

การพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2562

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Thailand's Precipitation Forecasting Using Deep Learning Approach



A Thesis Submitted in Partial Fulfillment of the Requirements  
for the Degree of Master of Science in Computer Science  
Department of Computer Engineering  
Faculty of Engineering  
Chulalongkorn University  
Academic Year 2019  
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยวิธีการ เรียนรู้เชิงลึก
โดย	น.ส.เพ็ญลดา มะโนกิจ
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ดร.กนกศรี ศรีนนภากร

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง  
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

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

คณะกรรมการสอบวิทยานิพนธ์

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

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก  
(ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม  
(ดร.กนกศรี ศรีนนภากร)

..... กรรมการ  
(อาจารย์ ดร.ดวงดาว วิชาดากุล)

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

เพื่อลด ภาระงาน : การพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก. ( Thailand's Precipitation Forecasting Using Deep Learning Approach) อ. ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวทีกุล, อ.ที่ปรึกษาร่วม : ดร.กนกศรี ศรีนภากร

การพยากรณ์น้ำฝนมีความสำคัญมากต่อประเทศไทยในเรื่องของการบริหารจัดการทรัพยากรน้ำ เนื่องจากการพยากรณ์น้ำฝนถูกนำไปใช้ในเรื่องการเตือนภัยว่าจะเกิดน้ำท่วม การวางแผนทางด้านเกษตรกรรม และอื่น ๆ งานวิจัยก่อนหน้าได้มีการพยายามทำนายปริมาณน้ำฝนผ่านข้อมูลที่เป็นโทรมาตรหรือสถานีวัดน้ำฝน โดยใช้แบบจำลองการเรียนรู้ของเครื่อง เช่น แบบจำลองอาร์มา แบบจำลองเคเอ็นเอ็นเข้ามาหาแนวทางการทำนาย จนกระทั่งได้มีแบบจำลองการเรียนรู้เชิงลึกเกิดขึ้น ซึ่งพบว่าแบบจำลองการเรียนรู้เชิงลึกสามารถเข้ามาช่วยทำนายและให้ผลการทำนายที่ดีกว่า อย่างไรก็ตามประเทศไทยยังพบปัญหาในเรื่องชุดข้อมูลไม่สมดุล เนื่องจากประเทศไทยมีช่วงฝนแล้งเป็นปริมาณมากเมื่อเทียบกับช่วงที่ฝนตกจริง ๆ

ดังนั้นในงานวิจัยนี้จะนำเสนอแบบจำลองการเรียนรู้เชิงลึกสองแบบจำลองต่อกันเพื่อแก้ปัญหาการทำนายไม่ได้จากชุดข้อมูลไม่สมดุล ได้แก่ แบบจำลองการจำแนกประเภทเพื่อนำมาจำแนกว่าในช่วงชั่วโมงข้างหน้าฝนจะตกหรือไม่ และแบบจำลองวิเคราะห์การถดถอยเพื่อทำนายปริมาณน้ำฝนที่เกิดขึ้นจริงโดยจะใช้ข้อมูลรับเข้าเฉพาะช่วงที่ฝนตกเท่านั้น นอกเหนือจากนี้งานวิจัยนี้ยังเพิ่มคุณลักษณะโทรมาตรใกล้เคียงเข้ามาช่วยทำนาย โดยงานวิจัยนำเสนอแบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันร่วมกับโครงข่ายประตูดวงกลับ และแบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันร่วมกับตัวเข้ารหัสข้อมูลอัตโนมัติ โดยทดลองจะใช้ข้อมูลปริมาณฝนที่ได้รับการสนับสนุนจากสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) หรือ สสน. โดยผลลัพธ์ของการทดลองแบบจำลองที่นำเสนอสามารถให้ค่าความคลาดเคลื่อนต่ำสุดเมื่อเปรียบเทียบกับปริมาณน้ำฝนทั้งหมดในทุกภาค สุดท้ายนี้งานวิจัยจะนำเสนอถึงแนวทางการทำนายหลายชั่วโมงโดยใช้ข้อมูลที่ถูกรับเข้ามาเป็นข้อมูลรับเข้า

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์

ปีการศึกษา 2562

ลายมือชื่อนิสิต .....

ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

ลายมือชื่อ อ.ที่ปรึกษาร่วม .....

# # 6071024421 : MAJOR COMPUTER SCIENCE

KEYWORD: Rainfall predict, convolutional neural network (CNN), Gated recurrent unit (GRU), Auto-encoder, Multi Layer Perceptron, Imbalanced data  
Fuenglada Manokij : Thailand's Precipitation Forecasting Using Deep Learning Approach. Advisor: Asst. Prof. PEERAPON VATEEKUL Co-advisor: Kanoksri Sarinnapakorn, Ph.D.

Precipitation prediction is necessary to use in water management, especially in Thailand, it can be applied for various water activities, such as flood warning, agriculture planning, etc. There are many prior attempts to forecast rainfall from the rain-gauge station. Some deployed traditional machine learning approaches: ARIMA, k-NN, etc. Recently, deep learning approach has shown promising result in this task. However, the accuracy is still limited since the raining period throughout the year in Thailand is very scarce, so most rainfall amount is zero.

In this research, we propose to cascade two deep learning networks: one is a classification to classify whether it is rain or not, and the other is a regression model to predict rainfall amount. Moreover, we use neighbor rainfall stations to help more accurate rainfall prediction. Our purpose models are a combination between CNN and GRU and a combination between CNN and auto-encoder and MLP. The experiment was conducted on hourly rainfall dataset received from the public government sector in Thailand. We use RMSE as performance metric to evaluate models and the results show that our cascading model give the lowest RMSE on average over all regions. Furthermore, we also multistep by applying a rolling mechanism that used the predicted rainfall predict the next 6 steps.

Field of Study: Computer Science

Student's Signature .....

Academic Year: 2019

Advisor's Signature .....

Co-advisor's Signature .....

## กิตติกรรมประกาศ

การที่วิทยานิพนธ์ฉบับนี้จะสำเร็จได้ด้วยดีนั้น นอกจากตัวผู้วิจัยเองแล้ว ยังมีบุคคลสำคัญอีกหลายท่านที่เป็นส่วนสำคัญในการจัดทำวิทยานิพนธ์ฉบับนี้ขึ้นมา ผู้วิจัยขอใช้กิตติกรรมประกาศของวิทยานิพนธ์แสดงความขอบพระคุณอย่างสูงมา ณ ที่นี้

ขอขอบพระคุณ อาจารย์ที่ปรึกษา ผศ. ดร. พีรพล เวทีกุล ผู้เป็นแรงผลักดันสำคัญที่ทำให้วิทยานิพนธ์สำเร็จได้ โดยอาจารย์คอยให้ความรู้ คำแนะนำ และคำปรึกษาตั้งแต่ผู้วิจัยได้เริ่มเรียนต่อในระดับชั้นปริญญาโทและยังไม่มีความรู้ใดๆ เกี่ยวกับแบบจำลองการเรียนรู้เชิงลึก นอกเหนือจากนี้อาจารย์ยังคอยให้กำลังใจอย่างเต็มที่และแก้ปัญหาให้แก่ผู้วิจัยและเพื่อนตลอดระยะเวลาที่จัดทำวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณ อาจารย์ที่ปรึกษาร่วม ดร. กนกศรี ศรีนนภากร ผู้เป็นส่วนสำคัญที่ทำให้วิทยานิพนธ์สามารถดำเนินต่อได้ โดยอาจารย์มีความเมตตาต่อผู้วิจัยอย่างมาก อาจารย์เป็นผู้ให้ข้อมูลที่สำคัญแก่ผู้วิจัย รวมทั้งคำแนะนำและคำปรึกษาตลอดการวิจัยที่ผ่านมา หากไม่มีอาจารย์ วิทยานิพนธ์ฉบับนี้จะไม่สำเร็จได้เลย

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ ซึ่งประกอบด้วย ศ. ดร. บุญเสริม กิจศิริกุล อ. ดร. ดวงดาว วิชาตากุล และดร. ธนภัทร ชังคะจิตร ที่กรุณาให้เกียรติเป็นคณะกรรมการให้กับผู้วิจัย รวมทั้งยังให้คำแนะนำและความรู้ที่สำคัญแก่ผู้วิจัยเพื่อที่สามารถนำไปต่อยอดในงานวิจัยได้

ขอขอบพระคุณ สถาบันสารสนเทศทรัพยากรน้ำ หรือ สสน. ที่ไว้วางใจผู้วิจัย โดยสนับสนุนให้ผู้วิจัยถือข้อมูลปริมาณน้ำฝน ซึ่งเป็นข้อมูลที่สำคัญต่อทางสถาบันและเป็นส่วนประกอบสำคัญที่สุดในวิทยานิพนธ์ฉบับนี้ รวมทั้งให้ผู้วิจัยได้เข้าไปใช้ทรัพยากรของทางสถาบัน

ขอขอบพระคุณ เพื่อน พี่ และ น้องใน “Data Mining Group, MIND Lab” และปริญญาโททุกท่านสำหรับการให้กำลังใจซึ่งกันและกัน รวมทั้งคอยให้ความรู้และคำแนะนำต่าง ๆ ที่นำมาปรับใช้ในวิทยานิพนธ์

และท้ายสุด ขอขอบพระคุณครอบครัวและบุคคลอันเป็นที่รักของผู้วิจัย ที่ให้กำลังใจและสนับสนุนผู้วิจัยในทุก ๆ ด้าน ตลอดระยะเวลาที่ผู้วิจัยได้เริ่มเส้นทางการศึกษาต่อปริญญาโทจนจบ การทำวิทยานิพนธ์ฉบับนี้ถือเป็นอีกหนึ่งประสบการณ์ที่คุณค่ามากต่อผู้วิจัย ผู้วิจัยจะนำสิ่งที่ได้รับส่งต่อเป็นแรงผลักดันให้กับบุคคลถัดไปที่อยู่ในเส้นทางของการทำวิทยานิพนธ์

เฟื่องลดา มะโนกิจ



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ช
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ .....	1
1.1 ความเป็นมาและความสำคัญของปัญหา .....	1
1.2 วัตถุประสงค์ของการวิจัย.....	4
1.3 ขอบเขตการวิจัย.....	4
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	4
1.5 ขั้นตอนการดำเนินงาน.....	5
1.6 ผลงานวิจัยที่ตีพิมพ์.....	5
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง .....	6
2.1 ฝนและการวัดปริมาณน้ำฝน .....	6
2.2 แบบจำลองอาร์มีมา (Arima Model) .....	9
2.3 นิวรอลเน็ตเวิร์ก (Neural Network).....	11
2.4 ตัวเข้ารหัสอัตโนมัติ (Auto-Encoder).....	14
2.5 นิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolution Neural Network) .....	14
2.6 หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory).....	18
2.7 โครงข่ายประตูกลับ (Gated Recurrent Unit Network).....	20



2.8 การวัดประสิทธิภาพ (Performance Evaluation) .....	21
บทที่ 3 งานวิจัยที่เกี่ยวข้อง .....	24
3.1 งานวิจัยในกลุ่มแบบจำลองอนุกรมเวลา.....	24
3.2 งานวิจัยในกลุ่มแบบจำลองการเรียนรู้เชิงลึก.....	25
บทที่ 4 แนวคิดและวิธีการดำเนินงาน.....	30
4.1 ข้อมูลรับเข้าและการเตรียมข้อมูล .....	30
4.2 แบบจำลองการทำนายปริมาณน้ำฝนในชั่วโมงถัดไป .....	34
4.3 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายขั้นโดยใช้เทคนิคการใส่ข้อมูลที่ถูกรายงานแล้ว เป็นข้อมูลรับเข้าเพื่อทำนายขั้นถัดไป .....	38
บทที่ 5 การทดลองและผลการทดลอง .....	41
5.1 ชุดข้อมูล.....	41
5.2 การเลือกใช้นอร์มัลไลเซชัน.....	43
5.3 แบบจำลองอื่น ๆ เพื่อนำมาเปรียบเทียบประสิทธิภาพ.....	43
5.4 การปรับจูนค่าไฮเปอร์พารามิเตอร์ของแบบจำลอง (Hyper-Parameter Tuning) .....	46
5.5 การวัดผล.....	47
5.6 ผลการทดลอง.....	48
บทที่ 6 สรุปการวิจัยและแนวทางการวิจัยในขั้นถัดไป .....	64
6.1 สรุปการวิจัย .....	64
6.2 ข้อจำกัดของงานวิจัย .....	65
6.3 แนวทางการวิจัยในอนาคต .....	66
บรรณานุกรม.....	67
ประวัติผู้เขียน.....	70

## สารบัญตาราง

	หน้า
ตารางที่ 1 คอนฟิวชันเมทริกซ์ของการจำแนกแบบ 2 คลาส .....	22
ตารางที่ 2 ข้อมูลตัวแปรทั้งหมดที่นำมาใช้ในงานวิจัยของ Hernández, Emilcy .....	26
ตารางที่ 3 แสดงการปรับจูนค่าไฮเปอร์พารามิเตอร์ในแบบจำลองสองแบบต่อกันโดยผสมนิเวศ เน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกลับ.....	46
ตารางที่ 4 แสดงการปรับจูนค่าไฮเปอร์พารามิเตอร์ในแบบจำลองสองแบบต่อกันโดยผสมนิเวศ เน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น .....	47
ตารางที่ 5 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาด กำลังสอง (RMSE) ในหน่วยมิลลิเมตรซึ่งพิจารณาจากปริมาณน้ำฝนทั้งหมดและแบ่งแยกตามภาค..	48
ตารางที่ 6 ค่าเอพวันจากแบบจำลองจำแนกข้อมูล .....	49
ตารางที่ 7 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาด กำลังสอง (RMSE) ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนตกและแบ่งแยกตามภาค .....	50
ตารางที่ 8 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาด กำลังสอง (RMSE) ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนไม่ตกและแบ่งแยกตามภาค .....	50
ตารางที่ 9 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ย ความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนทั้งหมดและ แบ่งแยกตามภาค .....	53
ตารางที่ 10 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ย ความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนตกและ แบ่งแยกตามภาค .....	55
ตารางที่ 11 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ย ความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนไม่ตก และแบ่งแยกตามภาค.....	56
ตารางที่ 12 เปรียบเทียบประสิทธิภาพของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ช่วงที่ฝนตกในแต่ละระดับของปริมาณน้ำฝน .....	57

ตารางที่ 13 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนาย ปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคกลาง .. 58

ตารางที่ 14 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนาย ปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคตะวันออกเฉียงเหนือ ..... 59

ตารางที่ 15 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนาย ปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคเหนือ .. 59

ตารางที่ 16 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนาย ปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาค ตะวันออกเฉียงเหนือ ..... 60

ตารางที่ 17 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนาย ปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคใต้..... 60

ตารางที่ 18 เปรียบเทียบประสิทธิภาพ RMSE ในหน่วยมิลลิเมตรของแบบจำลอง Multi-step และ แบบจำลอง Rolling mechanism โดยพิจารณาช่วงที่ฝนตกแต่ละระดับของภาคใต้..... 63

## สารบัญรูปภาพ

	หน้า
รูปที่ 1 ตัวอย่างกราฟที่ข้อมูลมีความคงที่ (Stationary) และข้อมูลมีแนวโน้ม (Trend).....	10
รูปที่ 2 โครงสร้างเพอร์เซปตรอนเมื่อแต่ละข้อมูลรับเข้ามีน้ำหนัก (weight) .....	12
รูปที่ 3 โครงสร้างตัวเข้ารหัสอัตโนมัติ .....	14
รูปที่ 4 นิเวรอลเน็ตเวิร์กคอนโวลูชันแบบ LeNet-5.....	15
รูปที่ 5 การทำคอนโวลูชันแบบแคบเมื่อมีขนาดของตัวกรองเป็น $3 \times 3$ .....	16
รูปที่ 6 การทำคอนโวลูชันแบบกว้างและวิธีการเสริมเติม.....	16
รูปที่ 7 การกำหนดการก้าวข้ามเป็น 2.....	17
รูปที่ 8 ตัวอย่างของขั้นตอนการรวมโดยเลือกค่ามากที่สุดและเลือกจากค่าเฉลี่ย .....	18
รูปที่ 9 โครงสร้างของหน่วยความจำระยะสั้นแบบยาว .....	19
รูปที่ 10 เปรียบเทียบโครงสร้างของแบบจำลองหน่วยความจำสั้นระยะยาว (ซ้าย).....	21
รูปที่ 11 โครงสร้างแบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น .....	27
รูปที่ 12 รายละเอียดตัวแปรที่วัดได้.....	28
รูปที่ 13 แนวทางการนำสถานีใกล้เคียงมาใช้ โดยสถานีที่สนใจที่กำหนดด้วย 0 ตรงกึ่งกลาง และ แบ่งพื้นที่ออกเป็น 8 ( $1 - 8$ ) ส่วนกับ 3 ช่วงระยะทางที่ห่างจากสถานีที่สนใจ (A, B, C).....	28
รูปที่ 14 โครงสร้างแบบจำลองนิเวรอลเน็ตเวิร์กคอนโวลูชันแบบมัลติทาสก์ .....	29
รูปที่ 15 ระยะทางของโทรมাত্রใกล้เคียงในบริเวณเดียวกับโทรมাত্রที่สนใจ KTLE หน่วยเป็น กิโลเมตร.....	33
รูปที่ 16 ค่าสหสัมพันธ์ (Correlation) ตัวแปรอุณหภูมิของโทรมাত্রที่สนใจในภาคใต้ (KTLE) และ โทรมাত্রใกล้เคียง (PANG , BTWN และ BMDG) .....	34
รูปที่ 17 ค่าสหสัมพันธ์ (Correlation) ตัวแปรความชื้นของโทรมাত্রที่สนใจในภาคใต้ (KTLE) และ โทรมাত্রใกล้เคียง (PANG , BTWN และ BMDG) .....	34

รูปที่ 18 โครงสร้างแบบจำลองสองแบบต่อกันโดยใช้แบบจำลองจำแนกประเภท (1) และแบบจำลองวิเคราะห์การถดถอย (2)..... 35

รูปที่ 19 โครงสร้างแบบจำลองที่นำเสนอโดยผสมนิเวศน์เน็ตเวิร์กคอนโวลูชัน และโครงข่ายประตูกลับ ..... 37

รูปที่ 20 โครงสร้างแบบจำลองที่นำเสนอโดยผสมนิเวศน์เน็ตเวิร์กคอนโวลูชัน และตัวเข้ารหัสข้อมูลร่วมกับเพอร์เซปตรอนหลายชั้น..... 38

รูปที่ 21 กระบวนการทำนายปริมาณน้ำฝนแบบหลายชั้นตอนโดยใช้เทคนิคการใส่ข้อมูลที่ถูกทำนายเป็นข้อมูลรับเข้าเพื่อทำนายขั้นถัดไป..... 39

รูปที่ 22 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายชั้นโดยใช้ แบบจำลองวิเคราะห์การถดถอยเป็นโครงข่ายประตูกลับ..... 40

รูปที่ 23 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายชั้นโดยใช้ แบบจำลองวิเคราะห์การถดถอยเป็นตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น ..... 40

รูปที่ 24 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลฝึกสอน (Training data) ..... 41

รูปที่ 25 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลตรวจสอบ (Validation data)..... 41

รูปที่ 26 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลทดสอบ (Test data)..... 42

รูปที่ 27 อัตราส่วนของช่วงที่ฝนไม่ตกและฝนตกในภาคใต้ในชุดข้อมูลฝึกสอน ..... 42

รูปที่ 28 อัตราส่วนของช่วงที่ฝนไม่ตกและฝนตกในภาคตะวันออกเฉียงเหนือในชุดข้อมูลฝึกสอน .... 42

รูปที่ 29 แบบจำลองมัลติทาสก์แบบนิเวศน์เน็ตเวิร์กคอนโวลูชัน..... 45

รูปที่ 30 แบบจำลองมัลติทาสก์แบบโครงข่ายประตูกลับ ..... 45

รูปที่ 31 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคใต้จากแบบจำลองอาร์มี..... 51

รูปที่ 32 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคใต้จากแบบจำลอง Cascade..... 51

รูปที่ 33 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคตะวันออกเฉียงเหนือจากแบบจำลองอาร์มี..... 52

รูปที่ 34 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคตะวันออกเฉียงเหนือจากแบบจำลอง Cascade ..... 52

รูปที่ 35 ค่าสหสัมพันธ์ (Correlation) ตัวแปรปริมาณน้ำฝนของโทรมาตรที่สนใจในภาคตะวันออก (KRKM) และโทรมาตรใกล้เคียง (BGBO, BLKO, BNKN, STOR และ BDCP).....	54
รูปที่ 36 ค่าสหสัมพันธ์ (Correlation) ตัวแปรปริมาณน้ำฝนของโทรมาตรที่สนใจในภาคเหนือ (BTTI) และโทรมาตรใกล้เคียง (MECN, DIWO, TTON, CGSN, RIKK และ WGCI) .....	55
รูปที่ 37 ผลการทำนายปริมาณน้ำฝน (สีแดง) เมื่อเปรียบเทียบกับน้ำฝนจริง (สีน้ำเงิน) ในแต่ละ ชั่วโมง ล่วงหน้าด้วยวิธี Rolling mechanism ของภาคใต้ .....	61
รูปที่ 38 ผลการทำนายปริมาณน้ำฝน (สีแดง) เมื่อเปรียบเทียบกับน้ำฝนจริง (สีน้ำเงิน) ในแต่ละ ชั่วโมง ล่วงหน้าด้วยวิธี Multi-Step ของภาคใต้ .....	62



## บทที่ 1

### บทนำ

วิทยานิพนธ์นี้ถูกจัดทำเพื่อต้องการนำเสนอแนวทางการทำนายปริมาณน้ำฝนของประเทศไทย โดยบทนำจะเกริ่นถึงความเป็นมาและความสำคัญของปัญหาของการทำนายปริมาณน้ำฝน วัตถุประสงค์ของการวิจัย ขอบเขตของการวิจัย ประโยชน์ที่คาดว่าจะได้รับ รวมถึงแผนการดำเนินงาน และผลงานตีพิมพ์ที่เกี่ยวข้องการทำนายปริมาณน้ำฝน

#### 1.1 ความเป็นมาและความสำคัญของปัญหา

การพยากรณ์ปริมาณน้ำฝนระยะสั้นมีความสำคัญต่อประเทศไทยมากในเรื่องการจัดสรรทรัพยากรน้ำ การวางแผนด้านการเกษตร รวมถึงการเตือนภัยเมื่อเกิดฝนตกหนัก อันสืบเนื่องมาจากเหตุการณ์น้ำท่วมใหญ่ในปี พ.ศ. 2554 ที่ทำให้หน่วยงานที่เกี่ยวข้องคอยเฝ้าระมัดระวังเวลาฝนตก และ คำนึงถึงปริมาณน้ำฝนที่เกิดมากขึ้น การพยากรณ์ปริมาณน้ำฝนให้แม่นยำนั้นถือว่าเป็นงานที่มีความท้าทายในศาสตร์ของพยากรณ์อากาศ เนื่องจากประเทศไทยมีความแปรปรวนทางด้านสภาพอากาศค่อนข้างสูง และเปลี่ยนแปลงอย่างรวดเร็วในระยะเวลานั้น จึงทำให้ยากต่อการจับรูปแบบที่ชัดเจนในการทำนาย รวมถึงงานในด้านนี้ยังไม่ค่อยแพร่หลายในประเทศไทยมากนัก

โดยปกติแบบจำลอง (Model) ที่นักอุตุนิยมวิทยานิยมใช้ในการพยากรณ์ปริมาณน้ำฝน คือแบบจำลองการพยากรณ์อากาศเชิงตัวเลข (Numerical Weather Predict : NWP model) ซึ่งเป็นแบบจำลองที่ใช้หลักการทางคณิตศาสตร์และฟิสิกส์ประยุกต์เข้าร่วมกัน เพื่อช่วยบอกอัตราการเปลี่ยนแปลงของตัวแปรทางอุตุนิยมวิทยาต่าง ๆ เช่น ลม ความกดอากาศ อุณหภูมิ และปริมาณความชื้นในอากาศ จากนั้นนำมาวิเคราะห์ร่วมกันเพื่อให้สามารถพยากรณ์ปริมาณฝนล่วงหน้าได้ แต่เนื่องจากมีปริมาณข้อมูลจำนวนมาก รวมถึงวิธีการคำนวณมีลักษณะยุ่งยากซับซ้อนเนื่องจากใช้สมการทางคณิตศาสตร์ จำเป็นต้องใช้คอมพิวเตอร์ขนาดใหญ่และมีความเร็วสูงในการประมวลผลสาเหตุดังกล่าวจึงเป็นที่มาถึงการหาแนวทางในการพยากรณ์โดยใช้วิธีการคำนวณอื่น ๆ ที่ไม่สูญเสียทรัพยากรเท่าแบบจำลองการพยากรณ์อากาศเชิงตัวเลข และได้ผลที่รวดเร็วกว่า

งานวิจัยทางคอมพิวเตอร์ด้านการพยากรณ์ปริมาณน้ำฝนสามารถแบ่งได้เป็น 3 เทคนิคหลัก เทคนิคแรกคือแบบจำลองอนุกรมเวลา (Time-series model) งานวิจัย [1] ใช้แบบจำลองอาร์มา (Arima) ที่เป็นแบบจำลองประเภทหนึ่งในหมวดแบบจำลองอนุกรมเวลาเพื่อจัดการกับข้อมูลที่มีลักษณะเกี่ยวข้องกันทางด้านเวลา กล่าวคือ ข้อมูลในอดีตสามารถส่งผลต่อข้อมูลในอนาคต งานวิจัยดังกล่าวจึงนำข้อมูลจากสถานีวัดปริมาณน้ำฝนสะสมของวันก่อนหน้ามาพยากรณ์ปริมาณน้ำฝนและอุณหภูมิบรรยากาศในวันถัดไปผ่านแบบจำลองอาร์มา จากนั้นทำการเปรียบเทียบการพยากรณ์

ปริมาณน้ำฝนแยกตามพื้นที่ที่แตกต่างกันในยุโรป โดยใช้ข้อมูลจากสถานีน้ำฝนที่ติดตั้งในแต่ละพื้นที่จำนวน 4 สถานี เทคนิคที่สองคือเทคนิคการเรียนรู้ของเครื่อง (Machine learning) ในงานวิจัย [2-4] มีการนำเทคนิคการเรียนรู้ของเครื่องหลากหลายรูปแบบ ได้แก่ ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Programming : GP) ซัพพอร์ตเวกเตอร์แบบการวิเคราะห์แบบรีเกรสชัน (Support Vector Regression : SVR) เครือข่ายฟังก์ชันฐานรัศมี (Radial basis neural networks) กฎเอ็มไฟว์ (M5 rules) แบบจำลองต้นไม้ตัดสินใจชนิดเอ็มไฟว์ (M5 model trees) และเคเนียบเรสเนเบอร์ (k-Nearest Neighbors : k-NN) มาทำนายปริมาณน้ำฝนสะสมรายวัน ซึ่งมีจุดประสงค์เพื่อเปรียบเทียบประสิทธิภาพของเทคนิคการเรียนรู้ของเครื่องว่าเทคนิคใดให้ผลค่าความคลาดเคลื่อนต่ำที่สุด ทั้งนี้ งานวิจัยยังได้นำเสนอวิธีการปรับเรียบข้อมูล (Smoothing data) เพื่อให้ข้อมูลที่มีความผันผวนสูงอย่างข้อมูลปริมาณน้ำฝนอยู่ในรูปแบบที่แบบจำลองสามารถจดจำได้ โดยมีจุดประสงค์คือการเพิ่มความแม่นยำในการทำนาย

เทคนิคสุดท้ายคือการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep learning model) ซึ่งเป็นเทคนิคที่ซับซ้อนมากขึ้น เพื่อช่วยเพิ่มความแม่นยำในพยากรณ์ ในช่วงแรกได้มีคิดค้นการนำวิธีทางปัญญาประดิษฐ์ (Artificial Intelligence : AI) โดยการสร้างนิวรอลเน็ตเวิร์ก (Artificial Neural Network : ANN) ขึ้นมา เพื่อใช้หาลักษณะความสัมพันธ์ระหว่างชุดข้อมูล จึงทำให้นักวิจัยหลายท่านเริ่มหันมาสนใจการนำวิธีดังกล่าวมาประยุกต์ใช้ในศาสตร์ของการพยากรณ์ และกลายเป็นแบบจำลองการเรียนรู้เชิงลึกที่ต่อยอดจากนิวรอลเน็ตเวิร์ก โดยมีการเพิ่มชั้นซ่อนตัว (Hidden layer) เพื่อเพิ่มความสามารถในการคิดมากขึ้น ข้อดีของวิธีการเรียนรู้เชิงลึกคือมนุษย์ไม่จำเป็นต้องคัดกรองลักษณะพิเศษของชุดข้อมูลด้วยตัวเอง โดยแบบจำลองจะคิดและประมวลผลให้แทนโดยอัตโนมัติ ซึ่งในแวดวงพยากรณ์ แบบจำลองการเรียนรู้ประสบความสำเร็จในการสกัดหาคุณลักษณะพิเศษของชุดข้อมูลที่ซับซ้อน งานวิจัย [5] ได้นำมาประยุกต์ใช้กับการพยากรณ์อากาศ โดยสกัดคุณลักษณะสำคัญของข้อมูลที่ถูกรวบรวมจากประวัติของชั้นบรรยากาศในประเทศฮ่องกงเพื่อทำนายสภาพอากาศที่เปลี่ยนไปในอีก 24 ชั่วโมงข้างหน้า ซึ่งเราสามารถนำแบบจำลองการเรียนรู้เชิงลึกมาหาคุณลักษณะที่บ่งชี้ถึงการเกิดฝนได้ ในช่วงระยะที่ผ่านมา มีนักวิจัยหลายท่านได้คิดค้นแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ทำนายปริมาณน้ำฝนโดยการเพิ่มชั้นซ่อนตัวในวิธีการเรียนรู้เชิงลึก เช่น การใช้วิธีเพอร์เซปตรอนหลายชั้น (Multi-Layer Perceptron : MLP) หรือ วิธีเข้ารหัสอัตโนมัติ (Auto-encoder) โดยวิธีการที่กล่าวมาใช้กับข้อมูลที่เป็นสถานีวัดปริมาณน้ำฝนเพื่อสกัดตัวแปรสำคัญ ในด้านของคอมพิวเตอร์วิทัศน์ (Computer vision) การเรียนรู้เชิงลึกถูกนำมาวิเคราะห์ภาพถ่ายเรดาร์ผ่านนิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolutional Neural Network : CNN) เพื่อหาลักษณะเมฆที่ทำให้เกิดฝน หรือ ลมมรสุม และ นอกจากนี้วิธีเรียนรู้เชิงลึกยังสามารถหาความสัมพันธ์ทางด้านอนุกรมเวลา โดยใช้นิวรอลเน็ตเวิร์กแบบวนซ้ำ (Recurrent Neural Network : RNN) ได้อีกด้วย



งานวิจัยนี้นำข้อมูลจากโทรมาตรวัดปริมาณน้ำฝนที่ได้รับการสนับสนุนจากสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) หรือ สสน. โดยมีจุดติดตั้งทั้งหมด 469 แห่งของประเทศไทยและเก็บข้อมูลรายชั่วโมงตั้งแต่ปี ค.ศ. 2012 ถึงปี ค.ศ. 2018 มาฝึกฝนในแบบจำลองการเรียนรู้เชิงลึก เพื่อให้แบบจำลองสกัดลักษณะสำคัญจากตัวแปรทางภูมิอากาศที่ส่งผลต่อการเกิดฝนและทำนายปริมาณน้ำฝนที่เกิดขึ้นในอีกหนึ่งชั่วโมงข้างหน้า โดยปัญหาที่พบคือประเทศไทยมีรูปแบบการเกิดฝนที่ค่อนข้างผันผวน จึงทำให้ยากต่อการทำนาย รวมถึงชั่วโมงที่ “ฝนไม่ตก” มีมากกว่า “ฝนตก” โดยเปรียบเทียบสัดส่วนข้อมูลรายโทรมาตร พบว่ามีชั่วโมงฝนไม่ตกประมาณ 95 เปอร์เซ็นต์ของข้อมูลทั้งหมด ก่อให้เกิดปัญหาชุดข้อมูลไม่สมดุล (Imbalanced data)

ในส่วนของการนำข้อมูลมาใช้งาน นอกเหนือจากการใช้ข้อมูลปริมาณน้ำฝนตรงบริเวณที่สนใจแล้ว งานวิจัยนี้ได้นำข้อมูลจากโทรมาตรใกล้เคียงเข้ามาช่วยพยากรณ์น้ำฝนด้วย โดยพิจารณาจากความสัมพันธ์เชิงพื้นที่ของแต่ละโทรมาตร แล้วนำข้อมูลเข้าสู่แบบจำลองการเรียนรู้เชิงลึก 2 แบบจำลองต่อกัน (Cascade models) ได้แก่ แบบจำลองการจำแนกข้อมูล (Classification model) ที่นำนิรอลเน็ตเวิร์กคอนโวลูชันมาพิจารณาความสัมพันธ์ของคุณลักษณะเพื่อจำแนกว่าอีกหนึ่งชั่วโมงข้างหน้าฝนจะตกหรือไม่ตก และแบบจำลองการถดถอย (Regression model) เพื่อทำนายปริมาณน้ำฝน งานวิจัยนี้ได้นำเสนอแบบจำลองสองแบบที่นำมาใช้ทำนายปริมาณน้ำฝนในอีกหนึ่งชั่วโมงข้างหน้าโดยสนใจเฉพาะช่วงเวลาที่ไม่ตกซึ่งเป็นผลลัพธ์จากแบบจำลองการจำแนกข้อมูล โดยแบบจำลองแรกคือโครงข่ายประตูกลับ (Gated Recurrent Unit : GRU) สำหรับพิจารณาความสัมพันธ์ในเชิงแกนเวลา เนื่องจากข้อมูลฝนโทรมาตรเมื่อพิจารณาแล้วพบว่าระยะเวลาก่อนหน้านี้ นาน ๆ ไม่ส่งผลกระทบต่อเกิดการเกิดฝนในเวลาปัจจุบัน หรือกล่าวได้ว่าข้อมูลไม่มีการพึ่งพากันระยะยาว (Long-term dependency) และแบบจำลองที่สองคือแบบจำลองตัวเข้ารหัสอัตโนมัติ (Auto-encoder model) ร่วมกับเพอร์เซปตรอนหลายชั้น (Multi-layer perceptron) โดยนำแนวคิดเรื่องการลดมิติของข้อมูล (Dimensionality reduction) มาใช้ร่วมกับข้อมูลปริมาณน้ำฝนและสภาพอากาศ เพื่อเพิ่มความสามารถในการดักจับปริมาณน้ำฝนที่มีค่าสูง ทำให้แบบจำลองมีประสิทธิภาพในการทำนายดีขึ้น

แบบจำลองต่อกันมีจุดประสงค์คือต้องการตัดบริเวณที่ฝนไม่ตกออก และนำบริเวณที่มีฝนตกจริง ๆ เข้าแบบจำลองการพยากรณ์ปริมาณน้ำฝน เพื่อให้แบบจำลองสามารถเรียนรู้รูปแบบที่มีการเกิดฝนได้ดีขึ้น เมื่อสรุปผลการทดลองทั้งหมดโดยพิจารณาจากประสิทธิภาพการพยากรณ์ของชุดข้อมูลปริมาณน้ำฝนรายโทรมาตรแบบแบ่งแยกภาค เนื่องจากแต่ละภาคมีพฤติกรรมการเกิดฝนแตกต่างกัน พบว่าแบบจำลอง 2 แบบต่อกันโดยใช้นิรอลเน็ตเวิร์กคอนโวลูชันร่วมกับแบบจำลองตัวเข้ารหัสอัตโนมัติให้ผลการพยากรณ์ที่ดีกว่าการใช้นิรอลเน็ตเวิร์กคอนโวลูชันร่วมกับโครงข่ายประตูกลับ สุดท้ายงานวิจัยนี้จะพยากรณ์ปริมาณน้ำฝนเฉพาะพื้นที่ภายในประเทศไทยเท่านั้น

## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อนำเสนอแนวทางการพยากรณ์ปริมาณน้ำฝนของประเทศไทยด้วยแบบจำลองการเรียนรู้เชิงลึก โดยมุ่งเน้นให้แบบจำลองสามารถวิเคราะห์คุณลักษณะสำคัญจากข้อมูลฝนและพิจารณาความสัมพันธ์ของแต่ละคุณลักษณะในอดีต รวมทั้งการแก้ปัญหาชุดข้อมูลไม่สมดุล เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ปริมาณน้ำฝนให้มีค่าความคลาดเคลื่อนต่ำที่สุด เมื่อเปรียบเทียบกับผลลัพธ์จากแบบจำลองอนุกรมเวลาที่เป็นมาตรฐานในการทำนายข้อมูลเกี่ยวกับอนุกรมเวลา และแบบจำลองการเรียนรู้เชิงลึกพื้นฐาน

## 1.3 ขอบเขตการวิจัย

1. ข้อมูลที่ใช้ในงานวิจัยนี้ คือ ข้อมูลระดับปริมาณน้ำฝนรายชั่วโมงที่มาจากสถานีวัดปริมาณน้ำฝนทั่วประเทศไทย โดยได้รับการสนับสนุนข้อมูลจากสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) หรือ สสน. ตั้งแต่ปี ค.ศ. 2012 ถึง ปี ค.ศ. 2018
2. นำข้อมูลตัวแปรสภาพอากาศมาวิเคราะห์ร่วมกับข้อมูลปริมาณน้ำฝน
3. นำข้อมูลโทรมาตรใกล้เคียงมาวิเคราะห์ร่วมกับโทรมาตรที่สนใจ
4. สร้างแบบจำลองทำนายปริมาณฝนล่วงหน้าหนึ่งชั่วโมงเพื่อใช้วัดประสิทธิภาพในการทำนาย
5. สร้างแบบจำลองทำนายปริมาณฝนล่วงหน้าหกชั่วโมงโดยใช้เทคนิคการนำข้อมูลวงกลับ (Rolling mechanism)
6. ทำการวัดประสิทธิภาพของแบบจำลองโดยพิจารณาจากค่าความคลาดเคลื่อนเฉลี่ยของการพยากรณ์ปริมาณน้ำฝนโดยวัดแต่ละภาคของประเทศไทย
7. เปรียบเทียบประสิทธิภาพของแบบจำลองที่นำเสนอซึ่งเป็นแบบจำลองแบบจำลองต่อกันที่ใช้นิเวศน์เน็ตเวิร์กคอนโวลูชันร่วมกับโครงข่ายประตูกลับ โดยเปรียบเทียบผลลัพธ์กับแบบจำลองอนุกรมเวลา แบบจำลองที่ทันสมัย (State-of-the-art) ที่ใช้แบบจำลองบีบอัดข้อมูลร่วมกับเพอร์เซปตรอนหลายชั้น แบบจำลองการเรียนรู้เชิงลึกพื้นฐาน ได้แก่ นิเวศน์เน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกลับ

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถปรับปรุงประสิทธิภาพของการทำนายพยากรณ์อากาศโดยใช้การสร้างแบบจำลองการเรียนรู้เชิงลึกกับข้อมูลปริมาณน้ำฝน
2. สามารถสร้างแบบจำลองในการจัดการปัญหาเรื่องชุดข้อมูลที่ไม่สมดุล ซึ่งปัญหานี้อาจเกิดกับฝนที่ตกอยู่พื้นที่ที่มีภูมิอากาศร้อนชื้น

3. สามารถหาความสัมพันธ์ของตัวแปรในข้อมูลปริมาณน้ำฝนว่ามีผลต่อการเกิดฝนมากน้อยอย่างไร

### 1.5 ขั้นตอนการดำเนินงาน

1. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง
2. ดำเนินการทดลองโดยพัฒนาแบบจำลองอนุกรมเวลาและเก็บผลการทดลอง (Baseline)
3. ดำเนินการทดลองโดยพัฒนาแบบจำลองการเรียนรู้เชิงลึกพื้นฐานและเก็บผลการทดลอง
4. พัฒนาแบบจำลองที่จะนำเสนอในหัวข้อวิทยานิพนธ์
5. สรุปผลการทดลอง
6. สอบหัวข้อวิทยานิพนธ์
7. เขียนบทความเพื่อตีพิมพ์ผลงานทางวิชาการ
8. ทำการทดลองเพิ่มเติมจากการสอบหัวข้อวิทยานิพนธ์
9. ปรับจูนแบบจำลองให้ได้ประสิทธิภาพที่ดีที่สุด
10. สรุปผลและเขียนวิทยานิพนธ์
11. สอบวิทยานิพนธ์

### 1.6 ผลงานวิจัยที่ตีพิมพ์

“Forecasting Thailand’s Precipitation with Cascading Model of CNN and GRU”  
 โดย เพ็ญอลดา มะโนกิจ กนกศรี ศรีนนทภากร และ พีรพล เวทีกุล ในงานประชุมวิชาการ “2019 – The 11<sup>th</sup> International Conference on Information Technology and Electrical Engineering” ซึ่งจัดขึ้น ณ โรงแรมฮอติเดย์อินน์ พัทยา จังหวัดชลบุรี ประเทศไทย ระหว่างวันที่ 10 – 11 ตุลาคม 2562

## บทที่ 2

### ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับงานวิจัยนี้ประกอบไปด้วย 7 หัวข้อหลัก โดยในหัวข้อแรกกล่าวถึงข้อมูลทั่วไปของการเกิดฝนในประเทศไทยและโทรมาตร จากนั้นในหัวข้อที่ 2 – 6 จะกล่าวถึงทฤษฎีของแบบจำลองที่ถูกนำมาใช้ในงานวิจัยนี้ และหัวข้อสุดท้ายแสดงถึงรายละเอียดตัววัดที่ใช้สำหรับเปรียบเทียบประสิทธิภาพแบบจำลอง

#### 2.1 ฝนและการวัดปริมาณน้ำฝน

หัวข้อนี้จะเล่าถึงข้อมูลพื้นฐานที่สำคัญของการเกิดฝน เนื่องจากฤดูและปริมาณน้ำฝนมีความสัมพันธ์กัน ซึ่งเป็นสาเหตุที่ทำให้ข้อมูลฝนของประเทศมีความไม่สมดุลเนื่องจากฤดูร้อนและฤดูหนาวมีฝนตกค่อนข้างน้อย ทั้งนี้ได้กล่าวถึงประเภทโทรมาตรที่ใช้สำหรับการวัดปริมาณน้ำฝน และเกณฑ์การอ่านฝนที่เป็นมาตรฐานของทางสสน.

##### 2.1.1 สภาพภูมิอากาศของประเทศไทย

ประเทศไทยอยู่ระหว่างละติจูด  $5^{\circ} 37'$  เหนือ กับ  $20^{\circ} 27'$  เหนือ และระหว่างลองจิจูด  $97^{\circ} 22'$  ตะวันออกกับ  $105^{\circ} 37'$  ตะวันออก โดยตั้งอยู่ในเขตร้อนใกล้เส้นศูนย์สูตร ทำให้ภูมิอากาศของประเทศไทยส่วนใหญ่มีลักษณะร้อนชื้นหรือภูมิอากาศแบบทุ่งหญ้าสะวันนา ในขณะที่ภาคใต้และเขตตะวันออกสุดของภาคตะวันออกเป็นเขตภูมิอากาศแบบมรสุมเขตร้อน ทำให้มีอากาศร้อนที่สุดในช่วงเดือนเมษายน และภายใต้อิทธิพลของลมมรสุมตะวันตกเฉียงใต้และตะวันออกเฉียงเหนือทำให้ประเทศไทยเข้าสู่ฤดูฝนและฤดูหนาวตามลำดับ ระยะเวลาของฤดูฝนและปริมาณฝนจะแตกต่างกันไปตามภูมิภาคและระดับความสูง ดังนั้นสภาพภูมิอากาศโดยรวมของประเทศไทยจะมีสภาพอากาศร้อนยาวนาน อุณหภูมิและความชื้นสูง โดยสามารถแบ่งฤดูของประเทศไทยได้เป็นทั้งหมด 3 ฤดู คือ ฤดูร้อนคือตั้งแต่ช่วงกลางเดือนกุมภาพันธ์จนถึงกลางเดือนมีนาคม ฤดูฝนคือตั้งแต่ช่วงกลางเดือนเมษายนจนถึงกลางเดือนตุลาคม และสุดท้ายฤดูหนาวคือตั้งแต่ช่วงกลางเดือนตุลาคมจนถึงกลางเดือนมกราคม

โดยทั่วไปแล้วประเทศไทยมีฝนอยู่ในเกณฑ์ปกติค่อนข้างดี พื้นที่ส่วนใหญ่มีปริมาณน้ำฝนอยู่ช่วง 1,200 – 1,600 มิลลิเมตรต่อปี คิดเป็นปริมาณฝนรวมต่อปีเฉลี่ยทั่วประเทศเป็น 1,500 มิลลิเมตร ทั้งนี้สามารถแปรเปลี่ยนไปตามลมมรสุมที่เข้ามากระทบ นอกเหนือจากนี้ปริมาณฝนยังแตกต่างกันไปตามแต่ละภูมิภาค เช่น บริเวณประเทศไทยตอนบนจะแห้งแล้งและมีฝนน้อย แต่เมื่อเข้าสู่ฤดูฝนถึงค่อยมีปริมาณฝนเพิ่มมากขึ้น พื้นที่ที่มีปริมาณฝนมากส่วนใหญ่จะอยู่ด้านหน้าทิวเขา

หรือด้านรับลมมรสุมตะวันตกเฉียงใต้ ได้แก่พื้นที่ทางด้านตะวันตกของประเทศและภาคตะวันออกเฉียงเหนือ ส่วนพื้นที่ที่มีฝนน้อยส่วนใหญ่อยู่ด้านหลังเขา ได้แก่พื้นที่บริเวณภาคเหนือ ภาคกลางและภาคตะวันออกเฉียงเหนือ ในส่วนของภาคใต้ ตามปกติแล้วมีฝนตกชุกเกือบตลอดปี พื้นที่บริเวณภาคใต้ฝั่งตะวันตก เป็นด้านรับลมมรสุมตะวันตกเฉียงใต้ จะมีปริมาณฝนมากกว่าภาคใต้ฝั่งตะวันออกเฉียงเหนือในช่วงฤดูฝน ในส่วนฤดูหนาวบริเวณภาคใต้ฝั่งตะวันออกเฉียงเหนือ จะมีปริมาณฝนมากกว่าภาคใต้ฝั่งตะวันตก เนื่องจากเป็นด้านรับลมมรสุมตะวันออกเฉียงเหนือ โดยภาคใต้มีปริมาณฝนรวมแล้วมากกว่า 4,000 มิลลิเมตร

### 2.1.2 การตรวจวัดปริมาณน้ำฝน

เครื่องมือการวัดปริมาณน้ำฝนสามารถแบ่งได้เป็น 3 กลุ่ม [6] กลุ่มแรกคือการตรวจวัดน้ำฝนด้วยเครื่องมือตรวจวัดน้ำฝนภาคพื้นดิน (Rain-gauge) หรือ โทรมมาตร กลุ่มที่สองคือ การตรวจวัดน้ำฝนด้วยสถานีเรดาร์ตรวจวัดอากาศภาคพื้นดิน (Ground-base weather radar station) และกลุ่มสุดท้ายคือการตรวจวัดน้ำฝนด้วยดาวเทียมอุตุนิยมวิทยา (Weather satellite) สำหรับงานวิจัยจะขออธิบายถึงการเก็บข้อมูลจากระบบโทรมมาตร เนื่องจากข้อมูลที่น่ามาใช้เป็นข้อมูลปริมาณน้ำฝนรายชั่วโมงที่วัดจากระบบโทรมมาตร ซึ่งได้รับการสนับสนุนจากสสน. โดยมีรายละเอียดดังต่อไปนี้

#### 1) ระบบโทรมมาตร [7]

คืออุปกรณ์ที่สามารถตรวจวัดค่าทางฟิสิกส์ เคมี หรือ ชีวภาพ เพื่อส่งค่าที่วัดได้ไปยังที่ที่กำหนดได้ไว้ภายใต้เงื่อนไขต่าง ๆ โดยจุดประสงค์ของระบบโทรมมาตรคือการตรวจวัดข้อมูลระยะไกล โดยสามารถตรวจวัดปัจจัยของทางสภาพภูมิอากาศ ได้แก่ ระดับน้ำ ปริมาณน้ำฝน อุณหภูมิ ความชื้น ความกดอากาศ ความเข้มแสง และความเร็วลม จากนั้นจะส่งข้อมูลอัตโนมัติผ่านระบบรับส่งข้อมูลของผู้ให้บริการโทรศัพท์เคลื่อนที่และระบบการสื่อสารผ่านดาวเทียม (Satellite communication system) ไปยังเซิร์ฟเวอร์ของทางระบบโทรมมาตร ก่อนที่จะนำมาประมวลผลและแสดงผลข้อมูลในรูปแบบของภูมิศาสตร์สารสนเทศบนเครือข่ายอินเทอร์เน็ต (Internet GIS) ตัวเครื่องมีขนาดเล็กและติดตั้งง่าย โดยระบบโทรมมาตรของทางสสน. มีดังนี้

- โทรมมาตรตรวจวัดสภาพอากาศอัตโนมัติแบบเสาสูง 9 เมตร

โทรมมาตรที่เก็บข้อมูลการตรวจวัดสภาพอากาศ ได้แก่ อุณหภูมิ ความชื้นสัมพัทธ์ ความเข้มแสง ความกดอากาศ การตรวจวัดปริมาณน้ำฝน และการตรวจวัดความเร็วและทิศทางลม ระบบดังกล่าวเหมาะสำหรับการติดตั้งในพื้นที่ต้นน้ำ เช่น ในป่าหรือเขาสูง โดยข้อมูลการตรวจวัดจะรายงานทุก 1 ชั่วโมง หรือ 10 นาทีในกรณีที่ฝนตก

- โทรมมาตรตรวจวัดระดับน้ำอัตโนมัติแบบยึดเกาะราวสะพาน

โทรมมาตรที่เก็บข้อมูลการตรวจวัดสภาพอากาศ และการตรวจวัดปริมาณน้ำฝน เช่นเดียวกับแบบเสาสูง 9 เมตร แต่เพิ่มการตรวจวัดระดับน้ำแบบเรดาร์ ซึ่งหัววัดระดับน้ำเป็นแบบเรดาร์ติดตั้ง โดยที่ตัวอุปกรณ์ไม่ต้องสัมผัสหรือจุ่มลงในน้ำ โดยข้อมูลจะรายงานทุก 10 นาที

- โทรมมาตรตรวจวัดคุณภาพน้ำ (ความเค็ม) แบบเสาสูง 2 เมตร

โทรมมาตรที่เก็บข้อมูลการตรวจวัดสภาพอากาศและการตรวจวัดปริมาณน้ำฝน เช่นเดียวกับแบบเสาสูง 9 เมตร แต่เพิ่มการตรวจวัดคุณภาพน้ำโดยวัดในเรื่องความเค็มในน้ำ

- 2) ข้อดีและข้อจำกัดของการใช้เครื่องมือวัดน้ำฝนภาคพื้นดิน [8]

- ข้อดี

- 1) ข้อมูลเป็นข้อมูลปริมาณน้ำฝนที่ตกลงสู่พื้นดินโดยตรง ค่าที่วัดได้จึงมีเกณฑ์ถูกต้องค่อนข้างสูง
- 2) มีความสะดวกในการอ่านและจัดเก็บข้อมูล โดยสามารถเก็บและวิเคราะห์ข้อมูลในช่วงเวลานาน
- 3) การติดตั้งทำได้ง่ายและสะดวก เนื่องจากอุปกรณ์มีขนาดเล็ก

- ข้อจำกัด

- 1) ข้อมูลที่ได้จากการวัดเป็นข้อมูลเพียงจุดเดียวในพื้นที่ทำให้ยากที่จะได้ข้อมูลปริมาณน้ำฝนที่ถูกต้อง จำเป็นต้องสร้างโครงข่ายโทรมมาตรให้มีความหนาแน่นในการวัดการกระจายตัวของฝน แต่อาจมีข้อจำกัดของบางพื้นที่ที่อาจทำให้ติดตั้งได้ยาก
- 2) ข้อมูลที่ได้อาจมีความคลาดเคลื่อนของการวัดปริมาณน้ำฝน โดยสามารถเกิดได้หลากหลายวิธี เช่น อุปกรณ์ไม่สมบูรณ์ การได้รับอิทธิพลจากลม หรือการติดตั้งในตำแหน่งที่ไม่เหมาะสม
- 3) ความล่าช้าในการรับข้อมูล อาจเกิดจากปัญหาทางด้านระบบการให้บริการเครือข่าย

### 2.1.3 เกณฑ์การวัดปริมาณน้ำฝน [9]

เกณฑ์การวัดสามารถแบ่งได้ตามปริมาณน้ำฝนเก็บได้ในโทรมมาตรโดยมีหน่วยเป็นมิลลิเมตร

- 1) ฝนวัดจำนวนไม่ได้ คือ ปริมาณน้ำฝนมีค่าน้อยกว่า 0.2 มิลลิเมตร
- 2) ฝนตกล็กน้อย คือ ปริมาณน้ำฝนมีค่าระหว่าง 0.2 – 10.0 มิลลิเมตร
- 3) ฝนตกปานกลาง คือ ปริมาณน้ำฝนมีค่าระหว่าง 10.1 – 35.0 มิลลิเมตร
- 4) ฝนตกหนัก คือ ปริมาณน้ำฝนมีค่าระหว่าง 35.1 – 90.0 มิลลิเมตร
- 5) ฝนตกหนักมาก คือ ปริมาณน้ำฝนมีค่ามากกว่า 90.1 มิลลิเมตรขึ้นไป

## 2.2 แบบจำลองอาร์มา (Arima Model)

เป็นแบบจำลองพื้นฐานในเชิงอนุกรมเวลาที่ถูกนำมาพยากรณ์ข้อมูลล่วงหน้าจากการใช้ข้อมูลในอดีต ซึ่งข้อมูลที่ใช้จะเป็นข้อมูลตัวแปรเดียว (Univariate variable) และมีการกำหนดพารามิเตอร์สำคัญที่ส่งผลต่อแบบจำลองอาร์มาได้แก่  $p$ ,  $d$  และ  $q$  โดยสามารถหาได้จาก 3 วิธีตามหัวข้อย่อที่จะกล่าวถึงถัดไป ในงานวิจัยนี้มีจุดประสงค์เพื่อนำมาเปรียบเทียบกับแบบจำลองการเรียนรู้เชิงลึกแบบต่าง ๆ ข้อมูลที่ใช้กับแบบจำลองนี้จะเป็นข้อมูลตัวแปรเดียว (Univariate variable)

### 1) ออตสหสัมพันธ์ (Autoregressive : AR)

เป็นกระบวนการสังเกตค่าหนึ่ง กำหนดเป็น  $Y$  สามารถหาได้จากความสัมพันธ์ของตัวมันเองในอดีต ( $Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-p}$ ) หรือกล่าวอีกนัยว่า ต้องใช้ข้อมูลปริมาณน้ำฝนล่วงหน้ากี่ชั่วโมงที่จะสามารถทำนายข้อมูลน้ำฝนในชั่วโมงถัดไปได้ เทคนิคนี้แทนด้วยพารามิเตอร์  $p$  แสดงถึงลำดับของคาบเวลาในอดีตที่เหมาะสม (Lag time) เพื่ออธิบายค่าของข้อมูล ณ เวลาปัจจุบัน สามารถแสดงได้ดังสมการที่ (1)

$$Y_t = c + \sum_{i=1}^p \Phi_i Y_{t-i} + \varepsilon_t \quad (1)$$

กำหนดให้  $Y$  คือ ตัวแปรตาม

$c$  คือ ค่าคงที่

$\Phi$  คือ ค่าสัมประสิทธิ์

$t$  คือ เวลา


$p$  คือ ลำดับคาบเวลาในอดีต

$\varepsilon_t$  คือ ค่าความผิดพลาดของแบบจำลอง

### 2) การบูรณาการ (Integrated : I)

เป็นตรวจสอบว่าข้อมูลมีความคงที่ (Stationary) หรือไม่ กล่าวคือข้อมูลที่นำมาใช้ในแบบจำลองอาร์มาจะต้องมีค่าเฉลี่ยและความแปรปรวนคงที่ ดังนั้นข้อมูลจะต้องไม่มีแนวโน้ม (Trend) และไม่แปรผันตามช่วงเวลา (Seasonal) โดยวิธีที่ทำให้ข้อมูลมีความคงที่ คือการนำข้อมูลจากลำดับก่อนหน้ามาหักลบกับลำดับปัจจุบัน (Differencing) เทคนิคนี้แทนด้วยพารามิเตอร์  $d$  แสดงถึงจำนวนครั้งของการหักลบ

ตัวอย่างของกราฟที่ข้อมูลมีความคงที่และข้อมูลมีแนวโน้มสามารถแสดงได้รูปที่ 1 โดยกราฟที่ 1 (บนสุด) และกราฟที่ 2 แสดงแนวโน้มของการกำเนิดไฟฟ้ารายเดือนที่วัดได้จริงกับแนวโน้ม หลังจากถูกปรับข้อมูลด้วยลอการิทึม (Logarithm) ตามลำดับ เห็นได้ว่าข้อมูลมีแนวโน้มสูงขึ้นเรื่อย ๆ ซึ่งกราฟลักษณะนี้สามารถกล่าวได้ว่าข้อมูลไม่มีความคงที่ ในส่วนกราฟที่ 3 และกราฟที่ 4 ข้อมูลได้ถูกนำมาทำการหักลบ 1 ครั้งและ 2 ครั้งตามลำดับ พบว่าข้อมูลที่ถูกลบ 1 ครั้งไม่มีลักษณะของแนวโน้มแล้วแต่ยังพบว่าการแปรผันตามช่วงเวลาอยู่ จึงทำการหักลบอีกครั้ง จะเห็นได้ว่ากราฟล่างสุดไม่มีทั้งแนวโน้มและการแปรผันตามช่วงเวลาแล้ว ทำให้ข้อมูลมีความคงที่และสามารถนำข้อมูลนี้ไปใช้กับแบบจำลองอาร์มาได้



รูปที่ 1 ตัวอย่างกราฟที่ข้อมูลมีความคงที่ (Stationary) และข้อมูลมีแนวโน้ม (Trend) (บนสุดและรองลงมา) กราฟที่ไม่มีความคงที่ (ตำแหน่งที่สามและล่างสุด) กราฟที่มีแนวโน้ม

[ที่มา: <https://www.qtmlresearch.com/2017/06/07/arma-part-1-the-basic/>

Accessed: December 1,2019]



### 3) ค่าเฉลี่ยเคลื่อนที่ (Moving Average : MA)

เทคนิคที่คล้ายกับอัตราส่วนสัมพัทธ์แต่เทคนิคนี้จะพิจารณาจากค่าความคลาดเคลื่อนแทน โดยพิจารณาถึงค่าความคลาดเคลื่อนก่อนหน้าที่ส่งผลถึงค่าความเคลื่อนของการทำนายในช่วงถัดไป เทคนิคนี้แทนด้วยพารามิเตอร์  $c$  แสดงถึงลำดับขอบคาบเวลาในอดีตที่เหมาะสมเพื่ออธิบายค่าความคลาดเคลื่อนในปัจจุบัน สามารถแสดงการคิดค่าเฉลี่ยเคลื่อนที่ได้ดังสมการที่ (2)

$$Y_t = c + \varepsilon_t + \sum_{i=1}^p \Phi_i \varepsilon_{t-i} \quad (2)$$

กำหนดให้  $Y$  คือ ตัวแปรตาม

$c$  คือ ค่าคงที่

$\Phi$  คือ ค่าสัมประสิทธิ์

$\varepsilon_t$  คือ ค่าความผิดพลาดของแบบจำลอง


$\varepsilon_{t-i}$  คือ ผลรวมของค่าความผิดพลาดเทอมที่  $t - i$

## 2.3 นิวรอลเน็ตเวิร์ก (Neural Network)

นิวรอลเน็ตเวิร์ก หรือ แบบจำลองโครงข่ายประสาทเทียม ถูกออกแบบมาให้เสมือนโครงข่ายประสาทสมอง ซึ่งมีวัตถุประสงค์ให้คอมพิวเตอร์สามารถทำงานได้แบบเดียวกับที่สมองมนุษย์ทำได้คือ คิดและจดจำ โดยนิวรอลเน็ตเวิร์กสามารถเรียนรู้ได้จากชุดข้อมูลฝึกสอนที่ถูกป้อนเข้าไป เพื่อนำไปใช้ทำนายข้อมูลทดสอบที่ไม่เคยเห็นมาก่อน โดยในหัวข้อนี้จะมีหัวข้อย่อยที่กล่าวถึงการทำงานของนิวรอลเน็ตเวิร์กหลักๆ ดังต่อไปนี้ เพอร์เซปตรอน ถัดมาคือฟังก์ชันกระตุ้น และสุดท้ายคือฟังก์ชัน

### 2.3.1 เพอร์เซปตรอน (Perceptron)

เพอร์เซปตรอนเป็นหน่วยย่อยที่สุดของนิวรอลเน็ตเวิร์กที่จำลองลักษณะของเซลล์ประสาท (neuron) ของมนุษย์ โดยทำหน้าที่นำข้อมูลรับเข้ามาคำนวณหาผลรวมเชิงเส้น (linear combination) เพื่อให้ได้ข้อมูลส่งออกที่เป็นค่าคงที่ และมีผลลัพธ์แตกต่างกันไปตามฟังก์ชันกระตุ้น (Activation function) ดังรูปที่ 2



รูปที่ 2 โครงสร้างเพอร์เซปตรอนเมื่อแต่ละข้อมูลรับเข้ามีน้ำหนัก (weight)

เราสามารถแทนฟังก์ชันของเพอร์เซปตรอนที่จำแนกผลลัพธ์ออกเป็นสองกลุ่มด้วย  $f(x)$  โดยที่  $x$  เป็นข้อมูลรับเข้า และ  $\hat{y}$  เป็นข้อมูลส่งออก โดยการแสดงการคำนวณสามารถเขียนได้ตามสมการที่ (3)

$$\hat{y} = f(x) = \begin{cases} 1 & \text{if } \sum_{i=1}^m w_i x_i + b > 0 \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

กำหนดให้  $w$  คือน้ำหนัก (weight)  $b$  คือไบแอส (bias) และ  $m$  คือจำนวนทั้งหมดของข้อมูลรับเข้า เนื่องจากเพอร์เซปตรอนไม่ได้จำแนกชุดข้อมูลตัวอย่างออกมาได้อย่างถูกต้องทุกตัว จึงจำเป็นต้องมีกระบวนการเรียนรู้ของเพอร์เซปตรอน เพื่อให้เพอร์เซปตรอนมีการปรับน้ำหนักในระหว่างการเรียนรู้ ส่งผลให้สามารถจำแนกตัวอย่างได้ถูกต้องมากขึ้น กำหนดให้ชุดข้อมูลตัวอย่างแทนด้วย  $x$  และผลลัพธ์จริงแทนด้วย  $y$  สามารถเขียนสมการการเรียนรู้ของเพอร์เซปตรอนได้ดังต่อไปนี้

$$w_i \leftarrow w_i + \Delta w_i \quad (4)$$

$$\Delta w_i = \alpha (\hat{y} - y) x_i \quad (5)$$

เมื่อ  $\alpha$  เป็นค่าอัตราการเรียนรู้ (Learning rate) ที่บ่งบอกถึงการเรียนรู้ของเพอร์เซปตรอนในแต่ละรอบมีการเปลี่ยนแปลงน้ำหนักเมื่อเทียบกับอัตราส่วนผลลัพธ์ไปมากเท่าใด ถ้าอัตราการเรียนรู้มีค่ามากเกินไป เพอร์เซปตรอนจะเรียนรู้ได้เร็ว แต่อาจไม่สำเร็จ แต่ถ้ามีค่าน้อย การปรับน้ำหนักสามารถทำได้อย่างละเอียด แต่จะใช้เวลาในการเรียนรู้นาน

### 2.3.2 ฟังก์ชันกระตุ้น (Activation Function)

สำหรับข้อมูลส่งออกของเพอร์เซปตรอนตามปกติแล้วผลลัพธ์ที่ได้มีลักษณะเป็นเชิงเส้น ทำให้ไม่สามารถตอบปัญหาที่ซับซ้อนได้ จำเป็นต้องมีการใช้ฟังก์ชันกระตุ้นเพื่อให้นิวรอลเน็ตเวิร์กสามารถตอบโจทย์ปัญหาได้หลากหลายรูปแบบ โดยฟังก์ชันกระตุ้นเปรียบเสมือนการทำงานของสมองขณะเรียนรู้ที่เซลล์ประสาทจะถูกกระตุ้นเพื่อส่งสัญญาณไปยังเซลล์อื่นๆ เพื่อให้ประมวลผลต่อไป สำหรับฟังก์ชันกระตุ้นที่ใช้ในงานวิจัยมีดังต่อไปนี้

#### 1) ฟังก์ชันซิกมอยด์ (Sigmoid Function)

เป็นฟังก์ชันที่ให้ผลลัพธ์มีค่าตั้งแต่ 0 ถึง 1 โดยเขียนฟังก์ชันซิกมอยด์แทนด้วยสัญลักษณ์  $\sigma$  และสามารถเขียนสมการคำนวณได้ตามสมการที่ (6)

$$\sigma(x) = \frac{1}{1+e^{-z}} \quad (6)$$

#### 2) ฟังก์ชันเรกติไฟต์เชิงเส้น (Rectified Linear Unit : ReLU Function)

เป็นฟังก์ชันที่ให้ผลลัพธ์มีค่ามากกว่าหรือเท่ากับ 0 สมการของฟังก์ชันเรกติไฟต์เชิงเส้นสามารถเขียน สมการคำนวณได้ดังนี้

$$ReLU(x) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases} \quad (7)$$

### 2.3.3 ฟังก์ชันต้นทุน (Cost Function หรือ Loss Function)

ฟังก์ชันต้นทุนเป็นฟังก์ชันที่แสดงถึงต้นทุนของนิวรอลเน็ตเวิร์ก โดยในกระบวนการเรียนรู้ของนิวรอลเน็ตเวิร์ก จะมีการปรับค่าน้ำหนักโดยมีจุดประสงค์เพื่อลดค่าของฟังก์ชันต้นทุน

กำหนดให้  $J$  คือ ฟังก์ชันต้นทุน

$n$  คือจำนวนของข้อมูลทั้งหมดที่ใช้เรียนรู้

$y_i$  คือผลลัพธ์จริงของข้อมูลชุดที่  $i$

$\hat{y}_i$  คือผลลัพธ์ที่ได้มาจากการทำนายชุดที่  $i$

สามารถเขียนสมการของฟังก์ชันต้นทุนที่นิยมได้ดังต่อไปนี้

#### 1) ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error : MSE)


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

#### 2) ค่าเฉลี่ยครอสเอนโทรปีแบบทวิภาค (Binary Cross-entropy)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (9)$$

## 2.4 ตัวเข้ารหัสอัตโนมัติ (Auto-Encoder)

ตัวเข้ารหัสอัตโนมัติเป็นการเรียนรู้เพื่อทำให้ข้อมูลส่งออกมีลักษณะใกล้เคียงกับข้อมูลรับเข้า กล่าวคือ เป็นการสร้างตัวแทนของข้อมูล โดยแบบจำลองถูกพัฒนาเหมือนกับนิวรอลเน็ตเวิร์กที่มีทั้งหมด 3 ชั้น ได้แก่ ชั้นข้อมูลรับเข้า (Input layer) ชั้นซ่อนตัว (Hidden layer) และชั้นข้อมูลส่งออก (Output layer) แต่แตกต่างกันตรงที่การเรียนรู้ของตัวเข้ารหัสอัตโนมัติเป็นการเรียนรู้แบบไม่มีผู้ฝึกสอน (Unsupervised learning) โครงสร้างหลักของตัวเข้ารหัสอัตโนมัติจะประกอบไปด้วย 2 ฟังก์ชัน คือฟังก์ชันการเข้ารหัส (Encoder function) สามารถเขียนแทนด้วย  $h = f(x)$  โดยเมื่อข้อมูลรับเข้าแทนด้วย  $x$  ผ่านชั้นข้อมูลรับเข้าไปยังชั้นซ่อนตัว ข้อมูลจะถูกทำการเข้ารหัส (Encode) เพื่อให้ได้คุณลักษณะที่สามารถเป็นตัวแทนให้กับข้อมูลทั้งหมด ก่อนจะส่งออกไปยังชั้นข้อมูลส่งออกเพื่อทำการสร้างคืน (Decode) ผ่านฟังก์ชันการถอดรหัส (Decoder function) เขียนแทนด้วย  $r = g(h)$  เพื่อให้คุณลักษณะตัวแทนเป็นลักษณะเดียวกับข้อมูลรับเข้า โดยที่คุณลักษณะตัวแทนจะมีค่าใกล้เคียงกับข้อมูลรับเข้า  $x \approx r$  โครงสร้างของตัวเข้ารหัสอัตโนมัติสามารถเขียนแสดงได้ดังรูปที่ 3




รูปที่ 3 โครงสร้างตัวเข้ารหัสอัตโนมัติ  
(อ้างจากรูปที่ 2.28 ใน [10])

## 2.5 นิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolution Neural Network)

นิวรอลเน็ตเวิร์กคอนโวลูชันถูกนำมาใช้แพร่หลายในงานวิจัยที่เกี่ยวข้องกับการจำแนกรูปภาพ เนื่องจากมีลักษณะพิเศษในการสกัดหาคุณลักษณะพิเศษของรูปภาพได้ ซึ่งภายหลังมีการถูกนำมาใช้สกัดคุณลักษณะพิเศษกับข้อมูลประเภทอื่น ๆ โดยอ้างอิงจากรูปแบบที่ใช้กับรูปภาพ โดยการแปลงข้อมูลรับเข้า (Input) ให้เป็นเวกเตอร์

เมื่อข้อมูลรับเข้า เข้าสู่นิวรอลเน็ตเวิร์กคอนโวลูชัน จะผ่านตัวกรอง (Filter) เพื่อดำเนินการสร้างพีเจอร์แมพ (Feature map) ซึ่งการกระทำดังกล่าวคือการสกัดคุณลักษณะพิเศษของข้อมูล โดยโครงสร้างของนิวรอลเน็ตเวิร์กคอนโวลูชันสามารถเขียนได้ดังรูปที่ 4



รูปที่ 4 นิเวรอลเน็ตเวิร์กคอนโวลูชันแบบ LeNet-5

[ที่มา: <https://www.pyimagesearch.com/2016/08/01/lenet-convolutional-neural-network-in-python/> Accessed: August 25,2019]

ส่วนประกอบของนิเวรอลเน็ตเวิร์กคอนโวลูชันมีดังนี้

### 2.5.1 ข้อมูลรับเข้า (Input)

ส่วนใหญ่แล้วข้อมูลรับเข้าของนิเวรอลเน็ตเวิร์กคอนโวลูชันมักเป็นรูปภาพ โดยก่อนที่นำข้อมูลเข้าไปยังแบบจำลอง รูปภาพต้องถูกแปลงให้อยู่ในรูปเวกเตอร์ของจุดพิกเซล (Pixel) โดยตัวเลขแสดงถึงความเข้มของสี

### 2.5.2 ชั้นคอนโวลูชัน (Convolution Layer)

เมื่อข้อมูลรับเข้า เข้าสู่ชั้นคอนโวลูชัน ชั้นนี้ทำหน้าที่หาพีเจอร์จากกลุ่มข้อมูลรับเข้าซึ่งพิจารณาข้อมูลรับเข้าเป็นเมทริกซ์ จากนั้นใช้วิธีการดอทเมทริกซ์กับตัวกรอง โดยน้ำหนักของตัวกรองจะเป็นน้ำหนักที่มีการใช้ร่วมกันในทุก ๆ การทำคอนโวลูชันของข้อมูลรับเข้า กำหนดให้ข้อมูลรับเข้าแทนด้วยเมทริกซ์  $a^{l-1}$  ขนาด  $N \times N$  และมีตัวกรองน้ำหนัก  $w$  ขนาด  $m \times m$  โดยผลลัพธ์  $a^l$  ของการทำคอนโวลูชันสามารถคำนวณได้จากสมการที่ (10) และ (11)

$$z_{ij}^l = \sum_{a=0}^{m-1} \sum_{b=0}^{m-1} w_{a,b}^l a_{i+a,j+b}^{l-1} + b^l \quad (10)$$

$$a_{ij}^l = g(z_{ij}^l) \quad (11)$$

ในชั้นคอนโวลูชัน มีองค์ประกอบที่ต้องคำนึงดังต่อไปนี้


#### 1) ขนาดของตัวกรอง (Filter Size)

คือการกำหนดความกว้างคุณความยาวของตัวกรอง โดยทั่วไปมักนิยามกำหนดให้ความกว้างเท่ากับความยาว

#### 2) ประเภทของการทำคอนโวลูชัน (Convolution Type)

- คอนโวลูชันแบบแคบ (Narrow Convolution)

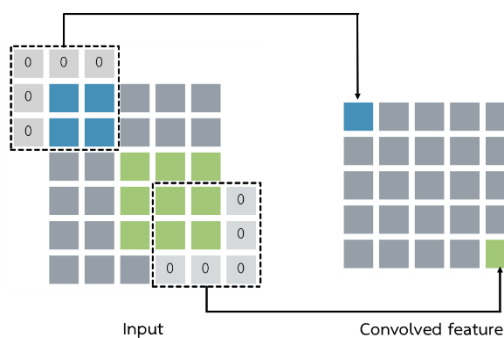
การทำคอนโวลูชันแบบแคบเป็นการที่เมื่อนำตัวกรองมาต่อทกับเมทริกซ์จะไม่กระทำเลยขอบของเมทริกซ์ข้อมูลรับเข้า ถ้ากำหนดให้ข้อมูลรับเข้ามีขนาด  $N \times N$  และตัวกรองมีขนาด  $M \times M$  ผลลัพธ์ที่ได้จากการทำคอนโวลูชันคือเมทริกซ์ขนาด  $(N - M + 1) \times (N - M + 1)$  โดยส่วนใหญ่มักนิยมใช้การทำคอนโวลูชันแบบแคบ ตัวอย่างการทำคอนโวลูชันแบบแคบสามารถแสดงได้ดังรูปที่ 5



รูปที่ 5 การทำคอนโวลูชันแบบแคบเมื่อมีขนาดของตัวกรองเป็น  $3 \times 3$

- คอนโวลูชันแบบกว้าง (Wide Convolution)


ตรงกันข้ามกับคอนโวลูชันแบบแคบ คอนโวลูชันแบบกว้างนั้น ตัวกรองที่นำมาต่อทเมทริกซ์จะกระทำเลยขอบของข้อมูลรับเข้า โดยพื้นที่ที่เกินออกไปนั้นจะมีการแทนค่าข้อมูลของช่องนั้น ๆ ด้วย 0 ซึ่งวิธีดังกล่าวเรียกว่า การเสริมเติม (padding) กำหนดให้ข้อมูลรับเข้ามีขนาด  $N \times N$  และตัวกรองมีขนาด  $M \times M$  ถ้าใช้วิธีการเสริมเติม จะทำให้ผลลัพธ์เมทริกซ์มีขนาดเป็น  $(N + M - 1) \times (N + M - 1)$  จุดประสงค์ของการทำคอนโวลูชันแบบกว้างคือป้องกันการสูญเสียข้อมูลตรงบริเวณขอบของข้อมูลรับเข้า ตัวอย่างแสดงได้รูปที่ 6



รูปที่ 6 การทำคอนโวลูชันแบบกว้างและวิธีการเสริมเติม

### 3) ขนาดของการก้าวข้าม (Stride Size)

คือการกำหนดจำนวนช่องของข้อมูลรับเข้าที่ใช้สำหรับเลื่อนเมทริกซ์เพื่อหาผลลัพธ์ของคอนโวลูชันในแต่ละช่อง โดยส่วนใหญ่แล้วมักจะกำหนดขนาดของการก้าวข้ามเป็น 1 แสดงดังรูปที่ 7



รูปที่ 7 การกำหนดการก้าวข้ามเป็น 2

(อ้างอิงจากรูปที่ 2.7 ใน [11])

### 4) จำนวนตัวกรอง (Number of Filters)

ในชั้นของคอนโวลูชัน สามารถกำหนดตัวกรองได้มากกว่าหนึ่ง โดยจำนวนตัวกรองหมายถึงการกำหนดจำนวนช่องสัญญาณของข้อมูลรับเข้าในชั้นถัดไป โดยน้ำหนักของตัวกรองแต่ละตัวจะมีน้ำหนักแตกต่างกัน

### 5) จำนวนช่องสัญญาณ (Number of Channels)

จำนวนช่องสัญญาณแสดงถึงความลึกของข้อมูลรับเข้า ยกตัวอย่างในกรณีที่มีข้อมูลรับเข้าเป็นรูปภาพ จะมีการใช้ช่องสัญญาณทั้งหมด 3 ช่องสัญญาณ เพื่อแสดงถึงค่าของแม่สี ดังตัวอย่างหรือสามารถเกิดจากจำนวนของตัวกรองในชั้นคอนโวลูชันก่อนหน้า

## 2.5.3 ชั้นการรวม (Pooling Layer)


ชั้นการรวมมีจุดประสงค์เพื่อลดขนาดของข้อมูลโดยพิจารณาเฉพาะลักษณะเด่นของข้อมูล สามารถทำได้ 2 วิธี คือ ชั้นการรวมโดยเลือกค่าที่มากที่สุด และชั้นการรวมโดยเลือกจากค่าเฉลี่ย แสดงตัวอย่างได้ดังรูปที่ 8 โดยส่วนใหญ่ชั้นการรวมโดยเลือกค่าที่มากที่สุดมักได้รับการนิยมนำมาใช้

#### 1) ชั้นการรวมโดยเลือกค่าที่มากที่สุด (Max Pooling)

ชั้นการรวมโดยเลือกค่าที่มากที่สุด จะทำการเลือกค่าที่มากที่สุดจากกลุ่มข้อมูลที่เราสงสัยจากนั้นจะนำไปใช้งานต่อในชั้นถัดไป ซึ่งพิจารณาข้อมูลเป็นเมทริกซ์เช่นเดียวกัน

#### 2) ชั้นการรวมโดยเลือกจากค่าเฉลี่ย (Average Pooling)

เช่นเดียวกับชั้นการรวมโดยเลือกค่าที่มากที่สุด แต่ชั้นการรวมโดยเลือกค่าเฉลี่ย จะพิจารณาจากค่าเฉลี่ยของกลุ่มที่เราสนใจแทน



รูปที่ 8 ตัวอย่างของชั้นการรวมโดยเลือกค่ามากที่สุดและเลือกจากค่าเฉลี่ย

[ที่มา: [https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max\\_fig2\\_333593451](https://www.researchgate.net/figure/Illustration-of-Max-Pooling-and-Average-Pooling-Figure-2-above-shows-an-example-of-max_fig2_333593451)

Accessed: August 25,2019]

#### 2.5.4 ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully-connected Layer)

ชั้นการเชื่อมโยงเต็มรูปแบบเป็นชั้นสุดท้ายของโครงข่ายประสาทเทียมคอนโวลูชัน หลังจากดำเนินการประกอบชั้นคอนโวลูชันและชั้นการรวมจำนวนหนึ่ง โดยชั้นนี้ประกอบไปด้วยเพอร์เซปตรอนหลาย ๆ ตัว โดยที่เพอร์เซปตรอนแต่ละตัว จะมีเส้นเชื่อมกับเพอร์เซปตรอนทุกตัวในชั้นก่อนหน้า และเพอร์เซปตรอนทุกตัวในชั้นถัดไป ทำให้สามารถคำนวณการป้อนไปข้างหน้าและการแพร่กระจายย้อนกลับได้ด้วยวิธีการปกติได้


#### 2.6 หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory)

เป็นโครงข่ายประสาทเทียมได้รับการปรับปรุงจากนิรลเน็ตเวิร์กแบบวนซ้ำ (Recurrent Neural Network : RNN) ที่ถูกสร้างขึ้นมาเพื่อใช้สำหรับปัญหาที่เป็นลำดับ (Sequence) โดยอาศัยการเรียนรู้จากข้อมูลรับเข้าในอดีตในระยะยาว (Long-term dependencies) แต่เนื่องจากนิรลเน็ตเวิร์กแบบวนซ้ำอาจทำให้เกิดปัญหาจากการแพร่กระจายย้อนกลับซึ่งอาศัยกฎลูกโซ่ (Chain rule) ในการปรับน้ำหนัก อาจทำให้เกิดปัญหาเกรเดียนต์ที่ได้มีค่าเป็นศูนย์ (Vanishing gradient) เมื่อน้ำหนักอยู่ในช่วงศูนย์ถึงหนึ่ง หรือปัญหาที่เกรเดียนต์เพิ่มมากเกินไป (Exploding gradient) คือน้ำหนักมีค่ามากกว่าหนึ่ง ดังนั้นเพื่อเป็นแก้ปัญหาการลดหรือเพิ่มมากเกินไปของเกรเดียนต์ หน่วยความจำระยะสั้นแบบยาวจึงถูกออกแบบมาเพื่อแก้ไขปัญหานี้ของนิรลเน็ตเวิร์กแบบวนซ้ำ

หน่วยความจำระยะสั้นแบบยาวถูกออกแบบโดยการจำลองรูปแบบความจำของมนุษย์ (memory) ที่มีความจำจำกัด หลักการของหน่วยความจำระยะสั้นแบบยาวคือการเก็บสถานะเพื่อให้สามารถรู้ได้ว่าข้อมูลก่อนหน้าเคยเป็นอย่างไรมาก่อน และสามารถเลือกได้ว่าข้อมูลไหนควร



จดจำหรือข้อมูลไหนควรลบทิ้ง โดยแสดงโครงสร้างหน่วยความจำระยะยสั้นแบบยาวสามารถแสดงได้ดังรูปที่ 9



รูปที่ 9 โครงสร้างของหน่วยความจำระยะยสั้นแบบยาว

[ที่มา: <https://medium.com/@vinayarun/from-scratch-an-lstm-model-to-predict-commodity-prices-179e12445c5a> Accessed: August 27,2019]

หน่วยความจำจะใช้สถานะเซลล์ (Cell state) ณ เวลาปัจจุบัน  $t$  แทนด้วยสัญลักษณ์  $C_t$  เพื่อส่งผ่านข้อมูลสำหรับเรียนรู้ในเวลาถัดถัดไป เมื่อเซลล์ทำงานกับข้อมูลรับเข้า ณ ลำดับเวลานั้น ๆ เสร็จแล้ว จะเพิ่มหรือลบข้อมูลของสถานะเซลล์ผ่านประตูต่าง ๆ โดยการทำงานแต่ละรอบ สามารถแสดงข้อมูลได้ดังนี้ ข้อมูลรับเข้า ณ เวลาปัจจุบันกำหนดให้เป็น  $x_t$  มีสถานะซ่อน (Hidden state) ในลำดับเวลาก่อนหน้า  $h_{t-1}$  และสถานะเซลล์ในลำดับเวลาก่อนหน้า  $C_{t-1}$  เมื่อทำงานเสร็จจะได้ผลลัพธ์เป็นสถานะเซลล์ที่เวลาปัจจุบัน และ สถานะซ่อนที่เวลาปัจจุบัน เพื่อนำมาใช้เป็นข้อมูลออกที่เวลาปัจจุบันหรือข้อมูลรับเข้าในเวลาถัดถัดไป การทำงานของสถานะเซลล์จะถูกควบคุมด้วยประตูซึ่งประกอบไปด้วย

- 1) ประตูข้อมูลรับเข้า (Input gate) ทำหน้าที่ประเมินความสำคัญของข้อมูลรับเข้าใหม่
- 2) ประตูลืม (Forget gate) ทำหน้าที่ประเมินว่าควรเก็บค่าสถานะเซลล์จากลำดับเวลาก่อนหน้าหรือไม่
- 3) ประตูข้อมูลส่งออก (Output gate) ทำหน้าที่ควบคุมปริมาณข้อมูลส่งออกก่อนไปยังลำดับเวลาถัดไป

กำหนดให้  $i$  คือ ประตูข้อมูลรับเข้า

$f$  คือ ประตูลืม

$o$  คือ ประตูข้อมูลส่งออก

$\sigma$  คือ ฟังก์ชันซิกมอยด์

สามารถเขียนชุดสมการของหน่วยความจำสั้นระยะยาวได้ดังต่อไปนี้

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (12)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (13)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (14)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (15)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (16)$$

$$h_t = o_t * \tanh(C_t) \quad (17)$$

## 2.7 โครงข่ายประตูกลับ (Gated Recurrent Unit Network)

โครงข่ายประตูกลับถูกพัฒนาต่อยอดจากหน่วยความจำระยะสั้นแบบยาว โดยลดความซับซ้อนของการทำงานจากหน่วยความจำระยะสั้นแบบยาวเพื่อให้มีขนาดเล็กและสามารถทำงานได้เร็วขึ้น โดยการปรับประตูที่ควบคุมสถานะเซลล์ให้เหลือเพียงสองอัน คือ

- 1) ประตูรีเซ็ต (Reset gate) ทำหน้าที่ประเมินว่าควรนำข้อมูลสถานะก่อนหน้ามาพิจารณา กับข้อมูลรับเข้าปัจจุบันมากน้อยเพียงใด
- 2) ประตูอัปเดต (Update gate) ทำหน้าที่ประเมินว่าควรเก็บข้อมูลสถานะก่อนหน้ามากน้อยเพียงใด

กำหนดให้  $r$  คือ ประตูรีเซ็ต

$z$  คือ ประตูอัปเดต

$x_t$  คือ ข้อมูลรับเข้าที่เวลาปัจจุบัน  $t$

$h_t$  คือ สถานะซ่อนที่เวลาปัจจุบัน  $t$


สามารถเขียนชุดสมการของโครงข่ายประตูกลับได้ดังต่อไปนี้

$$r = \sigma(x_t W_r + h_{t-1} U_r) \quad (18)$$

$$z = \sigma(x_t W_z + h_{t-1} U_z) \quad (19)$$

$$h_t = (z * \sigma((h_{t-1} * r) W_h + (x_t U_h))) + ((1 - z) * h_{t-1}) \quad (20)$$

โดยรูปที่ 10 แสดงการเปรียบเทียบระหว่างโครงข่ายประตูกลับและหน่วยความจำสั้นระยะยาว



รูปที่ 10 เปรียบเทียบโครงสร้างของแบบจำลองหน่วยความจำสั้นระยะยาว (ซ้าย) และโครงข่ายประตูกลับ (ขวา)

[ที่มา: <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21> Accessed: August 27,2019]

## 2.8 การวัดประสิทธิภาพ (Performance Evaluation)

การวัดประสิทธิภาพที่ใช้ในงานวิจัยนี้ประกอบไปด้วยตัววัดการจำแนกแบบสองคลาส (Binary classification) และตัววัดค่าความคลาดเคลื่อนจากผลการทำนายเมื่อเปรียบเทียบกับข้อมูลจริง โดยมีรายละเอียดดังต่อไปนี้

### 2.8.1 คอนฟิวชันเมทริกซ์

เมทริกซ์ที่แสดงผลของการจำแนกข้อมูลเป็น 2 คลาส โดยแจกแจงจำนวนที่ถูกทำนายได้ในแต่ละคลาสเทียบกับคำตอบจริงของจำนวนที่ถูกทำนายดังตารางที่ 2

กำหนดให้ข้อมูลการนับมีดังต่อไปนี้

- TP เป็นจำนวนคำตอบที่มีผลลัพธ์ทำนายได้ 1 และคำตอบคือ 1 (True positive)
- FP เป็นจำนวนคำตอบที่มีผลลัพธ์ทำนายได้ 1 และคำตอบคือ 0 (False positive)
- TN เป็นจำนวนคำตอบที่มีผลลัพธ์ทำนายได้ 0 และคำตอบคือ 0 (True negative)

- FN เป็นจำนวนคำตอบที่มีผลลัพธ์ทำนายได้ 0 และคำตอบคือ 1 (False negative)

ตารางที่ 1 คอนฟิวชันเมทริกซ์ของการจำแนกแบบ 2 คลาส

		คลาสที่ทำนาย	
		ฝนตก	ฝนไม่ตก
คลาสจริง	ฝนตก	TP	FN
	ฝนไม่ตก	FP	TN

## 2.8.2 ตัววัดประสิทธิภาพจำแนกตามคลาส

ค่าที่ใช้วัดประสิทธิภาพการจำแนก โดยส่วนใหญ่แล้วมักจะพิจารณาร่วมกันทั้งหมด 4 ค่า

### 1) ค่าความแม่นยำ (Accuracy)

เป็นการวัดความแม่นยำของแบบจำลองโดยรวม ค่าความแม่นยำจะบอกได้ว่าแบบจำลองทำนายถูกกี่ครั้งจากจำนวนการทำนายทั้งหมด โดยสมการสามารถเขียนได้จากข้อมูลการนับในหัวข้อคอนฟิวชันเมทริกซ์ดังนี้

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (21)$$

### 2) ค่าความเที่ยงตรง (Precision)

เป็นการวัดว่าแบบจำลองสามารถทำนายคำตอบถูกต้องเป็นเท่าไรจากคลาสที่กำลังพิจารณาอยู่ สามารถคำนวณได้จากสมการ (22)

$$Precision = \frac{TP}{TP+FP} \quad (22)$$

### 3) ค่าความระลึก (Recall)

เป็นการวัดความถูกต้องของแบบจำลองโดยพิจารณาแยกทีละคลาส กล่าวอีกนัยคือจำนวนที่ทายคลาส 1 ถูกต้องเมื่อเทียบกับคลาส 1 จริงทั้งหมด สามารถคำนวณได้จากสมการ (23)

$$Recall = \frac{TP}{TP+FN} \quad (23)$$

### 4) ค่าเอฟวัน (F1-measure)

เป็นการวัดค่าความเที่ยงตรงและค่าความระลึกของแบบจำลองไปพร้อมกัน โดยเขียนสมการได้ดังนี้

$$F1 = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (24)$$

### 2.8.3 รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error : RMSE)

เป็นตัววัดที่นำมาวัดประสิทธิภาพของแบบจำลองการถดถอย โดยวัดค่าความคลาดเคลื่อนระหว่างปริมาณน้ำฝนจริงจากจุดสังเกตการณ์และปริมาณน้ำฝนที่แบบจำลองทำนายได้ ซึ่งค่าที่ได้ ถ้ามีค่าน้อยแปลว่าแบบจำลองสามารถทำนายได้ใกล้เคียงกับค่าจริง สามารถเขียนสมการได้ดังนี้

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (25)$$

โดยที่  $y_i$  เป็นข้อมูลส่งออกที่แบบจำลองทำนายได้ของชุดข้อมูลตัวที่  $i$   $x_i$  เป็นข้อมูลจริงของชุดข้อมูลตัวที่  $i$  และ  $n$  เป็นจำนวนข้อมูลของชุดข้อมูลทั้งหมด



### บทที่ 3 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องในงานวิจัยนี้ จะทำการศึกษาใน 2 หัวข้อ คือ ศึกษาการใช้แบบจำลองอนุกรมเวลาที่เป็นแบบจำลองพื้นฐานในการจัดการปัญหาที่เกี่ยวข้องกับเวลา และศึกษาการใช้แบบจำลองการเรียนรู้เชิงลึกในแง่ของการนำมาใช้สกัดคุณลักษณะพิเศษของชุดข้อมูลที่วัดได้จากโทรมาตร และให้แบบจำลองทำนายปริมาณน้ำฝน โดยที่มนุษย์ไม่จำเป็นต้องใช้การคัดแยกด้วยตัวเอง รวมถึงการใส่กลวิธีบางอย่างเพื่อช่วยให้การทำนายเกิดความแม่นยำขึ้น

#### 3.1 งานวิจัยในกลุ่มแบบจำลองอนุกรมเวลา

แบบจำลองอาร์มาเป็นแบบจำลองอนุกรมเวลาที่ได้รับความนิยมในการนำมาจัดการปัญหาที่เกี่ยวข้องกับเวลา ตัวข้อมูลฝนถือเป็นหนึ่งในปัญหาดังกล่าว เนื่องจากข้อมูลฝนที่ตกในชั่วโมงก่อนหน้าอาจส่งผลให้ตกในชั่วโมงถัดไปได้

งานวิจัยของ Wang, Shengwei และคณะ (2013) [12] ได้นำแบบจำลองเอสอาร์มา (Seasonal Autoregressive Integrated Moving Average : SARIMA) มาใช้ร่วมกับข้อมูลเชิงสถิติเพื่อวิเคราะห์หาสหสัมพันธ์อัตโนมัติที่โดดเด่น (Strong autocorrelation) ของชุดข้อมูลปริมาณน้ำฝนในเมืองโซววง (Shouguang) ประเทศจีน โดยงานวิจัยได้อธิบายถึงขั้นตอนการเตรียมข้อมูลและการหาค่าที่ดีที่สุดของพารามิเตอร์ที่ถูกใช้งานในแบบจำลองตามทฤษฎีของหลักการทางอนุกรมเวลา โดยงานวิจัยของ Wang, Shengwei และคณะ ทำการตรวจสอบประสิทธิภาพของแบบจำลองโดยการนำไปทำนายปริมาณน้ำฝนสะสมรายเดือนของปี 2009 เมื่อพิจารณากราฟผลลัพธ์ที่ได้จากการทำนาย พบว่ากราฟมีค่าใกล้เคียงกับปริมาณน้ำฝนสะสมจริง โดยคิดเป็นค่าความคลาดเคลื่อนเฉลี่ยทั้งปีได้ 27.42 เปอร์เซ็นต์ นอกเหนือจากนี้แบบจำลองในงานวิจัยได้ถูกประยุกต์เป็นโปรแกรมสำหรับการเตือนภัยในสถานการณ์จริงอีกด้วย แต่อย่างไรก็ตามงานวิจัยของ Wang, Shengwei ไม่ได้พูดถึงการเปรียบเทียบระหว่างแบบจำลองเอสอาร์มากับแบบจำลองอื่น ๆ จึงทำให้ไม่มีการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลอง

เนื่องจากแบบจำลองอาร์มาเป็นแบบจำลองที่พิจารณาโดยใช้เพียงแค่ตัวแปรเดียว ซึ่งยังไม่ตอบโจทย์ในงานวิจัยที่กำลังดำเนินการ เพราะงานวิจัยนี้ต้องการหาความสัมพันธ์ระหว่างปริมาณน้ำฝนกับตัวแปรปัจจัยที่ทำให้เกิดฝนหลายตัว เพื่อนำมาช่วยเพิ่มประสิทธิภาพในการทำนาย แต่อย่างไรก็ตามแบบจำลองอนุกรมเวลาเป็นแบบจำลองพื้นฐานที่ใช้แก้ไขปัญหามูลฐานเวลา ซึ่งข้อมูลน้ำฝนถือเป็นอีกหนึ่งข้อมูลที่มีความเกี่ยวข้องกันทางด้านเวลา ดังนั้นสำหรับงานวิจัยนี้แบบจำลองอนุกรม

เวลาจะถูกนำมาใช้เป็นแบบจำลองมาตรฐาน (Baseline model) เพื่อเปรียบเทียบประสิทธิภาพร่วมกับแบบจำลองการเรียนรู้เชิงลึก

### 3.2 งานวิจัยในกลุ่มแบบจำลองการเรียนรู้เชิงลึก

งานวิจัยนี้มุ่งเน้นถึงการศึกษาแนวทางการนำแบบจำลองการเรียนรู้เชิงลึกมาใช้สกัดคุณลักษณะพิเศษของชุดข้อมูลที่เกี่ยวข้องกับด้านการพยากรณ์อากาศ ตัวอย่างงานวิจัยที่เกี่ยวข้องได้แก่

3.2.1 งานวิจัยของ Hung, Nguyen Q และคณะ ใช้ข้อมูลจากสถานีวัดปริมาณน้ำฝนร่วมกับสถานีวัดปริมาณน้ำฝนใกล้เคียงเพื่อทำนายปริมาณน้ำฝนแบบรายงานผลได้ทันที (real-time)

งานวิจัย [13] ในปี 2009 เป็นงานวิจัยแรกที่ใช้แบบจำลองการเรียนรู้เชิงลึกกับชุดข้อมูลที่ได้มาจากสถานีวัดปริมาณน้ำฝนในประเทศไทย โดยพิจารณาจากสถานีวัดปริมาณน้ำฝนในเขตกรุงเทพมหานคร และสถานีวัดปริมาณน้ำฝนรอบข้างที่อยู่ในรัศมี 21 ตารางกิโลเมตร โดยงานวิจัยนี้ได้้นำแบบจำลองการเรียนรู้เชิงลึกแบบนิเวศน์เน็ตเวิร์กมาทดลองเพื่อหาความสัมพันธ์ระหว่างคุณลักษณะ โดยงานวิจัยนี้นอกจากเสนอการปรับปรุงพารามิเตอร์ของแบบจำลองแล้ว ยังค้นพบว่าการใช้คุณลักษณะที่มาจากข้อมูลสถานีวัดปริมาณน้ำฝนใกล้เคียงมาพิจารณาร่วมกับข้อมูลปริมาณน้ำฝนจากจุดสังเกตการณ์ให้ค่าความคลาดเคลื่อนต่ำสุดโดยใช้รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองและมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง โดยให้ค่าความคลาดเคลื่อนลดลงถึง 71.19 % เมื่อเปรียบเทียบกับการใช้คุณลักษณะของสถานีวัดปริมาณน้ำฝนจากจุดสังเกตการณ์เพียงอย่างเดียว นอกจากนี้งานวิจัยนี้ยังวิเคราะห์ถึงการทำนายปริมาณน้ำฝนในอีก 6 ชั่วโมงล่วงหน้า โดยพบว่ายิ่งชั่วโมงห่างไกลเท่าไร ค่าความคลาดเคลื่อนก็จะเพิ่มมากขึ้น

วิทยานิพนธ์นี้นำเสนอวิธีการนำข้อมูลจากสถานีบริเวณใกล้เคียงของงานวิจัย Hung, Nguyen Q มาใช้เพื่อเพิ่มประสิทธิภาพการทำนายน้ำฝนโดยพิจารณาในเชิงพื้นที่ เมื่อพิจารณาจากเวลาที่ฝนตกมีโอกาสเป็นไปได้สูงที่บริเวณใกล้เคียงจะมีฝนตกพร้อมกัน หรือมีสภาพอากาศที่สามารถส่งผลให้ฝนตกในพื้นที่ที่กำลังสนใจ ดังนั้นแบบจำลองที่นำเสนอจะนำตัวแปรจากโทรมาตรใกล้เคียงป้อนเข้าไปยังแบบจำลอง เพื่อให้แบบจำลองวิเคราะห์ความสัมพันธ์ในเชิงพื้นที่ด้วย

3.2.2 งานวิจัยของ Hernández, Emilcy และคณะ ใช้ข้อมูลจากสถานีวัดปริมาณน้ำฝนในเมืองมานิซาลอส ประเทศโคลอมเบีย เพื่อทำนายปริมาณน้ำฝนสะสมรายวัน

งานวิจัย [14] ในปี 2016 ได้นำแบบจำลองการเรียนรู้เชิงลึกมาใช้กับข้อมูลปริมาณน้ำฝนจำนวนมาก เพื่อทำนายปริมาณฝนสะสมในวันถัดไปสำหรับป้องกันภัยพิบัติ จุดเด่นของงานวิจัยคือการสร้างข้อมูลรับเข้าปริมาณมากก่อนนำเข้าแบบจำลองเพื่อทำนายปริมาณน้ำฝน งานวิจัยนี้ได้้นำตัว

แปรของปริมาณน้ำฝนและสภาพอากาศ โดยมีลักษณะข้อมูลเป็นข้อมูลตัวเลข (Numerical data) ได้แก่ อุณหภูมิ ความดัน ความชื้น ความแรงลม ความเข้มแสง และจุดไอน้ำกลับตัว ที่เก็บรวบรวมจากสถานีวัดปริมาณน้ำฝนมาเพิ่มค่าคุณลักษณะที่เกี่ยวข้องเวลาในอดีตดังนี้

- ค่าของแต่ละตัวแปรที่วัดได้ย้อนหลัง 3 วัน
- ค่าเฉลี่ยของตัวแปรนั้น ๆ ในห้าวันย้อนหลัง
- ความต่างของค่าที่วัดได้ในช่วงเวลา 04:00 น. และ 24:00 น. ของแต่ละตัวแปร


ซึ่งแต่ละตัวแปรมีความสัมพันธ์ที่เกี่ยวข้องต่อการเกิดฝนทั้งหมด นอกเหนือจากการใช้ตัวแปรที่เป็นข้อมูลตัวเลขยังมีการเพิ่มตัวแปรที่เป็นข้อมูลหมวดหมู่ (Categorical data) เป็นเดือนและทิศทางลมเพื่อให้แบบจำลองหาความสัมพันธ์ของการเกิดฝนในแต่ละฤดู โดยค่าคุณลักษณะทั้งหมดของงานวิจัยนี้มีทั้งหมด 47 ตัวแปร สามารถแสดงรายละเอียดของค่าคุณลักษณะได้ดังตารางที่ 2

ตารางที่ 2 ข้อมูลตัวแปรทั้งหมดที่นำมาใช้ในงานวิจัยของ Hernández, Emilcy

Input column	Description	Observation
1-3	Rainfall in the last 3 days ago	Measurement unit: mm
4	Rainfall average 5 days ago	
5	Difference between the temperature at 4:00 and 24:00	
6-8	Temperature in the last 3 days ago	Measurement unit: C
9	Temperature average 5 days ago	
10	Difference between the temperature at 4:00 and 24:00	
11-13	Barometric pressure in the last 3 days ago	Measurement unit: hPa
14	Barometric pressure average 5 days ago	
15	Difference between the barometric pressure at 4:00 and 24:00	
16-18	Relative humidity in the last 3 days ago	Measurement unit: %
19	Relative humidity average 5 days ago	
20-22	Wind speed in the last 3 days ago	Measurement unit: m/s
23-25	Sun brightness in the last 3 days ago	Measurement unit: W/m <sup>2</sup>
26	Sun brightness average 5 days ago	
27	Dew point temperature	Measurement unit: C
28-39	Month value of the input records	12 components are used, i.e., February: 010000000000 May: 000010000010
40-47	Prevailing wind direction	North: 10000000 Northeast: 01000000 East: 00100000 Southeast: 00010000 South: 00001000 Southwest: 00000100 West: 00000010 Northwest: 00000001

จากนั้นข้อมูลรับเข้าจะถูกป้อนเข้าสู่แบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น โดยตัวเข้ารหัสอัตโนมัติถูกนำมาใช้เพื่อสกัดคุณลักษณะที่สำคัญและทำการหาความสัมพันธ์ของแต่ละคุณลักษณะ และเพอร์เซปตรอนหลายชั้นจะทำหน้าที่ในการทำนายปริมาณน้ำฝน โครงสร้างของแบบจำลองแสดงได้ดังรูปที่ 11





รูปที่ 11 โครงสร้างแบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น  
(อ้างอิงจาก Fig. 1 ใน [14])

ผลลัพธ์ของงานวิจัยนี้จะเปรียบเทียบกับวิธีการมาตรฐานคือการเปรียบเทียบกับปริมาณน้ำฝนวันก่อนหน้าที่ได้มาจากการคำนวณทางสถิติ รวมถึงแบบจำลองโครงข่ายประสาทเทียมพื้นฐาน ได้แก่ โครงข่ายประสาทเทียมที่มีการส่งค่าย้อนกลับ (Back Propagation : BP network) โครงข่ายเลเยอร์รีเคอร์เรนท์ (Layer Recurrent : LR network) และโครงข่ายประสาทเทียมที่มีการส่งค่าย้อนกลับแบบต่อเรียง (Cascaded Back-Propagation : CBP network) พบว่ามีค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error : MSE) ลดลงถึง 69.88%, 57.22%, 51.05% และ 50.84% ตามลำดับ

แบบจำลองการเรียนรู้เชิงลึกในงานวิจัยของ Hernández, Emilcy และคณะถือเป็นแบบจำลองที่ทันสมัย (State of the art) สำหรับการนำข้อมูลจากสถานีวัดปริมาณน้ำฝนมาทำนายน้ำฝนล่วงหน้าในกรณีที่พิจารณาแค่สถานีเดียว เนื่องจากงานวิจัยของ Hernández, Emilcy และคณะไม่ได้กล่าวถึงการนำคุณลักษณะของสถานีใกล้เคียงมาใช้ โดยวิทยานิพนธ์นี้ได้้นำแบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้นมาใช้กับข้อมูลฝนที่ได้จากโทรมาตรของประเทศไทย ซึ่งแบบจำลองดังกล่าวถูกนำมาพิจารณาเป็นแบบจำลองการเรียนรู้เชิงลึกมาตรฐานในกรณีที่ใช้ข้อมูลจากโทรมาตรเดียวในการทำนายปริมาณน้ำฝนในช่วงถัดไป

3.2.3 งานวิจัยของ Qiu, Minghui และคณะ ใช้ข้อมูลจากสถานีวัดปริมาณน้ำฝนทั้งหมดในจังหวัดกวางโจว ประเทศจีนเพื่อหาความสัมพันธ์เชิงเวลาและพื้นที่เพื่อทำนายปริมาณน้ำฝนล่วงหน้าระยะใกล้

งานวิจัย [15] ในปี 2017 ได้มีการต่อยอดจากงานวิจัย [14] ซึ่งเป็นการสกัดคุณลักษณะและหาความสัมพันธ์แต่ละคุณลักษณะเช่นเดียวกัน แต่เพิ่มกลวิธีของการหาความสัมพันธ์เชิงเวลาและเชิงพื้นที่ (Spatio-temporal) โดยใช้ข้อมูลของสถานีที่ใกล้เคียงเข้ามาช่วยในการเรียนรู้ ซึ่งมีหลักการว่า

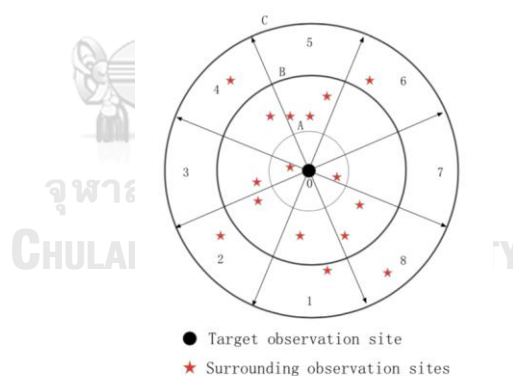
ถ้าหากมาตรวัดบริเวณหนึ่งวัดได้ว่าฝนตก มาตรวัดที่อยู่บริเวณใกล้เคียงจะต้องวัดได้ว่าฝนตกเหมือนกัน เช่นเดียวกับงานวิจัย [14] งานวิจัยนี้จะสร้างข้อมูลรับเข้าที่มาจากตัวแปรปริมาณน้ำฝนและสภาพอากาศ โดยมีตัวแปรทั้งหมด 17 ตัว แสดงได้ดังรูปที่ 12

Feature (Dimension)	Details
Rain condition (2)	rainy or not; rain amount
Observatory height (1)	height of our observatory site
Wind speed (2)	$\beta \times \cos(\alpha), \beta \times \sin(\alpha)$ , where $\beta$ and $\alpha$ are the speed and angle
Wind direction (8)	N,NE,E,SE,S,SW,W,NW (N:North,S:South, E:East,W:West)
Dew point (1)	dew point value
Temperature (1)	temperature of surface
Air pressure (1)	air pressure of the sites
Humidity (1)	air humidity of the sites

รูปที่ 12 รายละเอียดตัวแปรที่วัดได้

(อ้างอิงจาก Table 2 ใน [15])

จากนั้นจึงเพิ่มค่าคุณลักษณะที่เป็นผลรวมและค่าสูงสุดของแต่ละตัวแปรโดยพิจารณาตั้งแต่หนึ่งถึงสามชั่วโมงย้อนหลัง ทำให้มีค่าคุณลักษณะทั้งหมดคิดเป็น  $17 \times 2 \times 3 = 102$  ตัว และค่าคุณลักษณะจากสถานีวัดใกล้เคียง คิดจากพื้นที่รอบสถานีที่ถูกแบ่งออกเป็น 25 เซลล์ดังรูปที่ 13 สรุปคุณลักษณะทั้งหมดที่ถูกลำนำมาใช้มีค่าเท่ากับ  $102 \times 25 = 2,550$  ตัว

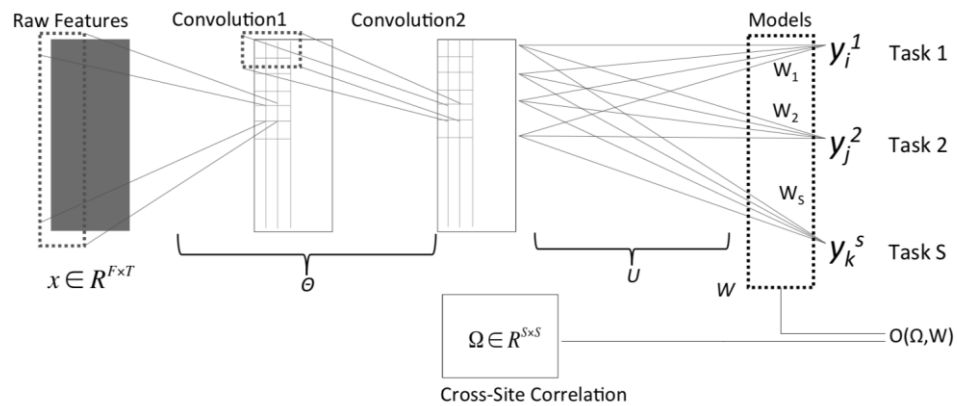


รูปที่ 13 แนวทางการนำสถานีใกล้เคียงมาใช้ โดยสถานีที่สนใจที่กำหนดด้วย 0 ตรงกึ่งกลาง และแบ่งพื้นที่ออกเป็น 8 (1 – 8) ส่วนกับ 3 ช่วงระยะทางที่ห่างจากสถานีที่สนใจ (A, B, C) ดังนั้นพื้นที่ทั้งหมดคิดเป็น 25 (8 × 3) เซลล์

(อ้างอิงจาก Fig. 2 ใน [15])

งานวิจัยนี้นำเสนอวิธีรอลเน็ตเวิร์กคอนโวลูชันเพื่อพิจารณาคุณลักษณะพร้อมกันทุกตัว และเลื่อนไปที่ละ 2 ช่วงเวลาเพื่อพิจารณาในแกนเวลา เมื่อหลังดำเนินการครบทุกช่วงเวลาจะได้คุณลักษณะพิเศษที่บอกว่าจะเกิดฝนและเกิดในปริมาณเท่าใด ทั้งนี้งานวิจัยได้สร้างแบบจำลองให้เป็น

แบบมัลติทาสก์ (Multitask) เพื่อรับข้อมูลรับเข้าพร้อมกันหลายสถานีวัดปริมาณน้ำฝนแล้วนำมาวัด สหสัมพันธ์กัน โดยค่าสหสัมพันธ์จะช่วยให้แบบจำลองสามารถพิจารณาความสัมพันธ์เชิงพื้นที่ที่ได้ โครงสร้างของแบบจำลองแสดงดังรูปที่ 14



รูปที่ 14 โครงสร้างแบบจำลองนิเวศวิทยาแบบมัลติทาสก์

(อ้างอิงจาก Fig. 1 ใน [15])

ผลลัพธ์ของงานวิจัยนี้เมื่อเปรียบเทียบกับ [14] พบว่าได้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย ลดลง 5.96% สำหรับงานวิจัยนี้เป็นงานวิจัยที่ให้ค่าความคลาดเคลื่อนต่ำสุดในชุดข้อมูลที่เป็นมาตรวัด ปริมาณน้ำฝน วิทยานิพนธ์นี้ได้้นำแบบจำลองในงานวิจัยของ Qiu, Minghui และคณะมาศึกษา และนำมาเป็นต้นแบบของแบบจำลองที่ต้องการนำเสนอ โดยได้นำแนวคิดในเรื่องของการพิจารณา ความสัมพันธ์ของคุณลักษณะในแกนเวลาและพื้นที่ โดยสร้างแบบจำลองนิเวศวิทยาแบบมัลติทาสก์ มาทำการพิจารณาทุกคุณลักษณะพร้อมกันและเปรียบเทียบกับคุณลักษณะในอดีตเพื่อสกัดหา คุณลักษณะสำคัญ รวมทั้งการพิจารณาคุณลักษณะของสถานีใกล้เคียงไปพร้อมกันเพื่อให้แบบจำลองได้ ข้อมูลบางอย่างเพื่อนำมาช่วยเพิ่มประสิทธิภาพการทำนายของสถานีที่สนใจให้แม่นยำมากขึ้น

## บทที่ 4

### แนวคิดและวิธีการดำเนินงาน

วิทยานิพนธ์นี้ได้ทำเทคนิคของ Hernández, Emilcy [14] จากหัวข้อ 3.2.2 มาประยุกต์ใช้ในการนำแบบจำลองการเรียนรู้เชิงลึกแบบวิธีบีบอัดข้อมูลอัตโนมัติมาหาความสัมพันธ์ของคุณลักษณะที่ไม่มีความสัมพันธ์เชิงเส้นต่อกัน (Non-linear relationship) ร่วมกับเพอร์เซปตรอนหลายชั้นเพื่อทำนายปริมาณน้ำฝน โดยวิทยานิพนธ์ใช้นิวรอลเน็ตเวิร์กคอนโวลูชันที่ได้แนวคิดมาจากรางานวิจัยของ Qiu, Minghui [15] จากหัวข้อ 3.2.3 แทนวิธีตัวเข้ารหัสอัตโนมัติ เพื่อสกัดความสัมพันธ์ระหว่างคุณลักษณะที่ไม่มีความสัมพันธ์เชิงเส้นต่อกัน และนำคุณลักษณะของโทรมาตรใกล้เคียงมาพิจารณารวมกันกับโทรมาตรที่สนใจ ในหัวข้อแรกจะกล่าวถึงการนำข้อมูลรับเข้ามาใช้ในงานวิจัย จากนั้นเมื่อสร้างข้อมูลแล้วจึงนำมาใส่แบบจำลองเพื่อทำนาย งานวิจัยนี้เสนอแนวคิดการใช้แบบจำลองสองแบบต่อกันในหัวข้อที่สอง โดยแบบจำลองแรกเป็นแบบจำลองการจำแนกประเภทนำมาใช้ทำนายว่าฝนตกหรือไม่ตก เพื่อกรองตำแหน่งของข้อมูลที่ถูกทำนายว่าฝนตกจริง ๆ ก่อนส่งต่อให้กับแบบจำลองที่สอง คือแบบจำลองการวิเคราะห์การถดถอยเพื่อทำนายปริมาณน้ำฝนที่เกิดขึ้นในอีกหนึ่งชั่วโมงข้างหน้า แบบจำลองนี้ถูกนำมาแก้ไขปัญหาจากชุดข้อมูลไม่สมดุลที่มาจากกรณีที่ฝนไม่ตกมีค่ามากกว่าทำให้การใช้ข้อมูลรับเข้าทั้งหมดอาจทำให้แบบจำลองจดจำการทำนายกรณีที่ไม่ตกได้ดีกว่า และหัวข้อสุดท้ายจะพูดถึงแนวทางการทำแบบจำลองเพื่อทำนายปริมาณฝนล่วงหน้าอีก 6 ชั่วโมงถัดไป

#### 4.1 ข้อมูลรับเข้าและการเตรียมข้อมูล

การสร้างข้อมูลรับเข้าในงานวิจัยจะแบ่งการดำเนินงานเป็น 2 ขั้นตอน โดยช่วงแรกนำข้อมูลที่วัดได้จากโทรมาตรที่ประกอบไปด้วยปริมาณน้ำฝนและสภาพอากาศมาใช้ในการทำนาย จากนั้นช่วงหลังจึงเพิ่มคุณลักษณะโดยใช้โทรมาตรใกล้เคียงเข้ามาดำเนินการ

##### 4.1.1 ข้อมูลที่วัดได้จากโทรมาตร

ชุดข้อมูลประกอบไปด้วยคุณลักษณะทั้งหมด 5 คุณลักษณะ โดยแบ่งเป็นปริมาณน้ำฝนและคุณลักษณะทางสภาพอากาศที่ส่งผลต่อการเกิดฝนที่วัดได้ในแต่ละชั่วโมง ได้แก่ อุณหภูมิมีหน่วยเป็นองศาเซลเซียส (Celsius) ความชื้นมีหน่วยเป็นเปอร์เซ็นต์ (%) และสุดท้ายความดันอากาศมีหน่วยมิลลิบาร์ (mBar)

## 1) การจัดการค่าว่าง

เนื่องจากข้อมูลน้ำฝนที่วัดจากโทรมาตรมีโอกาสเกิดค่าว่างเนื่องจากปัจจัยต่าง ๆ ดังนั้นเกณฑ์การเลือกโทรมาตรจะพิจารณาจากอัตราส่วนของค่าว่างในชุดข้อมูลที่มีน้อยกว่า 30 เปอร์เซ็นต์ของจำนวนจุดข้อมูลทั้งหมด โดยการเติมค่าว่างจะแบ่งตามภูมิภาคของประเทศไทย เนื่องจากปัจจัยทางสภาพอากาศ

- ภาคใต้

ภาคใต้เป็นภาคที่มีภูมิประเทศติดกับทะเลทั้งสองฝั่ง ทำให้บ่อยครั้งได้รับอิทธิพลจากลมมรสุมบ่อยกว่าภาคอื่น ๆ จึงทำให้ภาคใต้มีฝนตกอยู่ตลอดเวลา ดังนั้นวิธีเติมค่าว่างสามารถทำได้โดย การหาผลเฉลี่ยระหว่างค่าก่อนหน้าค่าว่างและค่าหลังจากค่าว่าง

- ภาคอื่น ๆ

เนื่องจากสภาพอากาศของประเทศไทยมีลักษณะเป็นอากาศร้อน ส่งผลให้มีช่วงฝนไม่ตกยาวนานกว่าช่วงที่ฝนตก โดยส่วนใหญ่แล้วประเทศไทยจะมีฝนตกตามฤดู ในช่วงเดือนพฤษภาคมจนถึงเดือนตุลาคม ซึ่งเป็นฤดูฝนของประเทศไทย ดังนั้นเติมค่าว่างจะแตกต่างจากภาคใต้ โดยถ้าเป็นฤดูฝนจะใช้วิธีหาผลเฉลี่ยระหว่างค่าก่อนหน้าค่าว่างและค่าหลังจากค่าว่าง ในส่วนฤดูอื่น ๆ คือการเติมค่าศูนย์แทนค่าว่างเพื่อแทนสภาพอากาศปกติของประเทศไทย

## 2) การเพิ่มข้อมูลคุณลักษณะทางสถิติ

เป็นการเพิ่มค่าคุณลักษณะทางสถิติให้กับข้อมูลปริมาณน้ำฝนก่อนที่จะถูกป้อนเข้าสู่แบบจำลอง จุดประสงค์คือเพิ่มความสัมพันธ์ที่เกี่ยวข้องกันของแต่ละคุณลักษณะในเชิงเวลา โดยทำการคำนวณค่าสูงสุด ค่าเฉลี่ยและผลรวม ซึ่งพิจารณาจากสามช่วงเวลาเมื่อนับจากเวลาปัจจุบัน คือ เปรียบเทียบเวลา ปัจจุบันกับชั่วโมงก่อนหน้า เปรียบเทียบเวลาปัจจุบันกับสองชั่วโมงก่อนหน้า และเปรียบเทียบเวลา ปัจจุบันกับสามชั่วโมงก่อนหน้า รวมถึงการสร้างคุณลักษณะที่บอกว่าฝนตกหรือไม่ตกจากการพิจารณาปริมาณน้ำฝน ถ้าหากปริมาณน้ำฝนอยู่ในช่วง 0 - 0.2 มิลลิเมตรหมายถึงฝนไม่ตก แต่ถ้าปริมาณน้ำฝนมากกว่า 0.2 มิลลิเมตรหมายถึงฝนตก สรุปแล้วจะมีจำนวนคุณลักษณะทั้งหมดเป็น 14 ตัวแปร

### 4.1.2 แนวทางการนำโทรมาตรใกล้เคียงมาใช้งาน

การพิจารณาหาโทรมาตรใกล้เคียงมาใช้งานประกอบไปด้วย 2 ขั้นตอน ได้แก่ การพิจารณาจากระยะห่างฮาเวอร์ไซน์ (Haversine distance) และการหาสหสัมพันธ์ (Correlation) ระหว่างตัวแปรของทั้งสองโทรมาตร

1) พิจารณาโดยใช้ระยะทางฮาเวอร์ไซน์ (Haversine distance) [16]

หลักเกณฑ์ในการนำข้อมูลจากโทรมাত্রใกล้เคียงมาใช้ เริ่มแรกจะพิจารณาเรื่องระยะทางของจุดติดตั้งโทรมাত্রสองจุดผ่านสูตรคำนวณฮาเวอร์ไซน์ (Haversine formula) ที่เป็นสูตรคำนวณระยะทางวงกลมขนาดใหญ่ โดยใช้ละติจูดและลองจิจูดของโทรมাত্রที่สนใจกับโทรมাত্রใกล้เคียงมาคิด ผลลัพธ์ที่ได้จะเป็นระยะทางเหนือพื้นผิวโลกในหน่วยกิโลเมตร ซึ่งการนำโทรมাত্রใกล้เคียงมาใช้จะต้องไม่ห่างจากโทรมাত্রที่กำลังสนใจเกิน 50 กิโลเมตร โดยสูตรการคำนวณระยะทางฮาเวอร์ไซน์ สามารถเขียนได้ตามสมการดังต่อไปนี้

$$\Delta lat = lat_2 - lat_1 \quad (26)$$

$$\Delta long = long_2 - long_1 \quad (27)$$

$$a = \sin^2\left(\frac{\Delta lat}{2}\right) + \cos(lat_1) \cos(lat_2) \sin^2\left(\frac{\Delta long}{2}\right) \quad (28)$$

$$c = 2(a)(\tan 2)(\sqrt{a}, \sqrt{1-a}) \quad (29)$$

$$d = R \cdot c \quad (30)$$

กำหนดให้  $R$  คือ รัศมีโลก มีค่าเท่ากับ 6,371 กิโลเมตร

$d$  คือ ระยะห่างระหว่างโทรมাত্রสองตัว

$lat_1$  คือ ละติจูดของโทรมাত্রที่กำลังสนใจ

$lat_2$  คือ ละติจูดของโทรมাত্রบริเวณใกล้เคียง

$long_1$  คือ ลองจิจูดของโทรมাত্রที่กำลังสนใจ

$long_2$  คือ ลองจิจูดของโทรมাত্রบริเวณใกล้เคียง

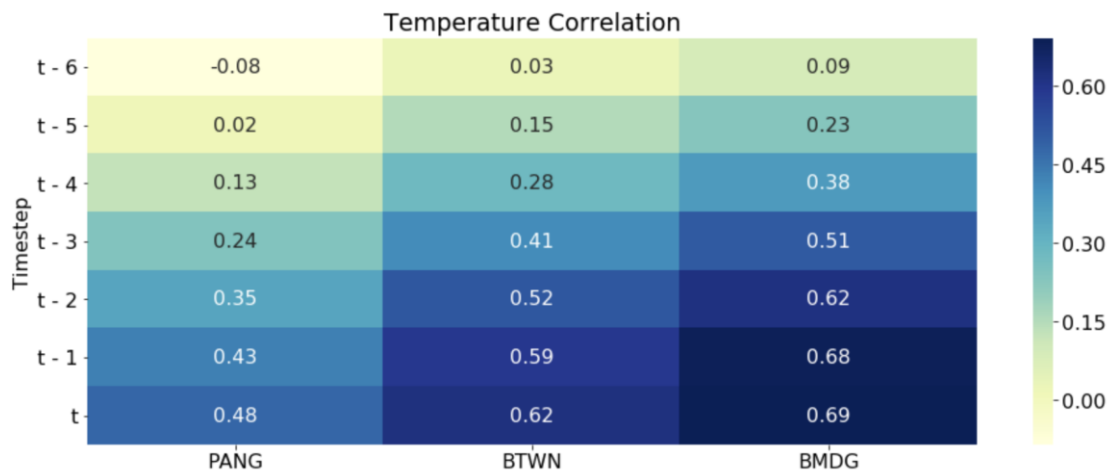
โดยการคำนวณเริ่มจากการผลต่างของละติจูดและลองจิจูดของโทรมাত্রที่สนใจและโทรมাত্রใกล้เคียงตามสมการที่ (25) และ (26) จากนั้นนำค่าที่ได้มาแทนใส่สูตรเพื่อคำนวณองศาตามสมการที่ (27) และ (28) โดยใช้หลักการทางตรีโกณมิติ ก่อนจะนำไปคูณกับรัศมีโลกเพื่อระยะห่างระหว่างจุดสองจุดในหน่วยกิโลเมตร

## 2) พิจารณาโดยใช้ค่าสหสัมพันธ์ (Correlation)

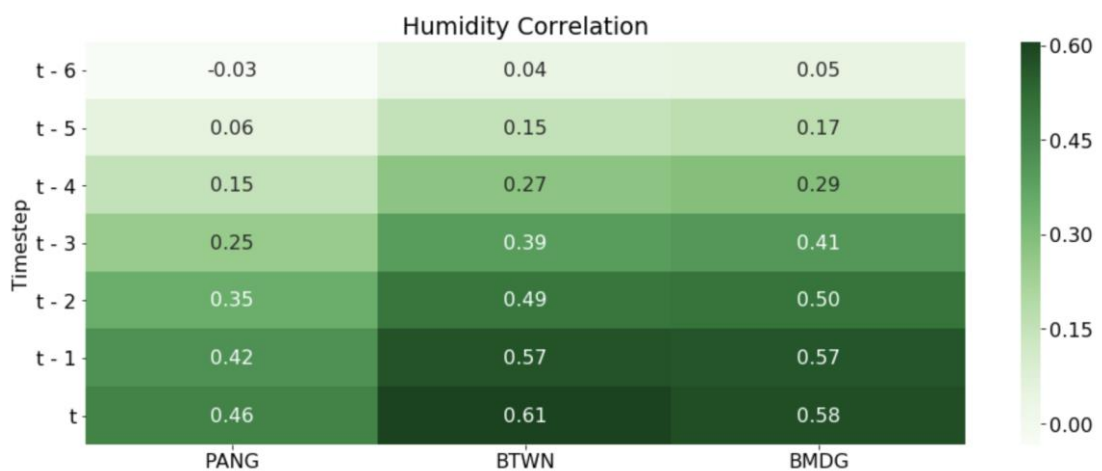
เมื่อได้จำนวนโทรมาตรเพื่อนบ้านตามรูปที่ 15 จะทำการหาสหสัมพันธ์ของตัวแปร อุณหภูมิและความชื้น เนื่องจากโทรมาตรที่อยู่ในพื้นที่หรือบริเวณเดียวกันควรมีอุณหภูมิและความชื้นไปในทางเดียวกัน ทั้งนี้สาเหตุที่ไม่ใช้ตัวแปรปริมาณน้ำฝน เพราะบางครั้งฝนอาจตกในบริเวณแคบ ๆ ทำให้การวัดค่าสหสัมพันธ์ของฝนมีค่าค่อนข้างต่ำ โดยค่าสหสัมพันธ์ของอุณหภูมิและความชื้นของโทรมาตรที่สนใจและโทรมาตรที่ใกล้เคียงต้องมีค่าไปทางบวก และนอกจากนี้ยังพิจารณาค่าสหสัมพันธ์ในเวลาก่อนหน้าด้วย เพราะอุณหภูมิและความชื้นในช่วงชั่วโมงก่อนหน้ากับชั่วโมงปัจจุบันควรมีค่าใกล้เคียงกัน โดยงานวิจัยนี้จะเลือกโทรมาตรที่มีค่าสหสัมพันธ์มากกว่า 0.5 ยกตัวอย่างจากรูปที่ 16 และรูปที่ 17 เป็นการแสดงค่าสหสัมพันธ์ของอุณหภูมิและความชื้นระหว่างโทรมาตรที่สนใจ คือ โทรมาตร “อบต. ชุนทะเล” แทนด้วย KTLE ในจังหวัดนครศรีธรรมราช ภาคใต้ และโทรมาตรใกล้เคียงที่อยู่ในระยะน้อยกว่าหรือเท่ากับ 50 กิโลเมตรได้แก่ โทรมาตร “อบต. ปากพยับฝิ่งตะวันออก” แทนด้วย PANG โทรมาตร “โรงเรียนวัดทวยการาม” แทนด้วย BTWN และโทรมาตร “อบต. นากะชะ” แทนด้วย BMDG ซึ่งตารางจะบอกค่าสหสัมพันธ์ในช่วงเวลาปัจจุบัน (t) และช่วงเวลาย้อนหลัง (ตั้งแต่ t - 1 ถึง t - 6 หน่วยเป็นหนึ่งชั่วโมง) พบว่าในช่วงเวลาใกล้เคียงกันมีเพียงโทรมาตร BTWN และ BMDG ที่มีค่ามากกว่า 0.5 จึงดำเนินการเลือกโทรมาตรดังกล่าวมาใช้งาน

	neighbor	distance
0	PANG	42.193146
1	BTWN	44.677244
2	BMDG	45.724534

รูปที่ 15 ระยะทางของโทรมาตรใกล้เคียงในบริเวณเดียวกับโทรมาตรที่สนใจ KTLE  
หน่วยเป็นกิโลเมตร



รูปที่ 16 ค่าสหสัมพันธ์ (Correlation) ตัวแปรอุณหภูมิของโทรมาตรที่สนใจในภาคใต้ (KTLE) และโทรมาตรใกล้เคียง (PANG , BTWN และ BMDG)



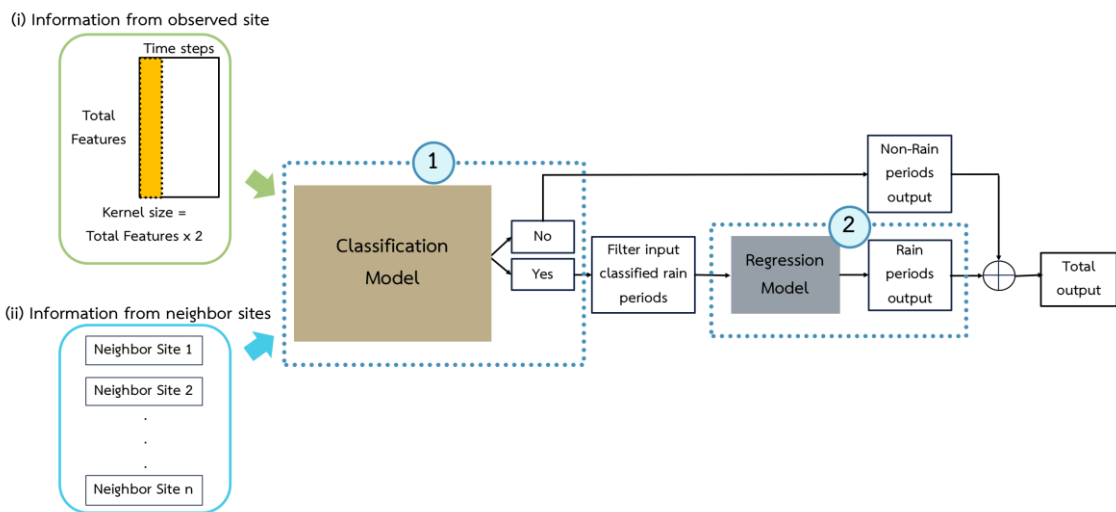
รูปที่ 17 ค่าสหสัมพันธ์ (Correlation) ตัวแปรความชื้นของโทรมาตรที่สนใจในภาคใต้ (KTLE) และโทรมาตรใกล้เคียง (PANG , BTWN และ BMDG)

#### 4.2 แบบจำลองการทำนายปริมาณน้ำฝนในชั่วโมงถัดไป

ในหัวข้อนี้ต้องการนำเสนอแบบจำลองสองแบบต่อกันเพื่อทำนายปริมาณน้ำฝนในหนึ่งชั่วโมงถัดไป โดยมีจุดประสงค์เพื่อวัดประสิทธิภาพในการทำนาย เนื่องจากการทำนายน้ำฝนในระยะใกล้สุดมีโอกาสแม่นยำที่สุด ดังนั้นจึงแบ่งการอธิบายแบบจำลองออกเป็นสองหัวข้อ คือ แบบจำลองจำแนกข้อมูลและแบบจำลองการวิเคราะห์การถดถอย ในส่วนแบบจำลองจำแนกข้อมูลได้นำนิเวศเน็ตเวิร์กคอนโวลูชันมาใช้เพื่อทำการพิจารณาความสัมพันธ์ทุกตัวแปรพร้อมกันเพื่อทำนายการเกิดฝนว่าตกหรือไม่ จากนั้นนำช่วงข้อมูลที่ฝนตกทั้งหมดเข้าสู่แบบจำลองการวิเคราะห์การถดถอย



โดยช่วงแรกของการทดลอง งานวิจัยได้ใช้โครงข่ายประตูกลับเพื่อพิจารณาข้อมูลในเชิง  
 แกวเวลา แต่พบว่าเมื่อนำมาใช้ร่วมกับข้อมูลโทรมาตรใกล้เคียงแล้ว ประสิทธิภาพการพยากรณ์ยังไม่  
 ค่อยดีนัก จึงได้ทดลองเปลี่ยนประเภทแบบจำลองวิเคราะห์การถดถอยเป็นตัวเข้ารหัสข้อมูลอัตโนมัติ  
 ร่วมกับเพอร์เซปตรอนหลายชั้น อันเนื่องมาจากแนวคิดลมิติข้อมูลเพื่อทำให้ข้อมูลมีความซับซ้อน  
 น้อยลงและให้ดักจับข้อมูลที่มีค่าสูงได้ ซึ่งจะกล่าวถึงในหัวข้อย่อยถัดไป ทั้งนี้สามารถเขียนภาพรวม  
 ของแบบจำลองสองแบบต่อกันได้ดังรูปที่ 18



รูปที่ 18 โครงสร้างแบบจำลองสองแบบต่อกันโดยใช้แบบจำลองจำแนกประเภท (1)  
 และแบบจำลองวิเคราะห์การถดถอย (2)

#### 4.2.1 แบบจำลองการจำแนกข้อมูล (Classification Model)

แบบจำลองที่ต้องการนำเสนอถูกปรับปรุงจากแบบจำลองในงานวิจัย [15] และ [17] ที่ใช้  
 นิวรอลเน็ตเวิร์กคอนโวลูชันในการสกัดคุณลักษณะสำคัญ ข้อมูลรับเข้าที่ใช้สำหรับแบบจำลองนี้เป็น  
 ข้อมูลปริมาณน้ำฝนรายชั่วโมงที่มาจากโทรมาตรที่กำลังสนใจและโทรมาตรใกล้เคียง  $n$  ตัว จากนั้น  
 ข้อมูลโทรมาตรทุกตัวจะถูกสร้างเป็นเมทริกซ์ขนาด  $F \times T$  โดยที่  $F$  คือจำนวนคุณลักษณะทั้งหมด  
 ของข้อมูลรับเข้า และ  $T$  คือจำนวนชั่วโมงก่อนหน้าที่ต้องการพิจารณาข้อมูลทั้งหมด ในงานวิจัยนี้  
 กำหนดให้  $T$  ให้มีขนาดเท่ากับ 12 หมายถึงต้องการพิจารณาข้อมูลปริมาณน้ำฝนทั้งหมดใน 12  
 ชั่วโมงก่อนหน้า จากนั้นนำเมทริกซ์ข้อมูลรับเข้าป้อนเข้าสู่นิวรอลเน็ตเวิร์กคอนโวลูชันที่มีชั้นคอนโวลู  
 ชันสองชั้นเพื่อสร้างพีเจอร์แมพที่ใช้หาความสัมพันธ์ของคุณลักษณะที่ไม่มีความสัมพันธ์เชิงเส้นต่อกัน  
 ก่อนที่จะนำเข้าชั้นการเชื่อมโยงเต็มรูปแบบและชั้นสถานะซ่อนที่มีฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์  
 โดยให้ผลลัพธ์เป็นการจำแนกว่าฝนตกหรือไม่ตก

สำหรับแบบจำลองนี้มีการกำหนดฟังก์ชันต้นทุนแบบพิเศษ คือ โฟคัลลอส (Focal loss) ที่นำมาจากงานวิจัย [18] ที่นำเสนอฟังก์ชันต้นทุนเพื่อจัดการปัญหาชุดข้อมูลไม่สมดุล เนื่องจากพบว่าเมื่อนำชุดข้อมูลปริมาณน้ำฝนตั้งแต่ปี ค.ศ. 2012 จนถึงปี ค.ศ. 2018 มาทำการวิเคราะห์ข้อมูลเบื้องต้นแล้ว พื้นที่ส่วนใหญ่ของประเทศไทยมีอัตราของชั่วโมงที่ฝนไม่ตกคิดเป็น 95 เปอร์เซ็นต์ของชุดข้อมูลทั้งหมด โดยงานวิจัยนี้ได้นำฟังก์ชันต้นทุนโฟคัลลอสใช้ร่วมกับฟังก์ชันซิกมอยด์ เพื่อช่วยให้แบบจำลองไม่โอนเอียงไปทางคลาสที่ฝนไม่ตก สามารถเขียนสมการของฟังก์ชันต้นทุนโฟคัลลอสได้ดังนี้

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (31)$$

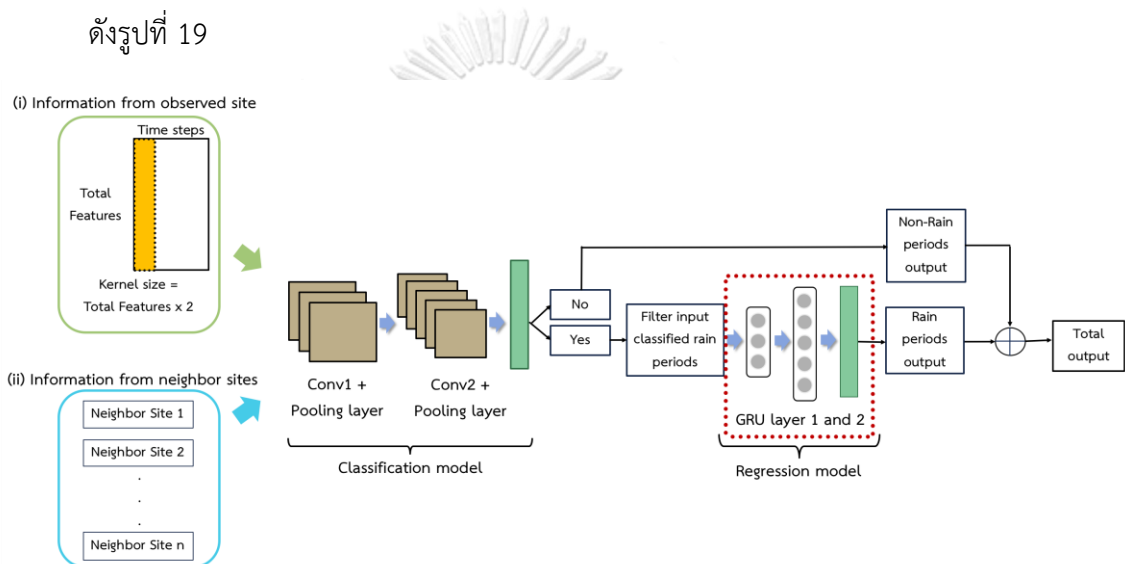
โดยพารามิเตอร์ที่สำคัญประกอบด้วยตัวแปร  $p_t$  คือค่าความน่าจะเป็นจากการคำนวณของฟังก์ชันต้นทุนที่ชุดข้อมูล  $t$  ตัวแปร  $\alpha_t$  คือน้ำหนักของแต่ละคลาสที่ชุดข้อมูล  $t$  เพื่อให้คลาสมีความสมดุลกัน โดย  $\alpha$  มีค่าตั้งแต่ 0 ถึง 1 ถ้ากำหนดให้  $\alpha$  เป็นน้ำหนักให้กับคลาสที่ฝนตก ดังนั้น  $1 - \alpha$  คือน้ำหนักของคลาสที่ฝนไม่ตก และสุดท้ายตัวแปร  $\gamma$  คือตัวแปรที่ใช้สำหรับปรับน้ำหนักในกรณีที่มีคลาสหนึ่งถูกทำนายตัวอย่างได้ถูกต้องมากเกินไป ตัวฟังก์ชันต้นทุนนี้จะมองว่าถ้าตัวอย่างถูกทำนายได้ถูกต้องมากแปลว่าตัวอย่างนั้นอยู่ในคลาสที่มีจำนวนตัวอย่างมากกว่าอีกคลาสหนึ่ง ต้องทำการปรับน้ำหนักให้สมดุล โดย  $\gamma$  มีค่ามากกว่าเท่ากับศูนย์

#### 4.2.2 แบบจำลองวิเคราะห์การถดถอย (Regression Model)

แบบจำลองนี้จะรับข้อมูลรับเข้าที่เป็นบริเวณฝนตกเท่านั้นเข้ามาทำนายปริมาณน้ำฝนโดยมีจุดประสงค์ให้แบบจำลองสามารถทำนายปริมาณน้ำฝนได้จริง ๆ โดยไม่มีความลำเอียงจากช่วงที่ฝนไม่ตกที่มีปริมาณเยอะกว่าช่วงที่ฝนตกมาก โดยในชุดข้อมูลจะใช้ข้อมูลรับเข้าที่มาจากผลลัพธ์ของแบบจำลองการจำแนกข้อมูล โดยจะกรองเฉพาะตัวอย่างที่ถูกจำแนกว่าเป็นฝนตก ในหัวข้อนี้มีสองแบบจำลองที่ถูกนำมาใช้งาน ได้แก่ โครงข่ายประตูกลับที่ถูกนำมาทดลองในช่วงแรกของการวิจัย และตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้นที่ถูกนำมาใช้เพื่อเพิ่มประสิทธิภาพในการดักจับข้อมูลปริมาณน้ำฝนที่มีค่าสูง

### 1) แบบจำลองวิเคราะห์การถดถอยโดยใช้โครงข่ายประตูกกลับ

แบบจำลองโครงข่ายประตูกกลับถูกนำมาใช้งานในเรื่องของการวิเคราะห์ข้อมูลอนุกรมเวลา โดยเมื่อได้ผลลัพธ์จากแบบจำลองการจำแนกข้อมูลแล้ว จะทำการแปลงเป็นข้อมูลรับเข้าที่มีมิติเป็น (จำนวนตัวอย่าง,  $T$ ,  $F$ ) โดยที่  $F$  คือจำนวนคุณลักษณะทั้งหมดของข้อมูลรับเข้า และ  $T$  คือจำนวนชั่วโมงก่อนหน้าซึ่งกำหนดเป็น 12 ชั่วโมงเช่นเดียวกับแบบจำลองการจำแนกประเภท จากนั้นแบบจำลองจะทำการพิจารณาข้อมูลปริมาณน้ำฝน 12 ชั่วโมงก่อนหน้าเพื่อทำนายปริมาณน้ำฝนในอีกหนึ่งชั่วโมงข้างหน้า สามารถแสดงโครงสร้างของแบบจำลองสองแบบต่อกันโดยใช้นิวรอลเน็ตเวิร์กและโครงข่ายประตูกกลับได้ ดังรูปที่ 19

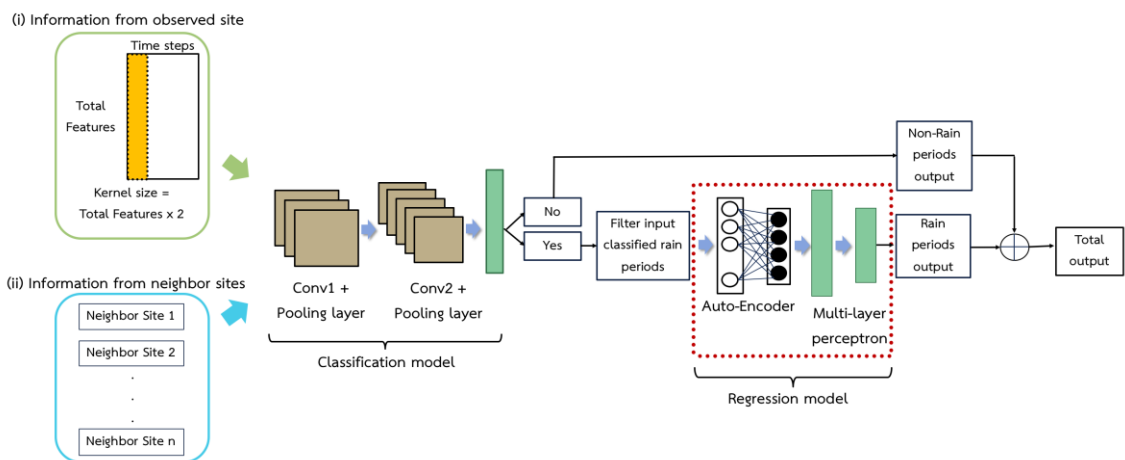


รูปที่ 19 โครงสร้างแบบจำลองที่นำเสนอโดยผสมนิวรอลเน็ตเวิร์กคอนโวลูชัน และโครงข่ายประตูกกลับ

### 2) แบบจำลองวิเคราะห์การถดถอยโดยใช้ตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น

แบบจำลองนี้ถูกนำมาใช้ในการทดลองช่วงหลังโดยเปลี่ยนประเภทของแบบจำลองในส่วนของแบบจำลองวิเคราะห์การถดถอย เนื่องจากการใช้โครงข่ายประตูกกลับยังไม่สามารถให้ผลที่ดีที่สุดและตรวจจับค่าสูงได้ จึงได้ทดลองเปลี่ยนเป็นแบบจำลองตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น ตัวเข้ารหัสข้อมูลอัตโนมัติถูกนำมาใช้เพื่อลดมิติของข้อมูล ทำให้เห็นรูปแบบของข้อมูลชัดเจนขึ้น โดยก่อนนำข้อมูลเข้าแบบจำลองต้องแปลงข้อมูลรับเข้าให้มีมิติเป็น (จำนวนตัวอย่าง,  $F \times T$ ) โดยแต่ละตัวแปรมีความหมายเดียวกับ

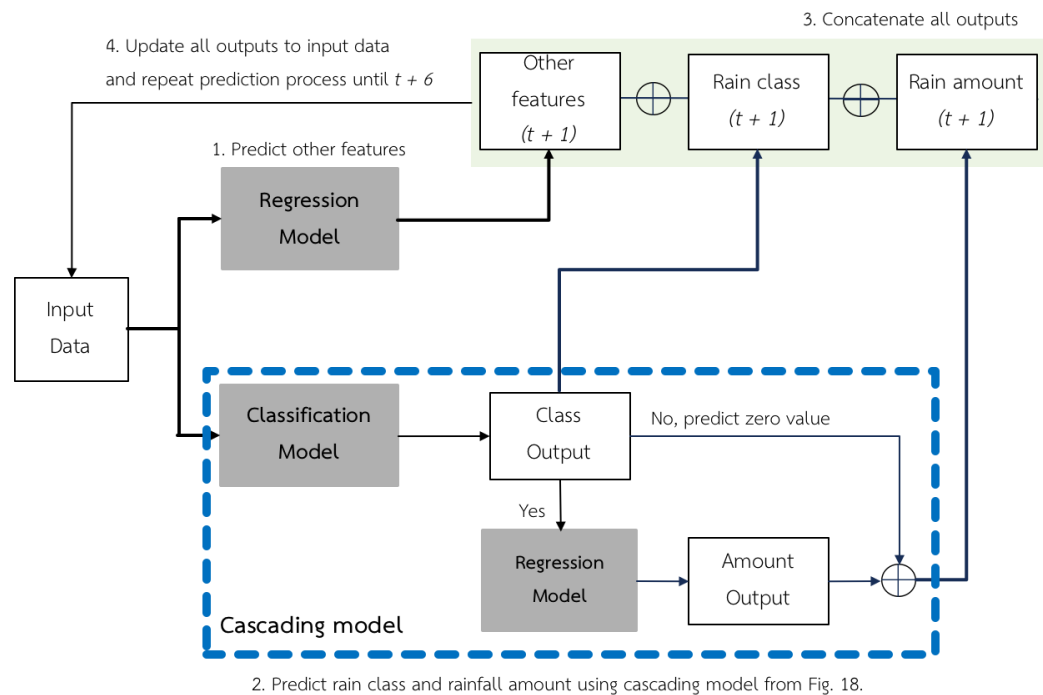
หัวข้อ 1) จากนั้นจึงป้อนเข้าชั้นตัวเข้ารหัสข้อมูลอัตโนมัติ ซึ่งเป็นการฝึกสอนโดยใช้ชุดข้อมูลตัวอย่างเป็นทั้งข้อมูลฝึกสอนและผลเฉลย (Label) โดยข้อมูลส่งออกที่ได้จะมีมิติที่ลดลงแต่สามารถเป็นตัวแทนให้กับข้อมูลตัวอย่างได้ จากนั้นจึงนำข้อมูลส่งออกของตัวเข้ารหัสข้อมูลอัตโนมัติป้อนไปยังแบบจำลองเพอร์เซปตรอนหลายชั้นเพื่อทำนายปริมาณน้ำฝน สามารถแสดงโครงสร้างของแบบจำลองสองแบบต่อกันโดยใช้นิวรอลเน็ตเวิร์กและตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้นได้ดังรูปที่ 20



รูปที่ 20 โครงสร้างแบบจำลองที่นำเสนอโดยผสมนิวรอลเน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสข้อมูลร่วมกับเพอร์เซปตรอนหลายชั้น


#### 4.3 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายชั้นโดยใช้เทคนิคการใส่ข้อมูลที่ถูกรับแล้วเป็นข้อมูลรับเข้าเพื่อทำนายขั้นถัดไป

แบบจำลองนี้ต้องการนำเสนอการทำนายปริมาณน้ำฝนหลายชั้นตอน ในที่นี้หมายถึงการทำนายปริมาณฝนในอีกหกชั่วโมงข้างหน้า ซึ่งเป็นการพยากรณ์ในระยะสั้นและสามารถนำไปใช้เชิงปฏิบัติจริงได้ โดยแบบจำลองนี้จะนำผลลัพธ์ที่ได้จากการทำนายมาเป็นข้อมูลรับเข้าเพื่อนำไปทำนายในชั่วโมงถัดไป โดยเพิ่มแบบจำลองโครงข่ายประตูกลับในการทำนายคุณลักษณะอื่น ๆ ที่ไม่ใช่ปริมาณน้ำฝนเข้าไปด้วย ซึ่งกระบวนการทำงานสามารถเขียนได้ดังรูปที่ 21

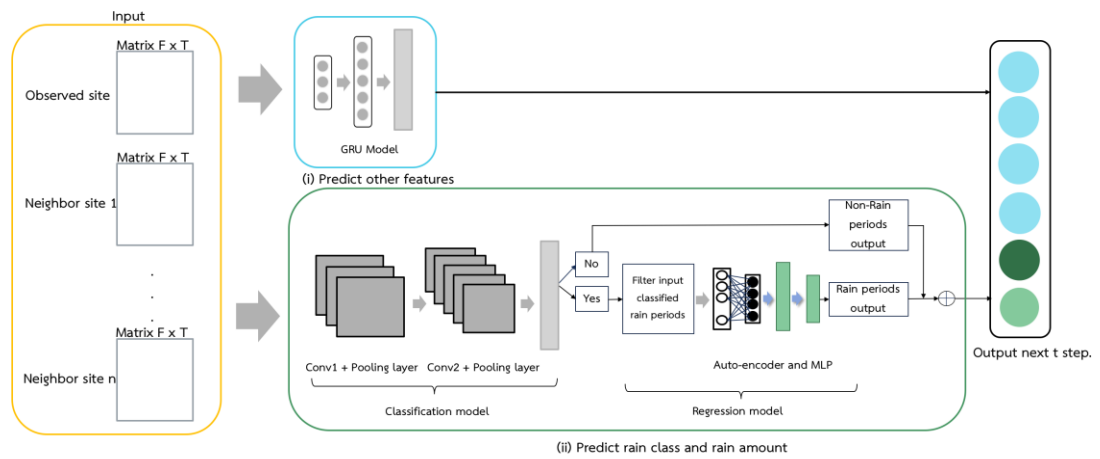


รูปที่ 21 กระบวนการทำนายปริมาณน้ำฝนแบบหลายขั้นตอนโดยใช้เทคนิคการใส่ข้อมูลที่ถูกทำนายเป็นข้อมูลรับเข้าเพื่อทำนายขั้นถัดไป

จากรูปที่ 21 สามารถอธิบายแต่ละกระบวนการได้ดังนี้ แบบจำลองที่นำเสนอประกอบไปด้วย 2 ส่วน คือส่วนแรก (i) เป็นส่วนที่นำเสนอแบบจำลองที่ใช้สำหรับทำนายคุณลักษณะอื่น ๆ ที่ไม่ใช่ปริมาณน้ำฝน โดยใช้แบบจำลองโครงข่ายประตูกลับ และส่วนที่สอง (ii) คือแบบจำลองที่มาจากหัวข้อ 4.2 ทั้งสองแบบจำลอง ใช้สำหรับการทำนายคลาสว่าฝนตกหรือไม่ตกและทำนายปริมาณน้ำฝนสมมติให้เวลาปัจจุบันที่เราสนใจเป็น  $t$  ผลลัพธ์ที่ได้จากแบบจำลองทั้งสองส่วนนี้คือคุณลักษณะทั้งหมดที่ถูกทำนายในเวลาถัดไป  $t+1$  จากนั้นนำคุณลักษณะทั้งหมดในเวลา  $t+1$  มาต่อกันเพื่อป้อนเป็นข้อมูลรับเข้าไปยังแบบจำลองอีกครั้งเพื่อทำนายข้อมูลในเวลา  $t+2$  ในขั้นตอนนี้ได้ใช้เทคนิคการเลื่อนหน้าต่าง (sliding window) โดยจะเลื่อนตำแหน่งบนเมทริกซ์ข้อมูลทีละหนึ่ง เพื่อให้แบบจำลองพิจารณาข้อมูลที่ถูกป้อนเข้าไปเป็นข้อมูลล่าสุด กระทำซ้ำแบบนี้ไปเรื่อย ๆ จนกระทั่งเวลาเท่ากับ  $t+6$  หรืออีกนัยหนึ่งหมายถึง เวลาที่ 6 ชั่วโมงข้างหน้า โดยโครงสร้างของแบบจำลองสามารถแสดงได้ดังรูปที่ 22 ซึ่งแบบจำลองวิเคราะห์การถดถอยเป็นโครงข่ายประตูกลับ และรูป 23 โดยเปลี่ยนแบบจำลองวิเคราะห์การถดถอยเป็นตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น



รูปที่ 22 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายขั้นโดยใช้แบบจำลองวิเคราะห์การถดถอยเป็นโครงข่ายประตูกลับ



รูปที่ 23 แบบจำลองการทำนายปริมาณน้ำฝนแบบหลายขั้นโดยใช้แบบจำลองวิเคราะห์การถดถอยเป็นตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น

## บทที่ 5


### การทดลองและผลการทดลอง

หัวข้อนี้จะกล่าวถึงชุดข้อมูลที่ใช้ในการทดลอง วิธีการเตรียมข้อมูลก่อนนำมาใช้ แบบจำลองอื่น ๆ ที่ถูกสร้างขึ้นเพื่อนำมาเปรียบเทียบประสิทธิภาพกับแบบจำลองที่นำเสนอ วิธีการวัดผล และผลการทดลองเบื้องต้น


#### 5.1 ชุดข้อมูล

ชุดข้อมูลที่นำมาใช้ในวิทยานิพนธ์นี้ เป็นข้อมูลปริมาณน้ำฝนรายชั่วโมงที่ถูกบันทึกโดยโทรมาตรที่ถูกติดตั้งในประเทศไทยทั้งหมด 469 สถานี โดยได้รับการสนับสนุนจากสสน. ซึ่งหลังจากกรองความสมบูรณ์ของโทรมาตรแล้ว ด้วยวิธีการจัดการค่าว่างในหัวข้อที่ 4.1.1 ในบทที่ 4 จะเหลือโทรมาตรที่นำมาใช้ได้ประมาณ 234 สถานี ชุดข้อมูลปริมาณน้ำฝนมีข้อมูลตั้งแต่ปี ค.ศ. 2012 จนถึงปี ค.ศ. 2018 เมื่อนับจำนวนจุดข้อมูลจะมีทั้งหมด 61,310 จุด ในการนำเข้ามาแบบจำลอง จะแบ่งข้อมูลตั้งแต่ปี ค.ศ. 2012 ถึงปี ค.ศ. 2016 เป็นข้อมูลฝึกสอน (Training data) จากนั้นปี ค.ศ. 2017 เป็นข้อมูลตรวจสอบ (Validation data) และสุดท้ายข้อมูลปี ค.ศ. 2018 เป็นข้อมูลทดสอบ (Test data)


โดยหลังจากแบ่งชุดข้อมูลเรียบร้อยแล้ว เมื่อนำมาตรวจสอบการกระจายตัวของแต่ละตัวแปรประกอบด้วย อุณหภูมิ (Temperature) ความชื้น (Humidity) ความกดอากาศ (Pressure) และปริมาณน้ำฝน (Rain amount) สามารถแสดงได้ดังรูปที่ 24 - 26 โดยพบว่าอุณหภูมิและความกดอากาศมีลักษณะใกล้เคียงกับการกระจายตัวปกติ ในขณะที่ความชื้นมีลักษณะเป็นกราฟเบ้ซ้าย และปริมาณน้ำฝนมีลักษณะเป็นกราฟเบ้ขวา



รูปที่ 24 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลฝึกสอน (Training data)




รูปที่ 25 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลตรวจสอบ (Validation data)




รูปที่ 26 การกระจายตัวในแต่ละตัวแปรของชุดข้อมูลฝนที่เป็นข้อมูลทดสอบ (Test data)

เมื่อลองนำมาวิเคราะห์อัตราส่วนของช่วงที่ฝนไม่ตกและช่วงที่ฝนตกพบว่ามีอัตราส่วนแตกต่างกันอย่างมากโดย 95% ของชุดข้อมูลเป็นช่วงที่ฝนไม่ตก และอีก 5% เป็นช่วงที่ฝนตก ซึ่งอัตราส่วนที่ได้เกิดจากการเปรียบเทียบจากชุดข้อมูลในภาคตะวันออกเฉียงเหนือ แต่ในภาคใต้ช่วงที่ฝนตกจะมีมากกว่าเล็กน้อย แสดงได้ดังรูปที่ 27 - 28



รูปที่ 27 อัตราส่วนของช่วงที่ฝนไม่ตกและฝนตกในภาคใต้ในชุดข้อมูลฝึกสอน



รูปที่ 28 อัตราส่วนของช่วงที่ฝนไม่ตกและฝนตกในภาคตะวันออกเฉียงเหนือในชุดข้อมูลฝึกสอน



## 5.2 การเลือกใช้นอร์มัลไลเซชัน

ก่อนที่จะนำข้อมูลเข้าสู่แบบจำลอง เนื่องจากคุณลักษณะของชุดข้อมูลในแต่ละอันมีมาตราส่วนของค่าที่วัดได้แตกต่างกัน รวมทั้งค่าของชุดข้อมูลมีลักษณะการกระจายตัวที่ไม่ใช่การแจกแจงปกติ (Normal distribution) จึงจำเป็นต้องแปลงค่าคุณลักษณะทั้งหมดให้มีค่าอยู่ในมาตราส่วนเดียวกัน โดยวิธีการนอร์มัลไลเซชันด้วยค่าสูงสุดและค่าต่ำสุด (Min-Max Normalization) ได้ถูกนำมาใช้ในช่วงทำการทดลองเบื้องต้นของแบบจำลองสองแบบต่อกันโดยใช้นิวรอลเน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกลับ ซึ่งเป็นการปรับค่าในชุดข้อมูลให้อยู่ในช่วง 0 – 1 สามารถเขียนสมการได้ดังนี้

$$y_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (32)$$

เมื่อกำหนดให้  $x$  เป็นค่าดั้งเดิมของชุดข้อมูลที่  $i$  โดยที่  $\min(x)$  เป็นค่าที่ต่ำสุดของชุดข้อมูล  $x$  และ  $\max(x)$  เป็นค่าที่สูงสุดของชุดข้อมูล  $x$  โดย  $y$  เป็นค่าที่ถูกทำนอร์มัลไลเซชันของชุดข้อมูลที่  $i$

แต่เมื่อทำการเปลี่ยนแบบจำลองเป็นแบบจำลองสองแบบต่อกันโดยใช้นิวรอลเน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น โดยแบบจำลองต้องการตรวจจับค่าผิดปกติ (Outlier) ทำให้พบว่าวิธีการนอร์มัลไลเซชันด้วยค่าคะแนนมาตรฐาน (Z-Score) เป็นวิธีที่เหมาะสมกับแบบจำลอง โดยเป็นการปรับการกระจายของข้อมูลให้มีค่าเฉลี่ยเป็น 0 และค่าเบี่ยงเบนมาตรฐานเป็น 1 ซึ่งการนอร์มัลไลเซชันในลักษณะจะช่วยในเรื่องการปรับเรียบค่าผิดปกติได้

$$y_i = \frac{x_i - \mu(x)}{\sigma(x)} \quad (33)$$

เมื่อกำหนดให้  $x$  เป็นค่าดั้งเดิมของชุดข้อมูลที่  $i$  โดยที่  $\mu(x)$  เป็นค่าเฉลี่ยของชุดข้อมูล  $x$  และ  $\sigma(x)$  เป็นค่าเบี่ยงเบนมาตรฐานของชุดข้อมูล  $x$  โดย  $y$  เป็นค่าที่ถูกทำนอร์มัลไลเซชันของชุดข้อมูลที่  $i$

## 5.3 แบบจำลองอื่น ๆ เพื่อนำมาเปรียบเทียบประสิทธิภาพ

หัวข้อนี้จะกล่าวถึงแบบจำลองอื่น ๆ ที่ได้ถูกนำมาใช้ทำนายปริมาณน้ำฝน โดยนำแบบจำลองเหล่านี้มาใช้กับชุดข้อมูลน้ำฝนของประเทศไทยเพื่อเปรียบเทียบประสิทธิภาพกับแบบจำลองที่นำเสนอ

### 5.3.1 แบบจำลองอาริมาโดยพิจารณาจากข้อมูลปริมาณน้ำฝนเพียงอย่างเดียว

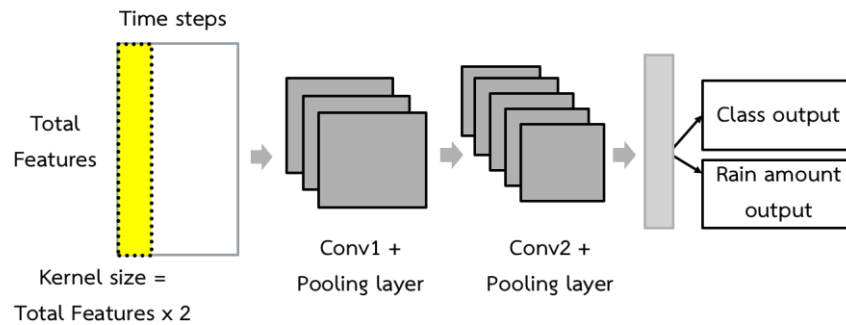
ตามที่กล่าวถึงแบบจำลองอาริมาในบทที่ 2 งานวิจัยนี้ได้หยิบแบบจำลองอาริมามาใช้กับข้อมูลปริมาณน้ำฝนเช่นเดียวกันเพื่อใช้สำหรับเปรียบเทียบกับแบบจำลองการเรียนรู้เชิงลึก โดยทำการหาค่าพารามิเตอร์ที่ดีที่สุดด้วยวิธีตะแกรง (grid search) เพื่อให้ได้ค่า  $(p,d,q)$  ซึ่งเป็นค่า  $(2,1,0)$  ที่ทำให้แบบจำลองมีค่าความคลาดเคลื่อนน้อยที่สุด โดยผลลัพธ์ที่ได้จะเป็นปริมาณน้ำฝนในชั่วโมงถัดไป

### 5.3.2 แบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้นโดยใช้ข้อมูลจากชุดข้อมูลทั้งหมด

แบบจำลองนี้ได้นำวิธีการจากงานวิจัย [14] มาใช้ โดยนำข้อมูลทั้งหมดจากชุดข้อมูลฝนมาเพิ่มข้อมูลคุณลักษณะ จากนั้นจึงแปลงข้อมูลให้มีขนาด  $(14 + n) \times 1$  เพื่อเป็นข้อมูลรับเข้าให้กับแบบจำลอง โดยกำหนดให้  $n$  เป็นข้อมูลน้ำฝนจากโทรมาตรใกล้เคียงซึ่งแต่ละภาคจะมีจำนวนไม่เท่ากัน จากนั้นนำคุณลักษณะ  $14 + n$  ตัวคุณจำนวนเวลาล่วงหน้าที่ใช้คือ 12 ชั่วโมงล่วงหน้า และนำเข้าแบบจำลองเพื่อทำนายปริมาณน้ำฝน โดยขอแทนแบบจำลองนี้ด้วยตัวย่อ AE-MLP

### 5.3.3 แบบจำลองมัลติทาสก์ (Multi-task) แบบนิรอรเน็ตเวิร์กคอนโวลูชันโดยใช้ข้อมูลจากชุดข้อมูลทั้งหมด

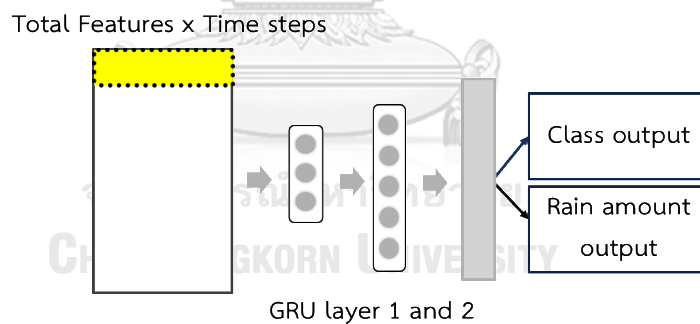
แบบจำลองนี้ประยุกต์จากงานวิจัย [15] และ [17] โดยนำข้อมูลทั้งหมดจากชุดข้อมูลฝนมาเพิ่มข้อมูลคุณลักษณะเช่นเดียวกับแบบจำลองตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น ข้อมูลจะถูกแปลงให้อยู่ในรูปแบบเมทริกซ์ที่มีขนาด  $(14 + n) \times 12 \times 1$  โดยข้อมูลรับเข้ามีคุณลักษณะทั้งหมด  $14 + n$  ตัวและใช้เวลาอย่างน้อยเท่ากับ 12 ชั่วโมง และมีจำนวนช่องสัญญาณเท่ากับ 1 ช่อง จากนั้นจึงป้อนข้อมูลทั้งหมดเข้าชั้นคอนโวลูชัน 2 ชั้นเพื่อสร้างพีเจอร์แมพ แต่ในงานวิจัยนี้แบบจำลองจะทำนายสองงานพร้อมกันในชั่วโมงถัดไป ได้แก่ ทำนายว่าฝนตกหรือไม่ตก และทำนายปริมาณน้ำฝน ขอแทนแบบจำลองนี้ด้วยตัวย่อ MT-CNN และแสดงโครงสร้างของแบบจำลองที่ปรับปรุงแล้วดังรูปที่ 29



รูปที่ 29 แบบจำลองมัลติทาสก์แบบนิรอลเน็ตเวิร์กคอนโวลูชัน

5.3.4 แบบจำลองมัลติทาสก์แบบโครงข่ายประตูกกลับ โดยใช้ข้อมูลจากชุดข้อมูลทั้งหมด

แบบจำลองนี้คล้ายกับแบบจำลอง 5.3.3 แต่เปลี่ยนจากแบบจำลองโครงข่ายประสาทเทียมคอนโวลูชันมาเป็นแบบจำลองโครงข่ายประตูกกลับ โดยข้อมูลรับเข้ามีคุณลักษณะทั้งหมด  $14 + n$  ตัวและเวลาที่ใช้ย้อนหลังคือ 12 ชั่วโมง โดยขนาดของข้อมูลรับเข้ามีขนาดเท่ากับ  $(14 + n) \times 12$  จากนั้นจึงป้อนเข้าแบบจำลองเพื่อพิจารณาความสัมพันธ์ของตัวแปรหลายตัวในแกนเวลา ผลลัพธ์สุดท้ายจะทำนายสองงานพร้อมกันในชั่วโมงถัดไป ได้แก่ทำนายว่าฝนตกหรือไม่ตก และทำนายปริมาณน้ำฝน ซึ่งขอแทนแบบจำลองนี้ด้วยตัวย่อ MT-GRU



รูปที่ 30 แบบจำลองมัลติทาสก์แบบโครงข่ายประตูกกลับ

#### 5.4 การปรับจูนค่าไฮเปอร์พารามิเตอร์ของแบบจำลอง (Hyper-Parameter Tuning)

หัวข้อนี้จะแสดงถึงค่าไฮเปอร์พารามิเตอร์ (Hyper-parameter) ที่ถูกการปรับจูนในแบบจำลองที่นำเสนอ โดยแบ่งเป็น 2 หัวข้อย่อย อ้างอิงตามหัวข้อ 4.2 ที่ได้นำเสนอแบบจำลอง 2 แบบ

##### 5.4.1 แบบจำลองสองแบบต่อกันโดยผสมนิรอรลเน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกกลับ

การปรับจูนจะถูกแบ่งเป็นสองส่วน คือ แบบจำลองการจำแนกประเภท และ แบบจำลองวิเคราะห์การถดถอย โดยค่าจะเป็นตามตารางที่ 3

ตารางที่ 3 แสดงการปรับจูนค่าไฮเปอร์พารามิเตอร์ในแบบจำลองสองแบบต่อกันโดยผสมนิรอรลเน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกกลับ

แบบจำลอง	ชั้นของแบบจำลอง (Layer)	ไฮเปอร์พารามิเตอร์ (Hyper-Parameter)
แบบจำลองการจำแนกประเภท (Classification Model)	Convolution Layer 1	8 filters, kernel size = Features x 2
	Convolution Layer 2	16 filters, kernel size = 1 x 3
	Max Pooling Layer	Pool size = 1 x 2
	Fully-Connected	512
แบบจำลองการวิเคราะห์การถดถอย (Classification Model)	GRU Layer 1	32
	GRU Layer 2	128
	Dense Layer	512
	Dropout	0.25

##### 5.4.2 แบบจำลองสองแบบต่อกันโดยผสมนิรอรลเน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น

ในหัวข้อนี้การปรับจูนของแบบจำลองการจำแนกประเภทจะเหมือนกับหัวข้อ 5.4.1 แต่แบบจำลองวิเคราะห์การถดถอยจะถูกเปลี่ยนเป็นแบบจำลองตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น โดยค่าจะเป็นตามตารางที่ 4

ตารางที่ 4 แสดงการปรับจูนค่าไฮเปอร์พารามิเตอร์ในแบบจำลองสองแบบต่อกันโดยผสมนิรอรลเน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น

แบบจำลอง	ชั้นของแบบจำลอง (Layer)	ไฮเปอร์พารามิเตอร์ (Hyper-Parameter)
แบบจำลองการจำแนกประเภท (Classification Model)	Convolution Layer 1	8 filters, kernel size = Features x 2
	Convolution Layer 2	16 filters, kernel size = 1 x 3
	Max Pooling Layer	Pool size = 1 x 2
	Fully-Connected	512
แบบจำลองการวิเคราะห์การถดถอย (Classification Model)	Encoder Layer	32
	Dense Layer 1	512
	Dense Layer 2	512
	Dropout	0.25

## 5.5 การวัดผล

ในแง่ของการเปรียบเทียบประสิทธิภาพในการทำนายปริมาณน้ำฝนของแต่ละแบบจำลอง จะพิจารณาจากค่าความคลาดเคลื่อนโดยใช้ตัววัดรากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง แต่ทั้งนี้ งานวิจัยนี้ได้ทำแสดงผลแบบจำลองจำแนกข้อมูลเพื่อดูประสิทธิภาพในการจำแนกคลาสฝนตกและไม่ตกในอีกหนึ่งชั่วโมงข้างหน้าด้วย

โดยทั่วไปแล้วแบบจำลองจำแนกประเภทมักใช้ค่าความแม่นยำ เป็นตัววัดเพื่อบ่งบอกความสามารถของแบบจำลองว่าทายถูกกี่ครั้งจากจำนวนการทายทั้งหมด แต่เนื่องจากงานวิจัยนี้ใช้ข้อมูลที่มีความไม่สมดุลระหว่างคลาสที่ฝนตกและคลาสที่ฝนไม่ตก โดยคลาสฝนไม่ตกอยู่ในอัตราส่วนที่มากกว่า ดังนั้นการใช้ค่าความแม่นยำอาจทำให้เกิดการโอนเอียงจากข้อมูลเพราะทำนายคลาสฝนไม่ตกได้ถูกต้องมากกว่า ดังนั้นค่าเอพวันจึงเหมาะที่นำมาใช้เป็นตัววัดในข้อมูลชุดนี้เพื่ออธิบายความสามารถในการทำนายคลาสที่ฝนตก

## 5.6 ผลการทดลอง

### 5.6.1 ผลการทดลองโดยเปรียบเทียบการทำนายปริมาณน้ำฝนล่วงหน้าหนึ่งชั่วโมง

การเปรียบเทียบการทำนายปริมาณน้ำฝนล่วงหน้าหนึ่งชั่วโมงจะแบ่งการวัดประสิทธิภาพเป็นสองแกน โดยแกนแรกจะเปรียบเทียบในเรื่องของแบบจำลองที่นำเสนอกับแบบจำลองอื่น ๆ ที่ได้กล่าวถึงในหัวข้อที่ 5.3 ในส่วนของแกนที่สองจะเป็นการเปรียบเทียบประสิทธิภาพการทำนายระหว่างการใช้ข้อมูลโทรมาตรเดียวกับการใช้ข้อมูลโทรมาตรที่สนใจร่วมกับโทรมาตรที่ใกล้เคียง

#### 1) การเปรียบเทียบระหว่างแบบจำลองที่ใช้ข้อมูลทั้งหมดและแบบจำลองสองแบบต่อกัน

จากผลการทดลองที่แสดงในตารางที่ 5 แสดงถึงการเปรียบเทียบประสิทธิภาพการทำนายปริมาณน้ำฝนทั้งหมดในแต่ละแบบจำลอง แยกตามภูมิภาคของประเทศไทย โดยใช้ตัววัดค่าความคลื่อนคือรากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองในหน่วยมิลลิเมตร พบว่าแบบจำลอง Cascade ให้ค่าความคลาดเคลื่อนต่ำสุด โดยสามารถคิดเปอร์เซ็นต์ที่พัฒนาขึ้นเป็น 12.4 เปอร์เซ็นต์เมื่อเปรียบเทียบค่าเฉลี่ยของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองของทุก ๆ ภูมิภาค ในขณะที่เดียวกันแบบจำลองอาร์มาให้ค่าความคลาดเคลื่อนมากที่สุดเมื่อเปรียบเทียบกับแบบจำลองการเรียนรู้ทั้งหมด ดังนั้นความสามารถในการสกัดคุณลักษณะพิเศษของแบบจำลองการเรียนรู้เชิงลึกสามารถเพิ่มประสิทธิภาพในการทำนายปริมาณน้ำฝนได้ดีกว่าใช้แบบจำลองอาร์มาที่พิจารณาเพียงตัวแปรปริมาณน้ำฝนเพียงอย่างเดียว

ตารางที่ 5 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตรซึ่งพิจารณาจากปริมาณน้ำฝนทั้งหมดและแบ่งแยกตามภาค

แบบจำลอง ภาค	แบบจำลองพื้นฐาน		วิธีการเรียนรู้เชิงลึก		ที่นำเสนอ
	แบบจำลอง ARIMA	แบบจำลอง AE-MLP	แบบจำลอง MT-CNN	แบบจำลอง MT-GRU	แบบจำลอง Cascade
ภาคกลาง	1.0405	0.9306	0.9296	0.9300	<b>0.9293</b>
ภาคตะวันออก	1.9917	1.8052	1.9345	1.8019	<b>1.7950</b>
ภาคเหนือ	1.0075	0.9076	0.9659	0.9193	<b>0.9066</b>
ภาคตะวันออก เฉียงเหนือ	1.5199	1.3678	1.4917	1.3650	<b>0.9917</b>
ภาคใต้	1.7560	1.6370	1.5995	1.5656	<b>1.5626</b>

\*หมายเหตุ ตัวหนา คือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

จากผลการทดลองที่แสดงในตารางที่ 6 แสดงถึงค่าตัววัดเอพวันจากแบบจำลองการจำแนกประเภทเพื่อแสดงประสิทธิภาพในการจำแนกฝนตกและฝนไม่ตก ซึ่งแบบจำลองสามารถจำแนกคลาสของฝนตกได้ถึงแม้มีอัตราส่วนของคลาสที่ฝนไม่ตก 95% ของชุดข้อมูล และแบบจำลองยังสามารถลดจำนวนการทำนายในกรณีที่บอกว่าฝนตกแต่จริงแล้วไม่ตก (False positive) เพื่อป้องกันไม่ให้คลาสที่ฝนไม่ตกเข้าสู่แบบจำลองการวิเคราะห์การถดถอย

ตารางที่ 6 ค่าเอพวันจากแบบจำลองจำแนกข้อมูล

ภาค \nคลาส	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคเหนือ	ภาคตะวันออก	ภาคใต้
ฝนไม่ตก	96.68%	92.51%	95.66%	96.98%	93.87%
ฝนตก	31.77%	36.29%	56.13%	35.71%	41.35%

ทั้งนี้ได้ทำการเปรียบเทียบประสิทธิภาพการทำนายแยกตามช่วงที่ฝนตกและฝนไม่ตกตามตารางที่ 7 และตารางที่ 8 ตามลำดับ โดยประสิทธิภาพของช่วงที่ฝนตกบ่งบอกได้ถึงความสามารถในการทำนายปริมาณน้ำฝนจริง ๆ จากตารางที่ 7 พบว่า ช่วงที่ฝนตกนั้นแบบจำลอง Cascade สามารถให้ค่าความคลาดเคลื่อนต่ำที่สุด เนื่องจากข้อมูลที่มาใช้ทำนายถูกจำแนกมาว่าฝนตกจริง ๆ ทำให้แบบจำลอง Cascade เรียนรู้การทำนายปริมาณฝนได้ดีกว่าแบบจำลองอื่น ๆ เนื่องจากแบบจำลองอื่นจะมีการทำนายผิดพลาดไปบางช่วง เช่น ในกรณีที่มีฝนตก บางครั้งแบบจำลองอื่นจะไม่สามารถจับได้ว่าเกิดฝนตก อันเนื่องมาจากการถูกไบแอสจากช่วงที่ฝนไม่ตก ทำให้ไม่สามารถทำนายปริมาณฝนในช่วงนั้นได้ แต่เมื่อพิจารณาจากตารางที่ 8 ที่เป็นการแสดงประสิทธิภาพของช่วงที่ฝนไม่ตก แบบจำลอง Cascade ยังไม่สามารถให้ค่าความคลาดเคลื่อนที่ต่ำสุดในทุกภาคของประเทศไทยได้ ได้แก่ ภาคตะวันออกเฉียงเหนือและภาคเหนือ ซึ่งแบบจำลอง AE-MLP สามารถทำได้ดีกว่า สาเหตุที่แบบจำลองยังให้ผลส่วนนี้ยังไม่ดีนัก เนื่องจากความผิดพลาดของการจำแนกประเภทของแบบจำลองจำแนกข้อมูล โดยแบบจำลองจำแนกประเภทยังมีความคลาดเคลื่อนในการคัดแยกฝนตกหรือไม่ตกอยู่ มีผลบางส่วนที่แบบจำลองบอกว่าฝนไม่ตก แต่จริงแล้วฝนตกอยู่ปริมาณหนึ่ง เมื่อวัดประสิทธิภาพจึงทำให้ค่าความคลาดเคลื่อนเพิ่มมากขึ้น

ตารางที่ 7 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนตกและแบ่งแยกตามภาค

แบบจำลอง ภาค	แบบจำลองพื้นฐาน		วิธีการเรียนรู้เชิงลึก		ที่นำเสนอ
	แบบจำลอง ARIMA	แบบจำลอง AE-MLP	แบบจำลอง MT-CNN	แบบจำลอง MT-GRU	แบบจำลอง Cascade
ภาคกลาง	5.8490	5.6769	5.7797	5.6935	<b>4.1577</b>
ภาคตะวันออก	7.6483	7.1601	7.5549	7.2301	<b>5.8689</b>
ภาคเหนือ	3.3920	3.3279	3.4863	3.3735	<b>3.2783</b>
ภาคตะวันออก เฉียงเหนือ	6.2155	5.7182	5.8311	5.7232	<b>4.5509</b>
ภาคใต้	6.1232	5.9659	5.9744	5.8772	<b>4.7885</b>

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

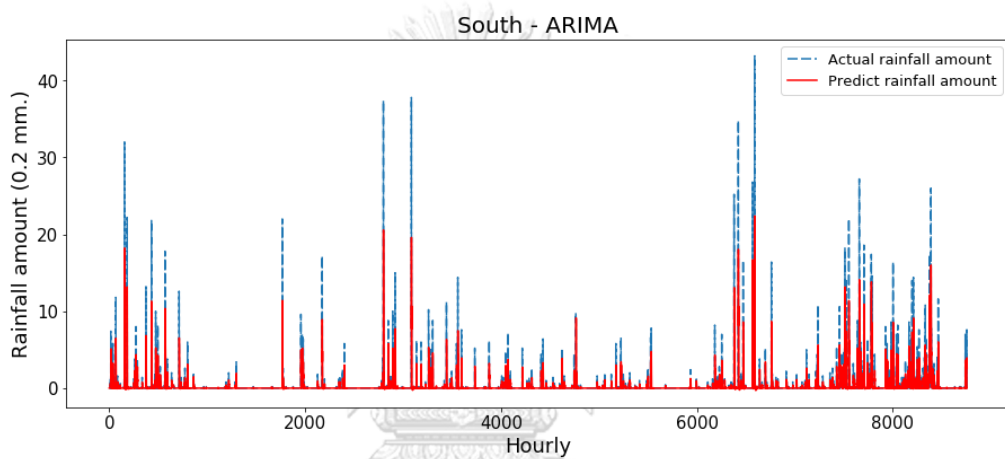
ตารางที่ 8 เปรียบเทียบประสิทธิภาพระหว่างแบบจำลองด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนไม่ตกและแบ่งแยกตามภาค

แบบจำลอง ภาค	แบบจำลองพื้นฐาน		วิธีการเรียนรู้เชิงลึก		ที่นำเสนอ
	แบบจำลอง ARIMA	แบบจำลอง AE-MLP	แบบจำลอง MT-CNN	แบบจำลอง MT-GRU	แบบจำลอง Cascade
ภาคกลาง	0.4871	0.2547	0.2155	0.2683	<b>0.1808</b>
ภาคตะวันออก	0.6481	0.3765	0.5245	<b>0.2437</b>	0.3074
ภาคเหนือ	0.4588	<b>0.1933</b>	0.2720	0.1968	0.2492
ภาคตะวันออก เฉียงเหนือ	0.4115	0.3035	0.3354	0.2227	<b>0.1735</b>
ภาคใต้	0.7411	0.5383	0.3969	0.3549	<b>0.3056</b>

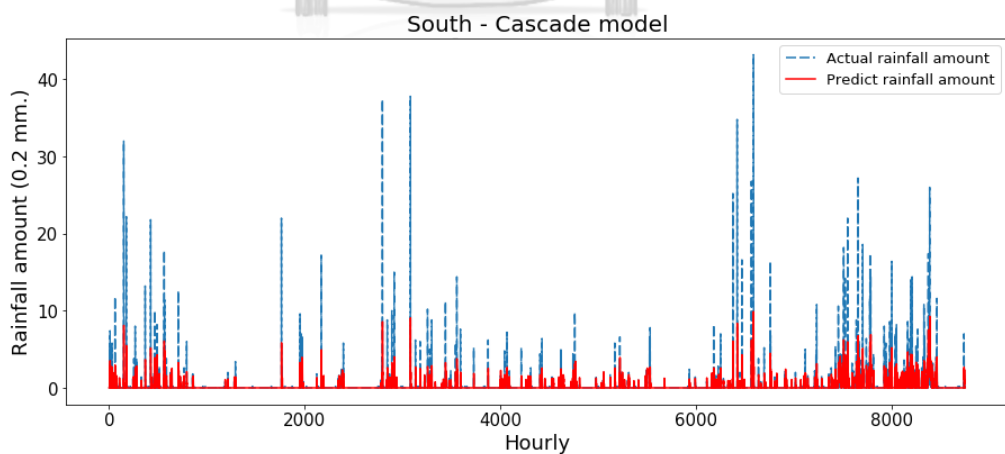
\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด



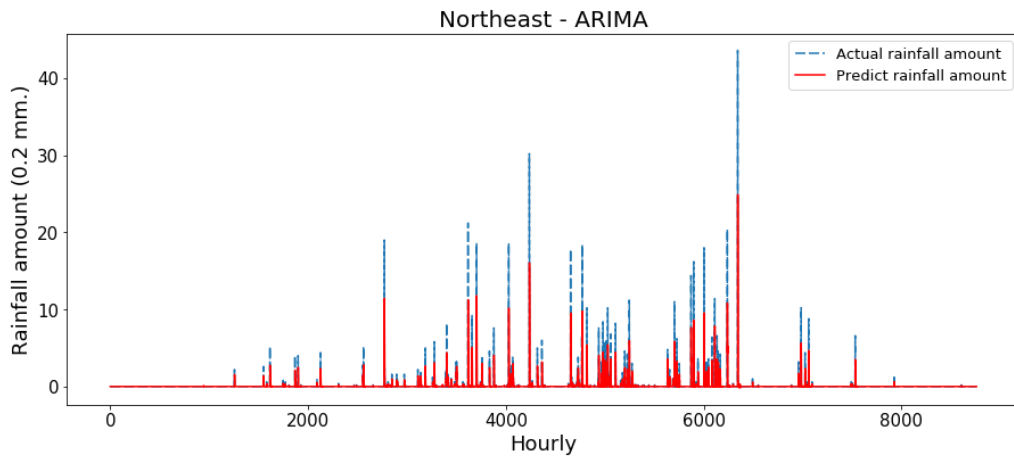
โดยรูปเปรียบเทียบการทำนายปริมาณน้ำฝนสามารถแสดงได้ดังรูปที่ 31 – 34 เป็นการเปรียบเทียบน้ำฝนจากแบบจำลองอาร์ิมาและแบบจำลอง Cascade โดยเลือกจากภาคใต้ และภาคตะวันออกเฉียงเหนือเป็นตัวแทนของพื้นที่ที่มีปริมาณน้ำฝนที่แตกต่างกัน กล่าวคือ ภาคใต้มีฝนตกเยอะที่สุดและภาคตะวันออกเฉียงเหนือมีฝนตกน้อยที่สุดในประเทศไทย เมื่อพิจารณาภาพรวม แบบจำลองอาร์ิมาสามารถตรวจจับปริมาณน้ำฝนที่มีค่าสูงได้ แต่เมื่อเทียบกับความถี่ของกราฟที่ตรวจจับฝนแล้วพบว่าแบบจำลองอาร์ิมายังไม่สามารถตรวจสอบฝนได้ดีเท่าแบบจำลองที่นำเสนอ ซึ่งสิ่งที่น่าสนใจต่อไปพัฒนาต่อคือการทำให้แบบจำลองสามารถตรวจจับค่าปริมาณน้ำฝนสูง ๆ ได้




รูปที่ 31 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคใต้จากแบบจำลองอาร์ิมา



รูปที่ 32 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคใต้จากแบบจำลอง Cascade



รูปที่ 33 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคตะวันออกเฉียงเหนือจาก  
แบบจำลองอาร์อิมา



รูปที่ 34 การเปรียบเทียบน้ำฝนจริงและน้ำฝนที่ทำนายได้ของภาคตะวันออกเฉียงเหนือจาก  
แบบจำลอง Cascade

2) การเปรียบเทียบระหว่างการใช้โทรมาตรเดียวและการใช้โทรมาตรใกล้เคียง

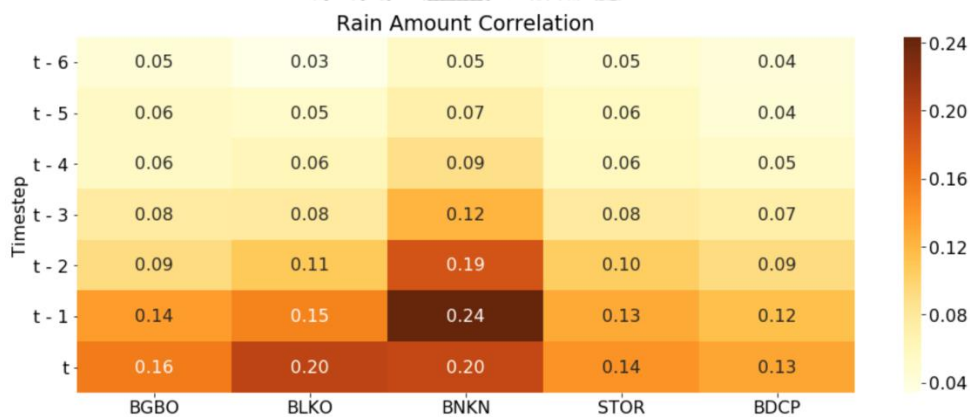
หัวข้อนี้แสดงผลการทดลองหลังจากเพิ่มโทรมาตรใกล้เคียงเข้ามาโดยใช้แบบจำลองที่นำเสนอ คือ นิวรอลเน็ตเวิร์กคอนโวลูชันและโครงข่ายประตูกลับ แทนด้วย CNN + GRU แต่หลังจากที่ใช้โทรมาตรใกล้เคียงพบว่ามีความซับซ้อนเพิ่มขึ้นจึงได้มีแบบจำลองที่นำเสนออีกแบบ คือ นิวรอลเน็ตเวิร์กคอนโวลูชันและตัวเข้ารหัสข้อมูลอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้น แทนด้วย CNN + AE-MLP แสดงได้ดังตารางที่ 9 - 11 ซึ่งเปรียบเทียบค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองแยกตามแต่ละภูมิภาคของประเทศไทย โดยแบ่งพิจารณาจากปริมาณน้ำฝนทั้งหมด ปริมาณฝนในช่วงที่ตก และไม่ตก ตามลำดับ

ตารางที่ 9 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนทั้งหมดและแบ่งแยกตามภาค


คุณลักษณะที่ใช้ทำนาย	แบบจำลอง	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคเหนือ	ภาคตะวันออก	ภาคใต้
ข้อมูลโทรมาตรเดียว	CNN+GRU	0.9293	1.7950	0.9066	0.9917	1.5626
	CNN+AE-MLP	0.9139	1.8308	0.9427	1.0563	1.5745
ข้อมูลโทรมาตรสนใจร่วมกับโทรมาตรเพื่อนบ้าน	CNN+GRU	0.9113	1.8124	0.9299	1.5706	1.5705
	CNN+AE-MLP	0.9019	1.8122	0.9298	0.9916	1.5573

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

จากตารางที่ 9 หลังจากการใช้โทรมาตรใกล้เคียง พบว่าการเพิ่มคุณลักษณะ ทำให้แบบจำลอง CNN + GRU ตรวจสอบได้แม่นยำขึ้นในบางภาค ได้แก่ ภาคเหนือ ภาคตะวันออกเฉียงเหนือ และภาคใต้ จึงได้ทดลองนำแบบจำลองตัวเข้ารหัสอัตโนมัติร่วมกับเพอร์เซปตรอนหลายชั้นมาใช้ โดยตัวเข้ารหัสอัตโนมัติจะช่วยลดมิติของข้อมูลเพื่อหาตัวแทนของข้อมูลสำหรับใช้ในการทำนาย ผลที่ได้พบว่า ทำให้สามารถลดค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ลงได้ แต่ทั้งนี้ยังมีภาคตะวันออกเฉียงเหนือและภาคเหนือที่ยังไม่ได้ค่าต่ำที่สุด เนื่องมาจากการนำโทรมาตรใกล้เคียงมาใช้งาน อาจไม่ส่งผลต่อการทำนายปริมาณน้ำฝนจริง ๆ บางโทรมาตรถึงแม้ว่าจะมีอุณหภูมิและความชื้นไปในทิศทางเดียวกัน แต่เมื่อวัดความสัมพันธ์ของฝนที่ตกแล้วพบว่ามีความสัมพันธ์ที่ต่ำมาก อ้างอิงตามรูปที่ 35 และ 36 โดยส่วนหนึ่งมาจากพฤติกรรมการเกิดฝนของประเทศไทย ที่จะเกิดฝนบริเวณแคบที่มาจากความร้อน รวมถึงสภาพภูมิประเทศที่เป็นภูเขา อาจทำให้มีบริเวณฝนที่ตกแตกต่างกัน ดังนั้นการนำโทรมาตรใกล้เคียงมาใช้ จึงทำได้บางพื้นที่เท่านั้น ทั้งนี้จากตารางที่ 10 และตารางที่ 11 การใช้โทรมาตรใกล้เคียงไม่สามารถให้ค่าต่ำสุดได้เช่นเดียวกัน



รูปที่ 35 ค่าสหสัมพันธ์ (Correlation) ตัวแปรปริมาณน้ำฝนของโทรมาตรที่สนใจในภาคตะวันออกเฉียงเหนือ (KRKM) และโทรมาตรใกล้เคียง (BGBO, BLKO, BNKN, STOR และ BDCP)



รูปที่ 36 ค่าสหสัมพันธ์ (Correlation) ตัวแปรปริมาณน้ำฝนของโทรมาตรที่สนใจในภาคเหนือ (BTTI) และโทรมาตรใกล้เคียง (MECN, DIWO, TTON, CGSN, RIKK และ WGCI)

ตารางที่ 10 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนตกและแบ่งแยกตามภาค

คุณลักษณะที่ใช้ทำนาย	แบบจำลอง	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคเหนือ	ภาคตะวันออก	ภาคใต้
ข้อมูลโทรมาตรเดี่ยว	CNN+GRU	4.1577	5.8689	3.2783	<b>4.5509</b>	4.7885
	CNN+AE-MLP	4.1190	6.0335	2.6357	4.7669	4.8488
ข้อมูลโทรมาตรสนใจร่วมกับโทรมาตรเพื่อนบ้าน	CNN+GRU	<b>4.0848</b>	5.9654	<b>2.5592</b>	4.7130	<b>4.7595</b>
	CNN+AE-MLP	5.9816	<b>5.9320</b>	2.5971	4.5695	4.7705

\*หมายเหตุ ตัวหนา คือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

ตารางที่ 11 เปรียบเทียบประสิทธิภาพระหว่างคุณลักษณะที่ใช้ทำนายด้วยค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ซึ่งพิจารณาจากปริมาณน้ำฝนในช่วงที่ฝนไม่ตก และแบ่งแยกตามภาค

คุณลักษณะที่ใช้ทำนาย	แบบจำลอง	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคเหนือ	ภาคตะวันออก	ภาคใต้
ข้อมูลโทรมาตรเดี่ยว	CNN+GRU	0.1808	0.3074	0.2492	0.1735	0.3056
	CNN+AE-MLP	<b>0.1378</b>	<b>0.2026</b>	<b>0.2391</b>	0.2673	<b>0.2614</b>
ข้อมูลโทรมาตรสนใจร่วมกับโทรมาตรเพื่อนบ้าน	CNN+GRU	0.1679	0.2211	0.2908	0.4511	0.3905
	CNN+AE-MLP	0.1588	0.2966	0.2396	<b>0.1475</b>	0.3076

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

### 3) การวิเคราะห์ความคลาดเคลื่อนในแต่ละระดับปริมาณน้ำฝน

สืบเนื่องจากรูปที่ 31 – 34 พบว่ากราฟของแบบจำลองอาร์มีสามารถจับค่าสูงได้ดีกว่าแบบจำลอง Cascade แต่ผลลัพธ์ของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง หรือ RMSE ของแบบจำลอง Cascade ดีกว่าของแบบจำลองอาร์มี จึงได้ทำการวิเคราะห์ค่าความคลาดเคลื่อนของการพยากรณ์ในแต่ละระดับปริมาณน้ำฝนมาเพิ่มเติมดังตารางที่ 12 โดยทำการแบ่งเกณฑ์ของปริมาณน้ำฝนดังนี้

- ฝนตกเล็กน้อย (Light rain) พิจารณาปริมาณน้ำฝนในช่วง 0.2 – 10.0 มิลลิเมตร
- ฝนตกปานกลาง (Moderate rain) พิจารณาปริมาณน้ำฝนในช่วง 10.1 – 35.0 มิลลิเมตร
- ฝนตกหนัก (Heavy rain) พิจารณาปริมาณน้ำฝนตั้งแต่ 35.0 มิลลิเมตรขึ้นไป

ตารางที่ 12 เปรียบเทียบประสิทธิภาพของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) ในหน่วยมิลลิเมตร ช่วงที่ฝนตกในแต่ละระดับของปริมาณน้ำฝน

ภาค	แบบจำลอง	ฝนตก เล็กน้อย	ฝนตก ปานกลาง	ฝนตกหนัก
ภาคกลาง	ARIMA	2.6725	<b>16.7693</b>	38.4001
	Cascade (โทรมาตรเดียว)	<b>2.0943</b>	16.8401	<b>38.4000</b>
	Cascade (หลายโทรมาตร)	2.1043	16.9064	<b>38.4000</b>
ภาคตะวันออกเฉียงเหนือ	ARIMA	4.1142	<b>16.0191</b>	<b>38.9015</b>
	Cascade (โทรมาตรเดียว)	<b>2.6006</b>	16.9271	43.0837
	Cascade (หลายโทรมาตร)	2.7055	16.6427	44.8169
ภาคเหนือ	ARIMA	1.6864	<b>13.0744</b>	<b>40.6708</b>
	Cascade (โทรมาตรเดียว)	1.7937	13.5041	41.0977
	Cascade (หลายโทรมาตร)	<b>1.4712</b>	13.6533	42.0106
ภาคตะวันออกเฉียงเหนือ	ARIMA	3.0947	<b>15.9547</b>	<b>39.2473</b>
	Cascade (โทรมาตรเดียว)	2.2799	16.4371	43.6000
	Cascade (หลายโทรมาตร)	<b>2.2665</b>	16.6671	37.9705
ภาคใต้	ARIMA	3.0313	<b>16.1113</b>	39.2722
	Cascade (โทรมาตรเดียว)	2.2148	16.3326	<b>39.0438</b>
	Cascade (หลายโทรมาตร)	<b>2.1978</b>	16.4500	39.3594

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

เมื่อเปรียบเทียบผลลัพธ์ทั้งหมดแล้วพบว่าแบบจำลอง Cascade สามารถทำได้ดีกว่าแบบจำลองอาร์ิมาในการพยากรณ์ปริมาณน้ำฝนในช่วงฝนตกเล็กน้อย สืบเนื่องมาจากในช่วงที่ฝนตกมีปริมาณฝนที่อยู่ในช่วง 0.2 – 10 มิลลิเมตรค่อนข้างเยอะ ทำให้แบบจำลอง Cascade สามารถเรียนรู้ในช่วงนี้ได้ดีกว่า แต่ทั้งนี้แบบจำลองอาร์ิมาสามารถทำนายการเกิดฝนตกปานกลางได้ดีกว่าแบบจำลอง Cascade อันเนื่องมาจากความสามารถของแบบจำลองอาร์ิมาที่สนใจค่าช่วงที่สูง ๆ ได้ และสุดท้ายนี้กรณีฝนตกหนักแบบจำลองอาร์ิมาและแบบจำลอง Cascade ให้ค่าที่ค่อนข้างใกล้เคียงกัน

### 5.6.2 ผลการทดลองโดยเปรียบเทียบการทำนายปริมาณน้ำฝนล่วงหน้าหลายชั่วโมง

จากแบบจำลองการทำนายหลายขั้นตอนในหัวข้อที่ 4.3 สามารถทำการเปรียบเทียบได้ในสองแกนเช่นเดียวกับการทำนายปริมาณน้ำฝนล่วงหน้าหนึ่งชั่วโมง โดยแกนแรกจะเปรียบเทียบระหว่างรูปแบบการทำนายปริมาณน้ำฝนระหว่างการทำนายล่วงหน้าหกชั่วโมงทีเดียว ขอแทนด้วย Multi-step และการทำนายน้ำฝนล่วงหน้าหกชั่วโมงโดยใช้เทคนิคการใส่ข้อมูลที่ถูกทำนายแล้วเป็นข้อมูลรับเข้าเพื่อทำนายขั้นถัดไป ขอแทนด้วย Rolling mechanism ในส่วนแกนที่สองจะเป็นการเปรียบเทียบระหว่างแบบจำลองสองแบบต่อกันที่ได้นำเสนอในบทที่ 4 ซึ่งเป็นการเปรียบเทียบประสิทธิภาพระหว่าง CNN + GRU กับ CNN + AE-MLP ผลการทดลองสามารถแสดงได้ดังตารางที่ 13 – 17 โดยตารางแสดงค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสองแต่ละชั่วโมงแยกตามภูมิภาค

ตารางที่ 13 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนายปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคกลาง

รูปแบบการทำนาย	แบบจำลอง	1 ชั่วโมง	2 ชั่วโมง	3 ชั่วโมง	4 ชั่วโมง	5 ชั่วโมง	6 ชั่วโมง
วิธี Multi-Step	CNN + GRU	0.9929	1.0355	1.0596	1.0415	1.0131	1.0038
	CNN + AE-MLP	0.9705	0.9707	0.9471	1.0990	1.0422	0.9494
วิธี Rolling Mechanism	CNN + GRU	0.9163	<b>0.9227</b>	<b>0.9267</b>	<b>0.9280</b>	<b>0.9280</b>	<b>0.9274</b>
	CNN + AE-MLP	<b>0.8901</b>	0.9350	0.9436	0.9436	0.9458	0.9474

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด



ตารางที่ 14 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนายปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคตะวันออก

รูปแบบการทำนาย	แบบจำลอง	1 ชั่วโมง	2 ชั่วโมง	3 ชั่วโมง	4 ชั่วโมง	5 ชั่วโมง	6 ชั่วโมง
วิธี Multi-Step	CNN + GRU	1.9018	1.9970	1.9512	1.9479	1.9596	1.9446
	CNN + AE-MLP	2.0534	2.1040	1.9405	2.0596	2.0370	1.9394
วิธี Rolling Mechanism	CNN + GRU	<b>1.3623</b>	<b>1.4069</b>	<b>1.4036</b>	<b>1.4071</b>	<b>1.4126</b>	<b>1.4117</b>
	CNN + AE-MLP	1.8973	1.9216	1.9266	1.9324	1.9282	1.9369

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

ตารางที่ 15 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนายปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคเหนือ

รูปแบบการทำนาย	แบบจำลอง	1 ชั่วโมง	2 ชั่วโมง	3 ชั่วโมง	4 ชั่วโมง	5 ชั่วโมง	6 ชั่วโมง
วิธี Multi-Step	CNN + GRU	1.0113	1.0272	1.0304	1.0007	1.0178	1.0601
	CNN + AE-MLP	1.0835	1.2033	0.9644	1.2255	1.1404	0.9657
วิธี Rolling Mechanism	CNN + GRU	<b>0.9240</b>	<b>0.9529</b>	<b>0.9579</b>	<b>0.9622</b>	0.9654	0.9658
	CNN + AE-MLP	0.9563	0.9592	0.9631	0.9634	<b>0.9643</b>	<b>0.9619</b>

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

ตารางที่ 16 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนายปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคตะวันออกเฉียงเหนือ

รูปแบบการทำนาย	แบบจำลอง	1 ชั่วโมง	2 ชั่วโมง	3 ชั่วโมง	4 ชั่วโมง	5 ชั่วโมง	6 ชั่วโมง
วิธี Multi-Step	CNN + GRU	1.0472	1.1386	1.1566	1.1793	1.1609	1.2263
	CNN + AE-MLP	1.0633	1.1235	1.0208	1.1018	1.1748	1.0205
วิธี Rolling Mechanism	CNN + GRU	<b>0.9888</b>	<b>1.0194</b>	<b>1.0195</b>	<b>1.0175</b>	1.0242	1.0196
	CNN + AE-MLP	1.0044	1.0262	1.0269	1.0193	<b>1.0174</b>	<b>1.0193</b>

\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด


ตารางที่ 17 แสดงผลของค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE) จากการทำนายปริมาณน้ำฝน โดยเปรียบเทียบการทำนายตามแต่ละชั่วโมงและรูปแบบการทำนายของภาคใต้

รูปแบบการทำนาย	แบบจำลอง	1 ชั่วโมง	2 ชั่วโมง	3 ชั่วโมง	4 ชั่วโมง	5 ชั่วโมง	6 ชั่วโมง
วิธี Multi-Step	CNN + GRU	1.6600	1.7175	1.6234	1.9265	1.7007	1.6330
	CNN + AE-MLP	2.0534	2.1040	1.9405	2.0596	2.0370	1.9394
วิธี Rolling Mechanism	CNN + GRU	<b>1.5819</b>	<b>1.5978</b>	<b>1.6065</b>	1.6174	1.6157	<b>1.6123</b>
	CNN + AE-MLP	1.6191	1.6064	1.6143	<b>1.6162</b>	<b>1.6131</b>	1.6255


\*หมายเหตุ ตัวหนาคือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

เมื่อทำการเปรียบเทียบผลการทำนายล่วงหน้าหลายช่วงเวลา (Multi-step) พบว่าวิธีการทำนายล่วงหน้าโดยใช้ข้อมูลที่ถูกทำนายเป็นข้อมูลรับเข้าใหม่ (Rolling mechanism) ให้ค่าความ

คลาดเคลื่อนต่ำกว่า แต่ลองพิจารณาที่ชั่วโมงใกล้ ๆ พบว่าวิธีการทำนายแบบ Multi-step จะสามารถตรวจจับปริมาณน้ำฝนได้ดีกว่าการทำนายแบบ Rolling mechanism เนื่องจากการนำข้อมูลที่ทำนาย ซึ่งมีความคลาดเคลื่อนป้อนเข้าสู่แบบจำลอง ทำให้แบบจำลองใช้ข้อมูลทำนายปริมาณน้ำฝนและก่อให้เกิดความคลาดเคลื่อนเพิ่ม ในกรณีที่นำมาใช้ในพยากรณ์จำเป็นต้องเพิ่มประสิทธิภาพการทำนายล่วงหน้าหนึ่งชั่วโมงก่อนเพื่อให้ไม่เกิดความคลาดเคลื่อน โดยรูปที่ 37 และ 38 จะแสดงความสามารถในการพยากรณ์ในแต่ละชั่วโมงที่ทำนายล่วงหน้าโดยใช้ภาคใต้เป็นตัวแทนของภาคทั้งหมด เนื่องจากภาคใต้ค่อนข้างมีปริมาณน้ำฝนที่สูงและค่อนข้างผันผวน



รูปที่ 37 ผลการทำนายปริมาณน้ำฝน (สีแดง) เมื่อเปรียบเทียบกับน้ำฝนจริง (สีน้ำเงิน) ในแต่ละชั่วโมงล่วงหน้าด้วยวิธี Rolling mechanism ของภาคใต้



รูปที่ 38 ผลการทำนายปริมาณน้ำฝน (สีแดง) เมื่อเปรียบเทียบกับน้ำฝนจริง (สีน้ำเงิน) ในแต่ละชั่วโมงล่วงหน้าด้วยวิธี Multi-Step ของภาคใต้

โดยพบว่าเมื่อพิจารณาจากกราฟ วิธีการทำนายแบบ Multi-step สามารถทำนายค่าสูงได้ดีกว่าวิธีจาก Rolling mechanism อันเนื่องจากแบบจำลอง Cascade จะให้ผลลัพธ์ที่ดีในช่วงฝนตกเล็กน้อยเท่านั้น ทำให้ตอนที่นำมาเป็นข้อมูลรับเข้าถัดไปอาจมีความคลาดเคลื่อนมากกว่าการทำนายหลายช่วงเวลาทีเดียวแบบ Multi-step โดยตารางที่ 18 จะทำการวิเคราะห์ปริมาณน้ำฝนแต่ละระดับของการทำนายแบบ Multi-step และการทำนายแบบ Rolling mechanism ในภาคใต้ อ้างอิงตามเกณฑ์วัดในหัวข้อที่ 5.6.1 หัวข้อย่อยที่ 3 ซึ่งจากตารางพบว่าการทำนายแบบ Rolling mechanism จะให้ผลดีกว่าในกรณีที่ฝนตกเล็กน้อย ในส่วนของกรณีที่ฝนตกปานกลางพบว่าการทำนายแบบ Multi-step จะให้ผลดีกว่าในชั่วโมงที่ 1 ชั่วโมงที่ 4 และชั่วโมงที่ 5 และสุดท้ายกรณีฝนตกหนัก การทำนายทั้งสองแบบไม่แตกต่างกัน ดังนั้นการทำนายแบบ Multi-step จะเหมาะแก่ดักจับฝนที่ค่าสูง ๆ และสามารถทำได้ล่วงหน้าได้มีความแม่นยำอยู่ในชั่วโมงที่ 1 – 4 และการทำนายแบบ Rolling mechanism จะทำนายช่วงฝนที่มีปริมาณน้อยได้ดีกว่าแบบ Multi-step

ตารางที่ 18 เปรียบเทียบประสิทธิภาพ RMSE ในหน่วยมิลลิเมตรของแบบจำลอง Multi-step และแบบจำลอง Rolling mechanism โดยพิจารณาช่วงที่ฝนตกแต่ละระดับของภาคใต้

ชั่วโมง	แบบจำลอง	ฝนตกเล็กน้อย	ฝนตกปานกลาง	ฝนตกหนัก
1	Multi-step	2.5014	<b>16.7079</b>	<b>38.8291</b>
	Rolling mechanism	<b>2.2771</b>	17.0140	39.3228
2	Multi-step	2.4340	17.0372	<b>39.0571</b>
	Rolling mechanism	<b>2.2072</b>	<b>17.0247</b>	39.3353
3	Multi-step	2.4403	17.6117	39.4568
	Rolling mechanism	<b>2.2601</b>	<b>17.3084</b>	<b>39.3228</b>
4	Multi-step	2.4497	<b>17.1199</b>	39.3293
	Rolling mechanism	<b>2.2613</b>	17.1983	<b>39.3228</b>
5	Multi-step	2.3768	<b>17.1622</b>	39.5552
	Rolling mechanism	<b>2.2785</b>	17.2298	<b>39.2791</b>
6	Multi-step	2.4744	17.7087	39.4608
	Rolling mechanism	<b>2.3200</b>	<b>17.4079</b>	<b>39.3228</b>

\*หมายเหตุ ตัวหนา คือค่าความคลาดเคลื่อนเฉลี่ยต่ำที่สุด

## บทที่ 6

### สรุปการวิจัยและแนวทางการวิจัยในขั้นถัดไป

#### 6.1 สรุปการวิจัย

วิทยานิพนธ์นี้มุ่งเน้นการสร้างแบบจำลองการเรียนรู้เชิงลึกที่เหมาะสมร่วมกับการใช้ข้อมูลหลายตัวแปรเพื่อที่จะสามารถทำนายปริมาณน้ำฝนและแก้ไขปัญหาการที่ชุดข้อมูลมีความไม่สมดุล ข้อมูลที่ใช้เป็นข้อมูลปริมาณน้ำฝนและสภาพอากาศที่ได้รับการสนับสนุนจากสสน. โดยงานวิจัยได้ดำเนินการตามขอบเขตดังนี้

1. สามารถทำการทำนายปริมาณน้ำฝนด้วยข้อมูลหลายตัวแปรโดยใช้ข้อมูลตัวแปรสภาพอากาศ และช่วงเวลาย้อนหลังผ่านแบบจำลองการเรียนรู้เชิงลึกสองแบบต่อกัน
2. สามารถให้ค่าความคลาดเคลื่อนต่ำสุดเมื่อเปรียบเทียบประสิทธิภาพของแบบจำลองพื้นฐานที่ใช้เทคนิคด้านอนุกรมเวลา และแบบจำลองการเรียนรู้เชิงลึกแบบต่าง ๆ ได้
3. สามารถให้ค่าความคลาดเคลื่อนต่ำสุดเมื่อเปรียบเทียบประสิทธิภาพของการใช้แบบจำลองที่ใช้ข้อมูลทั้งหมดในการดำเนินการ กับแบบจำลองสองแบบต่อกันซึ่งเป็นแบบจำลองที่แนะนำให้เสนอในงานวิจัย

สำหรับการทดลอง งานวิจัยนี้ได้แบ่งการทดลองออกเป็น 3 ส่วน สามารถแสดงได้ดังหัวข้อต่อไป

6.1.1 การเปรียบเทียบการทำนายปริมาณฝนระหว่างแบบจำลองโดยการใช้ข้อมูลรับเข้าทั้งหมด และแบบจำลองสองแบบต่อกันที่กรองบริเวณฝนไม่ตกออก

จากการทดลองพบว่าแบบจำลองสองแบบต่อกัน หรือ แบบจำลอง Cascade สามารถให้ค่าความคลาดเคลื่อนจากการทำนายปริมาณฝนต่ำสุดเมื่อเทียบกับแบบจำลองอื่น ๆ โดยเปรียบเทียบจากปริมาณน้ำฝนทั้งหมด และคิดจากช่วงที่ฝนตกจริง ๆ อ้างอิงตามตารางที่ 5 และ 7 ในหัวข้อ 5.6.1 เนื่องจากแบบจำลอง Cascade จะทำการคัดแยกช่วงเวลาที่ฝนตกหรือไม่ตกออกผ่านแบบจำลองจำแนกประเภท โดยแบบจำลองจำแนกประเภทได้นำเทคนิคการแก้ไขปัญหาเรื่องชุดข้อมูลไม่สมดุลเข้ามาใช้งานร่วมด้วย จึงทำให้แบบจำลองสามารถตรวจจับช่วงที่ฝนตกได้ มิฉะนั้นแบบจำลองจำแนกประเภทจะไม่สามารถจำแนกช่วงที่ฝนตกได้เลยเพราะมีความลำเอียงจากช่วงที่ฝนไม่ตกอยู่ปริมาณมาก คิดเป็นสัดส่วน 95% จากนั้นเมื่อข้อมูลฝนตกถูกส่งต่อไปยังแบบจำลองวิเคราะห์การถดถอยแบบจำลองจะสามารถตรวจจับรูปแบบปริมาณฝนที่เกิดขึ้นได้ดีกว่าการใส่ข้อมูลลงไปทั้งหมด ทำให้ค่าความคลาดเคลื่อนที่มาจากแบบจำลอง Cascade ต่ำกว่าแบบจำลองทั่วไป

แต่ทั้งนี้แบบจำลอง Cascade ยังไม่สามารถทำได้ดี เมื่อเปรียบเทียบประสิทธิภาพในช่วงที่ฝนไม่ตก อ้างอิงตามตารางที่ 8 ในหัวข้อ 5.6.2 อันเป็นผลมาจากการทำนายผิดของแบบจำลองจำแนกประเภท จำเป็นต้องปรับปรุงในส่วนนี้ต่อไป

#### 6.1.2 การเปรียบเทียบการทำนายปริมาณฝนโดยใช้ข้อมูลจากโทรมาตรเดียวและข้อมูลจากโทรมาตรใกล้เคียง

จากการทดลองเมื่อทำการเพิ่มข้อมูลจากโทรมาตรใกล้เคียง พบว่าข้อมูลจากโทรมาตรใกล้เคียงสามารถช่วยให้ค่าความคลาดเคลื่อนบางภาคลดลงได้ และบางภาคยังไม่สามารถทำได้ เนื่องจากข้อมูลโทรมาตรที่สนใจและข้อมูลโทรมาตรใกล้เคียงบางพื้นที่ยังไม่มีความสัมพันธ์กันมากพอรวมทั้งระยะทางระหว่างโทรมาตรค่อนข้างไกลกัน ซึ่งฝนที่ตกในไทยมักเป็นฝนตกที่เกิดจากความร้อนจากพื้นดิน ทำให้รัศมีฝนตกไม่กว้างมากนัก ดังนั้นอาจมีช่วงเวลาโทรมาตรที่สนใจมีฝนตก แต่โทรมาตรใกล้เคียงไม่ตก โดยภาคกลางและภาคตะวันออกเหนือเมื่อพิจารณาค่าความคลาดเคลื่อนโดยรวมสามารถทำให้มีประสิทธิภาพที่ดีกว่าได้

#### 6.1.3 การเปรียบเทียบการทำนายปริมาณฝนล่วงหน้าหลายชั่วโมงโดยเปรียบเทียบระหว่างการทำนายหกชั่วโมงทีเดียวและการทำนายโดยการนำข้อมูลส่งออกมาเป็นข้อมูลรับเข้าในช่วงเวลาถัดไป (Rolling mechanism)

การทดลองนี้เป็นการนำเสนอแนวทางการพยากรณ์แบบหลายขั้นตอน โดยเปรียบเทียบจากการทำนายหลายชั่วโมงล่วงหน้าทีเดียวอ้างอิงจากช่วงเวลาปัจจุบัน กับ การทำนายโดยใช้ข้อมูลส่งออกมาเป็นข้อมูลรับเข้า พบว่าการนำข้อมูลส่งออกมาเป็นข้อมูลรับเข้าสามารถทำให้ค่าความคลาดเคลื่อนต่ำกว่า แต่ยังมีปัญหาในกรณีที่ทำนายชั่วโมงไกล ๆ เมื่อลองดูรูปภาพยังไม่สามารถดักจับข้อมูลสูง ๆ ได้ โดยการทดลองนี้อาจต้องปรับปรุงในส่วนของการดักจับปริมาณน้ำฝนตอนช่วงค่าสูงให้ได้

### 6.2 ข้อจำกัดของงานวิจัย

ในการทำนายปริมาณน้ำฝนของประเทศไทยยังมีข้อจำกัดอยู่ แสดงรายละเอียดดังต่อไปนี้

1. ข้อมูลที่ใช้ในงานวิจัยเป็นข้อมูลปิดและยังไม่เผยแพร่ เนื่องจากเป็นชุดข้อมูลที่ทางสถาบันน้ำใช้สำหรับการวิจัยภายในเพื่อทำนายฝน ตรวจสอบน้ำท่วม และวิเคราะห์สภาพน้ำในประเทศไทย ซึ่งข้อมูลบางส่วนจำเป็นต้องอาศัยองค์ความรู้เฉพาะทางเข้ามาช่วยในการวิเคราะห์และตีความ
2. ข้อมูลจากโทรมาตรบางส่วนพบว่ามีส่วนที่ไม่สมบูรณ์ เช่น การมีค่าว่างจำนวนมาก จึงไม่สามารถนำมาใช้ในการทำนายได้

3. จำนวนโทรมาตรในพื้นที่จังหวัดต่าง ๆ ของประเทศไทยยังมีจำนวนไม่มากเมื่อเทียบกับประเทศที่มีการทำนายฝน อย่างเช่น จีนหรือฮ่องกง ดังนั้นการนำเอาโทรมาตรใกล้เคียงมาใช้ ยังมีข้อจำกัดอยู่บางพื้นที่ โดยบางพื้นที่อาจจะมีย่อยหรือไม่มีเลย ในระยะทางตามที่กำหนดไว้

### 6.3 แนวทางการวิจัยในอนาคต

ปัจจุบันงานวิจัยนี้ใช้ข้อมูลจากโทรมาตรซึ่งเป็นการวัดข้อมูลจากภาคพื้นดินเพียงอย่างเดียว แต่การเกิดฝนนั้นสามารถตรวจสอบได้หลายจุด เช่น การพิจารณาจากแผนภาพอากาศที่แสดงกลุ่มเมฆของการเกิดฝน โดยการเก็บฝนลักษณะนี้มักนิยมเก็บเป็นภาพถ่ายดาวเทียม และสามารถบอกทิศทางการเกิดของฝนได้ดีกว่าข้อมูลโทรมาตรเพียงอย่างเดียว ซึ่งในอนาคตอาจนำงานวิจัยที่ใช้ภาพถ่ายดาวเทียมร่วมกับโทรมาตรวัดน้ำฝนผ่านแบบจำลองการเรียนรู้เชิงลึกในลักษณะการนำเข้าข้อมูลหลายแหล่งเพื่อเพิ่มประสิทธิภาพการทำนาย





## บรรณานุกรม

- [1] M. Murat, I. Malinowska, M. Gos, and J. J. I. a. Krzyszczak, "Forecasting daily meteorological time series using ARIMA and regression models," vol. 32, no. 2, pp. 253-264, 2018.
- [2] S. Cramer, M. Kampouridis, A. A. Freitas, and A. K. J. E. S. w. A. Alexandridis, "An extensive evaluation of seven machine learning methods for rainfall prediction in weather derivatives," vol. 85, pp. 169-181, 2017.
- [3] A. S. Cofino, R. Cano Trueba, C. M. Sordo, and J. M. Gutiérrez Llorente, "Bayesian networks for probabilistic weather prediction," 2002.
- [4] R. Mittelman, B. Kuipers, S. Savarese, and H. Lee, "Structured recurrent temporal restricted boltzmann machines," in *International Conference on Machine Learning*, 2014, pp. 1647-1655.
- [5] J. N. Liu, Y. Hu, J. J. You, and P. W. Chan, "Deep neural network based feature representation for weather forecasting," in *Proceedings on the International Conference on Artificial Intelligence (ICAI)*, 2014, p. 1: The Steering Committee of The World Congress in Computer Science, Computer Engineering and Applied Computing (WorldComp).
- [6] S. J. M. o. S. Eiamprasert, National Institute of Development Administration, "Comparison of Spatial Daily Rainfall Amount Interpolation Methods by Using Geographic Information System at Chao-Phra-Ya Flood Plain," 2011.
- [7] "Telemetry," 2016.
- [8] ส. คุณชนกุลวงศ์และคณะ, "การประเมินและพยากรณ์น้ำฝนจากข้อมูลระยะไกล," 2550. คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
- [9] "ความรู้อุตุนิยมวิทยา."
- [10] ท. ยา and ถ. น. สูงเนิน, "การ แทน อนุกรม เวลา เพื่อ การ จัด กลุ่ม ที่ มี ประสิทธิภาพ," สาขา วิชา วิศวกรรม คอมพิวเตอร์ สำนัก วิชา วิศวกรรมศาสตร์ มหาวิทยาลัย เทคโนโลยี สุรนารี.
- [11] T. K., "Text Categorization for Thai Corpus Using Character-Level Convolutional Neural Network," 2016. Department of Computer Engineering

- [12] S. Wang, J. Feng, G. J. M. Liu, and C. Modelling, "Application of seasonal time series model in the precipitation forecast," vol. 58, no. 3-4, pp. 677-683, 2013.
- [13] N. Q. Hung, M. S. Babel, S. Weesakul, N. J. H. Tripathi, and E. S. Sciences, "An artificial neural network model for rainfall forecasting in Bangkok, Thailand," vol. 13, no. 8, pp. 1413-1425, 2009.
- [14] E. Hernández, V. Sanchez-Anguix, V. Julian, J. Palanca, and N. Duque, "Rainfall prediction: A deep learning approach," in *International Conference on Hybrid Artificial Intelligence Systems*, 2016, pp. 151-162: Springer.
- [15] M. Qiu *et al.*, "A short-term rainfall prediction model using multi-task convolutional neural networks," in *2017 IEEE International Conference on Data Mining (ICDM)*, 2017, pp. 395-404: IEEE.
- [16] "Haversine formula."
- [17] G. S. Babu, P. Zhao, and X.-L. Li, "Deep convolutional neural network based regression approach for estimation of remaining useful life," in *International conference on database systems for advanced applications*, 2016, pp. 214-228: Springer.
- [18] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, "Focal loss for dense object detection," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2980-2988.



จุฬาลงกรณ์มหาวิทยาลัย  
**CHULALONGKORN UNIVERSITY**

## ประวัติผู้เขียน

ชื่อ-สกุล	เฟื่องลดา มะโนกิจ
วัน เดือน ปี เกิด	13 ตุลาคม 2534
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	ปริญญาตรีจากคณะวิศวกรรมศาสตร์ สาขาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ที่อยู่ปัจจุบัน	40/1731 ซอยประชานิเวศน์ 3 ซอย 1 ถนนสามัคคี ตำบลท่าทราย อำเภอ เมือง จังหวัดนนทบุรี 11000



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY