

การผสมความรู้ทางวิทยาศาสตร์ก่อนหน้าเข้ากับการเรียนรู้เชิงลึกสำหรับพยากรณ์ปริมาณฝนในระยะ
สั้นจากภาพถ่ายเรดาร์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2563
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Incorporating Prior Scientific Knowledge Into Deep Learning for Precipitation
Nowcasting on Radar Images



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 2020
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การผสมความรู้ทางวิทยาศาสตร์ก่อนหน้าเข้ากับการเรียนรู้เชิงลึกสำหรับพยากรณ์ปริมาณฝนในระยะสั้นจากภาพถ่ายเรดาร์
โดย	นายภัทรพงษ์ ตำนพูนกิจ
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของ
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

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

คณะกรรมการสอบวิทยานิพนธ์

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

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

..... กรรมการ
(ดร.ดวงดาว วิชาดากุล)

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

ภัทรพงษ์ ด้านพุนกิจ : การผสมความรู้ทางวิทยาศาสตร์ก่อนหน้าเข้ากับการเรียนรู้เชิงลึก
สำหรับพยากรณ์ปริมาณฝนในระยะสั้นจากภาพถ่ายเรดาร์. (Incorporating Prior
Scientific Knowledge Into Deep Learning for Precipitation Nowcasting on
Radar Images) อ.ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวทีกุล

การทำนายปริมาณน้ำฝนในระยะสั้นมีจุดมุ่งหมายเพื่อทำนายปริมาณน้ำฝนในอนาคตอัน
ใกล้อย่างถูกต้องเพื่อนำไปใช้ประโยชน์ต่อในงานต่างๆ วิธีการดั้งเดิมทำนายผลโดยจำลอง
กระบวนการทางฟิสิกส์ที่ซับซ้อนหรือใช้การประมาณค่านอกช่วง โมเดลเชิงลึกที่ใช้ส่วนมากนั้นมัก
ประสบความสำเร็จเพียงระดับหนึ่งเท่านั้นเนื่องจากความซับซ้อนของปัญหา ดังนั้นวิทยานิพนธ์นี้จึง
เสนอวิธีการที่ผสมผสานระหว่างวิธีการทางวิทยาศาสตร์กับโมเดลเชิงลึกเพื่อใช้ประโยชน์จากทั้ง
สองศาสตร์ในการทำนาย โมเดลที่เสนอนี้มีโครงสร้างพื้นฐานบนวิธีการประมาณค่าเรดาร์นอกช่วง
ซึ่งเป็นวิธีการทางวิทยาศาสตร์ที่ทันสมัย โดยผู้วิจัยได้ทำการผสมผสานโดยแทนที่ส่วนย่อยของ
วิธีการนี้ที่ทำหน้าที่คำนวณสนามการเคลื่อนไหวด้วยโมเดลเชิงลึกที่เป็นโมเดลแบบรูปตัวยู ในขณะที่
คงส่วนหลังที่ใช้เทคนิคการบิดเบือนไว้เพื่อทำหน้าที่ประมาณค่านอกช่วง ในการทดลองผู้วิจัยได้
สร้างชุดข้อมูลจำลองที่ลอกเลียนคุณสมบัติสำคัญจากภาพถ่ายเรดาร์และทำการทดลองทั้งบนชุด
ข้อมูลจำลองดังกล่าวและชุดข้อมูลภาพถ่ายเรดาร์ที่ประกอบด้วยเหตุการณ์สภาพอากาศรุนแรง 7
กรณี นอกจากนี้ได้ทดลองใช้เทคนิคเปลี่ยนแปลงน้ำหนักของค่าสูญเสียเพื่อให้โมเดลมีประสิทธิภาพ
การทำนายฝนตกหนักสูงขึ้น จากผลการทดลองพบว่าวิธีการแบบผสมผสานที่เสนอให้ประสิทธิภาพ
ที่ดีกว่าวิธีการมาตรฐานในกรณีส่วนมากบนชุดข้อมูลทั้งคู่

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2563

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270206921 : MAJOR COMPUTER SCIENCE

KEYWORD: Deep learning, Nowcasting, Spatial-temporal analysis, Physical processes, Radar images

Pattarapong Danpoonkij : Incorporating Prior Scientific Knowledge Into Deep Learning for Precipitation Nowcasting on Radar Images. Advisor: Asst. Prof. PEERAPON VATEEKUL, Ph.D.

The objective of precipitation nowcasting is to precisely forecast the short-term rainfall intensity which can be used in many applications. The traditional approach is to simulate complicated physical processes or perform an extrapolation. Most deep learning models approaches have often been met with limited success due to the complexities of the problem. Therefore, this thesis proposes a hybrid model that combines both the scientific method and the deep learning model in order to take advantage of both paradigms. The proposed model's architecture is based on the radar extrapolation technique which is the state-of-the-art scientific method. We achieve the integration by replacing the sub-model of this method which calculates the motion field with a deep learning model known as U-Net while the latter part remains the warping scheme to perform an extrapolation. We created the simulated data that design to mimic essential features from radar image sequences and conducted the experiments on both the simulated and the radar image dataset that contains 7 severe weather phenomenon cases. Furthermore, we experiment with the weighted loss technique to help improve the model's ability to predict heavy rainfall. The results show that our hybrid modeling approach outperforms most baselines on both datasets.

Field of Study: Computer Science

Student's Signature

Academic Year: 2020

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลงได้ดีด้วยความกรุณาอย่างสูงจาก ผศ. ดร. พีรพล เวทีกุล ที่เป็นอาจารย์ที่ปรึกษางานวิจัยและกรุณาให้คำแนะนำปรึกษาตลอดจนปรับปรุงแก้ไขข้อบกพร่องต่างๆ ในการทำวิจัยด้วยความเอาใจใส่อย่างยิ่ง และขอขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอบพระคุณ ศ. ดร. บุญเสริม กิจศิริกุล ดร. ดวงดาว วิชาดากุล และ ดร. ธนภัทร ชังคะจิตร ที่สละเวลาเพื่อเป็นประธานและกรรมการในการสอบวิทยานิพนธ์

ขอขอบคุณบริษัท Weathernews Inc. ที่อนุญาตให้นำชุดข้อมูลภาพถ่ายเรดาร์มาใช้ในการทดลองในวิทยานิพนธ์นี้

ขอบคุณเพื่อนๆ และพี่ๆ ในห้องปฏิบัติการทำเหมืองข้อมูล (Data Mining lab) สำหรับคำแนะนำดีๆ และเป็นกำลังใจที่ทำให้งานวิจัยนี้เสร็จลงได้

สุดท้ายนี้ขอบพระคุณบิดา มารดา และครอบครัวที่เป็นกำลังใจ และได้สนับสนุนในทุกๆ ด้าน

ภัทรพงษ์ ด่านพูนกิจ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ	1
1.1. ที่มาและความสำคัญของปัญหา	1
1.2. วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ประโยชน์ที่ได้รับ.....	3
1.5 วิธีการดำเนินงานวิจัย.....	3
1.6 ผลงานตีพิมพ์จากงานวิจัย.....	3
1.7 แผนภูมิแกนต์ (Gantt chart).....	4
บทที่ 2 แนวคิดและทฤษฎีที่เกี่ยวข้อง.....	5
2.1 วิธีการพยากรณ์ปริมาณฝนในระยะสั้น	5
2.2 การทำนายอนุกรมเวลาของภาพ	6
2.3 การวัดประสิทธิภาพการทำนาย (Performance evaluation).....	6
2.4 ภาพถ่ายเรดาร์ (Radar images).....	9
บทที่ 3 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	11
3.1 วิธีการดั้งเดิมที่ใช้สำหรับทำนายปริมาณน้ำฝนในระยะสั้น	11

3.1.1	วิธีการคงสภาพเดิม (Persistence method).....	11
3.1.2	วิธีการคงสภาพแบบลางกรองจ์ (Lagrangian persistence).....	11
3.1.3	วิธีการเรนนี่โมชั่น (rainymotion).....	12
3.2	การใช้การเรียนรู้เชิงลึกทำนายภาพที่เป็นอนุกรมเวลา (Sequential images prediction deep learning model).....	14
3.2.1	โมเดลรูปตัวยู (U-Net).....	14
3.2.2	หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (Convolutional long short-term memory).....	15
3.2.3	หน่วยเกทวนกลับแบบคอนโวลูชัน (Convolutional gated recurrent unit).....	16
3.2.4	หน่วยเกทวนกลับเชิงวิถี (Trajectory gated recurrent unit).....	17
3.3	การผสมผสานความรู้ทางวิทยาศาสตร์เข้ากับการเรียนรู้ของเครื่อง (Integrated scientific-based knowledge with machine learning).....	19
บทที่ 4	แนวคิดและวิธีการดำเนินงาน.....	21
4.1	การเตรียมข้อมูล.....	21
4.1.1	ชุดข้อมูลจำลอง.....	21
4.1.2	ชุดข้อมูลภาพถ่ายเรดาร์.....	23
4.1.3	ชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง.....	26
4.2	การประมวลผลก่อน (Pre-processing).....	29
4.3	การผสมผสานความรู้เชิงวิทยาศาสตร์เข้ากับโมเดลเชิงลึก.....	30
4.4	การประมวลผลหลัง (Post-processing).....	34
4.5	การสอน (Training).....	35
4.6	การทดสอบ (Testing).....	36
บทที่ 5	การทดลองและผลการทดลอง.....	37
5.1	การแบ่งชุดข้อมูลและกำหนดชั้นเวลา.....	37
5.2	ผลการทดสอบบนชุดข้อมูลจำลอง.....	37

5.3 ผลการทดสอบบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง	43
บทที่ 6 สรุปการวิจัย	52
6.1 สรุปผลการวิจัย.....	52
6.2 แนวทางการวิจัยถัดไป.....	52
บรรณานุกรม.....	53
ภาคผนวก.....	55
ประวัติผู้เขียน.....	67



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

	หน้า
ตาราง 1 คอนฟิวชันเมทริกซ์สำหรับการจำแนกการตกของฝน	7
ตาราง 2 รูปแบบต่างๆ ของวิธีการเรณูนี้ไม่ชื้น	12
ตาราง 3 การตั้งไฮเปอร์พารามิเตอร์สำหรับสมการ (15).....	22
ตาราง 4 คุณลักษณะข้อมูลภาพถ่ายเรดาร์	24
ตาราง 5 สถิติของระดับน้ำฝนในชุดข้อมูลภาพถ่ายเรดาร์	24
ตาราง 6 เหตุการณ์สภาพอากาศรุนแรงในชุดข้อมูล	26
ตาราง 7 สัดส่วนพื้นที่ที่สนใจต่อพื้นที่ทั้งหมดในเหตุการณ์สภาพอากาศรุนแรงต่างๆ	27
ตาราง 8 สถิติของระดับน้ำฝนในชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง	29
ตาราง 9 การตั้งไฮเปอร์พารามิเตอร์เมื่อทดลองบนชุดข้อมูลต่างๆ.....	35
ตาราง 10 จำนวนข้อมูลในชุดข้อมูลฝึกสอน ชุดข้อมูลตรวจสอบ และชุดข้อมูลทดสอบ.....	37
ตาราง 11 จำนวนขั้นเวลาที่ใช้สำหรับชุดข้อมูลต่างๆ.....	37
ตาราง 12 ประสิทธิภาพการทำนายของวิธีการต่างๆ ทดสอบบนชุดข้อมูลจำลอง.....	38
ตาราง 13 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 1.....	46
ตาราง 14 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 2.....	48
ตาราง 15 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 3.....	50
ตาราง 16 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 4.....	56
ตาราง 17 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 5.....	58
ตาราง 18 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 6.....	60
ตาราง 19 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 7.....	62

สารบัญรูปภาพ

	หน้า
รูป 1 แผนภูมิแกนต์แสดงแผนการดำเนินงาน.....	4
รูป 2 แผนผังแสดงการทำงานของเรดาร์ตรวจอากาศ.....	10
รูป 3 ตัวอย่างผลการคำนวณสนามการเคลื่อนไหวจากภาพก่อนหน้า.....	12
รูป 4 เทคนิคการประมาณค่านอกช่วงที่ใช้กับโมเดลกลุ่มหนาแน่น [7].....	13
รูป 5 โครงสร้างของ U-Net [10].....	14
รูป 6 ลักษณะการเชื่อมต่อเครือข่ายแบบเอนโคเดอร์-ดีโคเดอร์ของ ConvLSTM [11].....	16
รูป 7 โครงสร้างความสัมพันธ์ของผลลัพธ์ในแต่ละลำดับเวลา [12].....	17
รูป 8 รูปแบบต่างๆ ในการผสมผสานวิธีการทางวิทยาศาสตร์กับโมเดลเชิงลึก [15].....	19
รูป 9 แผนภาพโมเดลไฮบริดระหว่างฟิสิกส์และการเรียนรู้ของเครื่อง [3].....	20
รูป 10 ภาพรวมของขั้นตอนที่งานวิจัยนี้นำเสนอ.....	21
รูป 11 ตัวอย่างลำดับข้อมูลจากชุดข้อมูลจำลอง.....	22
รูป 12 ตัวอย่างภาพถ่ายเรดาร์จากชุดข้อมูล.....	23
รูป 13 การกระจายตัวของอัตราการตกของน้ำฝนในชุดข้อมูล.....	25
รูป 14 การกระจายตัวของอัตราการตกของน้ำฝนเมื่อสเกลด้วยลอการิทึมฐานสิบ.....	25
รูป 15 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 1 เริ่มต้นที่เวลา 9:30.....	27
รูป 16 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 2 เริ่มต้นที่เวลา 9:30.....	27
รูป 17 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 3 เริ่มต้นที่เวลา 9:30.....	28
รูป 18 ตัวอย่างภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ (4) ถึง (7).....	28
รูป 19 ภาพรวมขั้นตอนการประมวลผลก่อน.....	29
รูป 20 ส่วนภูมิภาคย่อยต่างๆ จากภาพถ่ายเรดาร์เต็ม.....	30
รูป 21 การแบ่งโจทย์ที่ซับซ้อนออกเป็นหลายโจทย์ย่อย.....	31

รูป 22 ภาพรวมขั้นตอนการทำงานของวิธีที่นำเสนอ	32
รูป 23 ตัวอย่างสนามการเคลื่อนไหวจากลำดับของภาพ.....	32
รูป 24 การใช้งานเทคนิคการบิดเบือน [16].....	34
รูป 25 ภาพรวมขั้นตอนการประมวลผลหลัง	34
รูป 26 วิธีการป้อนวนกลับ.....	34
รูป 27 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ก).....	39
รูป 28 สนามการเคลื่อนไหวจากวิธีการผสมผสานในลำดับชั้นเวลาที่ $t = 6$	39
รูป 29 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ข).....	40
รูป 30 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ค).....	40
รูป 31 สนามการเคลื่อนไหวจากวิธีการผสมผสานในลำดับชั้นเวลาที่ $t = 6$	41
รูป 32 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ง).....	41
รูป 33 ค่าความสูญเสียโดยเฉลี่ยในแต่ละชั้นเวลาเมื่อทดสอบบนชุดข้อมูลจำลอง	42
รูป 34 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 1.....	47
รูป 35 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 1	47
รูป 36 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 2.....	49
รูป 37 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 2	49
รูป 38 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 3.....	51
รูป 39 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 3.....	51
รูป 40 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 4.....	57
รูป 41 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 4.....	57
รูป 42 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 5.....	59
รูป 43 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 5.....	59
รูป 44 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 6.....	61
รูป 45 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 6.....	61

รูป 46 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับชั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 7..... 63

รูป 47 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 7 63

รูป 48 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 1 64

รูป 49 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 2 65

รูป 50 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 3 65

รูป 51 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 4 65

รูป 52 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 5 66

รูป 53 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 6 66

รูป 54 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 7 66



บทที่ 1

บทนำ

1.1. ที่มาและความสำคัญของปัญหา

การพยากรณ์ปริมาณน้ำฝนในระยะสั้น (Precipitation nowcasting) เป็นการคาดการณ์ปริมาณน้ำฝนในตำแหน่งต่างๆ บนระนาบ 2 มิติในแต่ละช่วงเวลา (Timesteps) ในช่วงอนาคตอันใกล้ (เช่น 2 ถึง 3 ชั่วโมงข้างหน้า) โดยใช้ข้อมูลภาพถ่ายเรดาร์ (Radar images) จากช่วงก่อนหน้า ผลการทำนายจะสามารถนำไปใช้ประโยชน์ได้มากมาย เช่น ใช้เป็นข้อมูลในการวางแผนการใช้ชีวิตประจำวัน ใช้ประเมินความสามารถในการมองเห็นบนท้องถนนเพื่อเพิ่มความปลอดภัยในการขับขี่ หรือใช้จัดทำคำแนะนำเกี่ยวกับสภาพอากาศให้กับทางสนามบิน เป็นต้น โดยในงานนี้ได้ใช้ชุดข้อมูลภาพถ่ายเรดาร์ที่ได้รับมาและอนุญาตให้ใช้โดยบริษัท Weathernews Inc.

การทำนายปริมาณน้ำฝนเป็นปัญหาที่มีความท้าทายตั้งแต่อดีต เนื่องจากการทำนายจะต้องคำนึงถึงในแง่ตำแหน่ง เวลา และปริมาณ วิธีการดั้งเดิมมักอาศัยหลักการทางวิทยาศาสตร์ เช่น ใช้หลักการทางฟิสิกส์หรือใช้การอ้างอิงหลักการทางสถิติ อย่างไรก็ตามประสิทธิภาพการทำนายด้วยวิธีการดังกล่าวยังไม่สูงมากนัก [1] เนื่องจากกระบวนการทางอุตุนิยมวิทยานั้นมีความละเอียดอ่อน ซับซ้อน จึงยากที่จะจำลองทุกละเอียดให้ครบถ้วนเสมือนจริง [2] นอกจากนี้ยังมีข้อจำกัดในเรื่องความรู้ความเข้าใจเกี่ยวกับปรากฏการณ์ทางธรรมชาติต่างๆ ที่ยังไม่สมบูรณ์

ในปัจจุบันการพัฒนาของศาสตร์การเรียนรู้ของเครื่อง (Machine learning) และการเรียนรู้เชิงลึก (Deep learning) ได้ประสบความสำเร็จมากในการใช้กับโจทย์ที่หลากหลาย ไม่ว่าจะเป็นการแปลภาษาด้วยเครื่อง (Machine translation) จนไปถึงการทำนายวิดีโอ (Video prediction) อย่างไรก็ตามโมเดลประเภท “physics-free” เหล่านี้ยังไม่มีประสิทธิภาพที่ดีมากเมื่อนำมาใช้กับโจทย์การทำนายปรากฏการณ์ทางธรรมชาติที่มีความซับซ้อน [3] และในบางครั้งก็ยากสำหรับโมเดลที่จะทำนายเหตุการณ์ที่อยู่นอกเหนือชุดข้อมูลฝึกสอนให้ได้ผลลัพธ์ที่ดี

จากเหตุผลที่กล่าวมาข้างต้น การผสมผสานโมเดลเชิงลึกกับวิธีการเชิงวิทยาศาสตร์จึงเป็นสถาปัตยกรรมทางเลือกหนึ่งที่สามารถช่วยเพิ่มประสิทธิภาพให้ดีกว่าการใช้วิธีการเพียงแบบใดแบบหนึ่ง เพราะในขณะที่วิธีการแบบดั้งเดิมทำนายผลตามหลักการทางวิทยาศาสตร์ การใช้โมเดลเชิงลึกด้วยก็จะช่วยให้โมเดลสามารถเรียนรู้และใช้ประโยชน์จากชุดข้อมูลขนาดใหญ่ได้

งานวิจัยนี้จึงมุ่งเน้นที่จะพัฒนาสถาปัตยกรรมโมเดลที่ผสมผสานความรู้ทางวิทยาศาสตร์ก่อนหน้าเข้ากับโมเดลการเรียนรู้เชิงลึกเพื่อพยากรณ์ปริมาณน้ำฝนในระยะสั้น โดยโมเดลที่ใช้มีโครงสร้าง

พื้นฐานจากเทคนิคการประมาณค่าเรดาร์นอกช่วง (Radar extrapolation technique) ซึ่งเป็นหนึ่งในวิธีการทางวิทยาศาสตร์ที่ให้ประสิทธิภาพการทำนายสูง [5] จากนั้นจึงทำการผสมผสานโดยแทนที่ส่วนย่อยของวิธีการที่ทำหน้าที่หาสนามการเคลื่อนไหวด้วยโมเดลเชิงลึกที่เป็นโมเดลรูปตัวยู (U-Net) ในขณะที่คงส่วนหลังที่ใช้เทคนิคการบิดเบือน (Warping Scheme) ไว้เพื่อทำการประมาณค่านอกช่วง ในการทดลองได้มีการสร้างชุดข้อมูลจำลองที่ลอกเลียนคุณสมบัติเด่นจากลำดับภาพถ่ายเรดาร์ (Radar image sequences) แล้วทำการทดสอบทั้งบนชุดข้อมูลจำลองดังกล่าวและชุดข้อมูลภาพถ่ายเรดาร์ที่ประกอบด้วยเหตุการณ์สภาพอากาศรุนแรง 7 กรณี เพื่อเปรียบเทียบผลกับวิธีการทางวิทยาศาสตร์และโมเดลเชิงลึกต่างๆ ได้แก่ วิธีการคงสภาพเดิม (Persistence method) วิธีการเรนนี่โมชัน (rainymotion) โมเดลแบบรูปตัวยู หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (ConvLSTM) และหน่วยเกทวนกลับเชิงวิถี (TrajGRU) โดยมีตัวชี้วัดหลักเป็นรากของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root mean squared error) ค่าดัชนีแห่งความสำเร็จ (Critical success index หรือ “CSI”) และค่า CSI แบบหลายคลาส นอกจากนี้ได้มีการทดลองเปลี่ยนแปลงเพิ่มน้ำหนักของค่าสูญเสีย (Loss) เมื่อทำนายจุดที่อัตราปริมาณน้ำฝนสูง เพื่อเพิ่มประสิทธิภาพการทำนายของโมเดลแบบผสมผสานเมื่อฝนตกหนัก จากผลการทดลองพบว่าวิธีการที่เสนอนี้ให้ประสิทธิภาพดีกว่าวิธีการมาตรฐานในกรณีส่วนมากบนชุดข้อมูลทั้งคู่

1.2. วัตถุประสงค์ของงานวิจัย

งานวิจัยนี้มีจุดประสงค์เพื่อเสนอสถาปัตยกรรมการเรียนรู้เชิงลึกที่ผสมผสานกับวิธีการที่ใช้ความรู้ทางวิทยาศาสตร์สำหรับพยากรณ์ปริมาณน้ำฝนในระยะสั้น เพื่อให้ประสิทธิภาพการทำนายเพิ่มขึ้นจากการใช้เพียงโมเดลเชิงลึกหรือวิธีการพยากรณ์แบบดั้งเดิมเท่านั้น

1.3 ขอบเขตของการวิจัย

1. ใช้ข้อมูลปริมาณน้ำฝนจากชุดข้อมูลภาพถ่ายเรดาร์ในภูมิภาคญี่ปุ่นที่มีอันตรายภาค 10 นาที
2. เปรียบเทียบประสิทธิภาพการทำนายจากแต่ละวิธีการบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง (ช่วง 3 ชั่วโมงข้างหน้า) และชุดข้อมูลจำลองที่มีจำนวนวัตถุ 1 ชั้น
3. ตัวชี้วัดหลักในการเปรียบเทียบประสิทธิภาพเป็นรากของค่าเฉลี่ยความผิดพลาดกำลังสอง ค่าดัชนีแห่งความสำเร็จและ CSI แบบหลายคลาส

1.4 ประโยชน์ที่ได้รับ

สามารถทำนายปริมาณน้ำฝนในระยะสั้นโดยใช้วิธีการที่ผสมผสานการเรียนรู้เชิงลึกกับความรู้ทางวิทยาศาสตร์ซึ่งให้ผลที่มีความแม่นยำกว่าวิธีการเชิงวิทยาศาสตร์หรือวิธีการที่ใช้การเรียนรู้เชิงลึกเพื่อแสดงให้เห็นว่าการนำความรู้เชิงวิทยาศาสตร์มาผสมผสานกับโมเดลเชิงลึกเป็นหนึ่งในแนวทางที่สามารถใช้ตอบโจทย์ที่มีความซับซ้อนได้

งานวิจัยนี้ได้สร้างและใช้ชุดข้อมูลจำลองขนาดเล็กที่ลอกเลียนคุณสมบัติที่สำคัญจากลำดับของภาพถ่ายเรดาร์ เพื่อใช้วิเคราะห์ความสามารถและประสิทธิภาพของโมเดลในการทำนายคุณสมบัติต่างๆ

1.5 วิธีการดำเนินงานวิจัย

1. ศึกษาวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับหัวข้องานวิจัย เช่น การเรียนรู้เชิงลึก การทำนายปริมาณน้ำฝนในระยะสั้น และวิธีการประเมินผลที่นิยมใช้ เป็นต้น
2. รวบรวมข้อมูลภาพถ่ายเรดาร์ที่ได้จากบริษัท Weathernews Inc.
3. ศึกษาการใช้งานเครื่องมือการเรียนรู้เชิงลึกโดยใช้ไพทอน (PyTorch) [4]
4. ดำเนินการเขียนโค้ดแล้วทำการทดลองพร้อมบันทึกผล
5. เขียนงานวิจัยและตีพิมพ์เพื่อนำไปเสนอผลงานทางวิชาการ
6. จัดทำวิทยานิพนธ์

1.6 ผลงานตีพิมพ์จากงานวิจัย

งานวิจัยในวิทยานิพนธ์ฉบับนี้ได้รับการตีพิมพ์เป็นบทความทางวิชาการ

P. Danpoonkij, N. Kleawsirikul, P. Leepaisomboon, N. Gaviphatt, H. Sakaino and P. Vateekul, "Incorporating Prior Scientific Knowledge Into Deep Learning for Precipitation Nowcasting on Radar Images," in *2021 18th Int'l Joint Conf. Comput. Sci. and Software Engineer.*, Thammasat University, Thailand, Jun, 2021.

1.7 แผนภูมิแกนต์ (Gantt chart)

รูป 1 แผนภูมิแกนต์แสดงแผนการดำเนินงาน

งาน	2563						2564							
	7	8	9	10	11	12	1	2	3	4	5	6	7	8
เลือกหัวข้องานวิจัย														
ศึกษาเนื้อหาที่เกี่ยวข้อง														
รวบรวมและเตรียมข้อมูล														
จัดเตรียมวิธีการมาตรฐาน														
ออกแบบและพัฒนาวิธีการที่เสนอ														
ประเมินและตรวจสอบผล														
วิเคราะห์และสรุปผลการทดลอง														
เขียนรายงานวิจัย														
ส่งรายงานวิจัย														
จัดทำวิทยานิพนธ์														
เสนอผลงานวิจัย														

บทที่ 2

แนวคิดและทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับงานวิจัยนี้ประกอบด้วยวิธีการที่ใช้ในการพยากรณ์ปริมาณฝนระยะสั้น ลักษณะของโจทย์การทำนายอนุกรมเวลาของภาพ (Sequential images prediction) และวิธีการวัดประสิทธิภาพจากการทำนาย (Performance evaluation)

2.1 วิธีการพยากรณ์ปริมาณฝนในระยะสั้น

การพยากรณ์ปริมาณฝนในระยะสั้นเป็นปัญหาในการพยากรณ์อากาศที่มีความท้าทายมาตั้งแต่อดีตกาล การทำนายจะเจาะจงภายในภูมิภาคหนึ่งๆ และภายในช่วงเวลาข้างหน้าสั้นๆ (เช่น 2 ถึง 3 ชั่วโมง) โดยใช้ข้อมูลปริมาณน้ำฝนที่ได้จากภาพถ่ายเรดาร์ ผลจากการทำนายสามารถนำไปใช้ประโยชน์ได้มากมายตั้งแต่ช่วยในการวางแผนชีวิตประจำวันจนถึงช่วยลดความสูญเสียทั้งชีวิตและทรัพย์สิน

วิธีการทางวิทยาศาสตร์สำหรับพยากรณ์ปริมาณฝนแบ่งออกเป็น 2 ประเภท ได้แก่ วิธีการพยากรณ์อากาศเชิงตัวเลข (Numerical weather models หรือ “NWP”) และวิธีการประมาณค่าสัญญาณสะท้อนเรดาร์นอกช่วง¹ (Radar echo extrapolation techniques) วิธีการแบบ NWP เป็นการพยากรณ์ลักษณะสภาพอากาศโดยอาศัยหลักอุทกพลศาสตร์ประกอบด้วยเทอร์โมไดนามิกส์ จำลองสภาพสภาวะอากาศที่จะเกิดขึ้นโดยแก้สมการที่ซับซ้อน ดังนั้นเวลาที่ใช้ในการประมวลผลจึงค่อนข้างนาน ส่วนวิธีการประมาณค่าสัญญาณสะท้อนเรดาร์นอกช่วงเป็นวิธีที่ทำนายผลโดยใช้หลักการติดตามการเคลื่อนไหว (Tracking motion) ร่วมกับการประมาณค่านอกช่วง (Extrapolation) เป็นวิธีที่ใช้การคำนวณเรียบง่ายกว่าจึงใช้เวลาน้อยกว่า นอกจากนี้ยังให้ผลที่แม่นยำกว่าในเวลาช่วงสั้นๆ (2 ถึง 3 ชั่วโมงแรก) จึงนับได้ว่าเป็นวิธีการที่ทันสมัย (State-of-the-art) ในกลุ่มของวิธีการทางวิทยาศาสตร์ [5]

ในช่วงทศวรรษที่ผ่านมาด้วยการเพิ่มขึ้นของปริมาณข้อมูลและความสามารถในการคำนวณของคอมพิวเตอร์ที่สูงขึ้นส่งผลให้เทคโนโลยีปัญญาประดิษฐ์ (Artificial intelligence) ได้พัฒนาอย่างก้าวกระโดด สำหรับใช้งานทั้งในด้านการประมวลผลภาษาธรรมชาติ (Natural language processing)

¹ แผนที่สัญญาณสะท้อนเรดาร์ (Radar echo maps) เป็นภาพจากผลการตรวจเรดาร์ทางราบหลายๆ มุมที่มีความสูงหนึ่งๆ (CAPPI หรือ Constant Altitude Plan Position Indicator)

การวิเคราะห์ข้อมูลเชิงโครงสร้าง (Structured data) คอมพิวเตอร์วิทัศน์ (Computer vision) จนไป การทำนายวิทัศน์ จึงได้มีผู้คิดค้นโมเดลเชิงลึกจำนวนมากสำหรับใช้งานกับโจทย์แต่ละประเภท

โจทย์ของการทำนายปริมาณน้ำฝนอาจนับได้ว่าอยู่ในหมวดหนึ่งของการทำนายวิทัศน์ ดังนั้นโมเดลเชิงลึกที่ออกแบบมาเพื่อทำนายภาพในลักษณะอนุกรมเวลา (Sequential images predictions) ก็จะสามารถนำมาใช้ในการทำนายในโจทย์นี้ได้

2.2 การทำนายอนุกรมเวลาของภาพ

ปัญหาการทำนายอนุกรมเวลาของภาพเป็นปัญหาที่วิธีการหรือโมเดลถูกป้อนด้วยข้อมูลภาพ 2 มิติที่มีหลายช่องสัญญาณ โดยแต่ละช่องสัญญาณแทนข้อมูลในแต่ละชั้นเวลา แล้วจึงให้ผลลัพธ์ (ผล การทำนาย) เป็นข้อมูลภาพ 2 มิติที่มีหลายช่องสัญญาณหรือชั้นเวลาเช่นกัน ซึ่งจำนวนช่องสัญญาณ ในข้อมูลป้อนเข้าและผลลัพธ์ไม่จำเป็นต้องเท่ากัน โจทย์ลักษณะนี้แสดงได้ดังสมการ (1)

$$\tilde{\mathcal{X}}_{t+1}, \dots, \tilde{\mathcal{X}}_{t+K} = \operatorname{argmax}_{\mathcal{X}_{t+1}, \dots, \mathcal{X}_{t+K}} p(\mathcal{X}_{t+1}, \dots, \mathcal{X}_{t+K} | \hat{\mathcal{X}}_{t-J+1}, \hat{\mathcal{X}}_{t-J+2}, \dots, \hat{\mathcal{X}}_t) \quad (1)$$

โดยที่ $\tilde{\mathcal{X}}$ เป็นผลการทำนายในชั้นเวลาต่างๆ ล่วงหน้า K ชั้น จากข้อมูล $\hat{\mathcal{X}}$ ในชั้นเวลาต่างๆ ย้อนไป J ชั้น โดย \mathcal{X} เป็นข้อมูลที่ประกอบด้วยมิติของความกว้างและความสูง

2.3 การวัดประสิทธิภาพการทำนาย (Performance evaluation)

ในวิทยานิพนธ์นี้ได้ใช้หลายตัวชี้วัดที่นิยมใช้ในการทำนายปริมาณน้ำฝน ได้แก่ รากของ ค่าเฉลี่ยความผิดพลาดกำลังสอง (Root mean squared error หรือ “RMSE”) ค่าดัชนีแห่ง ความสำเร็จ (Critical success index หรือ Threat score หรือ “CSI”) อัตราการแจ้งเตือนผิดพลาด (False alarm rate หรือ “FAR”) และค่าความเป็นไปได้ที่จะตรวจจับ (Possibility of detection หรือ “POD”)

ค่า RMSE บ่งบอกผลเฉลี่ยของค่าความผิดพลาดระหว่างผลการทำนายและผลเฉลย (Groundtruth) ซึ่งคำนวณได้จากสมการ (2)

$$\text{RMSE} = \sqrt{\frac{1}{N \times H \times W} \sum_{n=1}^N \sum_{i=1}^H \sum_{j=1}^W (x_{n,i,j} - \hat{x}_{n,i,j})^2} \quad (2)$$

โดยที่ N แทนจำนวนชั้นเวลาที่ทำนาย
 H แทนความสูงของภาพ
 W แทนความกว้างของภาพ
 x แทนค่าที่ตำแหน่งในลำดับเวลาต่างๆ

ค่า CSI FAR และ POD นั้นมีความหมายใกล้เคียงกับค่าความแม่นยำ (Precision) และค่าความครบถ้วน (Recall) จากศาสตร์การเรียนรู้ของเครื่อง ซึ่งคำนวณได้จากสมการ (3) ถึง (5)

$$\text{CSI} = \frac{\text{hits}}{\text{hits} + \text{misses} + \text{false alarms}} * 100 \quad (3)$$

$$\text{FAR} = \frac{\text{false alarms}}{\text{hits} + \text{false alarms}} * 100 \quad (4)$$

$$\text{POD} = \frac{\text{hits}}{\text{hits} + \text{false alarms}} * 100 \quad (5)$$

ตัวแปรจากที่ในสมการข้างต้นได้อธิบายไว้ในตาราง 1 โดยที่ H (Hit) คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นและผลลัพธ์คือคลาสนั้น F (False alarm) คือ จำนวนข้อมูลที่ทำนายได้คลาสนั้นแต่ผลลัพธ์คือคลาสนอื่น และ M (Miss) คือ จำนวนข้อมูลที่ทำนายได้คลาสนอื่นแต่ผลลัพธ์คือคลาสนั้น โดยขีดแบ่งของการแบ่งคลาส (Threshold) อยู่ที่ 1 มิลลิเมตรต่อชั่วโมง (Millimeters per hour หรือ “mm/hr.”) ซึ่งเป็นค่าที่แบ่งแยกระหว่างฝนตกกับฝนไม่ตก

ตาราง 1 คอนฟิวชันเมทริกซ์สำหรับการจำแนกการตกของฝน

		คลาสที่ทำนาย	
		ฝนตก	ฝนไม่ตก
คลาสจริง	ฝนตก	Hits	Misses
	ฝนไม่ตก	False alarms	True negative

ค่า CSI เป็นตัวชี้วัดส่วนที่ทำนายฝนตกได้ถูกเทียบกับส่วนที่ทำนายว่าตกได้ถูกรวมกับส่วนที่ทำนายผิด สำหรับตัวชี้วัดนี้ค่ายิ่งมายิ่งดี ค่า FAR เป็นตัวชี้วัดสัดส่วนความผิดพลาดชนิดที่หนึ่ง

(Type I error) สำหรับค่านี้ยิ่งน้อยยิ่งดี และค่า POD บ่งบอกสัดส่วนที่ทำนายฝนตกได้ถูกเทียบกับส่วนที่ทำนายว่าฝนตกทั้งหมด สำหรับค่านี้ยิ่งมากยิ่งดี

เนื่องจาก CSI เป็นเพียงการวัดค่าที่ขีดแบ่งเดียว จึงไม่สามารถบ่งบอกประสิทธิภาพการทำนายขณะฝนตกหนักได้ว่าเป็นเช่นใด จึงได้ใช้ตัวชี้วัดประสิทธิภาพอีกประเภทเป็น CSI แบบหลายคลาส โดยมีขีดแบ่งที่ 1 3 และ 10 มิลลิเมตรต่อชั่วโมง สำหรับวัดประสิทธิภาพ CSI เมื่อฝนตกเบา ฝนตกปานกลาง และฝนตกหนัก ตามลำดับ

นอกจากนี้แล้วผู้วิจัยได้เห็นถึงความสำคัญของผลการทำนายจากการมอง (Predictive visual) จึงได้ใช้ตัวชี้วัดความคล้ายของโครงสร้าง (Structural similarity หรือ “SSIM”) [6] เพื่อบ่งบอกว่าผลจากการทำนายคล้ายกับผลเฉลยเพียงใดในเชิงทัศน์ ซึ่งพิจารณาจาก 3 ปัจจัย ได้แก่ (1) แสง (Luminance) (2) ความคมชัด (Contrast) และ (3) โครงสร้างของรูปภาพ (Structure) โดยคำนวณดังแสดงในสมการ (6) ถึง (8) ตามลำดับ และคำนวณ SSIM ได้โดยใช้สมการ (9)

$$l(\mathbf{x}, \mathbf{y}) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (6)$$

$$c(\mathbf{x}, \mathbf{y}) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (7)$$

$$s(\mathbf{x}, \mathbf{y}) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (8)$$

โดยที่ μ แทนค่าเฉลี่ยของพิกเซลทั้งภาพ
 σ แทนส่วนเบี่ยงเบนมาตรฐานของค่าพิกเซลทั้งภาพ
 C แทนค่าเพิ่มความเสถียรในการหาร (Division stabilizer)

$$SSIM(\mathbf{x}, \mathbf{y}) = l(\mathbf{x}, \mathbf{y}) \cdot c(\mathbf{x}, \mathbf{y}) \cdot s(\mathbf{x}, \mathbf{y}) \quad (9)$$


ในการใช้งาน SSIM จริงส่วนมากจะไม่คำนวณทั้งภาพทีเดียวแต่จะแยกคำนวณเป็นส่วนย่อยๆ (Chunk) แล้วมาเฉลี่ยเพื่อหาผลลัพธ์สุดท้าย เนื่องจากค่าทางสถิติส่วนมากมักแตกต่างกันไปตามแต่ละบริเวณของภาพ ในงานวิจัยนี้ได้คำนวณ SSIM แต่ละส่วนของภาพและให้นำหนักโดยใช้เกาส์เซียนเคอร์เนล (Gaussian kernel) ขนาด 11×11 พิกเซล แล้วเคลื่อนไปที่ละ 1×1 พิกเซล จนได้ค่าครบทั้งภาพ แล้วจึงหาค่าเฉลี่ยเป็นค่า SSIM สุดท้าย

2.4 ภาพถ่ายเรดาร์ (Radar images)

ภาพถ่ายเรดาร์หรือแผนที่สัญญาณสะท้อนเรดาร์เป็นข้อมูลภาพ 2 มิติ ที่ได้จากรีดาร์ตรวจอากาศ (Weather radar) ซึ่งเป็นเครื่องมือส่งและรับสัญญาณเพื่อตรวจจับเม็ดฝน (หรือหยาดน้ำแบบอื่นๆ) ในปัจจุบันนิยมใช้เรดาร์ตรวจอากาศแบบดอปเปลอร์ (Doppler radar) ซึ่งมี 3 ชนิดย่อย ได้แก่

1. **เรดาร์ตรวจอากาศแบบ X-BAND** เป็นเรดาร์ขนาดเล็ก ใช้คลื่นความถี่ 6,200 ถึง 10,900 เมกะเฮิรตซ์ (MHz) ความยาวคลื่น 2.75 ถึง 4.84 เซนติเมตร (cm) มีรัศมีหวังผลประมาณ 100 กิโลเมตร (km) เหมาะสำหรับใช้ตรวจฝนกำลังอ่อนถึงปานกลาง เนื่องจากเป็นเรดาร์ขนาดเล็กและความยาวคลื่นสั้น
2. **เรดาร์ตรวจอากาศแบบ C-BAND** เป็นเรดาร์ขนาดปานกลาง ใช้คลื่นความถี่ 3,900 ถึง 6,200 MHz ความยาวคลื่น 4.84 ถึง 7.69 cm มีรัศมีหวังผล 240 km เหมาะสำหรับใช้ตรวจฝนระดับปานกลางถึงกำลังแรง
3. **เรดาร์ตรวจอากาศแบบ S-BAND** เป็นเรดาร์ขนาดปานกลาง ใช้คลื่นความถี่ 1,550 ถึง 3,900 MHz ความยาวคลื่น 7.69 ถึง 19.3 cm มีรัศมีหวังผลเกินกว่า 300 km เหมาะสำหรับใช้ตรวจฝนกำลังแรงถึงแรงมาก

ในการทำงานระบบจานเรดาร์จะส่งสัญญาณในช่วงคลื่นไมโครเวฟ (สัญญาณเรดาร์) ที่มีความถี่ตามประเภทของเรดาร์ หากคลื่นไปกระทบกับหยาดน้ำฝน คลื่นจะสะท้อนกลับมายังเรดาร์ดังแสดงในรูป 2 ซึ่งจะมีระบบคอยรับสัญญาณอยู่เพื่อประมวลผล โดยช่วงเวลาระหว่างปล่อยและได้รับสัญญาณจะบอกถึงตำแหน่งได้ ส่วนความเข้มของการสะท้อนจะบอกถึงปริมาณน้ำฝน ดังนั้นจึงสามารถนำมาสร้างเป็นภาพถ่ายเรดาร์ 2 มิติได้ โดยที่ค่าแต่ละจุดในภาพบ่งบอกถึงปริมาณน้ำฝนในบริเวณหนึ่งๆ ในหน่วยมิลลิเมตรต่อชั่วโมง



รูป 2 แผนผังแสดงการทำงานของเรดาร์ตรวจอากาศ²



² อ้างอิงจาก canada.ca/en/environment-climate-change/services/weather-general-tools-resources/radar-overview/wind-turbine-interference/overview-wind-turbine-interference.html

บทที่ 3

เอกสารและงานวิจัยที่เกี่ยวข้อง

เอกสารและงานวิจัยที่เกี่ยวข้องในงานวิจัยนี้แบ่งออกเป็น 3 กลุ่ม ได้แก่ วิธีการดั้งเดิมสำหรับทำนายปริมาณน้ำฝนในระยะสั้น งานวิจัยเกี่ยวกับการใช้การเรียนรู้เชิงลึกทำนายภาพที่เป็นอนุกรมเวลา (Sequential images prediction deep learning model) และวิธีการผสมผสานความรู้ทางวิทยาศาสตร์เข้ากับการเรียนรู้ของเครื่อง (Integrated scientific-based knowledge with machine learning)

3.1 วิธีการดั้งเดิมที่ใช้สำหรับทำนายปริมาณน้ำฝนในระยะสั้น

วิธีการแบบดั้งเดิม (Traditional method) เป็นวิธีการทำนายปริมาณน้ำฝนในระยะสั้นที่ใช้หลักการทางวิทยาศาสตร์ โดยวิธีการแบบดั้งเดิมที่สนใจในงานวิจัยนี้ ได้แก่ วิธีการคงสภาพเดิม (Persistence method) และวิธีการคงสภาพแบบลางรองจ์ (Lagrangian persistence) ซึ่งเป็นพื้นฐานของวิธีการประมาณค่าสัญญาณสะท้อนเรดาร์นอกช่วง (Radar echo extrapolation techniques) อย่างวิธีการเรนนี่โมชัน (rainymotion)[7]

3.1.1 วิธีการคงสภาพเดิม (Persistence method)


วิธีการคงสภาพเดิมหรือวิธีการคงเดิมยูเลอร์เรียน (Eulerian persistence method) เป็นหนึ่งในวิธีการพยากรณ์อากาศที่จะให้ผลการทำนายสภาพอากาศที่คงเดิมและไม่มีการเปลี่ยนแปลง หรือกล่าวอีกนัยคือวิธีการนี้จะให้ผลการทำนายเหมือนเดิมในทุกชั้นเวลาที่ทำนาย

3.1.2 วิธีการคงสภาพแบบลางรองจ์ (Lagrangian persistence)

วิธีการคงสภาพแบบลางรองจ์เป็นพื้นฐานของวิธีการประมาณค่าสัญญาณสะท้อนเรดาร์นอกช่วงที่ใช้ทำนายปริมาณน้ำฝนในระยะสั้น โดยแบ่งเป็น 2 ขั้นตอน ได้แก่ การติดตามการเคลื่อนไหวและการประมาณค่านอกช่วง

1. การติดตามการเคลื่อนไหว เป็นการคำนวณหาความเร็ว (Velocity) บนแต่ละบริเวณในภาพ ซึ่งผลลัพธ์ที่ได้มักนำไปใช้ต่อในสมการพื้นฐานอย่างสมการการพา (Advection equations) หรือสมการนาเวียร์-สโตกส์ (Navier–Stokes equations) ส่วนมากนั้นนิยมใช้อัลกอริทึมการวิเคราะห์การไหลของแสง (Optical flow) ในการคำนวณหาความเร็ว

การวิเคราะห์การไหลของแสงเป็นเครื่องมือสำหรับหาทิศทางและการเคลื่อนไหวของวัตถุ ซึ่งคำนวณจากลำดับภาพที่ต่อเนื่องกันอย่างน้อย 2 ภาพ สร้างเป็นสนามการไหลของแสงหรือเรียกว่า “สนามการเคลื่อนไหว” (Motion field) ดังแสดงในรูป 3



รูป 3 ตัวอย่างผลการคำนวณสนามการเคลื่อนไหวจากภาพก่อนหน้า³

ในรูป 3 แสดงวัตถุสี่เหลี่ยมเคลื่อนย้ายจากบริเวณตรงกึ่งกลางภาพไปยังตำแหน่งใหม่อยู่บนซ้ายของภาพ สนามการเคลื่อนไหวที่สร้างจากลำดับจากภาพทั้ง 2 จึงมีลูกศรที่ชี้จากตำแหน่งเดิมไปยังตำแหน่งใหม่ หากมองสนามการเคลื่อนไหวเป็นแถวลำดับ (Array) 2 มิติ บริเวณดังกล่าว (ที่มีลูกศร) จะเป็นบริเวณที่มีค่าสูงในขณะที่บริเวณรอบข้างที่ไม่มีการเคลื่อนไหวมีค่าต่ำหรือเป็นศูนย์

2. การประมาณค่านอกช่วง เป็นการย้ายค่าจุดต่างๆ ในภาพจากตำแหน่งเดิมไปยังตำแหน่งใหม่ในลำดับเวลาถัดไปโดยใช้ข้อมูลจากสนามการเคลื่อนไหวที่คำนวณได้จากขั้นตอนก่อนหน้า เพื่อให้ได้ภาพที่เป็นผลลัพธ์สุดท้าย การประมาณค่านอกช่วงสามารถทำได้หลายวิธีโดยจะกล่าวในส่วนถัดไป

3.1.3 วิธีการเรนนี่โมชัน (rainymotion)

ในปี 2018 Ayzel, G., et al. [7] ได้เสนออัลกอริทึมเรนนี่โมชัน (rainymotion) สำหรับพยากรณ์ปริมาณน้ำฝนในระยะสั้น โดยวิธีการดังกล่าวมีพื้นฐานอยู่บนวิธีการคงสภาพแบบลงกรองจซึ่งแบ่งการคำนวณออกเป็น 2 ขั้นตอน ในขั้นตอนแรกเป็นการติดตามซึ่งจะคำนวณสนามการเคลื่อนไหวจากลำดับของภาพเรดาร์ในอดีต แล้วจึงนำสนามการเคลื่อนไหวดังกล่าวไปเคลื่อนย้ายฝนจากภาพเรดาร์ล่าสุดไปยังตำแหน่งใหม่โดยใช้เทคนิคการประมาณค่านอกช่วง ทางผู้เขียนได้เลือกอัลกอริทึมในแต่ละขั้นตอนแตกต่างกันออกไป 4 รูปแบบ ดังแสดงในตาราง 2

ตาราง 2 รูปแบบต่างๆ ของวิธีการเรนนี่โมชัน


ชื่อโมเดล	อัลกอริทึมการติดตาม	การประมาณค่านอกช่วง
SparseSD	ตัวตรวจหามุมของชีและโทมาซี (Shi-Tomasi corner detector) หรือการไหลของแสงโดยลูคาสคาเนด (Lucas-Kanade optical flow)	การเปลี่ยนแปลงของเดลต้าอย่างคงที่ (Constant delta-change) หรือการบิดเบือนสัมพันธ์ (Affine warping)

³ อ้างอิงจาก homepages.inf.ed.ac.uk/rbf/CVonline/LOCAL_COPIES/OWENS/LECT12/node3.html

ชื่อโมเดล	อัลกอริทึมการติดตาม	การประมาณค่านอกช่วง
Sparse	ตัวตรวจหามุมของซีและโทมาซี หรือ การไหลของแสงโดยลูคาสคาเนด	การถดถอยเชิงเส้น (Linear regression) หรือการบิดเบือน สัมพรรค
Dense	การคำนวณการไหลของแสงแบบ DIS (DIS optical flow)	การพาเวกเตอร์คงที่ย้อนกลับ (Backward constant-vector advection)
DenseRotation	การคำนวณการไหลของแสงแบบ DIS	การพากึ่งลงกรองจย้อนกลับ (Backward semi-Lagrangian advection)

โมเดลกลุ่มที่ใช้การติดตามการเคลื่อนไหวเฉพาะที่ (Sparse) ได้แก่ “SparseSD” และ “Sparse” เป็นโมเดลที่ใช้อัลกอริทึมการติดตามที่จะหาจุดที่เป็นลักษณะเฉพาะของภาพ (เช่น ขอบหรือมุม) โดยดูจากเกรเดียนต์ในภาพเพื่อใช้ยึดเป็นจุดสำคัญในการหาความเร็ว ในขณะที่โมเดลกลุ่มที่ใช้การติดตามการเคลื่อนไหวทั้งภาพ (Dense) ได้แก่ “Dense” และ “DenseRotation” ใช้ อัลกอริทึมการติดตามแบบที่หาความเร็วทุกๆ จุดในภาพ

ในงานวิจัยนี้สนใจวิธีการแบบ DenseRotation ซึ่งเป็นวิธีการที่ให้ประสิทธิภาพสูงสุดในการทำนายปริมาณน้ำฝนเมื่อเทียบวิธีการเรนนี่โมชันอื่นๆ DenseRotation ใช้อัลกอริทึมติดตามเป็นการคำนวณการไหลของแสงแบบ DIS [8] และประมาณค่านอกช่วงโดยใช้วิธีการพากึ่งลงกรองจแบบย้อนกลับ [9] ซึ่งทำงานโดยย้ายจุดต่างๆ จากตำแหน่งเดิมไปยังตำแหน่งใหม่ในลำดับเวลาข้างหน้า โดยความเร็วของแต่ละจุดนั้นมาจากสนามความเร็วที่คำนวณได้ในขั้นก่อนหน้าและจะถูกอัปเดตทุกครั้งเมื่อตำแหน่งจุดนั้นเปลี่ยนไป ทำให้สามารถทำนายเคลื่อนที่แบบหมุนได้ ดังแสดงในรูป 4 เทคนิคการประมาณค่านอกช่วงที่ใช้กับโมเดลกลุ่มหนาแน่น [7]



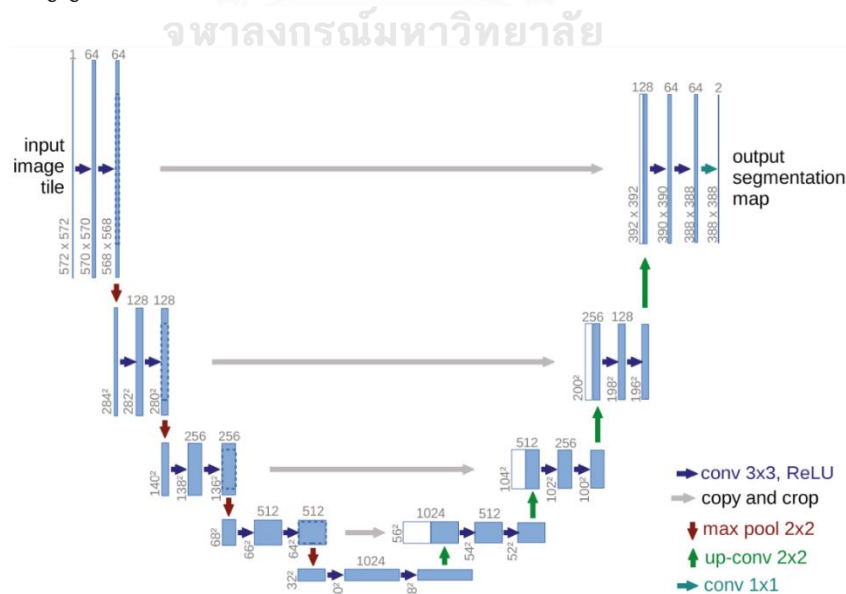
รูป 4 เทคนิคการประมาณค่านอกช่วงที่ใช้กับโมเดลกลุ่มหนาแน่น [7]

3.2 การใช้การเรียนรู้เชิงลึกทำนายภาพที่เป็นอนุกรมเวลา (Sequential images prediction deep learning model)

ในปัจจุบันมีงานวิจัยจำนวนมากใช้โมเดลเชิงลึกทำนายภาพแบบอนุกรมเวลา ในส่วนนี้จะกล่าวถึงโมเดลเกี่ยวข้องหรือเคยมีการนำมาใช้ในงานการทำนายปริมาณน้ำฝนในระยะสั้น ได้แก่ โมเดลรูปตัวยู (U-Net) [10] หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (ConvLSTM) [11] และหน่วยเกทวนกลับเชิงวิถี (TrajGRU) [12]

3.2.1 โมเดลรูปตัวยู (U-Net)

โมเดลรูปตัวยู (U-Net) [10] เป็นนิรอรอลเน็ตเวิร์กแบบคอนโวลูชัน (Convolutional neural network) ที่เชื่อมโยงกันหลายชั้นดังแสดงในรูป 5 มีโครงสร้างแบ่งออกเป็น 2 ฝั่ง โดยฝั่งแรกจะเป็นการหดตัว (Contracting path) ประกอบด้วยแต่ละชั้นที่มีการทำคอนโวลูชัน (Convolution) ขนาด 3×3 ตามด้วยฟังก์ชันกระตุ้น (Activation function) แบบเรกติไฟด์เชิงเส้น (Rectified linear unit หรือ “ReLU”) สองรอบ ตามด้วยการทำพูลลิง (Pooling) ขนาด 2×2 เมื่อถึงขั้นสุดท้ายจะมีช่วงคอขวด (Bottleneck) เป็นช่วงระหว่างการลดขนาดและเพิ่มขนาด ส่วนฝั่งหลังจะเป็นการเพิ่มขนาด (Expansive path) โดยเปลี่ยนจากการทำพูลลิงเป็นการทำอัพแซมปิง (Upsampling) ขนาด 2×2 แทน แล้วตามด้วยการทำคอนโวลูชันขนาด 3×3 ตามด้วยฟังก์ชันกระตุ้นแบบเรกติไฟด์เชิงเส้นสองรอบเช่นเดิม เพื่อขยายภาพให้มีขนาดเท่าเดิม ซึ่งแต่ละชั้นก็จะมีการนำข้อมูลหลังการทำคอนโวลูชันจากฝั่งแรกมาประกอบ แล้วมีขั้นสุดท้ายเป็นการทำคอนโวลูชันขนาด 1×1 เพื่อแปลงภาพให้มีจำนวนช่องสัญญาณ (Channels) ตามที่ต้องการ



รูป 5 โครงสร้างของ U-Net [10]

3.2.2 หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (Convolutional long short-term memory)


ในปี 2015 Xingjian, S., et al. [11] ได้เสนอหน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (ConvLSTM) เป็นเครือข่ายประสาทเทียมแบบคอนโวลูชันที่ออกแบบมาเพื่อประมวลผลภาพสองมิติที่เป็นลำดับ (Sequence) โดยเครือข่ายมีลักษณะคล้ายหน่วยความจำระยะสั้นระยะยาว (LSTM) แต่มีการเพิ่มการทำคอนโวลูชันเข้ามาในขั้นตอนการป้อนข้อมูลและการคำนวณภายในหน่วย ช่วยให้สามารถเรียนรู้และรักษาข้อมูลที่เป็น 2 มิติได้ ภายในเซลล์ ConvLSTM จะมีการคำนวณต่างๆ ดังสมการ (10) โดยสัญลักษณ์ * หมายถึงการทำคอนโวลูชันและ \circ หมายถึงการทำผลคูณฮาดามาร์ด (Hadamard product)

$$\begin{aligned}
 i_t &= \sigma(W_{xi} * \mathcal{X}_t + W_{hi} * \mathcal{H}_{t-1} + W_{ci} \circ \mathcal{C}_{t-1} + b_i) \\
 f_t &= \sigma(W_{xf} * \mathcal{X}_t + W_{hf} * \mathcal{H}_{t-1} + W_{cf} \circ \mathcal{C}_{t-1} + b_f) \\
 \mathcal{C}_t &= f_t \circ \mathcal{C}_{t-1} + i_t \circ \tanh(W_{xc} * \mathcal{X}_t + W_{hc} * \mathcal{H}_{t-1} + b_c) \\
 o_t &= \sigma(W_{xo} * \mathcal{X}_t + W_{ho} * \mathcal{H}_{t-1} + W_{co} \circ \mathcal{C}_t + b_o) \\
 \mathcal{H}_t &= o_t \circ \tanh(\mathcal{C}_t)
 \end{aligned} \tag{10}$$

โดยที่	i_t	แทนผลลัพธ์จากประตูป้อน (Input gate)
	f_t	แทนผลลัพธ์จากประตูลืม (Forget gate)
	o_t	แทนผลลัพธ์จากประตูผลลัพธ์ (Output gate)
	σ	แทนฟังก์ชันซิกมอยด์ (Sigmoid)
	W	แทนน้ำหนักที่ใช้ในประตูต่างๆ
	x_t	แทนข้อมูลป้อนเข้า
	H	แทนผลลัพธ์ของหน่วย
	C	แทนข้อมูลในเซลล์ความจำ (Memory cell)
	b	แทนค่าไบแอส (Bias)

เช่นเดียวกับเครือข่าย U-Net การใช้เครือข่ายจำเป็นต้องนำแต่ละหน่วยมาเชื่อมต่อกันอย่างเหมาะสมในลักษณะเอนโคดเดอร์-ดีโคดเดอร์ (Encoding-Decoding) ดังแสดงในรูป 6 เพื่อให้สามารถใช้งานได้ ในส่วนเอนโคดเดอร์จะประกอบด้วยชั้นป้อนข้อมูล (Input layer) มีหน้าที่รับข้อมูลและทำคอนโวลูชัน ต่อด้วยชั้นของ ConvLSTM ซึ่งจะประมวลผลข้อมูลในลักษณะ 2 มิติ ผลลัพธ์ (Output) จากฝั่งเอนโคดเดอร์ จะถูกป้อนไปยังฝั่งดีโคดเดอร์ (หรือ Forecasting) เพื่อสร้างผลการ

ทำนาย เช่นเดียวกันในฝั่งดีโคดเดอร์ ประกอบด้วยชั้นของ ConvLSTM ต่อกัน โดยผลลัพธ์จากชั้นก่อนหน้าส่งข้อมูลป้อนกับชั้นต่อไปเรื่อยๆ และในชั้นสุดท้ายจะมีการทำคอนโวลูชันแบบ 1×1 เพื่อลดจำนวนช่องสัญญาณให้เป็นไปตามที่ต้องการและเป็นผลการทำนายท้ายที่สุด



รูป 6 ลักษณะการเชื่อมต่อเครือข่ายแบบเอนโคดเดอร์-ดีโคดเดอร์ของ ConvLSTM [11]

3.2.3 หน่วยเกทวนกลับแบบคอนโวลูชัน (Convolutional gated recurrent unit)

ในปี 2017 Xingjian, S., et al. [12] ได้เสนอหน่วยเกทวนกลับแบบคอนโวลูชัน (ConvGRU) ซึ่งพัฒนามาจากหน่วยเกทแบบวนกลับ (Gated recurrent unit หรือ “GRU”) [13] แต่ได้รับการดัดแปลงให้มีโครงสร้างคอนโวลูชันเพื่อให้รองรับการใช้งานกับข้อมูลภาพ 2 มิติ โดยภายในหน่วยเกทวนกลับแบบคอนโวลูชันมีการคำนวณต่างๆ ดังสมการ (11)

$$\begin{aligned}
 \mathcal{Z}_t &= \sigma(W_{xz} * \mathcal{X}_t + W_{hz} * \mathcal{H}_{t-1}) \\
 \mathcal{R}_t &= \sigma(W_{xr} * \mathcal{X}_t + W_{hr} * \mathcal{H}_{t-1}) \\
 \mathcal{H}'_t &= f(W_{xh} * \mathcal{X}_t + \mathcal{R}_t \circ (W_{hh} * \mathcal{H}_{t-1})) \\
 \mathcal{H}_t &= (1 - \mathcal{Z}_t) \circ \mathcal{H}'_t + \mathcal{Z}_t \circ \mathcal{H}_{t-1}
 \end{aligned} \tag{11}$$

โดยที่	x_t	แทนข้อมูลป้อนเข้า
	H	แทนผลลัพธ์ของหน่วย
	H'_t	แทนผลลัพธ์ถูกเสนอ (Candidate)
	σ	แทนฟังก์ชันซิกมอยด์
	f	แทนฟังก์ชันกระตุ้น (Activation function)
	Z_t	แทนผลลัพธ์จากประตูอัปเดต (Update gate)
	R_t	แทนผลลัพธ์จากประตูรีเซ็ต (Reset gate)
	W	แทนน้ำหนักที่ใช้ในประตูต่างๆ


3.2.4 หน่วยเกทวนกลับเชิงวิถี (Trajectory gated recurrent unit)

ในปี 2017 Xingjian, S., et al. [12] ได้เสนอหน่วยเกทวนกลับเชิงวิถี (TrajGRU) ที่พัฒนาต่อยอดจาก ConvGRU ให้สามารถเรียนรู้โครงสร้างที่ผันเปลี่ยนไปตามตำแหน่ง (Location variant) สำหรับเชื่อมโยงแบบวนกลับ โดยได้ดัดแปลงวิธีการคำนวณผลลัพธ์ที่จะเสนอ (H') จากการทำคอนโวลูชันกับผลลัพธ์ในเวลาก่อนหน้า (H_{t-1}) ให้เป็นการเลือกข้อมูล H_{t-1} จากตำแหน่งต่างๆ แทน ซึ่งสามารถแสดงการคำนวณดังในสมการ (12)

$$\mathcal{H}'_{t,:i,j} = f\left(\sum_{l=1}^L \mathbf{W}_{hh}^l \mathcal{H}_{t-1,:p_l,i,j}(\theta), q_{l,i,j}(\theta)\right) \quad (12)$$

โดยที่ H_{t-1} แทนผลลัพธ์ของหน่วยในเวลาก่อนหน้า
 L แทนจำนวนเพื่อนบ้านที่พิจารณา
 W_{hh} แทนน้ำหนักที่ให้กับเพื่อนบ้านต่างๆ

การคำนวณผลลัพธ์ที่จะเสนอจะใช้ค่าจากตำแหน่งรอบข้าง (Neighbors) ทั้งหมด L ตำแหน่งที่เปลี่ยนไปในแต่ละลำดับเวลาและมีการให้น้ำหนักที่ต่างกัน หาก L เท่ากับ 3 จะสามารถแสดงการเลือกเพื่อนบ้านในแต่ละลำดับเวลาได้ดังรูป 7



รูป 7 โครงสร้างความสัมพันธ์ของผลลัพธ์ในแต่ละลำดับเวลา [12]

สมการ (13) แสดงการคำนวณต่างๆ ภายในหน่วย TrajGRU

$$\begin{aligned}
\mathcal{U}_t, \mathcal{V}_t &= \gamma(\mathcal{X}_t, \mathcal{H}_{t-1}) \\
\mathcal{Z}_t &= \sigma(\mathcal{W}_{xz} * \mathcal{X}_t + \sum_{l=1}^L \mathcal{W}_{hz}^l * \text{warp}(\mathcal{H}_{t-1}, \mathcal{U}_{t,l}, \mathcal{V}_{t,l})) \\
\mathcal{R}_t &= \sigma(\mathcal{W}_{xr} * \mathcal{X}_t + \sum_{l=1}^L \mathcal{W}_{hr}^l * \text{warp}(\mathcal{H}_{t-1}, \mathcal{U}_{t,l}, \mathcal{V}_{t,l})) \\
\mathcal{H}'_t &= \sigma(\mathcal{W}_{xh} * \mathcal{X}_t + \mathcal{R}_t \circ (\sum_{l=1}^L \mathcal{W}_{hh}^l * \text{warp}(\mathcal{H}_{t-1}, \mathcal{U}_{t,l}, \mathcal{V}_{t,l}))) \\
\mathcal{H}_t &= (1 - \mathcal{Z}_t) \circ \mathcal{H}'_t + \mathcal{Z}_t \circ \mathcal{H}_{t-1}
\end{aligned} \tag{13}$$

โดยที่ $\mathcal{U}_t, \mathcal{V}_t$ แทนผลการคำนวณสนามการเคลื่อนไหวจาก γ
 \mathcal{Z}_t แทนผลลัพธ์จากประตูอัปเดต
 \mathcal{R}_t แทนผลลัพธ์จากประตูรีเซ็ต
 \mathcal{W} แทนน้ำหนักที่ใช้ในประตูต่างๆ
 \mathcal{X}_t แทนข้อมูลป้อนเข้า
 \mathcal{H} แทนผลลัพธ์ของหน่วย
 \mathcal{H}'_t แทนผลลัพธ์ถูกเสนอ

เนื่องจากค่าของตำแหน่งเป็นตัวเลขที่ไม่ต่อเนื่อง (Discrete) จึงหาอนุพันธ์ไม่ได้ (Non-differentiable) ผู้วิจัยจึงได้ใช้สนามการเคลื่อนไหวหาค่าเป็นตัวแทนตำแหน่งเหล่านี้แทน ซึ่งคำนวณจากเครือข่ายคอนโวลูชันขนาดเล็ก (γ) ส่วน “warp” เป็นฟังก์ชันเลือกตำแหน่งเพื่อนบ้าน จากการใช้เคอร์เนลสุ่มตัวอย่างแบบเชิงเส้นคู่ (Bilinear sampling kernel) [14] คำนวณได้จากสมการ (14)

$$\begin{aligned}
\mathcal{M} &= \text{warp}(\mathcal{I}, \mathbf{U}, \mathbf{V}) \\
\mathcal{M}_{c,i,j} &= \sum_{m=1}^H \sum_{n=1}^W \mathcal{I}_{c,m,n} \max(0, 1 - |i + \mathbf{V}_{i,j} - m|) \max(0, 1 - |j + \mathbf{U}_{i,j} - n|)
\end{aligned} \tag{14}$$

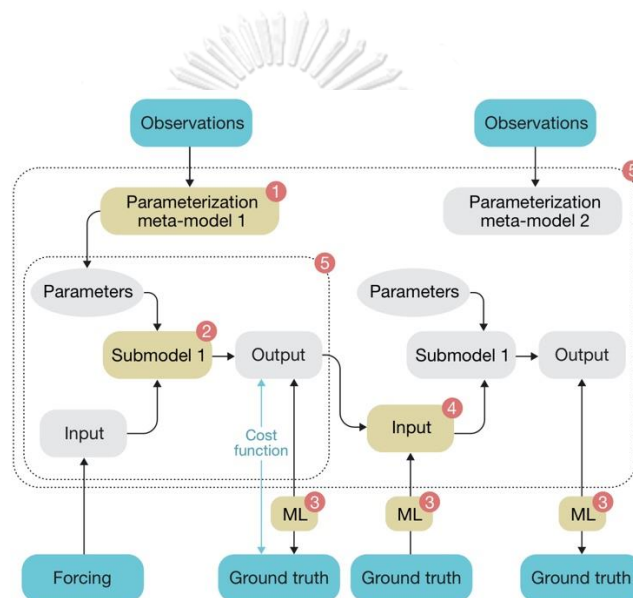
โดยที่ \mathcal{I} แทนค่าที่ตำแหน่งและช่องสัญญาณต่างๆ ในเทนเซอร์

จากที่กล่าวในบทที่ 3.1 ถึง 3.2 ในงานวิจัยนี้จะใช้วิธีการคงสภาพเดิมและวิธีเร็นนี่ไม่ซับซ้อนแบบ DenseRotation (หรือทางผู้เขียนใช้ชื่อย่อว่า “Rainymotion”) เป็นวิธีการมาตรฐาน (Baselines) ที่

ใช้หลักการทางวิทยาศาสตร์ และใช้ U-Net ConvLSTM และ TrajGRU เป็นวิธีการมาตรฐานที่ใช้วิธีการเรียนรู้เชิงลึก ในการเปรียบเทียบประสิทธิภาพในการทำนายปริมาณน้ำฝน

3.3 การผสมผสานความรู้ทางวิทยาศาสตร์เข้ากับการเรียนรู้ของเครื่อง (Integrated scientific-based knowledge with machine learning)

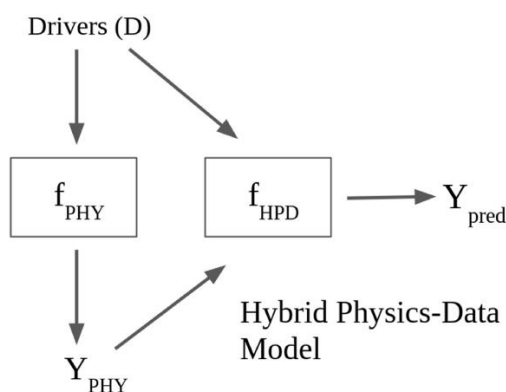
การผสมผสานวิธีการเชิงวิทยาศาสตร์เข้ากับการเรียนรู้ของเครื่องหรือการเรียนรู้เชิงลึกสามารถทำได้หลายวิธี [15] ดังแสดงในรูป 8 เช่น ใช้ฟิสิกส์ชั้นนำฟังก์ชันสูญเสีย ใช้ช่วยปรับค่าเริ่มต้นให้เครือข่ายประสาทเทียม หรือใช้เป็นแนวทางออกแบบโมเดลแบบผสมผสานหรือแบบไฮบริด (Hybrid model)



รูป 8 รูปแบบต่างๆ ในการผสมผสานวิธีการทางวิทยาศาสตร์กับโมเดลเชิงลึก [15]

1. **การกำหนดพารามิเตอร์** เนื่องจากวิธีการฟิสิกส์มักจำเป็นต้องกำหนดพารามิเตอร์จำนวนมากก่อนใช้งานซึ่งส่วนมากไม่สามารถคำนวณได้โดยตรง การใช้โมเดลของเครื่องหรือโมเดลเชิงลึกเรียนรู้ที่จะหาค่าพารามิเตอร์เหล่านี้จึงเป็นแนวทางหนึ่งที่จะช่วยลดความผิดพลาดได้
2. **การแทนที่ส่วนย่อยด้วยโมเดลของเครื่อง** วิธีการทางวิทยาศาสตร์มักเป็นโมเดลขนาดใหญ่ที่ประกอบด้วยค่าคำนวณหลายขั้นตอนย่อย การแทนที่ส่วนที่มีความแม่นยำต่ำหรือเป็นการคำนวณแบบกึ่งประจักษ์ (Semi-empirical) ด้วยโมเดลของเครื่องที่เหมาะสมย่อมส่งผลให้ประสิทธิภาพในแง่ความถูกต้องสูงขึ้น (อาจรวมถึงความเร็วด้วย) เช่น หากวิธีการทางวิทยาศาสตร์ประกอบด้วย 2 ขั้นตอน โดยขั้นตอนหนึ่งให้ผลลัพธ์ที่นำไปใช้ในขั้นตอนถัดไป การแทนที่โมเดลย่อยของวิธีการเชิงฟิสิกส์ด้วยโมเดลของเครื่องจะสามารถทำได้ดังแสดงใน

รูป 9 ซึ่งเป็นการแทนการคำนวณส่วนหลังด้วยโมเดลของเครื่อง แต่ในขณะเดียวกันก็สามารถแทนขั้นตอนส่วนแรกได้ด้วยเช่นกัน



รูป 9 แผนภาพโมเดลไฮบริดระหว่างฟิสิกส์และการเรียนรู้ของเครื่อง [3]

รูป 9 แสดงแผนภาพของโมเดลไฮบริดรูปแบบหนึ่ง โดย f_{PHY} คือโมเดลที่มีพื้นฐานบนหลักฟิสิกส์ทำหน้าที่แปลงข้อมูลป้อนเข้า (หรือ Driver) เป็นผลลัพธ์ Y_{PHY} ส่วน f_{HPD} คือโมเดลไฮบริดที่รับทั้งข้อมูลป้อนเข้าและผลลัพธ์จากการคำนวณจาก f_{PHY} เพื่อหาผลลัพธ์สุดท้าย Y_{pred}


3. **วิเคราะห์ผลลัพธ์ที่ผิดพลาด** ความผิดพลาดของผลจากวิธีการเชิงวิทยาศาสตร์มักเกิดจากความเข้าใจที่ไม่สมบูรณ์ การนำโมเดลของเครื่องมาวิเคราะห์ข้อผิดพลาดที่เกิดขึ้นอาจแสดงให้เห็นถึงรูปแบบที่มักผิดพลาดเพื่อจะได้นำไปปรับปรุงแก้ไขต่อ
4. **จำกัดความผิดพลาดของส่วนย่อย** การที่วิธีการทางวิทยาศาสตร์ประกอบด้วยหลายขั้นตอนส่งผลให้ความผิดพลาดที่เกิดจากส่วนหนึ่งส่งผลต่อส่วนที่เหลือ การนำโมเดลของเครื่องมาขับเคลื่อนผลลัพธ์จากส่วนหนึ่งก่อนจะป้อนเข้าอีกส่วนจะสามารถลดความผิดพลาดได้
5. **การใช้โมเดลของเครื่องทั้งหมด** เป็นการใช้โมเดลของเครื่องหรือโมเดลเชิงลึกทำงานแทนวิธีการทางวิทยาศาสตร์ทั้งหมด ซึ่งหากความซับซ้อนของโจทย์อยู่ในระดับที่โมเดลรองรับได้ จะมีโอกาสช่วยให้ประสิทธิภาพทั้งในเรื่องความถูกต้องและความเร็วสูงขึ้น

การผสมผสานแบบที่ 2 เป็นรูปแบบที่ได้รับความนิยมเนื่องจากการแทนที่โมเดลเชิงลึกแต่ยังรักษาเค้าโครงของวิธีการทางวิทยาศาสตร์ไว้ช่วยให้โมเดลได้ประโยชน์จากทั้ง 2 ศาสตร์ เพราะในขณะที่ส่วนที่เป็นวิธีการทางวิทยาศาสตร์มีทฤษฎีรองรับและตีความหมายได้ โมเดลเชิงลึกก็สามารถเรียนรู้และปรับตัวที่จะหาผลลัพธ์จากข้อมูลที่ซับซ้อน การผสมผสานเช่นนี้ประสบความสำเร็จทั้งในงานการทำนายอุณหภูมิน้ำทะเลของ de Bezenac et al. (2019) [16] และการทำนายอุณหภูมิในแม่น้ำในงานของ Karpatne et al. (2017) [17] จึงเป็นรูปแบบที่จะเลือกใช้ในงานวิจัยนี้

บทที่ 4

แนวคิดและวิธีการดำเนินงาน

ในบทนี้นำเสนอแนวคิดและวิธีการดำเนินงาน แบ่งออกเป็น 4 ส่วน ดังแสดงในรูป 10 ในส่วนแรก (1) เป็นการเตรียมชุดข้อมูลจำลองและชุดข้อมูลภาพถ่ายเรดาร์ (2) การประมวลผลข้อมูลก่อนนำไปฝึกสอน (Pre-processing) (3) การจัดทำและฝึกโมเดลผสมผสาน และ (4) การประมวลผลหลัง (Post-processing)



รูป 10 ภาพรวมของขั้นตอนที่งานวิจัยนี้นำเสนอ

4.1 การเตรียมข้อมูล

ในงานวิจัยนี้ได้ใช้ชุดข้อมูลทั้งหมด 3 ประเภท ได้แก่ ชุดข้อมูลจำลอง ชุดข้อมูลภาพถ่ายเรดาร์ และชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง


4.1.1 ชุดข้อมูลจำลอง

ชุดข้อมูลจำลองเป็นชุดข้อมูลขนาดเล็กที่ประกอบด้วยลำดับของภาพ 2 มิติต่อเนื่องกันและมีคุณสมบัติต่างๆ (Features) ลอกเลียนจากลำดับของภาพถ่ายเรดาร์ เช่น การเคลื่อนที่เชิงเส้น การเคลื่อนที่แบบหมุน การรบกวนบนภาพ (Noise) และการเปลี่ยนแปลงความเข้ม (Change in intensity) โดยชุดข้อมูลนี้สร้างขึ้นโดยมีจุดประสงค์เพื่อช่วยวิเคราะห์ความสามารถของโมเดลในการทำนายคุณสมบัติต่างๆ ก่อนนำไปทดสอบบนชุดข้อมูลภาพถ่ายเรดาร์

การสร้างชุดข้อมูลจำลองจะทำอย่างสุ่ม โดยจะต้องกำหนดการเคลื่อนที่อย่างน้อย 1 รูปแบบก่อน (อาจเป็นการเคลื่อนที่เชิงเส้นหรือการหมุน) เป็นคุณลักษณะหลัก แล้วจากนั้นจึงเลือกคุณสมบัติเพิ่มเติมอื่นๆ เช่น สามารถสร้างชุดข้อมูลที่ประกอบด้วยวัตถุเคลื่อนที่เชิงเส้นพร้อมกับเปลี่ยนแปลงความเข้มได้ ซึ่งในกรณีนี้จะมีลักษณะคล้ายกับการเคลื่อนที่ของฝนบนภาพถ่ายเรดาร์ นอกจากนี้ยังสามารถกำหนดจำนวนวัตถุที่ปรากฏในภาพได้ตามต้องการ

ในงานวิจัยนี้ได้กำหนดจำนวนวัตถุไว้ไม่เกิน 1 ชิ้นและสนใจการผสมผสานลักษณะที่สำคัญเท่านั้น ได้แก่ การเคลื่อนที่เชิงเส้น การหมุน และการเปลี่ยนแปลงความเข้ม ดังนั้นชุดข้อมูลจำลองที่ใช้ในงานวิจัยนี้จะมีทั้งหมด 4 แบบ ดังแสดงในรูป 11 ได้แก่ (ก) จุดที่เคลื่อนที่เชิงเส้น (ข) จุดที่

เคลื่อนที่เชิงเส้นพร้อมเปลี่ยนแปลงระดับความเข้ม (ค) วัตถุที่เคลื่อนที่เชิงเส้นและหมุน และ (ง) วัตถุที่เคลื่อนที่เชิงเส้นและหมุนพร้อมเปลี่ยนแปลงระดับความเข้ม



รูป 11 ตัวอย่างลำดับข้อมูลจากชุดข้อมูลจำลอง

สำหรับชุดข้อมูลประเภท (ก) เป็นการจำลองการเคลื่อนที่ของจุดในแนวเชิงเส้น โดยจุดมีรัศมีได้ตั้งแต่ 2 ถึง 5 (พิกเซล) มีความเร็วตั้งแต่ 2 ถึง 5 พิกเซลต่อขั้นเวลา และสามารถเคลื่อนที่ในทิศทางได้ตั้งแต่ 0° ถึง 360° ส่วนในชุดข้อมูลประเภท (ข) มีลักษณะเหมือนกับชุดข้อมูลประเภท (ก) แต่มีการเพิ่มลักษณะการเปลี่ยนแปลงความเข้ม (ความสว่าง) ของจุดที่เคลื่อนที่ โดยการเปลี่ยนแปลงความเข้มดังกล่าวเป็นไปตามสมการ (15) ซึ่งมีการกำหนดค่าพารามิเตอร์ตามตาราง 3

$$I(t) = I_0 \sin(\omega t + \theta) + I_b \quad (15)$$

โดยที่ I แทนค่าความเข้มของจุดหรือวัตถุ


ตาราง 3 การตั้งไฮเปอร์พารามิเตอร์สำหรับสมการ (15)

พารามิเตอร์	ค่าต่ำสุด	ค่าสูงสุด
I_0	0.7	1
ω	0.8	1.3
θ	$-\pi/2$	$\pi/2$
I_b	0	$1 - I_0$

สำหรับชุดข้อมูลประเภท (ค) เป็นการแสดงลักษณะการหมุนจึงจำเป็นต้องเปลี่ยนรูปร่างวัตถุ จากวงกลมทึบเป็นวัตถุที่มีลักษณะคล้ายพายไต้ฝุ่น เพื่อให้เห็นการเปลี่ยนแปลงของวัตถุเมื่อมีการหมุน โดยอัตราการหมุนสามารถเป็นไปได้ตั้งแต่ 7° ถึง 10° ต่อชั้นเวลา และสุดท้ายในชุดข้อมูลประเภท (ง) ได้มีการเพิ่มลักษณะการเปลี่ยนแปลงความเข้ม ซึ่งลักษณะของการเปลี่ยนแปลงดังกล่าวเหมือนกับที่ใช้ในชุดข้อมูล (ข)

4.1.2 ชุดข้อมูลภาพถ่ายเรดาร์

ชุดข้อมูลภาพถ่ายเรดาร์ที่ใช้ในวิทยานิพนธ์นี้มาจากสถานีเรดาร์ตรวจอากาศออปเปิลอร์ แบบ C-BAND รวมกันจากหลายๆ สถานีในญี่ปุ่น ข้อมูลที่ได้จึงเป็นภาพ 2 มิติขนาดใหญ่ โดยที่ค่าในแต่ละจุดแสดงถึงอัตราการตกของปริมาณน้ำฝนในบริเวณหนึ่งๆ และแต่ละสีแสดงถึงอัตราการตกของฝนที่ต่างกัน ดังแสดงในรูป 12



อัตราการตกของฝน (mm/hr.)

> 60	30 - 50	10 - 20	1 - 5	< 0.2
50 - 60	20 - 30	5 - 10	0.2 - 1	

รูป 12 ตัวอย่างภาพถ่ายเรดาร์จากชุดข้อมูล

ข้อมูลภาพถ่ายเรดาร์ที่ใช้มีคุณสมบัติเป็นภาพที่มีความละเอียดสูงมาก โดยที่ลำดับของภาพมีอันตรภาค 10 นาที และมีคุณสมบัติอื่นๆ ดังแสดงในตาราง 4

ตาราง 4 คุณสมบัติข้อมูลภาพถ่ายเรดาร์

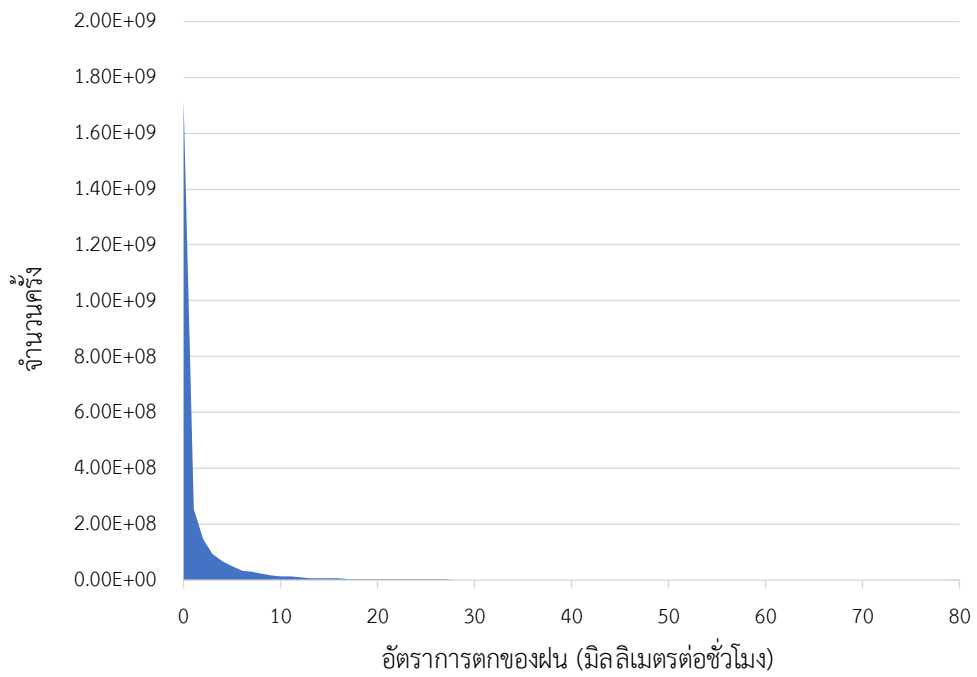
คุณสมบัติ	ค่า
ความละเอียด (พิกเซล)	3,360 × 2,560
พื้นที่ที่ครอบคลุม	1 ตารางกิโลเมตรต่อ 1 พิกเซล
ชนิดของเรดาร์	เรดาร์ตรวจอากาศดอปเปลอร์ แบบ C-BAND
ภูมิภาค	ญี่ปุ่น
พิกัดภูมิศาสตร์ (Geographic coordinates)	ละติจูด [20.005 ถึง 47.9958] ลองจิจูด [118.006 ถึง 149.994]
อัตราภาค (นาทีก)	10
รูปแบบไฟล์	ข้อมูลฐานสอง (Binary files)
ช่วงเวลา (ทั้งหมดที่มี)	1 มิถุนายน 2018 ถึง 31 พฤษภาคม 2019
ขนาดไฟล์	ประมาณเดือนละ 280 กิกะไบต์ (Gigabytes)

ในงานวิจัยนี้จะสนใจชุดข้อมูลเฉพาะในช่วง 1 กรกฎาคม ถึง 30 สิงหาคม 2018 โดยที่ข้อมูลในช่วงดังกล่าวมีส่วนการกระจายตัวอัตราการตกของฝนที่ระดับต่างๆ ดังแสดงในตาราง 5

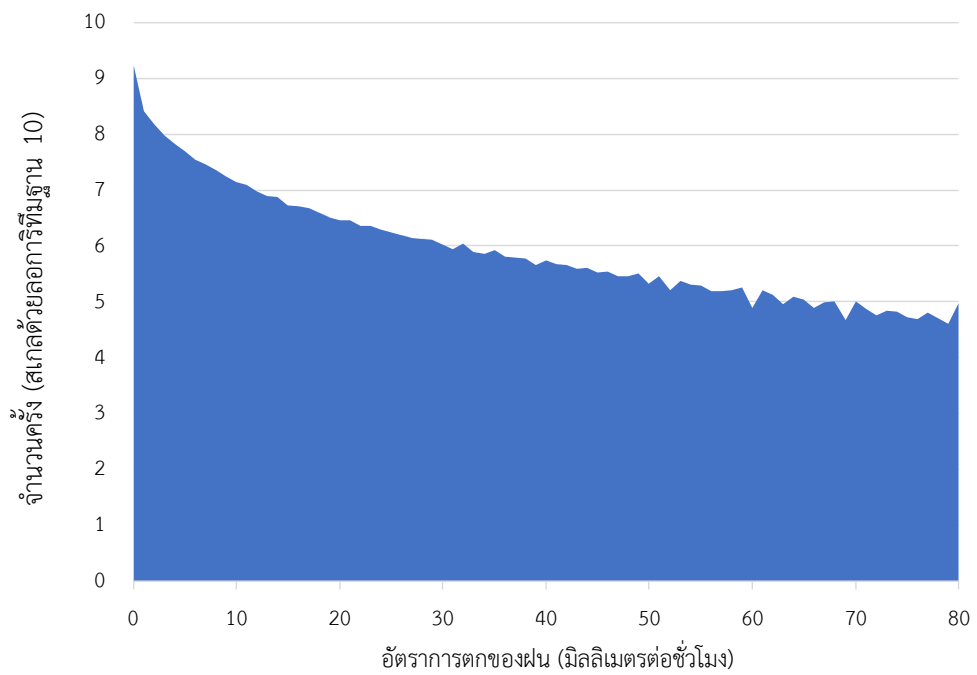
ตาราง 5 สถิติของระดับน้ำฝนในชุดข้อมูลภาพถ่ายเรดาร์

อัตราการตกของฝน (มิลลิเมตรต่อชั่วโมง)	สัดส่วน (ร้อยละ)	ปริมาณน้ำฝน
$0 \leq x < 1$	67.65%	ไม่มีฝน
$1 \leq x < 10$	28.11%	ฝนเล็กน้อย
$10 \leq x < 20$	2.88%	ฝนปานกลาง
$20 \leq x < 30$	0.77%	ฝนหนัก
$30 \leq x$	0.45%	ฝนตกหนักมาก

ค่าปริมาณน้ำฝนของชุดข้อมูลในช่วงที่กำหนดมีการกระจายตัวดังแสดงในรูป 13 ซึ่งเห็นได้ว่าข้อมูลมีการกระจายตัวที่ไม่สม่ำเสมอ เนื่องจากอัตราการตกที่ 0 มิลลิเมตรต่อชั่วโมงสูงมาก ในขณะที่ช่วงอื่นๆ มีค่าเข้าใกล้ศูนย์ ดังนั้นจึงมีการสเกลด้วยลอการิทึมเพื่อให้การกระจายตัวที่สม่ำเสมอมากขึ้น ดังแสดงในรูป 14



รูป 13 การกระจายตัวของอัตราการตกลของน้ำฝนในชุดข้อมูล



รูป 14 การกระจายตัวของอัตราการตกลของน้ำฝนเมื่อสเกลด้วยลอการิทึมฐานสิบ

ค่าจากข้อมูลดิบนั้นอยู่ในหน่วยมิลลิเมตรต่อชั่วโมง (R) ซึ่งมีการกระจายตัวที่ไม่เหมาะสมที่จะนำมาใช้ป้อนเข้าโมเดลโดยตรง จึงได้มีการเปลี่ยนเป็นหน่วยเดซิเบล (dBZ) ก่อนเพื่อให้ข้อมูลกระจายตัวอย่างสม่ำเสมอโดยใช้สมการ (16)

$$R = \left(\frac{10^{\frac{dBZ}{10}}}{200} \right)^{\frac{5}{8}} \quad (16)$$

4.1.3 ชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง

ชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรงเป็นชุดข้อมูลที่รวบรวมเหตุการณ์สภาพอากาศรุนแรงที่สำคัญในภูมิภาคญี่ปุ่นระหว่างปี 2018 ถึง 2019 ทั้งหมด 7 เหตุการณ์ดังแสดงในตาราง 6 เป็นข้อมูลสำหรับใช้ในการทดสอบวิธีการหรือโมเดลต่างๆ โดยมีคุณสมบัติเช่นเดียวกับชุดข้อมูลภาพถ่ายเรดาร์ (ในตาราง 4)

ตาราง 6 เหตุการณ์สภาพอากาศรุนแรงในชุดข้อมูล


ลำดับ	เหตุการณ์	วันที่ (วัน/เดือน/ปี)
1	พายุไต้ฝุ่นฟ้าใส (Typhoon Faxai)	08/09/2019
2	พายุไต้ฝุ่นฮาภิบิส (Typhoon Hagibis)	12/10/2019
3	พายุโซนร้อนนารี (Typhoon Nari)	26/07/2019
4	ฝนตกหนัก	25/10/2019
5	แนวพายุฝน (Squall line)	30/06/2019
6	พายุไต้ฝุ่นทรามิ (Typhoon Trami)	30/09/2018
7	พายุไต้ฝุ่นกรอซา (Typhoon Krosa)	15/08/2019

เนื่องจากเหตุการณ์ดังกล่าวเกิดขึ้นในส่วนตัวส่วนหนึ่งของภูมิภาคเท่านั้น ดังนั้นจึงไม่มีความจำเป็นต้องใช้ขนาดภาพเต็มและได้จำกัดบริเวณเฉพาะส่วนที่สนใจได้ โดยร้อยละของพื้นที่ที่พิจารณาต่อพื้นที่ทั้งหมดในเหตุการณ์สภาพอากาศรุนแรงต่างๆ แสดงในตาราง 7

ตาราง 7 สัดส่วนพื้นที่ที่สนใจต่อพื้นที่ทั้งหมดในเหตุการณ์สภาพอากาศรุนแรงต่างๆ


	ลำดับเหตุการณ์สภาพอากาศรุนแรง						
	1	2	3	4	5	6	7
ร้อยละของพื้นที่ที่สนใจ	5.09%	25.15%	11.07%	20.37%	10.07%	14.76%	21.80%

1. พายุไต้ฝุ่นฟ้าใส ในวันที่ 8 กันยายน 2019 พายุไต้ฝุ่นฟ้าใสพัดเข้าทางชายฝั่งตะวันออกของญี่ปุ่นด้วยความกดอากาศต่ำสุด 955 เฮกโตปาสคาลทำให้เกิดฝนตกหนักและลมแรงถึง 155 กม./ชม. นับเป็นพายุไต้ฝุ่นรุนแรงที่สุดลูกหนึ่งที่ถล่มกรุงโตเกียวในรอบทศวรรษ




รูป 15 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 1 เริ่มต้นที่เวลา 9:30

2. พายุไต้ฝุ่นฮาภิบิส ในวันที่ 12 ตุลาคม 2019 พายุไต้ฝุ่นฮาภิบิสเคลื่อนตัวขึ้นฝั่งตะวันออกของญี่ปุ่นที่ภูมิภาคโตไคโดด้วยความกดอากาศต่ำสุด 925 เฮกโตปาสคาล ทำให้เกิดฝนตกหนักและลมแรงถึง 195 กม./ชม.



รูป 16 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 2 เริ่มต้นที่เวลา 9:30

3. พายุโซนร้อนนารี ในวันที่ 26 สิงหาคม 2019 พายุโซนร้อนนารีเคลื่อนตัวในทะเลฟิลิปปินด้วยความกดอากาศ 998 เฮกโตปาสคาล และความเร็วลมสูงสุดถึง 65 กม./ชม.




รูป 17 ภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ 3 เริ่มต้นที่เวลา 9:30

4. ฝนตกหนัก วันที่ 25 ตุลาคม 2019 หลังเกิดพายุไต้ฝุ่นฮาภิบิสสองสัปดาห์ เกิดฝนตกหนักอย่างต่อเนื่องทางตะวันออกของโตเกียว


5. แนวพายุฝน วันที่ 30 มิถุนายน 2019 เกิดแถบแนวยาวขึ้นบริเวณทางใต้ของญี่ปุ่นและทะเลฟิลิปปิน

6. พายุไต้ฝุ่นทรามิ ในวันที่ 30 กันยายน 2018 พายุไต้ฝุ่นทรามิพัดขึ้นฝั่งบริเวณเกาะเรียวกูของญี่ปุ่นด้วยความกดอากาศต่ำสุด 925 เฮกโตปาสคาล และลมแรงถึง 195 กม./ชม.


7. พายุไต้ฝุ่นกรอซา ในวันที่ 15 สิงหาคม 2019 พายุไต้ฝุ่นกรอซาพัดขึ้นฝั่งที่ภูมิภาคชิโกะ-กุของญี่ปุ่นด้วยความกดอากาศต่ำสุด 965 เฮกโตปาสคาล ทำให้เกิดฝนตกหนักและลมกระโชกแรงถึง 140 กม./ชม.




(4) ฝนตกหนัก



(5) แนวพายุฝน



(6) พายุไต้ฝุ่นทรามิ



(7) พายุไต้ฝุ่นกรอซา

รูป 18 ตัวอย่างภาพถ่ายเรดาร์จากเหตุการณ์สภาพอากาศรุนแรงที่ (4) ถึง (7)


ข้อมูลเหตุการณ์สภาพอากาศรุนแรงต่างๆ มีสัดส่วนการกระจายตัวของอัตราการตกของฝนในพื้นที่ที่สนใจดังแสดงในตาราง 8

ตาราง 8 สถิติของระดับน้ำฝนในชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง

อัตราการตก ของฝน (มิลลิเมตรต่อ ชั่วโมง)	ลำดับเหตุการณ์สภาพอากาศรุนแรง						
	1	2	3	4	5	6	7
$0 \leq x < 1$	88.91%	85.05%	96.74%	91.11%	85.09%	80.18%	91.01%
$1 \leq x < 10$	8.50%	12.43%	2.73%	7.93%	12.64%	15.88%	7.70%
$10 \leq x < 20$	1.67%	1.66%	0.38%	0.70%	1.57%	2.75%	0.91%
$20 \leq x < 30$	0.55%	0.52%	0.10%	0.15%	0.43%	0.72%	0.24%
$30 \leq x$	0.30%	0.29%	0.05%	0.07%	0.21%	0.37%	0.12%

4.2 การประมวลผลก่อน (Pre-processing)

การประมวลผลก่อนที่ใช้กับชุดข้อมูลภาพถ่ายเรดาร์แบ่งออกเป็น 4 ขั้นตอนดังแสดงในรูป 19 เริ่มจาก (1) การจัดเรียงข้อมูลเป็นลำดับ (2) การลดขนาดภาพ (3) การทำนอร์มัลไลเซชัน และ (4) การตัดภาพออกเป็นส่วนๆ



รูป 19 ภาพรวมขั้นตอนการประมวลผลก่อน

- 1. การจัดลำดับภาพเป็นลำดับ (Image sequencing)** ในการประมวลผลก่อนขั้นแรกจะเป็นการจัดเรียงภาพเป็นลำดับ พร้อมตรวจสอบว่าไม่มีภาพในชั้นเวลาใดขาดไป ซึ่งจะทำให้ลำดับของภาพขาดความต่อเนื่อง
- 2. การลดขนาดภาพ (Image downsampling)** แปลงภาพเป็นเทนเซอร์แล้วลดขนาด เนื่องจากภาพถ่ายเรดาร์เป็นภาพถ่ายความละเอียดสูงซึ่งมีขนาดใหญ่เกินกว่าที่จะบรรจุในหน่วยความจำจึงต้องลดขนาดจาก $3,360 \times 2,560$ พิกเซลเป็น 840×640 พิกเซล (ลดลง 4 เท่า) โดยประมาณค่า (Interpolate) แบบเชิงเส้นคู่ (Bilinear)

3. การทำนอร์มัลไลเซชัน (Normalization) ทำการเปลี่ยนหน่วยข้อมูลจากมิลลิเมตรต่อชั่วโมงเป็น dBZ โดยใช้สมการ (16) ตามด้วยการทำนอร์มัลไลเซชันด้วยการปรับค่าจากช่วง [min, max] ให้อยู่ในช่วง 0 ถึง 1 โดยนำภาพแต่ละจุดลบด้วยค่า min แล้วหารด้วยค่า max - min (หรือ range) ดังแสดงในสมการ (17)

$$x_{normalized} = \frac{(x - x_{minimum})}{(x_{maximum} - x_{minimum})} \quad (17)$$

4. การตัดภาพเป็นส่วนๆ (Cropping) ในขั้นตอนสุดท้ายเป็นการตัดภาพออกเป็นส่วนย่อยๆ ดังแสดงในรูป 20 โดยให้แต่ละส่วนย่อยมีขนาด 80 × 80 พิกเซล



รูป 20 ส่วนภูมิภาคย่อยต่างๆ จากภาพถ่ายเรดาร์เต็ม⁴

4.3 การผสมผสานความรู้เชิงวิทยาศาสตร์เข้ากับโมเดลเชิงลึก


การพัฒนาอย่างก้าวกระโดดในศาสตร์ของการเรียนรู้ของเครื่องและโมเดลเชิงลึก ส่งผลให้หลายๆ โจทย์ที่ก่อนหน้านี้ต้องใช้อัลกอริทึมที่ซับซ้อน ไม่ว่าจะเป็นการแปลงเสียงเป็นข้อความหรือการตรวจจับวัตถุในภาพ สามารถแก้ไขได้โดยการใช้โมเดลการเรียนรู้ของเครื่อง อย่างไรก็ตาม

⁴ ภาพพื้นหลังจาก maps.stamen.com/terrain

ความสามารถของโมเดลนั้นขึ้นอยู่กับปริมาณข้อมูลที่มีและความซับซ้อนของโจทย์ โจทย์การทำงาน ปริมาณน้ำฝนนั้นนับว่าเป็นโจทย์ที่มีความซับซ้อน เพราะนอกจากลักษณะของโจทย์ที่เป็นการทำงาน ในระนาบสองมิติที่เป็นลำดับเวลาแล้ว ยังมีปรากฏการณ์และปัจจัยที่ซับซ้อนมากมายอยู่เบื้องหลังแต่ ไม่ได้ปรากฏในตัวข้อมูลโดยตรง เช่น การเคลื่อนตัวในแนวตั้ง (Advection) สภาพทางอุตุนิยมวิทยา อื่นๆ (เช่น อุณหภูมิและลม) และลักษณะทางภูมิศาสตร์ ซึ่งความซับซ้อนทั้งหมดเหล่านี้ต่างจำกัด ความสามารถของโมเดล

ในขณะที่เดียวกันวิธีการทางวิทยาศาสตร์อย่างการคงสภาพแบบลงกรองจึงเป็นวิธีที่มีโครงสร้าง ชัดเจนแบ่งเป็น 2 ขั้นตอน ได้แก่ การติดตามและการประมาณค่านอกช่วง ในขั้นตอนการติดตามนั้น มักใช้อัลกอริทึมการไหลของแสงในการคำนวณ ไม่ว่าจะเป็วิธีของฮอร์นสชังก์ (Horn-Schunk) [18] หรือฟาร์นแบค (Farneback) [19] อย่างไรก็ตามแต่ละอัลกอริทึมเหล่านี้ต่างมีจุดอ่อนและที่สำคัญนั้น ไม่ได้ถูกพัฒนาเพื่อมาใช้กับงานการทำงานปริมาณน้ำฝนโดยตรง ดังนั้นการใช้โมเดลเชิงลึกที่สามารถ เข้าใจและเรียนรู้ที่จะหาสนามการเคลื่อนไหวสำหรับใช้กับข้อมูลภาพถ่ายเรดาร์โดยตรงจึงเป็น ทางเลือกที่อาจช่วยเพิ่มประสิทธิภาพวิธีการโดยรวมได้


การผสมผสานโมเดลจากต่างสาขาวิชาสามารถดำเนินได้หลายวิธี (ดังที่กล่าวในบทที่ 3) สำหรับวิธีการที่ประกอบด้วยหลายขั้นตอนและผลลัพธ์จากขั้นตอนหนึ่งนำไปป้อนในส่วนถัดๆ ไปดัง แสดงในรูป 21 สามารถทำการผสมผสานได้โดยนำโมเดลเชิงลึกแทนที่ส่วนที่ยังทำหน้าที่ได้ไม่ดีหรือมี ประสิทธิภาพต่ำ เพื่อให้โมเดลเพิ่มประสิทธิภาพของส่วนนั้นๆ การจัดการปัญหาในลักษณะนี้อาจ เรียกว่าการแบ่งแยกและเอาชนะ (Divide & conquer)



รูป 21 การแบ่งโจทย์ที่ซับซ้อนออกเป็นหลายโจทย์ย่อย


สำหรับวิธีการคงสภาพแบบลงกรองที่มีการคำนวณ 2 ขั้นตอนดังแสดงในรูป 22 เริ่มจาก (1) คำนวณสนามการเคลื่อนที่จากภาพเรดาร์ก่อนหน้า แล้ว (2) ทำนายผลจากการประมาณค่านอก ช่วง ในที่นี้ได้ทำการผสมผสานโดยแทนที่วิธีการในส่วนที่ (1) โดยเปลี่ยนจากการใช้วิธีคำนวณการไหล

ของแสงเป็นการใช้โมเดลเชิงลึกแทนด้วยเหตุผลที่กล่าวไว้ข้างต้น ในขณะที่ส่วนที่ (2) คงเป็นวิธีการทางวิทยาศาสตร์ไว้ เพื่อช่วยขึ้นำการเรียนรู้ของโมเดลเชิงลึก



รูป 22 ภาพรวมขั้นตอนการทำงานของวิธีที่นำเสนอ

1. การคำนวณสนามการเคลื่อนไหว การคำนวณสนามการเคลื่อนไหวเป็นจุดอ่อนหนึ่งของวิธีการทางวิทยาศาสตร์ที่ยังให้ประสิทธิภาพไม่ดึนึก แต่หลายงานวิจัยแสดงให้เห็นว่าการใช้เครือข่ายประเภทคอนโวลูชันสามารถให้ประสิทธิภาพดีกว่า [20, 21] ดังนั้นการใช้โมเดลเชิงลึกเข้ามาทำงานแทนในจุดนี้จึงเป็นตัวเลือกที่เหมาะสม โดยในที่นี้ได้เลือกใช้เครือข่าย U-Net เนื่องจากโมเดลมีโครงสร้างที่เหมาะสมสำหรับรับป้อนข้อมูลที่เป็นอนุกรมเวลาของภาพเพื่อเปลี่ยนเป็นภาพที่มีหลายช่องสัญญาณ (แต่ละช่องสัญญาณแสดงการเคลื่อนไหวทีละแฉก) นอกจากนี้เป็นโมเดลที่มีโครงสร้างไม่ซับซ้อนเกินไปช่วยให้การคำนวณรวดเร็ว



ภาพที่ 1 ภาพที่ 2 สนามการเคลื่อนไหว

รูป 23 ตัวอย่างสนามการเคลื่อนไหวจากลำดับของภาพ

2. การประมาณค่านอกช่วง ในขั้นตอนการประมาณค่านอกช่วงเป็นการนำภาพถ่ายเรดาร์ในช่วงเวลาสุดท้ายที่ป้อนเข้าโมเดลมาประมาณค่านอกช่วงเพื่อเคลื่อนย้ายความเข้มของแต่ละพิกเซลจากตำแหน่งเดิมไปยังตำแหน่งใหม่ ในที่นี้ได้เลือกใช้เทคนิคการบิดเบือน (Warping scheme) [14] ซึ่งเป็นวิธีการทางวิทยาศาสตร์

เทคนิคการบิดเบือนมีพื้นฐานมาจากหลักการทางวิทยาศาสตร์ที่อธิบายกระบวนการทางฟิสิกส์ทั่วไป เช่น พลศาสตร์ของไหล การนำความร้อน การไหลของลม และอื่นๆ ซึ่งปรากฏการณ์

เหล่านี้อธิบายได้ด้วยหลักการ 2 ประการ ได้แก่ การพา (Advection) และการแพร่ (Diffusion) การพาเป็นการเคลื่อนที่ของของไหลหรือปริมาณ I ใดๆ (เช่น อุณหภูมิหรือปริมาณน้ำฝน) จากบริเวณหนึ่งไปอีกบริเวณหนึ่งอย่างเป็นกลุ่มก้อน ส่วนการแพร่เป็นการเคลื่อนที่เชิงสุ่มของ I จากบริเวณที่มีความเข้มข้นสูงไปยังบริเวณที่มีความเข้มข้นต่ำซึ่งเกิดขึ้นในระดับย่อย สมการ (18) อธิบายการขนส่ง I ที่มีทั้งการพาและการแพร่

$$\frac{\partial I}{\partial t} + (w \cdot \nabla)I = D\nabla^2 I \quad (18)$$

โดยที่	I	แทนค่าปริมาณที่สนใจ
	w	แทนเวกเตอร์ของการเคลื่อนที่
	D	แทนสัมประสิทธิ์การแพร่
	t	แทนค่าลำดับเวลา

เมื่อแก้สมการ (18) เพื่อหา I จะได้ตั้งสมการ (19)


$$I(x, t) = \int_{R^2} k(x - w, y) I_0(y) dy \quad (19)$$

โดยที่	x	แทนตำแหน่งที่สนใจ
	y	แทนตำแหน่งรอบข้าง x
	I_0	แทนค่าที่เวลาเริ่มต้น

ในที่นี้ k เป็นเคอร์เนลฟังก์ชันฐานแนวรัศมี (Radial function kernel) หรือการแจกแจงปกติแบบเกาส์เซียนในระนาบ 2 มิติ (Gaussian probability density) ซึ่งคำนวณได้จากสมการ (20)

$$k(u, v) = \frac{1}{4\pi Dt} e^{-\frac{1}{4Dt}\|u-v\|^2} \quad (20)$$

ในการใช้งานเทคนิคการบิดเบือนโดยเบี่ยงตันจะเป็นไปตามรูป 24 เช่น หากต้องการคำนวณค่าพิกเซลที่ตำแหน่ง x ณ เวลา $t + 1$ จะต้องหาตำแหน่งนี้ในเวลา t ก่อน จากการใช้สนามการเคลื่อนไหว ซึ่งจะได้ตำแหน่งก่อนหน้าอยู่ที่ $x - w$ จากนั้นใช้การแจกแจงแบบเกาส์เซียน (Gaussian distribution) ให้น้ำหนักของความเข้มของพิกเซลที่อยู่ใกล้เคียงกับ $x - w$ โดยตำแหน่งที่อยู่ใกล้จะให้ น้ำหนักมากและตำแหน่งที่อยู่ห่างออกไปจะให้น้ำหนักน้อย เมื่อทำการหาเฉลี่ยของค่าเหล่านี้แล้วจะได้เป็นค่าความเข้มของพิกเซลที่ตำแหน่ง x ในเวลา $t + 1$




รูป 24 การใช้งานเทคนิคการบิดเบือน [16]

ในการเขียนโค้ดได้ใช้ส่วนเทคนิคการบิดเบือนจากงานของ de Bezenac et al. (2019) [16] ซึ่งเขียนด้วยไพทอนจึงเป็นส่วนที่สามารถหาอนุพันธ์ย้อนกลับได้ ดังนั้นเมื่อนำส่วนนี้ประกอบกับส่วนการคำนวณสนามการเคลื่อนไหวที่ใช้ U-Net และเขียนด้วยไพทอนเช่นกันจะทำให้พารามิเตอร์ในเครือข่าย U-Net สามารถเรียนรู้จากการเทียบผลลัพธ์สุดท้ายกับผลเฉลยเมื่อฝึกสอนโมเดลได้ ซึ่งจะช่วยให้ U-Net สามารถเรียนรู้ที่คำนวณหาสนามการเคลื่อนไหวที่เหมาะสมกับข้อมูล


4.4 การประมวลผลหลัง (Post-processing)

การประมวลผลหลังเป็นกระบวนการที่ดำเนินหลังจากข้อมูลเข้าโมเดลแล้ว โดยแบ่งเป็น 4 ขั้นตอน ดังแสดงในรูป 25 เริ่มจาก (1) การป้อนวนกลับ (2) การรวมภาพจากส่วนย่อย (3) การทำดีนอร์มัลไลเซชัน และ (4) การขยายขนาดภาพ



รูป 25 ภาพรวมขั้นตอนการประมวลผลหลัง

- 1. การป้อนวนกลับ (Input rolling)** การป้อนวนกลับเป็นการนำผลการทำนายกลับมาป้อนเป็นข้อมูลป้อนเข้าอีกครั้งดังแสดงในรูป 26 เพื่อให้โมเดลทำนายต่อเรื่อยๆ จนกระทั่งได้ผลลัพธ์ถึงจำนวนขั้นเวลาที่ต้องการ



รูป 26 วิธีการป้อนวนกลับ

2. การรวมภาพจากส่วนย่อย เป็นการนำผลการทำนายจากส่วนย่อยที่ตัดมา (ดังแสดงในรูป 20) ต่อกันเป็นภาพเดี่ยวที่ครอบคลุมทั้งภูมิภาค

3. การทำคืนอร์มัลไลเซชัน (Denormalization) ในขั้นตอนถัดมาเป็นการเปลี่ยนหน่วยจาก dBZ เป็นมิลลิเมตรต่อชั่วโมงแล้วทำคืนอร์มัลไลเซชันโดยใช้สมการ (21)

$$x = x_{normalized} \cdot (x_{maximum} - x_{minimum}) + x_{minimum} \quad (21)$$

4. การขยายขนาดภาพ (Image upsampling) ในขั้นตอนสุดท้ายเป็นการขยายภาพกลับเป็นขนาดเดิมที่ $3,360 \times 2,560$ พิกเซล เพื่อประเมินผลลัพธ์

4.5 การสอน (Training)

การสอนโมเดลเป็นขั้นตอนสำคัญในการเรียนรู้เชิงลึก มีจุดมุ่งหมายเพื่อสอนให้เครือข่ายเรียนรู้พารามิเตอร์ที่เหมาะสมเพื่อให้สามารถให้ผลลัพธ์ที่ดีที่สุดเมื่อได้รับป้อนข้อมูลใดๆ โดยการสอนโมเดลด้วยชุดข้อมูลจำลองและชุดข้อมูลภาพถ่ายเรดาร์จะต่างกันออกไปเล็กน้อย เนื่องจากชุดข้อมูลจำลองได้สร้างขึ้นมาให้มีความพร้อมกับการใช้งานจึงไม่ต้องใช้ขั้นตอนการประมวลผลก่อนและหลังอย่างที่ต้งใช้ในชุดข้อมูลภาพถ่ายเรดาร์ ในการฝึกโมเดลได้ตั้งค่าไฮเปอร์พารามิเตอร์ต่างๆ ดังแสดงในตาราง 9

ตาราง 9 การตั้งไฮเปอร์พารามิเตอร์เมื่อทดลองบนชุดข้อมูลต่างๆ

พารามิเตอร์	ชุดข้อมูลภาพถ่ายเรดาร์	ชุดข้อมูลจำลอง
ขนาดรุ่นของการผลิต (Batch Size)	32	32
จำนวนอีพอค (Epoch)	7	10
ตัวเพิ่มประสิทธิภาพ (Optimizer)	อัดัม (Adam) [22]	อัดัม
อัตราการเรียนรู้ (Learning rate)	0.001	0.001
ค่าความอดทนของจุดหยุด (Early stopping patience)	7	7

ผลลัพธ์จากโมเดลจะถูกนำไปเปรียบเทียบกับลำดับภาพผลเฉลยผ่านการคำนวณค่าสูญเสีย (Loss) แบบค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error หรือ “MSE”) ดังสมการ (22) เพื่อนำมาแพร่กระจายย้อนกลับไป (Backpropagate) และปรับพารามิเตอร์ในโมเดล

$$\text{MSE} = \frac{1}{N \times H \times W} \sum_{n=1}^N \sum_{i=1}^H \sum_{j=1}^W (x_{n,i,j} - \hat{x}_{n,i,j})^2 \quad (22)$$

สำหรับการฝึกบนชุดข้อมูลภาพถ่ายเรดาร์จะมีการทดลองเปลี่ยนค่าความสูญเสียจาก MSE เป็น MSE แบบมีการให้น้ำหนัก (Weighted Mean Squared Error หรือ “W-MSE”) เพื่อเพิ่มความสามารถของโมเดลในการทำนายฝนตกหนัก โดย W-MSE คำนวณดังสมการ (23)

$$\text{W-MSE} = \frac{1}{N \times H \times W} \sum_{n=1}^N \sum_{i=1}^H \sum_{j=1}^W w_{n,i,j} (x_{n,i,j} - \hat{x}_{n,i,j})^2 \quad (23)$$

โดย w เป็นพจน์ให้น้ำหนักค่าความผิดพลาด (Error) ซึ่งมีค่าขึ้นอยู่กับค่าปริมาณน้ำฝนในภาพผลเฉลย (ในหน่วยมิลลิเมตรต่อชั่วโมง) ณ ตำแหน่งและชั้นเวลาใดๆ ดังนี้

$$w(x) = \begin{cases} 1, & x < 1 \\ 3, & 1 \leq x < 10 \\ 5, & 10 \leq x < 30 \\ 10, & x \geq 30 \end{cases}$$

4.6 การทดสอบ (Testing)

ในการทดสอบประสิทธิภาพจะนำโมเดลที่ให้ค่าความสูญเสียน้อยที่สุดจากการประเมินบนชุดข้อมูลตรวจสอบ (Validation) มาทดสอบบนชุดข้อมูลทดสอบที่เตรียมไว้

สำหรับโมเดลที่ฝึกสอนโดยชุดข้อมูลภาพถ่ายเรดาร์ การทดสอบจะดำเนินบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง เนื่องจากเป็นชุดข้อมูลลำดับภาพถ่ายเรดาร์ที่มีความหลากหลาย ซึ่งจะช่วยให้สามารถประเมินผลการทำงานของโมเดลได้ในหลายแง่

บทที่ 5

การทดลองและผลการทดลอง

ในบทนี้จะกล่าวถึงรายละเอียดของการทดลองและผลการทดลอง ประกอบด้วย การแบ่งชุดข้อมูลและการกำหนดจำนวนชั้นเวลาที่ใช้ในชุดข้อมูลต่างๆ และผลการทดลองบนชุดข้อมูลจำลองและภาพถ่ายเรดาร์ที่เป็นเหตุการณ์สภาพอากาศรุนแรง

5.1 การแบ่งชุดข้อมูลและกำหนดชั้นเวลา

ในการทดลองบนชุดข้อมูลต่างๆ ได้ทำการแบ่งข้อมูลเป็นส่วนฝึกสอน ตรวจสอบ และทดสอบด้วยปริมาณดังที่แสดงในตาราง 10 โดยข้อมูลแต่ละประเภทมีจำนวนชั้นเวลาที่ป้อนเข้าและเป็นผลลัพธ์ดังแสดงในตาราง 11

ตาราง 10 จำนวนข้อมูลในชุดข้อมูลฝึกสอน ชุดข้อมูลตรวจสอบ และชุดข้อมูลทดสอบ

ชุดข้อมูล	ชุดข้อมูลฝึกสอน	ชุดข้อมูลตรวจสอบ	ชุดข้อมูลทดสอบ
ข้อมูลจำลอง	43,000	440	440
ข้อมูลภาพถ่ายเรดาร์	7,024	900	147*

* การทดสอบโมเดลหรือวิธีการต่างๆ ในการทำนายภาพถ่ายเรดาร์จะดำเนินบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ตาราง 11 จำนวนชั้นเวลาที่ใช้สำหรับชุดข้อมูลต่างๆ

ชุดข้อมูล	ชุดข้อมูลฝึกสอนและตรวจสอบ		ชุดข้อมูลทดสอบ	
	ชั้นเวลาป้อนเข้า	ชั้นเวลาผลลัพธ์	ชั้นเวลาป้อนเข้า	ชั้นเวลาผลลัพธ์
ข้อมูลจำลอง	3	3	3	9
ข้อมูลภาพถ่ายเรดาร์	3	3	3	18

5.2 ผลการทดสอบบนชุดข้อมูลจำลอง

การทดสอบโมเดลบนชุดข้อมูลจำลองจะดำเนินบนชุดข้อมูลจำลองทั้ง 4 ประเภท (ดังที่ได้กล่าวในบทที่ 4.1.1) ได้แก่ (ก) วัตถุเคลื่อนที่ (ข) วัตถุเคลื่อนที่และเปลี่ยนแปลงระดับความเข้ม

(ค) วัตถุเคลื่อนที่และหมุน (ง) วัตถุเคลื่อนที่และหมุนพร้อมเปลี่ยนแปลงระดับความเข้ม เพื่อประเมินและวิเคราะห์ความสามารถของโมเดลในการทำนายคุณสมบัติต่างๆ


ในการทดลองได้ทำการฝึกแล้วทดสอบวิธีการแบบผสมผสาน (วิธีการที่นำเสนอ) บนชุดข้อมูลข้างต้น เพื่อวิเคราะห์ความสามารถของโมเดลในการทำนายคุณสมบัติต่างๆ ที่เกิดขึ้นได้ในลำดับของภาพถ่ายเรดาร์ แล้วเปรียบเทียบผลการทำนายกับ U-Net ซึ่งเป็นโมเดลการเรียนรู้เชิงลึกและ Rainymotion ซึ่งเป็นวิธีการที่ใช้หลักการทางวิทยาศาสตร์ จากการทดลองได้ผลการทดสอบดังแสดงในตาราง 12

ตาราง 12 ประสิทธิภาพการทำนายของวิธีการต่างๆ ทดสอบบนชุดข้อมูลจำลอง

วิธีการหรือโมเดล	ค่า RMSE			
	(ก)	(ข)	(ค)	(ง)
U-Net	0.0581	0.0401	0.1018	0.0852
Rainymotion	<u>0.0519</u>	<u>0.0381</u>	0.1385	0.1237
วิธีการผสมผสาน	0.0514	0.0306	<u>0.1024</u>	<u>0.1054</u>


* ในตารางแสดง **ตัวหนา** สำหรับค่า RMSE ที่ต่ำที่สุด (หรือดีที่สุด) และ ตัวขีดเส้นใต้ สำหรับค่าที่ดีรองลงมาสำหรับข้อมูลแต่ละประเภท

ในรูป 27 แสดงตัวอย่างผลการทำนายจากชุดทดสอบบนชุดข้อมูลจำลองประเภท (ก) ในลำดับภาพผลเฉยนั้นแสดงวัตถุลักษณะวงกลมที่ขนาดเล็กละเอียดที่ด้วยความเร็วคงที่ในทิศทางล่างเฉียงซ้าย วิธีการทั้ง 3 นั้นสามารถทำนายตำแหน่งของวัตถุได้ใกล้เคียงกับผลเฉย แต่ U-Net ทำนายความเข้มของวัตถุพลาดจากความเป็นจริงไปเล็กน้อย (เห็นได้ในเวลา $t = 5$ ถึง 6) วิธีการ Rainymotion ทำนายรูปร่างวัตถุบิดเบี้ยวไปค่อนข้างมาก ส่วนวิธีการผสมผสานทำนายรูปร่างบิดเบี้ยวไปเล็กน้อยแต่ก็สามารถรักษาความเข้มของวัตถุไว้ได้คงที่ ดังนั้นจากกรณีนี้แสดงว่าวิธีการผสมผสานสามารถทำนายการเคลื่อนที่ของวัตถุเชิงเส้นพร้อมรักษาความเข้มและรูปร่างได้ดี



รูป 27 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ก)


เมื่อพิจารณาสนามการเคลื่อนไหวที่คำนวณจากส่วนแรกของวิธีการผสมผสาน ในรูป 28 (ก) แสดงสนามการเคลื่อนไหวในแนวแกน x ซึ่งบริเวณที่วัตถุอยู่มีค่าเป็นบวกสูงเนื่องจากวัตถุกำลังเคลื่อนที่ไปในทิศทาง $+x$ (ด้านซ้าย) ด้วยความเร็วสูง ส่วนในรูป 28 (ข) แสดงสนามการเคลื่อนไหวในแนวแกน y เช่นเดียวกับในแกน x จะเห็นได้ว่าบริเวณที่วัตถุอยู่มีค่าเป็นบวกเช่นกันแต่จะมีค่าน้อยกว่าเนื่องจากวัตถุกำลังเคลื่อนที่ในทิศ $+y$ (ลงล่าง) ด้วยความเร็วต่ำ ดังนั้นการเคลื่อนที่สุทธิของวัตถุจึงเป็นการลงล่างเฉียงซ้ายสอดคล้องกับผลการทำนาย



รูป 28 สนามการเคลื่อนไหวจากวิธีการผสมผสานในลำดับขั้นเวลาที่ $t = 6$


ในรูป 29 แสดงตัวอย่างผลการทำนายจากชุดทดสอบของชุดข้อมูลจำลองประเภท (ข) ในลำดับภาพผลเฉลยนั้นแสดงจุดที่ขนาดเล็กเคลื่อนที่ด้วยความเร็วคงที่ลงในทิศใต้เฉียงซ้ายพร้อมกับเปลี่ยนแปลงความสว่างจากมืดไปสว่างแล้วกลับมามืดอีกครั้ง โดยลำดับขั้นที่เริ่มทำนายนั้นมีความสว่างสูงสุด พบว่าโมเดล U-Net และวิธีการผสมผสานสามารถทำนายการลดลงของความสว่างได้ ส่วนวิธีการ Rainymotion นั้นไม่สามารถทำนายการลดลงของความสว่างได้ จากกรณีนี้แสดงให้เห็น

ว่าแม้วิธีการผสมผสานจะไม่ได้มีขั้นตอนจัดการการเปลี่ยนแปลงความเข้มของภาพโดยตรงแต่ก็ยังสามารถทำนายความเข้มที่ลดลงได้




รูป 29 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ข)

ถัดมาในรูป 30 แสดงตัวอย่างผลการทำนายจากชุดทดสอบของชุดข้อมูลจำลองประเภท (ค) ในลำดับภาพผลเฉยนั้นแสดงวัตถุลักษณะคล้ายพายุเคลื่อนที่ในทิศลงเฉียงซ้ายพร้อมกับมีการหมุน วิธีการทั้ง 3 สามารถทำนายการเคลื่อนที่และการหมุนได้ แต่จะเห็นได้ว่าโมเดล U-Net ให้ผลที่ค่อนข้างคมชัด ในขณะที่ Rainymotion ทำนายรูปร่างที่บิดเบี้ยวไปมากในลำดับขั้นเวลาหลังๆ ส่วนวิธีการผสมผสานให้ผลลัพธ์ที่ค่อนข้างเบลอร์ ในกรณีนี้แสดงให้เห็นว่าวิธีการผสมผสานสามารถทำนายการเคลื่อนที่เชิงเส้นพร้อมกับการหมุนได้ อย่างไรก็ตามด้วยรูปร่างของวัตถุที่ซับซ้อนและขนาดเล็กจึงส่งผลให้ผลลัพธ์เบลอร์จากขั้นตอนการทำบิดเบือน




รูป 30 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ค)

เมื่อนำสนามการเคลื่อนไหวจากวิธีการผสมผสานมาพิจารณา จะเห็นว่าสนามการเคลื่อนไหวในรูป 31 สอดคล้องกับทิศทางการเคลื่อนของวัตถุและการหมุนในทิศทางตามเข็มนาฬิกาดังในรูป 30




รูป 31 สนามการเคลื่อนไหวจากวิธีการผสมผสานในลำดับชั้นเวลาที่ $t = 6$

สุดท้ายในรูป 32 แสดงผลการทำนายจากชุดทดสอบของชุดข้อมูลจำลองประเภท (ง) ในลำดับภาพผลเฉลยนั้นแสดงวัตถุคล้ายพายุก่อตัวขึ้นในทิศกลางเฉียงซ้ายพร้อมหมุนและเปลี่ยนแปลงความสว่างจากมืดไปสว่างแล้วกลับมามืดอีกครั้ง ซึ่งลำดับชั้นเวลาการทำนายเริ่มจากขณะที่ความสว่างสูงสุด วิธีการทั้ง 3 สามารถทำนายการเคลื่อนที่และการหมุนได้ในลักษณะเดียวกับในชุดข้อมูล (ค) โมเดล U-Net และวิธีการผสมผสานสามารถทำนายการลดลงของความเข้มได้ ในขณะที่ Rainymotion ไม่สามารถทำนายการลดลงของความสว่างได้ ดังนั้นจากกรณีนี้แสดงว่าวิธีการผสมผสานสามารถทำนายวัตถุที่มีการทั้งเชิงเส้นและการหมุนพร้อมกับการเปลี่ยนแปลงความเข้มแบบลดลงได้



รูป 32 ตัวอย่างการผลทำนายของวิธีการต่างๆ บนชุดข้อมูลจำลองประเภท (ง)

หากพิจารณาค่าความสูญเสียในแต่ละลำดับเวลาจากการทำนายบนชุดข้อมูลจำลองทั้ง 4 ประเภท พบว่าทุกๆ โมเดลที่ทดลองให้ค่า RMSE ที่สูงขึ้นในแต่ละลำดับเวลาดังแสดงในรูป 33 (ในบางกรณีค่า RMSE ลดลงเมื่อลำดับขั้นเวลาท้ายๆ เนื่องจากวัตถุได้เคลื่อนออกไปนอกกรอบแล้ว)



รูป 33 ค่าความสูญเสียโดยเฉลี่ยในแต่ละขั้นเวลาเมื่อทดสอบบนชุดข้อมูลจำลอง

จากการทดลองบนชุดข้อมูลจำลองทั้ง 4 รูปแบบ พบว่าวิธีการที่นำเสนอให้ผลที่มีประสิทธิภาพดีในการทำนายคุณสมบัติสำคัญที่เกิดขึ้นได้ในลำดับของภาพถ่ายเรดาร์ตั้งแต่การเคลื่อนที่ในเชิงเส้น การเคลื่อนตัวแบบหมุน จนไปถึงการเปลี่ยนแปลงความเข้ม (แบบลดลง) และวิธีการนี้ยังให้ประสิทธิภาพในการทำนายที่สูงกว่าวิธีการ Rainymotion และ U-Net ในหลายกรณี ดังนั้นจึงคาดว่าวิธีการดังกล่าวจะให้ประสิทธิภาพที่ดีบนการทำนายภาพถ่ายเรดาร์เช่นกัน

5.3 ผลการทดสอบบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรง

วิธีการหรือโมเดลต่างๆ ที่ถูกฝึกสอนโดยใช้ข้อมูลภาพถ่ายเรดาร์จะถูกทดสอบบนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรงทั้ง 7 กรณี (ที่ได้กล่าวไว้ในบทที่ 4.1.3) เพื่อพิจารณาความสามารถทำนาย โดยวิธีการและโมเดลที่นำมาทดสอบ ได้แก่ วิธีการคงสภาพเดิม U-Net Rainymotion ConvLSTM TrajGRU วิธีการผสมผสานที่ฝึกด้วยค่าความสูญเสียแบบ MSE และ W-MSE ในที่นี้จะพิจารณาผลในรายละเอียด 3 กรณีแรก โดยได้แสดงผลลัพธ์ในตาราง 13 ถึงตาราง 15 (สามารถดูผลของกรณีที่ 4 ถึง 7 ได้ในภาคผนวก)

เหตุการณ์สภาพอากาศรุนแรงที่ 1

ในเหตุการณ์สภาพอากาศรุนแรงที่ 1 เป็นเหตุการณ์ขณะพายุไต้ฝุ่นฟ้าใสพัดขึ้นฝั่งตะวันออกของญี่ปุ่น ทำให้เกิดกระแสลมและฝนตกหนักบริเวณกว้างรอบข้างลักษณะเป็นวงกลม พายุมีการเคลื่อนที่ทั้งในเชิงเส้นและมีการหมุน

- **วิธีการเชิงวิทยาศาสตร์** วิธีการคงสภาพเดิมให้ประสิทธิภาพที่ไม่ดีทั้งในเชิง RMSE และ CSI เนื่องจากวัตถุในภาพมีการเคลื่อนที่ทั้งในเชิงเส้นและการหมุน แต่เป็นวิธีการที่ให้ SSIM สูงสุดเนื่องจากสามารถรักษารายละเอียดโครงสร้างไว้ได้ทั้งหมด ส่วนวิธีการ Rainymotion ยังทำนายการหมุนได้ไม่ดีมาก ส่งผลให้ค่า RMSE สูงและ CSI ค่อนข้างต่ำเมื่อเปรียบเทียบกับผลจากโมเดลเชิงลึก
- **วิธีการเรียนรู้เชิงลึก** โมเดลการเรียนรู้เชิงลึกทั้ง 3 โมเดล ได้แก่ U-Net ConvLSTM และ TrajGRU ต่างให้ผลลัพธ์ที่ต่างกัน ในกรณีนี้ ConvLSTM ให้ค่า RMSE และ CSI ที่ดีที่สุดในกลุ่มของโมเดลเชิงลึก อย่างไรก็ตามโมเดลกลุ่มนี้ให้ค่า SSIM ต่ำกว่าวิธีการเชิงวิทยาศาสตร์มากเนื่องจากโมเดลให้ผลการทำนายที่เบลอซึ่งเป็นผลจากความมั่นใจการทำนายที่ลดลงเรื่อยๆ ในแต่ละลำดับเวลา
- **วิธีการผสมผสาน** วิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ MSE สามารถทำนายตำแหน่งที่ฝนจะตกได้แม่นยำที่สุด (โดยดูจากค่า CSI ที่สูงที่สุด) ในขณะที่ให้ค่า FAR ต่ำและสามารถรักษาค่า SSIM ไว้ได้สูงเทียบกับกลุ่มโมเดลเชิงลึก ในขณะที่วิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ W-MSE สามารถทำนายปริมาณน้ำฝนได้ใกล้เคียงกับความเป็นจริงมากที่สุด (โดยดูจากค่า RMSE ที่ต่ำที่สุด)

ดังนั้นจากกรณีที่ 1 สามารถเห็นได้ว่าโมเดลแบบผสมผสานสามารถทำนายพฤติกรรมการเคลื่อนที่เชิงเส้นพร้อมกับการหมุนได้ดี ซึ่งพฤติกรรมนี้เห็นได้เช่นกันในชุดข้อมูลจำลองประเภท (ค)

และการใช้ค่าความสูญเสียแบบ W-MSE สามารถช่วยเพิ่มค่า CSI ในคลาส 2 และ 3 ของวิธีการผสมผสานได้ 36.9% และ 135.9% ตามลำดับ

เหตุการณ์สภาพอากาศรุนแรงที่ 2

ในเหตุการณ์สภาพอากาศรุนแรงที่ 2 เป็นเหตุการณ์ขณะพายุไต้ฝุ่นฮาจิบิสพัดเข้าฝั่งตะวันออกเฉียงใต้ของญี่ปุ่น ก่อให้เกิดฝนตกหนัก แต่ในกรณีนี้ 2 ต่างจากกรณีที่ 1 เนื่องจากในช่วงเวลาที่พิจารณานี้พายุใกล้สลายตัวจึงไม่มีการเคลื่อนตัวอย่างเป็นกลุ่มก้อนมากแต่เคลื่อนไหวส่วนมากเกิดขึ้นภายในกลุ่มก้อน

- **วิธีการเชิงวิทยาศาสตร์** พายุในกรณีนี้ต่างจากกรณีก่อนหน้านี้เนื่องจากไม่มีการเคลื่อนตัวเป็นกลุ่มก้อน (Bulk movement) แต่มีเฉพาะการเคลื่อนที่ภายใน วิธีการคงสภาพเดิมจึงให้ผลการทำนายดีในหลายๆ ตัวชี้วัด เช่น ค่า SSIM และค่า CSI ในคลาส 2 และ 3
- **วิธีการเรียนรู้เชิงลึก** ในกรณีนี้การเคลื่อนตัวของฝนเกิดขึ้นภายในกลุ่มก้อนที่ไม่มีการเปลี่ยนแปลงรูปร่างมากนักจึงทำนายตำแหน่งที่ฝนตกได้ไม่ยาก โมเดลที่ซับซ้อนอย่าง TrajGRU ให้ค่า CSI สูงสุด ส่วนโมเดล ConvLSTM และ U-Net แม้จะทำนาย CSI ได้สูงเช่นกันแต่ทำนายการเคลื่อนตัวของปริมาณน้ำฝนภายในกลุ่มก้อนได้ไม่ดีนักจึงส่งผลให้ค่า RMSE ไม่ดีเท่า TrajGRU
- **วิธีการผสมผสาน** วิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ MSE สามารถทำนายตำแหน่งที่ฝนจะตกได้สอดคล้องกับปริมาณน้ำฝนแม่นยำ (โดยดูจากค่า RMSE ที่ต่ำและค่า CSI ที่สูง) นอกจากนี้ยังให้ค่า FAR ต่ำและสามารถรักษาค่า SSIM ไว้ได้สูงเทียบกับโมเดลเชิงลึกอื่นๆ ส่วนวิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ W-MSE สามารถทำนายปริมาณน้ำฝนได้ใกล้เคียงกับความเป็นจริงมากที่สุด (จากค่า RMSE ที่ต่ำที่สุด)

ดังนั้นในกรณีนี้แสดงให้เห็นว่าวิธีการแบบผสมผสานสามารถทำนายปริมาณและการเคลื่อนที่ของน้ำฝนภายในกลุ่มก้อนได้ดี และการใช้ค่าความสูญเสียแบบ W-MSE ช่วยเพิ่มค่า CSI คลาส 2 และ 3 ของวิธีการผสมผสานได้ 9.56% และ 89.7% ตามลำดับ

เหตุการณ์สภาพอากาศรุนแรงที่ 3

ในเหตุการณ์สภาพอากาศรุนแรงที่ 3 เป็นเหตุการณ์ขณะพายุโซนร้อนนารีเคลื่อนตัวในทะเลฟิลิปปิน ในกรณีพายุกำลังสะสมตัวพร้อมเคลื่อนตัวไปยังทิศตะวันออกเฉียงเหนือ โดยพายุมีการเคลื่อนตัวในเชิงเส้นพร้อมกับขยายตัว

- **วิธีการเชิงวิทยาศาสตร์** ในกรณีนี้การเคลื่อนที่ส่วนใหญ่เป็นแบบกลุ่มก้อนในเชิงเส้น วิธีการ Rainymotion จึงสามารถทำนายการเคลื่อนที่พร้อมกับรักษารายละเอียดพื้นผิวได้ดี ส่งผลให้การทำนาย SSIM และ CSI ในคลาส 2 และ 3 มีค่าสูง
- **วิธีการเรียนรู้เชิงลึก** ในกรณีนี้แต่ละโมเดลให้ผลในแต่ละด้านที่แตกต่างกันออกไป โมเดล U-Net ทำนายบริเวณที่ฝนตกมากเกินไปส่งผลให้ FAR สูง ในขณะที่โมเดล TrajGRU ทำนายตำแหน่งของฝนตกน้อยเกินไปส่งผลให้ CSI ต่ำ ในกรณีนี้โมเดล ConvLSTM ค่อนข้างให้ผลที่ค่อนข้างรอบด้านกว่าโมเดลเชิงลึกที่กล่าวมาก่อนหน้าโดยโมเดลให้ผลที่ดีทั้งในแง่ RMSE และ CSI
- **วิธีการผสมผสาน** วิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ MSE สามารถทำนายตำแหน่งที่ฝนจะตกได้แม่นยำ (โดยดูจากค่า CSI ที่สูง) และสามารถทำนายโดยให้ค่า FAR ที่ต่ำ และสามารถรักษาค่า SSIM ไว้ได้สูงเทียบกับโมเดลเชิงลึกอื่นๆ ในขณะที่วิธีการผสมผสานที่ฝึกด้วยค่าสูญเสียแบบ W-MSE สามารถทำนายตำแหน่งที่ฝนจะตกได้แม่นยำที่สุด (โดยดูจากค่า CSI ที่สูงที่สุด) และสามารถทำนายปริมาณน้ำฝนได้ใกล้เคียงกับความเป็นจริงมากที่สุด (โดยดูจากค่า RMSE ที่ต่ำที่สุด)


ดังนั้นในกรณีนี้แสดงให้เห็นว่าวิธีการแบบผสมผสานสามารถทำนายการเคลื่อนที่ของปริมาณน้ำฝนของกลุ่มก้อนที่มีการขยายตัวได้ดี ซึ่งพฤติกรรมนี้ใกล้เคียงกับในชุดข้อมูลจำลองประเภท (ข) และการใช้ค่าความสูญเสียแบบ W-MSE สามารถช่วยเพิ่มค่า CSI คลาส 2 และ 3 ของวิธีการผสมผสานได้ 60.6% และ 37.5% ตามลำดับ

จากผลการทดลองในเหตุการณ์สภาพอากาศรุนแรงทั้ง 7 (กรณี 4 ถึง 7 แสดงในภาคผนวก) พบว่าในวิธีการผสมผสานให้ผลการทำนายที่ตัวชี้วัดหลัก (ค่า RMSE และ CSI) มีค่าเทียบเท่าหรือดีกว่าวิธีการเชิงวิทยาศาสตร์และวิธีการเรียนรู้เชิงลึกในกรณีทดสอบส่วนมาก ซึ่งให้เห็นว่าโมเดลสามารถทำนายปริมาณน้ำฝนได้สอดคล้องกับตำแหน่งได้อย่างถูกต้อง พร้อมทั้งให้ค่า FAR ที่ต่ำ วิธีการผสมผสานสามารถทำนายทั้งการเคลื่อนที่เชิงเส้น การหมุน การเคลื่อนที่ภายในกลุ่มก้อน และการกระจายตัวของกลุ่มก้อนฝน นอกจากนี้ยังสามารถรักษารายละเอียดพื้นผิวได้ดีเมื่อเทียบกับโมเดลเชิงลึกอื่นๆ (จากค่า SSIM ที่สูง) จากการทดลองบนทั้ง 7 เหตุการณ์สภาพอากาศรุนแรง พบว่าการใช้ค่าความสูญเสียแบบ W-MSE ช่วยให้โมเดลทำนายฝนตกหนักได้มากขึ้น โดยสามารถเพิ่มคะแนน CSI คลาส 2 และ 3 ได้โดยเฉลี่ย 41.16% และ 71.95% ตามลำดับ


ตาราง 13 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 1

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	3.4549	0.4393	0.3456	0.8177	0.9155	0.2967	0.1297	<u>0.0404</u>	0.3442	0.5530	0.7210	
U-Net	3.6243	0.5168	0.3598	0.7861	0.8998	0.3353	0.1707	0.0334	0.4055	0.7996	0.6456	
Rainymotion	3.3601	0.5151	0.3721	0.8308	0.9271	0.3518	0.1494	0.0594	0.3009	0.6467	<u>0.7191</u>	
ConvLSTM	3.0600	0.5464	0.3677	0.8162	0.9153	0.3920	<u>0.1533</u>	0.0103	0.3433	0.7694	0.5645	
TrajGRU	3.1408	0.5458	0.3535	0.8485	0.9338	0.4148	0.0581	0.0073	0.2385	0.6566	0.6059	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>3.0120</u>	0.5644	<u>0.3732</u>	<u>0.8474</u>	<u>0.9319</u>	0.4354	0.1100	0.0142	<u>0.2694</u>	0.7073	0.6048	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	2.9208	<u>0.5525</u>	0.3812	0.8273	0.9183	<u>0.4227</u>	0.1506	0.0335	0.3423	<u>0.7769</u>	0.5626	

* ในตาราง **ตัวหนา** สำหรับค่าที่ดีที่สุดและ ตัวขีดเส้นใต้ สำหรับค่าที่ตรงลงมาสำหรับแต่ละตัวชี้วัด




รูป 34 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 1




รูป 35 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 1

ตาราง 14 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 2

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	2.7060	0.6451	0.4691	0.8376	0.9221	0.5273	<u>0.2856</u>	0.1413	0.2361	0.8047	<u>0.7417</u>	
U-Net	3.4532	0.5979	0.4028	0.7939	0.9028	0.4423	0.1954	0.0707	0.3057	0.7986	0.6907	
Rainymotion	2.7537	0.6590	0.4586	0.8437	0.9291	0.5237	0.2728	<u>0.1077</u>	0.1997	0.7836	0.7455	
ConvLSTM	2.8086	<u>0.6837</u>	0.4456	0.8278	0.9230	0.5205	0.3023	0.0366	0.2553	0.8961	0.6263	
TrajGRU	2.4431	0.7061	0.4427	0.8603	0.9359	0.5949	0.2190	0.0211	0.1933	0.8504	0.6665	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>2.3757</u>	0.6807	0.4515	<u>0.8573</u>	<u>0.9331</u>	0.5720	0.2604	0.0389	<u>0.1949</u>	0.8092	0.6705	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	2.3642	0.6781	<u>0.4638</u>	0.8446	0.9248	<u>0.5714</u>	0.2853	0.0738	0.2018	<u>0.8802</u>	0.6499	



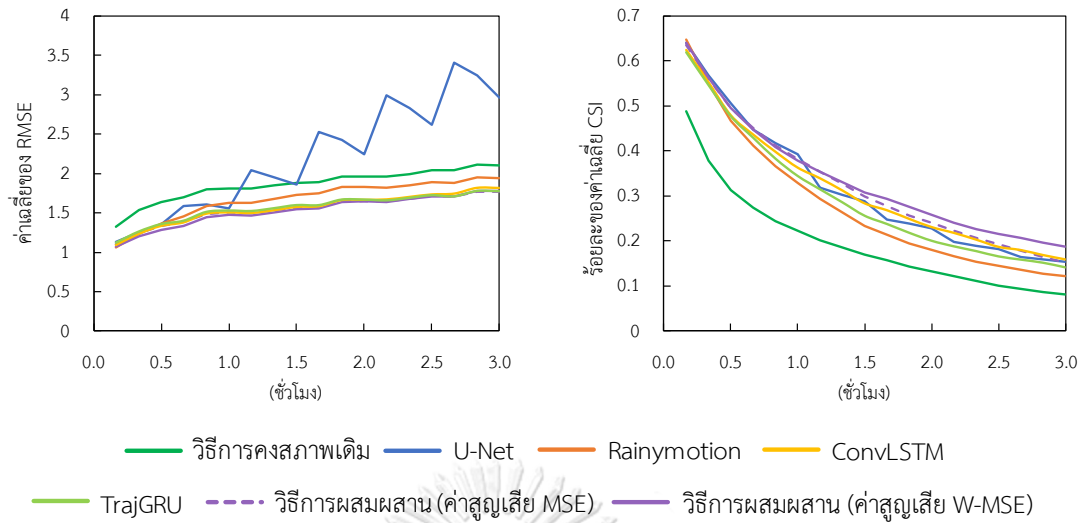
รูป 36 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 2




รูป 37 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 2

ตาราง 15 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 3

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	1.8546	0.1948	0.2913	0.9151	0.9580	0.1452	0.0534	<u>0.0084</u>	0.6686	0.2915	<u>0.8522</u>	
U-Net	2.2001	0.3135	0.3158	0.8787	0.9397	0.2265	0.0904	0.0065	0.6134	0.6407	0.7737	
Rainymotion	1.6729	0.2781	0.3175	0.9268	0.9648	0.2130	<u>0.0815</u>	0.0100	0.5389	0.3808	0.8540	
ConvLSTM	1.5622	0.3141	0.3180	0.9213	0.9617	0.2469	0.0606	0.0028	0.5197	0.4571	0.7034	
TrajGRU	1.5600	0.2950	0.3092	<u>0.9343</u>	<u>0.9684</u>	0.2355	0.0309	0.0019	0.4534	0.3742	0.7351	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>1.5448</u>	<u>0.3226</u>	0.3712	0.9350	0.9690	<u>0.2608</u>	0.0368	0.0016	<u>0.4555</u>	0.4210	0.7505	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	1.5251	0.3349	<u>0.3216</u>	0.9127	0.9574	0.2677	0.0591	0.0022	0.5754	<u>0.5818</u>	0.6899	



รูป 38 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 3



รูป 39 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 3

บทที่ 6

สรุปการวิจัย

6.1 สรุปผลการวิจัย

ในวิทยานิพนธ์นี้ได้นำเสนอสถาปัตยกรรมโมเดลแบบผสมผสานสำหรับพยากรณ์ปริมาณน้ำฝนจากภาพถ่ายเรดาร์ใน 3 ชั่วโมงล่วงหน้า การผสมผสานนี้เป็นการแทนที่โมเดลจากศาสตร์ของการเรียนรู้เชิงลึกเข้าในส่วนย่อยของวิธีการทางวิทยาศาสตร์ โดยที่โมเดลเชิงลึกทำหน้าที่คำนวณหาสนามการเคลื่อนไหว ในขณะที่ส่วนที่ใช้วิธีการทางฟิสิกส์ทำการประมาณค่านอกช่วง ทางผู้วิจัยได้ทำการทดลองบนชุดข้อมูลจำลองเพื่อประเมินความสามารถของโมเดลในการทำนายลักษณะการเคลื่อนที่ต่างๆ ที่สามารถเกิดขึ้นได้ในลำดับของภาพถ่ายเรดาร์ และบนข้อมูลภาพถ่ายเรดาร์เพื่อประเมินประสิทธิภาพในการทำนายสภาพอากาศที่รุนแรง จากการทดสอบพบว่าวิธีการที่นำเสนอให้ผลการทำนายที่ประสิทธิภาพดีกว่าการใช้วิธีการเชิงวิทยาศาสตร์และโมเดลเชิงลึกในกรณีส่วนมากบนชุดข้อมูลทั้งคู่ นอกจากนี้ได้ทดลองใช้ค่าความสูญเสีย W-MSE ซึ่งสามารถเพิ่มความสามารถทำนายฝนตกหนักให้กับวิธีการที่นำเสนอ ผู้วิจัยเชื่อว่าวิทยานิพนธ์นี้จะแสดงให้เห็นถึงศักยภาพของวิธีการใช้โมเดลแบบผสมผสาน และคาดว่าจะงานนี้จะสามารถนำไปใช้กับงานที่เกี่ยวข้องกับการทำนายวิถีไออื่นๆ ได้ในอนาคต

6.2 แนวทางการวิจัยถัดไป

สำหรับแนวทางการวิจัยในอนาคต งานวิจัยนี้สามารถต่อยอดได้ใน 2 แง่ ในส่วนแรกเป็นการพัฒนาชุดข้อมูลจำลองให้รองรับคุณสมบัติต่างๆ ที่กว้างขึ้นเพื่อให้สามารถวิเคราะห์การทำงานของโมเดลได้ละเอียดขึ้น โดยคุณสมบัติดังกล่าวอาจไม่จำเป็นต้องจำกัดเพียงแค่จากลำดับของภาพถ่ายเรดาร์เท่านั้น เช่น อาจจะนำคุณสมบัติที่เกี่ยวข้องกับการนำความร้อนในแหล่งน้ำมาปรับใช้ ในส่วนที่สองเป็นการพัฒนาต่อยอดจากวิธีการผสมผสาน โดยอาจใช้วิธีการผสมผสานที่มีหลายรูปแบบร่วมกัน หรือใช้วิธีการทางวิทยาศาสตร์อื่นๆ เป็นโครงสร้างหลัก ซึ่งอาจช่วยให้ประสิทธิภาพเพิ่มขึ้น

บรรณานุกรม

1. Šaur, D. *Evaluation of the Accuracy of Numerical Weather Prediction Models*. 2015. Cham: Springer International Publishing.
2. Pu, Z. and E. Kalnay, *Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation*, in *Handbook of Hydrometeorological Ensemble Forecasting*, Q. Duan, et al., Editors. 2019, Springer Berlin Heidelberg: Berlin, Heidelberg. p. 67-97.
3. Willard, J., et al. *Integrating Physics-Based Modeling with Machine Learning: A Survey*. 2020. arXiv:2003.04919.
4. Paszke, A., et al. *PyTorch: An Imperative Style, High-Performance Deep Learning Library*. in *NeurIPS*. 2019.
5. Reyniers, M., *Quantitative precipitation forecasts based on radar observations: Principles, algorithms and operational systems*. 2008: Institut Royal Météorologique de Belgique Brussel, Belgium.
6. Wang, Z., et al., *Image quality assessment: from error visibility to structural similarity*. *IEEE Trans Image Process*, 2004. **13**(4): p. 600-12.
7. Ayzel, G., M. Heistermann, and T. Winterrath, *Optical flow models as an open benchmark for radar-based precipitation nowcasting (rainymotion v0.1)*. *Geosci. Model Dev.*, 2019. **12**(4): p. 1387-1402.
8. Kroeger, T., et al. *Fast optical flow using dense inverse search*. in *European Conference on Computer Vision*. 2016. Springer.
9. Germann, U. and I. Zawadzki, *Scale-Dependence of the Predictability of Precipitation from Continental Radar Images. Part I: Description of the Methodology*. *Monthly Weather Review*, 2002. **130**(12): p. 2859-2873.
10. Ronneberger, O., P. Fischer, and T. Brox. *U-net: Convolutional networks for biomedical image segmentation*. in *International Conference on Medical image computing and computer-assisted intervention*. 2015. Springer.
11. Shi, X., et al., *Convolutional LSTM network: A machine learning approach for precipitation nowcasting*. *Advances in neural information processing systems*,

2015. **2015**: p. 802-810.
12. Shi, X., et al., *Deep learning for precipitation nowcasting: A benchmark and a new model*. arXiv preprint arXiv:1706.03458, 2017.
 13. Cho, K., et al., *Learning phrase representations using RNN encoder-decoder for statistical machine translation*. arXiv preprint arXiv:1406.1078, 2014.
 14. Jaderberg, M., et al., *Spatial transformer networks*. arXiv preprint arXiv:1506.02025, 2015.
 15. Reichstein, M., et al., *Deep learning and process understanding for data-driven Earth system science*. *Nature*, 2019. **566**(7743): p. 195-204.
 16. De Bézenac, E., A. Pajot, and P. Gallinari, *Deep learning for physical processes: Incorporating prior scientific knowledge*. *Journal of Statistical Mechanics: Theory and Experiment*, 2019. **2019**(12): p. 124009.
 17. Karpatne, A., et al., *Physics-guided neural networks (pgnn): An application in lake temperature modeling*. arXiv preprint arXiv:1710.11431, 2017.
 18. Horn, B.K.P. and B.G. Schunck, *Determining optical flow*. *Artif. Intell.*, 1981. **17**(1-3): p. 185-203.
 19. Farneback, G. *Two-frame motion estimation based on polynomial expansion*. in *Scandinavian conference on Image analysis*. 2003. Springer.
 20. Hur, J. and S. Roth, *Optical Flow Estimation in the Deep Learning Age*, in *Modelling Human Motion: From Human Perception to Robot Design*, N. Noceti, A. Sciutti, and F. Rea, Editors. 2020, Springer International Publishing: Cham. p. 119-140.
 21. Savian, S., M. Elahi, and T. Tillo, *Optical flow estimation with deep learning, a survey on recent advances*, in *Deep biometrics*. 2020, Springer. p. 257-287.
 22. Kingma, D.P. and J. Ba, *Adam: A Method for Stochastic Optimization*. *CoRR*, 2015. **abs/1412.6980**.


ภาคผนวก

ในส่วนภาคผนวกแสดงผลการทดสอบวิธีการและโมเดลต่างๆ บนชุดข้อมูลเหตุการณ์สภาพอากาศรุนแรงกรณีที่ 4 ถึง 7 (ต่อจากส่วนที่ 5.3)




ตาราง 16 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 4

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	2.3689	0.4513	0.3697	0.8584	0.9275	0.3931	0.1165	<u>0.0417</u>	0.3939	0.6198	<u>0.7922</u>	
U-Net	3.1047	0.4768	0.3528	0.8217	0.9129	0.3608	0.1066	0.0311	0.4512	0.7647	0.7250	
Rainymotion	2.1405	0.5197	<u>0.3960</u>	0.8808	0.9414	0.4496	<u>0.1401</u>	0.0520	0.3125	0.6654	0.7983	
ConvLSTM	2.0107	<u>0.5614</u>	0.3942	0.8703	0.9353	0.4891	0.1393	0.0132	0.3559	0.8228	0.6687	
TrajGRU	1.8997	0.5618	0.3811	0.8882	0.9443	0.5015	0.0680	0.0106	0.3000	0.7393	0.7008	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>1.8671</u>	0.5495	0.3865	<u>0.8872</u>	<u>0.9435</u>	<u>0.4898</u>	0.0944	0.0166	<u>0.3083</u>	0.7108	0.7043	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	1.8507	0.5466	0.3988	0.8731	0.9350	0.4851	0.1437	0.0313	0.3696	<u>0.7882</u>	0.6667	



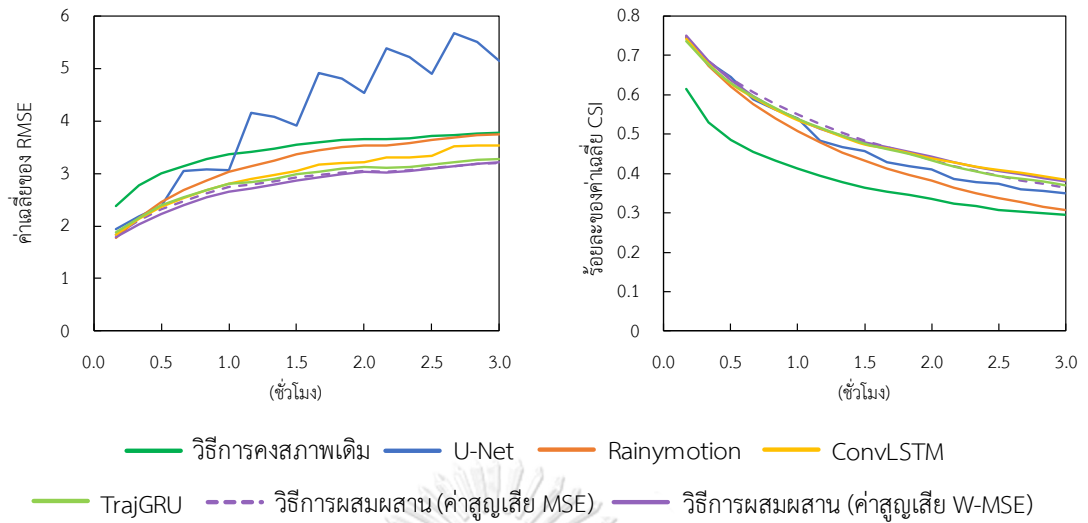
รูป 40 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 4




รูป 41 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 4

ตาราง 17 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 5

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	3.4217	0.3860	0.3236	0.7508	0.8645	0.2901	0.1068	<u>0.0330</u>	0.4255	0.5281	<u>0.6398</u>	
U-Net	4.1074	0.4797	0.3411	0.7021	0.8343	0.3512	0.1491	0.0300	0.4630	0.8174	0.5604	
Rainymotion	3.1699	0.4568	0.3531	0.7810	<u>0.8853</u>	0.3501	0.1417	0.0356	0.3556	0.5881	0.6554	
ConvLSTM	2.9654	<u>0.5005</u>	<u>0.3572</u>	0.7620	0.8698	0.3908	<u>0.1488</u>	0.0192	0.3928	0.7374	0.4912	
TrajGRU	2.8645	0.4958	0.3445	<u>0.7874</u>	0.8849	<u>0.4080</u>	0.0767	0.0083	<u>0.3585</u>	0.6691	0.4952	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>2.8036</u>	0.5002	0.3529	0.7993	0.8939	0.4059	0.0987	0.0130	0.3292	0.6443	0.5223	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	2.7601	0.5025	0.3566	0.7555	0.8614	0.4092	0.1358	0.0199	0.4342	<u>0.7975</u>	0.4542	



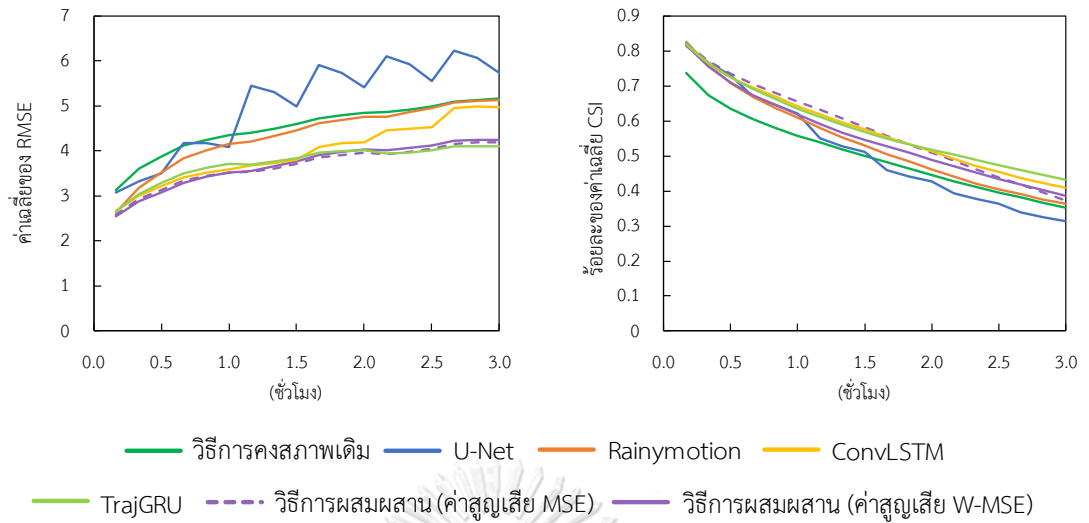
รูป 42 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 5




รูป 43 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 5

ตาราง 18 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 6

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	4.5216	0.5041	0.3574	0.7122	0.8447	0.3769	0.1569	0.0511	0.3588	0.6999	<u>0.6017</u>	
U-Net	5.0448	0.5156	0.3347	0.6655	0.8231	0.3270	0.1552	0.0335	0.3992	0.7703	0.5175	
Rainymotion	4.3483	0.5398	0.3678	0.7364	0.8648	0.3930	0.1700	<u>0.0430</u>	0.3119	0.6907	0.6168	
ConvLSTM	3.9723	<u>0.5775</u>	0.3779	0.7204	0.8539	0.4061	0.2347	0.0169	0.3396	<u>0.8216</u>	0.4557	
TrajGRU	3.7410	0.5814	0.3610	<u>0.7514</u>	<u>0.8705</u>	0.4508	0.1092	0.0134	<u>0.3045</u>	0.7710	0.4587	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	3.6724	0.5753	<u>0.3725</u>	0.7551	0.8726	<u>0.4433</u>	0.1498	0.0230	0.2930	0.7395	0.4891	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	<u>3.7020</u>	0.5564	0.3696	0.7175	0.8408	0.4340	<u>0.1717</u>	0.0320	0.3819	0.8322	0.4497	




รูป 44 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 6




รูป 45 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 6

ตาราง 19 ประสิทธิภาพการทำนายด้วยวิธีการต่างๆ บนเหตุการณ์สภาพอากาศรุนแรงที่ 7

วิธีการหรือโมเดล	RMSE	CSI	Multi-CSIs							FAR	POD	SSIM
			Macro avg.	Micro avg.	คลาส 0	คลาส 1	คลาส 2	คลาส 3				
วิธีการคงสภาพเดิม	2.4771	0.4389	0.3663	0.8487	0.9255	0.3422	0.1532	0.0444	0.3938	0.6013	<u>0.7831</u>	
U-Net	3.2450	0.4753	0.3601	0.8126	0.9098	0.3368	0.1503	<u>0.0435</u>	0.4476	<u>0.7646</u>	0.7052	
Rainymotion	2.3800	0.5053	0.3739	<u>0.8672</u>	0.9371	0.4011	0.1358	0.0220	0.3244	0.6551	0.7838	
ConvLSTM	2.2869	0.5384	0.3848	0.8583	0.9331	0.4136	0.1832	0.0092	0.3491	0.7605	0.6403	
TrajGRU	2.1468	<u>0.5421</u>	0.3665	0.8800	0.9430	<u>0.4483</u>	0.0689	0.0057	0.2811	0.6823	0.6633	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย MSE)	<u>2.1075</u>	0.5458	0.3752	0.8800	<u>0.9429</u>	0.4537	0.0953	0.0087	<u>0.2936</u>	0.6951	0.6760	
วิธีการผสมผสาน (ฝึกด้วยค่าสูญเสีย W-MSE)	2.0906	0.5204	<u>0.3837</u>	0.8474	0.9229	0.4298	<u>0.1683</u>	0.0139	0.4142	0.8135	0.6242	



รูป 46 ค่าเฉลี่ย RMSE และ CSI ในแต่ละลำดับขั้นเวลาของเหตุการณ์สภาพอากาศรุนแรงที่ 7




รูป 47 ผลภาพถ่ายการทำนายจากเหตุการณ์สภาพอากาศรุนแรงที่ 7

ในรูป 48 ถึงรูป 54 แสดงสนามการเคลื่อนไหวจากวิธีการที่มีขั้นตอนการหาสนามการเคลื่อนไหวในการทำนายเหตุการณ์สภาพอากาศรุนแรง ได้แก่ (ก) วิธีการผสมผสาน และ (ข) Rainymotion โดยวิธีการผสมผสานคำนวณสนามการเคลื่อนไหวจากส่วนของโมเดลเชิงลึก (เครือข่าย U-Net) ในขณะที่ Rainymotion ใช้อัลกอริทึมการไหลของแสงแบบ DIS

จากเหตุการณ์สภาพอากาศรุนแรงที่ 1 เป็นเหตุการณ์ขณะพายุไต้ฝุ่นฟ้าใสกำลังเคลื่อนที่ขึ้นพร้อมกับหมุนทวนเข็มนาฬิกา เมื่อพิจารณาสนามการเคลื่อนไหวจากวิธีการผสมผสานในรูป 48 (ก) จะเห็นได้ว่าทิศทางการหมุนของพายุสอดคล้องสนามการเคลื่อนไหว โดยบริเวณด้านซ้ายของรูปแกน Y จะมีค่าเป็นบวกสูงเนื่องจากบริเวณพายุส่วนนี้กำลังเคลื่อนที่ในทิศ $+y$ (ลงล่าง) ในขณะที่บริเวณด้านขวามีค่าเป็นลบเนื่องจากบริเวณพายุส่วนนี้กำลังเคลื่อนที่ในทิศ $-y$ (ขึ้นบน) เช่นเดียวกันเมื่อพิจารณาในแกน X บริเวณด้านบนของรูปจะมีค่าเป็นลบเนื่องจากบริเวณพายุส่วนนี้กำลังเคลื่อนที่ในทิศ $-x$ (ด้านซ้าย) ในขณะที่บริเวณด้านล่างมีค่าเป็นบวกเนื่องจากบริเวณพายุส่วนนี้กำลังเคลื่อนที่ในทิศ $+x$ (ด้านขวา) ดังนั้นการหมุนจึงเป็นการหมุนแบบทวนเข็มนาฬิกา


หากมองโดยคร่าวจะเห็นได้ว่าสนามการเคลื่อนไหวจากวิธีการผสมผสานจะมีเฉดสีคล้ายกับสนามจาก Rainymotion ในรูป 48 (ข) ซึ่งสามารถทำนายการหมุนได้เหมือนกัน แต่จะพบว่าความละเอียดต่ำกว่า เนื่องจากอัลกอริทึมการไหลของแสงแบบ DIS เป็นอัลกอริทึมที่เน้นความเร็ว ดังนั้นอัลกอริทึมจะเลือกใช้ความละเอียดเท่าที่เพียงพอจะอธิบายการเคลื่อนที่เท่านั้น



(ก) วิธีการผสมผสาน

(ข) Rainymotion


รูป 48 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 1



(ก) วิธีการผสมผสาน

(ข) Rainymotion


รูป 49 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 2



(ก) วิธีการผสมผสาน

(ข) Rainymotion


รูป 50 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 3



(ก) วิธีการผสมผสาน

(ข) Rainymotion

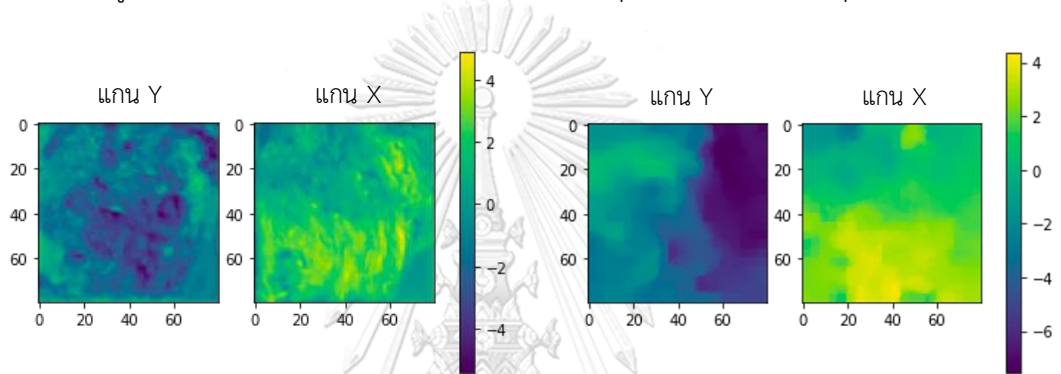
รูป 51 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 4



(ก) วิธีการผสมผสาน

(ข) Rainymotion


รูป 52 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 5



(ก) วิธีการผสมผสาน

(ข) Rainymotion

รูป 53 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 6



(ก) วิธีการผสมผสาน

(ข) Rainymotion

รูป 54 สนามการเคลื่อนไหวสำหรับทำนายเหตุการณ์สภาพอากาศรุนแรงที่ 7

ประวัติผู้เขียน

ชื่อ-สกุล	ภัทรพงษ์ ด่านพูนกิจ
วัน เดือน ปี เกิด	3 มีนาคม 2540
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	วศ.บ. (เกียรตินิยมอันดับสอง) วิศวกรรมเคมี จุฬาลงกรณ์มหาวิทยาลัย (พ.ศ. 2558-2562)
ที่อยู่ปัจจุบัน	63 ซ.ประชาอุทิศ5(พลอยไพลิน-เสริมปรีดี) แขวงดอนเมือง เขตดอนเมือง กรุงเทพมหานคร



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY