Air Quality Research*, 2019. **19**(5): p. 1139-1151.
7. Il-Soo, P., et al., *Impact Comparison of Synoptic Meteorology and Nationwide/local Emissions on the Seoul Metropolitan Area during High PM Multi-event and Non-event Days*. *Asian Journal of Atmospheric Environment*, 2020. **14**(3): p. 263-279.
8. Park, I.-S., et al., *Meteorological Characteristics during Periods of Greatly Reduced PM2.5 Concentrations in March 2020 in Seoul*. *Aerosol and Air Quality Research*, 2021. **21**(9): p. 200512.
9. Sukitpaneenit, M. and N.T. Kim Oanh, *Satellite monitoring for carbon monoxide and particulate matter during forest fire episodes in Northern Thailand*. *Environmental Monitoring and Assessment*, 2014. **186**(4): p. 2495-2504.
10. Pantitcha, O. and Katiyalvanovitch, *THE EFFECT OF SEASONAL VARIATION*

- ANDMETEOROLOGICAL DATA ON PM10 CONCENTRATIONS IN NORTHERN THAILAND*. GEOMATE Journal, 2019. **16**(56): p. 46-53.
11. Kayee, J., et al., *Metal Concentrations and Source Apportionment of PM2.5 in Chiang Rai and Bangkok, Thailand during a Biomass Burning Season*. ACS Earth and Space Chemistry, 2020. **4**(7): p. 1213-1226.
  12. Suriya, W., P. Chunpang, and T. Laosuwan, *Patterns of relationship between PM10 from air monitoring quality station and AOT data from MODIS sensor onboard of Terra satellite*. Scientific Review Engineering and Environmental Sciences (SREES), 2021. **30**(2): p. 236-249.
  13. Wang, W. and Y. Guo. *Air Pollution PM2.5 Data Analysis in Los Angeles Long Beach with Seasonal ARIMA Model*. in *2009 International Conference on Energy and Environment Technology*. 2009.
  14. Zhang, L., et al., *Trend analysis and forecast of PM2.5 in Fuzhou, China using the ARIMA model*. Ecological Indicators, 2018. **95**: p. 702-710.
  15. Yan, X. and X. Enhua. *ARIMA and Multiple Regression Additive Models for PM2.5 Based on Linear Interpolation*. in *2020 International Conference on Big Data & Artificial Intelligence & Software Engineering (ICBASE)*. 2020.
  16. Suárez Sánchez, A., et al., *Application of an SVM-based regression model to the air quality study at local scale in the Avilés urban area (Spain)*. Mathematical and Computer Modelling, 2011. **54**(5): p. 1453-1466.
  17. Vong, C.-M., et al., *Short-Term Prediction of Air Pollution in Macau Using Support Vector Machines*. Journal of Control Science and Engineering, 2012. **2012**: p. 518032.
  18. Yang, W., et al., *Prediction of hourly PM2.5 using a space-time support vector regression model*. Atmospheric Environment, 2018. **181**: p. 12-19.
  19. Singh, K.P., et al., *Linear and nonlinear modeling approaches for urban air quality prediction*. Science of The Total Environment, 2012. **426**: p. 244-255.
  20. Hochreiter, S. and J. Schmidhuber, *Long Short-term Memory*. Neural computation, 1997. **9**: p. 1735-80.
  21. Tsai, Y.T., Y.R. Zeng, and Y.S. Chang. *Air Pollution Forecasting Using RNN with LSTM*. in *2018 IEEE 16th Intl Conf on Dependable, Autonomic and Secure*

- Computing, 16th Intl Conf on Pervasive Intelligence and Computing, 4th Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech). 2018.
22. Cho, K., et al., *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation*. 2014.
  23. V, A., et al., *DeepAirNet: Applying Recurrent Networks for Air Quality Prediction*. *Procedia Computer Science*, 2018. **132**: p. 1394-1403.
  24. Cheng, W., et al., *A Neural Attention Model for Urban Air Quality Inference: Learning the Weights of Monitoring Stations*. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018. **32**(1).
  25. Liu, B., et al., *A Sequence-to-Sequence Air Quality Predictor Based on the n-Step Recurrent Prediction*. *IEEE Access*, 2019. **7**: p. 43331-43345.
  26. Liu, B., et al., *A Spatiotemporal Recurrent Neural Network for Prediction of Atmospheric PM2.5: A Case Study of Beijing*. *IEEE Transactions on Computational Social Systems*, 2021. **8**(3): p. 578-588.
  27. Nguyen, M.H., et al., *PM2.5 Prediction Using Genetic Algorithm-Based Feature Selection and Encoder-Decoder Model*. *IEEE Access*, 2021. **9**: p. 57338-57350.
  28. Wen, C., et al., *A novel spatiotemporal convolutional long short-term neural network for air pollution prediction*. *Science of The Total Environment*, 2019. **654**: p. 1091-1099.
  29. Shi, G., et al., *A novel method for identifying hotspots and forecasting air quality through an adaptive utilization of spatio-temporal information of multiple factors*. *Science of The Total Environment*, 2021. **759**: p. 143513.
  30. Xu, X. and M. Yoneda, *Multitask Air-Quality Prediction Based on LSTM-Autoencoder Model*. *IEEE Transactions on Cybernetics*, 2021. **51**(5): p. 2577-2586.
  31. Zhang, Q., et al., *Deep-AIR: A Hybrid CNN-LSTM Framework for Fine-Grained Air Pollution Estimation and Forecast in Metropolitan Cities*. *IEEE Access*, 2022. **10**: p. 55818-55841.
  32. Shi, X., et al., *Convolutional LSTM Network: a machine learning approach for precipitation nowcasting*, in *Proceedings of the 28th International Conference*

- on *Neural Information Processing Systems - Volume 1*. 2015, MIT Press: Montreal, Canada. p. 802–810.
33. Wang, Y., et al., *PredRNN: recurrent neural networks for predictive learning using spatiotemporal LSTMs*, in *Proceedings of the 31st International Conference on Neural Information Processing Systems*. 2017, Curran Associates Inc.: Long Beach, California, USA. p. 879–888.
  34. Wang, Y., et al., *Memory In Memory: A Predictive Neural Network for Learning Higher-Order Non-Stationarity from Spatiotemporal Dynamics*. 2018.
  35. Lin, Z., et al., *Self-Attention ConvLSTM for Spatiotemporal Prediction*. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020. **34**(07): p. 11531-11538.
  36. Chang, Z., et al., *MAU: A Motion-Aware Unit for Video Prediction and Beyond*. *Advances in Neural Information Processing Systems*, 2021. **34**.
  37. Zhangyang, G., et al., *SimVP: Simpler yet Better Video Prediction*. 2022.
  38. Koomsubha, T., *Text Categorization for Thai Corpus Using Character-Level Convolutional Neural Network*, in *Department of Computer Engineering*. 2016, Chulalongkorn University.
  39. Lioma, C., et al., *Deep Learning Relevance: Creating Relevant Information (as Opposed to Retrieving it)*. 2016.
  40. Shi, X., et al., *Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting*. 2015.
  41. Yang, Z., et al., *Dynamic Gesture Recognition Using Surface EMG Signals Based on Multi-Stream Residual Network*. *Frontiers in Bioengineering and Biotechnology*, 2021. **9**: p. 779353.
  42. Hersbach, H., Bell, B., Berrisford, P., Biavati, G., Horányi, A., Muñoz Sabater, J., Nicolas, J., Peubey, C., Radu, R., Rozum, I., Schepers, D., Simmons, A., Soci, C., Dee, D., Thépaut, J-N., *ERA5 hourly data on single levels from 1959 to present*. 2018: Copernicus Climate Change Service (C3S) Climate Data Store (CDS).
  43. *NRT VIIRS 375 m Active Fire product VJ114IMGTDL\_NRT distributed from NASA FIRMS*. <https://earthdata.nasa.gov/firms>.
  44. *NRT VIIRS 375 m Active Fire product VNP14IMGTDL distributed from NASA FIRMS*.

<https://earthdata.nasa.gov/firms>.

45. MODIS Collection 6 Hotspot / Active Fire Detections MCD14ML distributed from NASA FIRMS. <https://earthdata.nasa.gov/firms>.





จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	ณัฐ ศิริสัมพันธ์
วัน เดือน ปี เกิด	24 พฤศจิกายน 2540
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	213/1 ซอยเฉลิมสุข แขวงจันทระเกษม เขตจตุจักร กรุงเทพมหานคร 10900
ผลงานตีพิมพ์	N. Sirisumpun, K. Wongwailikhit, P. Painmanakul and P. Vateekul, "Spatio-Temporal PM2.5 Forecasting in Thailand Using Encoder-Decoder Networks," in IEEE Access, vol. 11, pp. 69601-69613, 2023, doi: 10.1109/ACCESS.2023.3293398.

